Guia do usuário

AWS Glue

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

AWS Glue: Guia do usuário

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

As marcas comerciais e imagens comerciais da Amazon não podem ser usadas no contexto de nenhum produto ou serviço que não seja da Amazon, nem de qualquer maneira que possa gerar confusão entre os clientes ou que deprecie ou desprestigie a Amazon. Todas as outras marcas comerciais que não pertencem à Amazon pertencem a seus respectivos proprietários, que podem ou não ser afiliados, patrocinados pela Amazon ou ter conexão com ela.

Table of Contents

O que é o AWS Glue? 1
Recursos do AWS Glue 2
Aprender sobre inovações no AWS Glue 4
Conceitos básicos do AWS Glue 4
Como acessar o AWS Glue 4
Serviços relacionados 5
Como funciona 6
Trabalhos de ETL com tecnologia sem servidor executados em isolamento 7
Conceitos 8
Terminologia do AWS Glue 10
Componentes 13
Console do AWS Glue 14
AWS Glue Data Catalog 14
Crawlers e classificadores do AWS Glue 15
Operações de ETL no AWS Glue 16
ETL de streaming no AWS Glue 16
O sistema de trabalhos do AWS Glue 16
Componentes do Visual ETL 17
AWS Glue para Spark e AWS Glue para Ray 23
O que é AWS Glue para Ray? 24
Converter esquemas semiestruturados em esquemas relacionais 25
Tipos do AWS Glue 27
Tipos de AWS Glue Data Catalog 27
Tipos em scripts do AWS Glue com Spark 27
Tipos de crawler do AWS Glue 28
Conceitos básicos 29
Visão geral do uso do AWS Glue 29
Configurar permissões do IAM 31
Próximas etapas 36
Configuração do AWS Glue Studio 36
Conceitos básicos de cadernos no AWS Glue Studio 49
Configurar perfis de uso 52
Como gerenciar perfis de uso 53
Perfis de uso e tarefas 66

Conceitos básicos da AWS Glue Data Catalog 67
Visão geral 67
Etapa 1: criar um banco de dados 67
Etapa 2. Criar uma tabela 69
Next steps (Próximas etapas) 70
Configurar o acesso de rede aos armazenamentos de dados 74
Configurar uma VPC para se conectar ao PyPI para AWS Glue 75
Configurar o DNS na VPC 77
Configurar a criptografia 78
Configurar redes para desenvolvimento 82
Configurar a rede para um endpoint de desenvolvimento 82
Configurar o Amazon EC2 para um servidor de cadernos 84
Descoberta e catalogação de dados 86
Preencher o Data Catalog 89
Usar um Crawler do AWS Glue 89
Definir metadados manualmente 180
Integração a outros serviços da AWS 200
Configurações do Catálogo de Dados 201
Preencher e gerenciar tabelas transacionais 204
Criar tabelas Iceberg 204
Otimizar tabelas Iceberg 208
Otimizar a performance da consulta para tabelas Iceberg 240
Gerenciar o Catálogo de Dados 242
Atualizar o esquema e adicionar novas partições 243
Otimizar a performance da consulta usando estatísticas de coluna 251
Como criptografar seu Data Catalog 277
Proteger seu catálogo de dados usando o Lake Formation 277
Trabalho com as visualizações do AWS Glue Data Catalog 277
Acessar o Catálogo de Dados 282
Conectar ao Catálogo de Dados usando o endpoint REST do Iceberg do AWS Glue 283
Conectar ao Catálogo de Dados usando o endpoint da extensão REST do Iceberg do AWS Glue 286
APIs REST do AWS Glue para Apache Iceberg 287
Conectar ao Catálogo de Dados via aplicação Spark autônoma 307
Mapeamento de dados entre o Amazon Redshift e o Amazon Iceberg 309
Considerações e limitações ao usar APIs do catálogo REST do Iceberg do AWS Glue 310

Práticas recomendadas do Catálogo de Dados 311
Monitorar métricas de uso do Catálogo de Dados do Amazon CloudWatch 312
Visão geral das métricas do Catálogo de Dados 312
Adicionar métricas ao seu painel do CloudWatch 312
..... 314
Registro de esquemas do AWS Glue 314
Esquemas 315
Registros 317
Versionamento e compatibilidade de esquema 319
Bibliotecas Serde de código aberto 324
Cotas do registro do esquemas 324
Como funciona 325
Conceitos básicos 327
Integração com o registro de esquemas do AWS Glue 350
Migrar para o registro de esquemas do AWS Glue 376
Conectar a dados 379
Visão geral do uso de conectores e conexões 379
Conexões unificadas 380
Tipos de autenticação compatíveis 384
Considerações 385
Conexões disponíveis 385
Limitações 388
Propriedades da conexão do AWS Glue 389
Requisitos de propriedades de conexão 389
Propriedades da conexão JDBC 390
Propriedades de conexão do MongoDB e do MongoDB Atlas 395
Propriedades de conexão do Salesforce 396
Conexão do Snowflake 397
Conexão do Vertica 398
Conexão do SAP HANA 399
Conexão do Azure SQL 400
Conexão do Teradata Vantage 400
Conexão do OpenSearch Service 401
Conexão do Azure Cosmos 402
Propriedades de conexão SSL 403
Propriedades de conexão do Kafka para autenticação 406

Conexão do Google BigQuery 407
Conexão do Vertica 398
Armazenando credenciais de conexão em AWS Secrets Manager 407
Adicionar uma conexão do AWS Glue 408
Conexão com o Adobe Analytics 410
Conexão com o Adobe Marketo Engage 419
Conectar-se ao Amazon Redshift 428
Conexão com o Asana 433
Conectar ao Azure Cosmos DB 443
Conectar ao Azure SQL 446
Conexão ao Raiser's Edge NXT da Blackbaud 449
Conexão ao CircleCI 459
Conexão ao Datadog 472
Conexão ao Docusign Monitor 479
Conexão ao Domo 487
Conexão ao Dynatrace 496
Conexão com o Facebook Ads 502
Conexão com o Facebook Page Insights 510
Conexão com o Freshdesk 532
Conexão com o Freshsales 542
Conexão com o Google Ads 549
Conectando-se ao Google Analytics 4 577
Conexão com o Google BigQuery 590
Conectar ao Google Search Console 595
Conectando-se ao Google Sheets 604
Conectando-se a HubSpot 611
Conexão com o Instagram Ads 638
Conexão com o Intercom 646
Conectando-se ao Jira Cloud 667
Conexão ao Kustomer 694
Conexão com o LinkedIn 722
Conexão ao Mailchimp 730
Conexão ao Microsoft Teams 741
Conexão com o Mixpanel 751
Conexão ao Monday 766
Conectar ao MongoDB 775

Conectando-se ao Oracle NetSuite 779
Conectar ao OpenSearch Service 791
Conexão ao Okta 794
Conexão com o PayPal 802
Conexão ao Pendo 810
Conexão ao Pipedrive 818
Conexão ao Productboard 827
Conexão com o QuickBooks 836
Conectar ao Salesforce 844
Conexão com o Salesforce Marketing Cloud 856
Conexão ao Salesforce Commerce Cloud 882
Conexão com o Salesforce Marketing Cloud Account Engagement 893
Conectar ao SAP HANA 906
Conexão com o SAP OData 910
Conexão com o SendGrid 932
Conectando-se a ServiceNow 942
Conexão com o Slack 953
Conectar ao Smartsheet 964
Conexão com o Snapchat Ads 976
Conectar ao Snowflake 986
Conexão com o Stripe 990
Conectar ao Teradata 1039
Conexão com o Twilio 1042
Conectar ao Vertica 1061
Conexão com o WooCommerce 1065
Conectando-se ao Zendesk 1094
Conexão com o Zoho CRM 1122
Conexão com o Zoom Meetings 1133
Adicionar uma conexão JDBC usando seus próprios drivers JDBC 1144
Usar conectores e conexões personalizados 1149
Criar conectores personalizados 1151
Criar conexões para conectores 1155
Criação de trabalhos com conectores personalizados 1164
Gerenciar conectores e conexões 1172
Desenvolvimento de conectores personalizados 1175
Restrições de uso de conectores e conexões no AWS Glue Studio 1178

Testar uma conexão do AWS Glue 1178
Configurando AWS chamadas para passar por seu VPC 1179
Conectando-se a um armazenamento de JDBC dados em um VPC 1180
Acessando VPC dados usando interfaces de rede elástica 1180
Propriedades da interface de rede elástica (ENI) 1181
Usar uma conexão do MongoDB ou do MongoDB Atlas 1182
Rastreando um armazenamento de dados do Amazon S3 usando um endpoint VPC 1182
Pré-requisitos 1183
Criar a conexão com o Amazon S3 1184
Testar a conexão com o Amazon S3 1187
Criar um crawler para um armazenamento de dados do Amazon S3 1189
Criação de um crawler para tabelas de catálogo de dados baseadas no Amazon S3 1191
Executar um crawler 1192
Solução de problemas 1192
Trabalhar com dados protegidos pelo AWS Lake Formation 1193
Acesso total a uma tabela 1193
Solução de problemas de conexão 1194
Tutorial: Usar o AWS Glue Connector for Elasticsearch 1195
Pré-requisitos 1196
Etapa 1: (opcional) Criar um segredo da AWS para as informações do cluster do OpenSearch 1196
Etapa 2: Assinar o conector 1197
Etapa 3: Ativar o conector no AWS Glue Studio e criar uma conexão 1198
Etapa 4: Configurar uma função do IAM para o trabalho de ETL 1199
Etapa 5: Criar um trabalho que usa a conexão do OpenSearch 1199
Etapa 6: Executar o trabalho 1201
Criando AWS Glue trabalhos com sessões interativas 1202
Visão geral das sessões interativas do AWS Glue 1202
Limitações 1203
Conceitos básicos das sessões interativas do AWS Glue 1203
Pré-requisitos para configurar sessões interativas localmente 1203
Instalação do Jupyter e de kernels do Jupyter para sessões interativas do AWS Glue 1203
Execução do Jupyter 1203
Configuração de credenciais e região da sessão 1204
Atualização com base na prévia das sessões interativas 1206
Usar sessões interativas com o SageMaker AI Studio 1206

Uso de sessões interativas com o Microsoft Visual Studio Code 1206
Sessões interativas com o IAM 1210
Configuração de sessões interativas do AWS Glue para cadernos do Jupyter e do AWS Glue Studio 1218
Introdução às mágicas do Jupyter 1218
Mágicas compatíveis com sessões interativas do AWS Glue para Jupyter 1219
Nomeação de sessões 1237
Especificação de um perfil do IAM para sessões interativas 1238
Configurar sessões com perfis nomeados 1238
Converter um script ou caderno em um trabalho do AWS Glue 1239
Trabalhar com operações de streaming em sessões do AWS Glue interativas 1240
Alterar o tipo de sessão de transmissão 1240
Amostrar o fluxo de entrada para desenvolvimento interativo 1240
Executar aplicativos de transmissão em sessões interativas 1242
Desenvolver e testar no local 1243
Desenvolver usando o AWS Glue Studio 1244
Desenvolvimento com sessões interativas 1244
Desenvolvimento de trabalhos do AWS Glue localmente com o Docker 1244
Endpoints de desenvolvimento 1254
Migrar de endpoints de desenvolvimento para sessões interativas 1256
Desenvolver scripts com endpoints de desenvolvimento 1257
Gerenciar cadernos 1287
Criar trabalhos ETL visuais com o AWS Glue Studio 1289
Fazer login no console 1289
Próximas etapas para criar um trabalho no AWS Glue Studio 1290
Iniciar trabalhos de ETL visual no AWS Glue Studio 1290
Iniciar trabalhos no AWS Glue Studio 1290
Recursos do editor de trabalhos 1292
Transformar dados com transformações gerenciadas do AWS Glue 1300
Transformar dados com transformações visuais personalizadas 1377
Usar estruturas do Data Lake com o AWS Glue Studio 1395
Conectar a origens de dados 1407
Configurar nós de destino de dados 1417
Editar ou carregar um script de trabalho 1423
Alterar os nós pais de um nó no diagrama de trabalho 1427
Excluir nós do diagrama de trabalho 1428

Adicionar parâmetros de origem e destino ao nó do AWS Glue Data Catalog 1432
Usando sistemas de controle de versão do Git no AWS Glue 1434
Criação de código com notebooks AWS Glue Studio 1443
Limitações 1443
Visão geral do uso de cadernos 1444
Criar um trabalho de ETL usando cadernos no AWS Glue Studio 1445
Componentes do editor de cadernos 1446
Salvar o caderno e o script do trabalho 1447
Gerenciar sessões de cadernos 1448
Usar o Amazon Q Developer com cadernos do AWS Glue Studio 1450
Monitorar execuções de trabalhos 1450
Acessar o painel de monitoramento de trabalhos 1450
Visão geral do painel de monitoramento de trabalhos 1450
Visualizar execuções do trabalho 1451
Visualizar os logs de execuções de trabalho 1456
Visualizar os detalhes de uma execução de trabalho 1457
Visualizar métricas do Amazon CloudWatch para uma execução de trabalho do Spark 1460
Visualizar métricas do Amazon CloudWatch para uma execução de trabalho do Ray 1461
Detectar e processar dados sigilosos 1463
Como escolher a forma como os dados serão lidos 1463
Escolha das entidades de PII para detecção 1465
Especificar o nível da sensibilidade de detecção 1469
Como escolher o que fazer com dados de PII identificados 1470
Adicionar substituições de ações refinadas 1471
Gerenciar trabalhos 1472
Iniciar uma execução de trabalho 1472
Programar execuções de trabalho 1473
Gerenciar programações de trabalho 1474
Interromper execuções de trabalho 1475
Visualizar os trabalhos 1475
Exibir informações para execuções de trabalho recentes 1476
Visualizar o script de trabalho 1477
Modificar as propriedades do trabalho 1478
Salvar o trabalho 1481
Clonar um trabalho 1483
Excluir trabalhos 1484

Executar trabalhos ... 1485
Versões do AWS Glue ... 1486
Versões do AWS Glue ... 1486
Política de suporte a versão do AWS Glue ... 1505
Migrar o AWS Glue para trabalhos do Spark para o AWS Glue versão 5.0 ... 1507
Migrar trabalhos do AWS Glue para Spark para o AWS Glue versão 4.0 ... 1522
Atualizar análises com IA ... 1537
Lidar com trabalhos do Spark ... 1555
Parâmetros de trabalho ... 1555
Trabalhos Spark e PySpark ... 1565
Trabalhos de transmissão de ETL ... 1715
Correspondência de registros com o FindMatches ... 1730
Programas do Apache Spark ... 1767
Trabalhar com trabalhos do Ray ... 1776
Conceitos básicos do AWS Glue para Ray ... 1776
Ambientes de runtime do Ray compatíveis ... 1777
Explicar os operadores em trabalhos do Ray ... 1778
Parâmetros de trabalho do Ray ... 1779
Métricas de trabalho do Ray ... 1782
Configurar propriedades de trabalhos shell Python ... 1784
Limitações ... 1784
Definir propriedades de trabalho para trabalhos de shell Python ... 1785
Bibliotecas compatíveis com trabalhos de shell Python ... 1787
Fornecer sua própria biblioteca Python ... 1789
Use AWS CloudFormation com trabalhos de shell Python no AWS Glue ... 1792
Migração do shell Python 3.6 para o shell Python 3.9 ... 1793
Migrar dos trabalhos do shell Python do AWS Glue ... 1793
Monitorar ... 1795
Tags do AWS ... 1796
Automatizar o com o EventBridge ... 1801
Monitorar recursos do ... 1804
Registrar em log usando o CloudTrail ... 1807
Status de execução de trabalho ... 1810
AWS Glue Streaming ... 1814
Casos de uso para o streaming ... 1814
Quais são os benefícios do uso do AWS Glue Streaming? ... 1815

Quando devo usar o AWS Glue Streaming? 1816
Fonte de dados compatíveis 1817
Destinos de dados com suporte 1817
Tutorial: desenvolvimento da sua primeira workload de streaming usando o AWS Glue Studio 1818
Pré-requisitos 1818
Consumo de dados de streaming do Amazon Kinesis 1818
Tutorial: desenvolvimento da sua primeira workload de streaming usando cadernos do AWS Glue Studio 1829
Pré-requisitos 1830
Consumo de dados de streaming do Amazon Kinesis 1830
Conceitos do Streaming 1837
Anatomia de um trabalho de streaming do AWS Glue 1837
Conexões de streaming 1841
Conexões do Kafka 1841
Conexões do Kinesis 1848
Ajuste de escala automático de streaming do AWS Glue 1855
Habilitar Auto Scaling no AWS Glue Studio 1855
Habilitar o Auto Scaling com a AWS CLI ou SDK 1856
Como funciona 1857
Janelas de manutenção 1859
Configurar uma janela de manutenção 1859
Comportamento da janela de manutenção 1860
Monitorar trabalhos 1861
Como tratar perda de dados 1863
Conceitos avançados de streaming do AWS Glue 1864
Considerações sobre o tempo ao processar fluxos 1864
Geração de janelas 1865
Tratamento de dados atrasados e de marcas d'água 1871
Monitoramento de trabalhos de streaming do AWS Glue 1873
Visualizar métricas de streaming do AWS Glue 1874
Usar métricas do AWS Glue Streaming 1875
Como obter a melhor performance 1881
Integrações ETL zero 1882
Recursos de ETL zero no AWS Glue 1882
Pré-requisitos 1883

Configurar recursos de origem 1884
Configurar recursos de destino 1885
Criar um data warehouse do Amazon Redshift 1890
Configurar uma VPC 1890
Configurar uma integração entre contas 1894
Configurar uma origem 1895
Suporte para entidades SAP especiais 1895
Origem do Amazon DynamoDB 1895
Origem do Salesforce 1897
Origem do Salesforce MCAE 1897
Configuração adicional do Salesforce 1898
Origem SAP OData 1898
Origem ServiceNow 1898
Origem Zendesk 1899
Origem Zoho CRM 1899
Origem Facebook Ads 1901
Origem Instagram Ads 1901
Campos do Salesforce sem suporte 1901
Campos não compatíveis com o ServiceNow 1904
Como configurar um destino 1909
SageMaker Lakehouse com armazenamento do S3 1910
Destino das Tabelas do S3 1911
SageMaker Lakehouse com armazenamento do Amazon Redshift 1915
Destino do data warehouse do Amazon Redshift 1916
Configurar o destino da integração 1917
Desaninhamento de partição e esquema 1918
Comportamento padrão de desaninhamento e particionamento 1919
Desaninhamento de esquemas 1919
Particionamento de dados para integrações ETL zero 1923
Limitações 1934
Tarefas comuns 1934
Criar uma integração 1934
Modificar uma integração 1936
Excluir uma integração 1937
Usar APIs 1937
Monitorar uma integração 1938

Estados de integração ... 1938
Visualizar logs ... 1938
Visualizar métricas ... 1940
Notificações de eventos ... 1941
Limitações ... 1942
AWS Glue Data Quality ... 1952
Benefícios e principais atributos ... 1952
Como funciona ... 1953
Qualidade de dados para o AWS Glue Data Catalog ... 1953
Qualidade de dados para trabalhos de ETL do AWS Glue ... 1954
Comparar os pontos de entrada do AWS Glue Data Quality ... 1954
Considerações ... 1956
Terminologia ... 1956
Limites ... 1958
Notas de versão do AWS Glue Data Quality ... 1958
Disponibilidade geral: novos atributos ... 1958
27 de novembro de 2023 (pré-visualização) ... 1959
12 de março de 2024 ... 1959
26 de junho de 2024 ... 1959
7 de agosto de 2024 ... 1959
22 de novembro de 2024 ... 1959
6 de dezembro de 2024 ... 1960
30 de junho de 2025 ... 1960
Detecção de anomalias no AWS Glue Data Quality ... 1960
Como funciona ... 1961
Detalhes do algoritmo de detecção de anomalias ... 1965
Permissões do IAM para o AWS Glue Data Quality ... 1966
Permissões do IAM ... 1967
A configuração do IAM é requerida para agendar execuções de avaliação ... 1970
Políticas de exemplo do IAM ... 1971
Introdução ao AWS Glue Data Quality para o Data Catalog ... 1976
Pré-requisitos ... 1976
Exemplo passo a passo ... 1977
Gerar recomendações de regras ... 1977
Monitorar recomendações de regras ... 1979
Editar conjuntos de regras recomendadas ... 1979

Criar um conjunto de regras ... 1981
Como executar um conjunto de regras para avaliar a qualidade de dados ... 1982
Como visualizar o índice de qualidade de dados e os resultados ... 1984
Tópicos relacionados ... 1984
Avaliar qualidade de dados com o AWS ... 1985
Benefícios ... 1985
Avaliar a qualidade dos dados para trabalhos de ETL no AWS Glue Studio ... 1986
Compilador de regras de qualidade de dados ... 1997
Configuração da detecção de anomalias em tarefas de ETL do AWS Glue ... 2002
Visualização de pontuações de qualidade de dados e anomalias ... 2005
Qualidade de dados para trabalhos de ETL em cadernos do AWS Glue Studio ... 2009
Pré-requisitos ... 2010
Criar um trabalho de ETL no AWS Glue Studio ... 2010
Referência de Data Quality Definition Language (DQDL) ... 2015
Sintaxe ... 2017
Referência de tipos de regra ... 2033
Usar APIs para medir e gerenciar a qualidade dos dados ... 2095
Pré-requisitos ... 2095
Trabalhar com as recomendações do AWS Glue Data Quality ... 2096
Trabalhar com conjuntos de regras do AWS Glue Data Quality ... 2099
Trabalhar com execuções do AWS Glue Data Quality ... 2101
Trabalhar com resultados do AWS Glue Data Quality ... 2106
Configurar alertas, implantações e agendamentos ... 2112
Configurar alertas e notificações na integração com o Amazon EventBridge ... 2112
Configurar alertas e notificações na integração com o CloudWatch ... 2121
Consultar resultados de qualidade de dados ... 2122
Implantar regras de qualidade de dados ... 2126
Agendar regras de qualidade de dados ... 2126
Criptografia de dados em repouso no AWS Glue Data Quality ... 2127
chaves de propriedade da AWS ... 2127
Chaves gerenciadas pelo cliente ... 2127
Criar uma chave gerenciada pelo cliente ... 2130
Criar uma configuração de segurança ... 2133
Contexto de criptografia do AWS Glue Data Quality ... 2134
Monitoramento das suas chaves de criptografia para o AWS Glue Data Quality ... 2135
Saiba mais ... 2140

Solução de problemas de erros do AWS Glue Data Quality 2140
Erro: módulo ausente 2141
Erro: permissões insuficientes 2141
Erro: conjuntos de regras não exclusivos 2141
Erro: tabelas com caracteres especiais 2141
Erro: estouro com um conjunto de regras grande 2142
Erro: o status das regras é com falha 2142
AnalysisException: não é possível verificar a existência de banco de dados padrão 2142
O mapa de chaves fornecido não é adequado para os quadros de dados fornecidos 2143
java.lang.RuntimeException: falha ao buscar dados. 2143
ERRO DE INICIALIZAÇÃO: erro ao baixar o S3 para o bucket 2143
InvalidInputException (status: 400): as regras DataQuality não podem ser analisadas 2144
Erro: o Eventbridge não está acionando trabalhos do Glue DQ com base na agenda que eu configurei 2144
Erros de CustomSQL 2144
Regras dinâmicas 2145
Exceção na classe de usuário: org.apache.spark.sql.AnalysisException: org.apache.hadoop.hive.ql.metadata.HiveException 2147
UNCLASSIFIED_ERROR; IllegalArgumentException: erro de análise: nenhuma regra ou analisador fornecido, nenhuma alternativa viável na entrada 2148
Integração de dados do Amazon Q no AWS Glue 2149
O que é o Amazon Q? 2149
Integração de dados do Amazon Q no AWS Glue 2149
Como trabalhar com a integração de dados do Amazon Q 2150
Práticas recomendadas 2152
Melhoria de serviços 2152
Considerações 2153
Configurar a integração de dados do Amazon Q 2153
Configurar permissões do IAM 2153
Geração de código suportada 2156
Interações de exemplo 2157
Interações de chat do Amazon Q 2157
Interações do AWS Glue com um caderno do Studio 2158
Uso do reconhecimento de contexto 2162
Exemplo: interações 2162
Limitações 2166

Orquestração 2167
Iniciar trabalhos e crawlers usando acionadores 2167
Gatilhos do AWS Glue 2167
Adição de acionadores 2170
Ativar e desativar acionadores 2174
Realizar atividades de ETL complexas usando esquemas e fluxos de trabalho 2175
Visão geral de fluxos de trabalho 2176
Criar e desenvolver um fluxo de trabalho manualmente 2180
Iniciar um fluxo de trabalho com um evento do EventBridge 2185
Visualizar os eventos do EventBridge que iniciaram um fluxo de trabalho 2192
Executar e monitorar um fluxo de trabalho 2193
Interromper uma execução de fluxo de trabalho 2195
Reparar e retomar uma execução de fluxo de trabalho 2196
Obter e configurar as configurações de execução de fluxo de trabalho 2203
Consultar fluxos de trabalho usando o AWS Glue API 2204
Restrições de esquema e fluxo de trabalho 2209
Solucionar erros de esquema 2210
Permissões para pessoas e funções de esquemas 2215
Desenvolver esquemas 2219
Visão geral dos esquemas 2220
Desenvolver esquemas 2224
Registrar um esquema 2249
Visualizar esquemas 2251
Atualizar um esquema 2253
Criar um fluxo de trabalho com base em um esquema 2255
Visualizar execuções de esquemas 2257
AWS CloudFormation para AWS Glue 2259
Banco de dados de exemplo 2261
Exemplo de banco de dados, tabela e partições 2262
Exemplo de classificador grok 2266
Exemplo de classificador JSON 2267
Exemplo de classificador XML 2268
Exemplo de crawler do Amazon S3 2269
Exemplo de conexão 2272
Exemplo de crawler do JDBC 2273
Exemplo de trabalho do Amazon S3 para o Amazon S3 2276

Exemplo de trabalho para JDBC para o Amazon S3 ... 2277
Exemplo de acionador sob demanda ... 2279
Exemplo de acionador programado ... 2280
Exemplo de acionador condicional ... 2281
Exemplo de transformação de machine learning ... 2283
Exemplo de conjunto de regras de qualidade e dados ... 2284
Exemplo de conjunto de regras de qualidade de dados com o agendador do EventBridge ... 2286
Exemplo de endpoint de desenvolvimento ... 2288
Guia de programação do AWS Glue ... 2290
Fornecer seus próprios scripts personalizados ... 2290
AWS Glue para Spark ... 2291
Tutorial: criar um script do Spark ... 2291
ETL no PySpark ... 2305
ETL no Scala ... 2540
Recursos e otimizações ... 2626
AWS Glue para Ray ... 2897
Tutorial: escrever um script do Ray ... 2897
Usar o Ray Core e o Ray Data no AWS Glue para Ray ... 2904
Fornecer arquivos e bibliotecas do Python ... 2906
Conectar-se a dados ... 2911
Como trabalhar com AWS SDKs ... 2913
API do AWS Glue ... 2915
Segurança ... 2942
— tipos de dados — ... 2942
DataCatalogEncryptionSettings ... 2943
EncryptionAtRest ... 2943
ConnectionPasswordEncryption ... 2944
EncryptionConfiguration ... 2945
S3Encryption ... 2945
CloudWatchEncryption ... 2945
JobBookmarksEncryption ... 2946
SecurityConfiguration ... 2946
GluePolicy ... 2947
DataQualityEncryption ... 2947
— operações — ... 2948
GetDataCatalogEncryptionSettings (get_data_catalog_encryption_settings) ... 2948

PutDataCatalogEncryptionSettings (put_data_catalog_encryption_settings) 2949
PutResourcePolicy (put_resource_policy) 2949
GetResourcePolicy (get_resource_policy) 2951
DeleteResourcePolicy (delete_resource_policy) 2952
CreateSecurityConfiguration (create_security_configuration) 2953
DeleteSecurityConfiguration (delete_security_configuration) 2954
GetSecurityConfiguration (get_security_configuration) 2954
GetSecurityConfigurations (get_security_configurations) 2955
GetResourcePolicies (get_resource_policies) 2956
Catálogar objetos 2957
Catálogos 2957
Bancos de dados 2970
Tabelas 2980
Partições 3028
Conexões 3054
Funções definidas pelo usuário 3098
Importar um catálogo do Athena 3105
Otimizador de tabelas 3107
— tipos de dados — 3107
TableOptimizer 3108
TableOptimizerConfiguration 3108
TableOptimizerVpcConfiguration 3109
CompactionConfiguration 3110
IcebergCompactionConfiguration 3110
TableOptimizerRun 3111
BatchGetTableOptimizerEntry 3112
BatchTableOptimizer 3113
BatchGetTableOptimizerError 3113
RetentionConfiguration 3114
IcebergRetentionConfiguration 3114
OrphanFileDeletionConfiguration 3115
IcebergOrphanFileDeletionConfiguration 3115
CompactionMetrics 3115
RetentionMetrics 3116
OrphanFileDeletionMetrics 3116
IcebergCompactionMetrics 3116

IcebergRetentionMetrics 3117
IcebergOrphanFileDeletionMetrics 3117
RunMetrics 3118
— operações — 3118
GetTableOptimizer (get_table_optimizer) 3118
BatchGetTableOptimizer (batch_get_table_optimizer) 3120
ListTableOptimizerRuns (list_table_optimizer_runs) 3121
CreateTableOptimizer (create_table_optimizer) 3122
DeleteTableOptimizer (delete_table_optimizer) 3123
UpdateTableOptimizer (update_table_optimizer) 3124
Crawlers e classificadores 3125
Classificadores 3126
Crawlers 3140
Estatísticas de colunas 3168
Scheduler 3184
Scripts de ETL de geração automática 3187
— tipos de dados — 3187
CodeGenNode 3187
CodeGenNodeArg 3188
CodeGenEdge 3188
Local 3189
CatalogEntry 3189
MappingEntry 3189
— operações — 3190
CreateScript (create_script) 3190
GetDataflowGraph (get_dataflow_graph) 3191
GetMapping (get_mapping) 3192
GetPlan (get_plan) 3193
API de trabalhos visuais 3194
— tipos de dados — 3194
CodeGenConfigurationNode 3198
JDBCConnectorOptions 3205
StreamingDataPreviewOptions 3206
AthenaConnectorSource 3207
JDBCConnectorSource 3207
SparkConnectorSource 3208

CatalogSource ... 3209
MySQLCatalogSource ... 3209
PostgreSQLCatalogSource ... 3210
OracleSQLCatalogSource ... 3210
MicrosoftSQLServerCatalogSource ... 3211
CatalogKinesisSource ... 3211
DirectKinesisSource ... 3212
KinesisStreamingSourceOptions ... 3212
CatalogKafkaSource ... 3215
DirectKafkaSource ... 3216
KafkaStreamingSourceOptions ... 3216
RedshiftSource ... 3219
AmazonRedshiftSource ... 3220
AmazonRedshiftNodeData ... 3220
AmazonRedshiftAdvancedOption ... 3222
Opção ... 3223
S3CatalogSource ... 3223
S3SourceAdditionalOptions ... 3224
S3CSVSource ... 3224
DirectJDBCSource ... 3227
S3DirectSourceAdditionalOptions ... 3227
S3JsonSource ... 3228
S3ParquetSource ... 3229
S3DeltaSource ... 3231
S3CatalogDeltaSource ... 3232
CatalogDeltaSource ... 3232
S3HudiSource ... 3233
S3CatalogHudiSource ... 3234
S3ExcelSource ... 3234
CatalogHudiSource ... 3236
DynamoDBCatalogSource ... 3236
RelationalCatalogSource ... 3237
JDBCConnectorTarget ... 3237
SparkConnectorTarget ... 3238
BasicCatalogTarget ... 3239
MySQLCatalogTarget ... 3239

PostgreSQLCatalogTarget 3240
OracleSQLCatalogTarget 3240
MicrosoftSQLServerCatalogTarget 3241
RedshiftTarget 3241
AmazonRedshiftTarget 3242
UpsertRedshiftTargetOptions 3243
S3CatalogTarget 3243
S3GlueParquetTarget 3244
CatalogSchemaChangePolicy 3245
S3DirectTarget 3245
S3HudiCatalogTarget 3246
S3HudiDirectTarget 3247
S3DeltaCatalogTarget 3248
S3DeltaDirectTarget 3249
S3HyperDirectTarget 3250
S3IcebergDirectTarget 3250
DirectSchemaChangePolicy 3251
ApplyMapping 3252
Mapeamento 3252
SelectFields 3253
DropFields 3254
RenameField 3254
Spigot 3255
Ingressar 3255
JoinColumn 3256
SplitFields 3256
SelectFromCollection 3257
FillMissingValues 3257
Filtro 3258
FilterExpression 3258
FilterValue 3259
CustomCode 3259
SparkSQL 3260
SqlAlias 3261
DropNullFields 3261
NullCheckBoxList 3262

NullValueField 3262
DataType 3262
Mesclar 3263
Union 3263
PIIdetection 3264
Agregar 3265
DropDuplicates 3266
GovernedCatalogTarget 3266
GovernedCatalogSource 3267
AggregateOperation 3267
GlueSchema 3268
GlueStudioSchemaColumn 3268
GlueStudioColumn 3268
DynamicTransform 3269
TransformConfigParameter 3270
EvaluateDataQuality 3271
DQResultsPublishingOptions 3272
DQStopJobOnFailureOptions 3272
EvaluateDataQualityMultiFrame 3272
Fórmula 3273
RecipeReference 3274
SnowflakeNodeData 3274
SnowflakeSource 3277
SnowflakeTarget 3277
ConnectorDataSource 3277
ConnectorDataTarget 3278
RecipeStep 3279
RecipeAction 3280
ConditionExpression 3280
Tarefas 3281
Tarefas 3281
Execuções de trabalhos 3308
Acionadores 3328
APIs de integração 3342
— tipos de dados — 3342
Integração 3343

IntegrationConfig 3344
IntegrationPartition 3345
IntegrationError 3346
IntegrationFilter 3346
InboundIntegration 3347
SourceProcessingProperties 3348
TargetProcessingProperties 3348
SourceTableConfig 3349
TargetTableConfig 3349
— operações — 3350
CreateIntegration (create_integration) 3350
ModifyIntegration (modify_integration) 3353
DescribeIntegrations (describe_integrations) 3356
DeleteIntegration (delete_integration) 3357
DescribeInboundIntegrations (describe_inbound_integrations) 3359
CreateIntegrationTableProperties (create_integration_table_properties) 3361
UpdateIntegrationTableProperties (update_integration_table_properties) 3362
GetIntegrationTableProperties (get_integration_table_properties) 3363
DeleteIntegrationTableProperties (delete_integration_table_properties) 3365
CreateIntegrationResourceProperty (create_integration_resource_property) 3365
UpdateIntegrationResourceProperty (update_integration_resource_property) 3367
GetIntegrationResourceProperty (get_integration_resource_property) 3368
UntagResource (untag_resource) 3369
ListTagsForResource (list_tags_for_resource) 3369
— exceções — 3370
ResourceNotFoundException 3370
InternalServerException 3371
IntegrationAlreadyExistsFault 3371
IntegrationConflictOperationFault 3371
IntegrationQuotaExceededFault 3371
KMSKeyNotAccessibleFault 3372
IntegrationNotFoundFault 3372
TargetResourceNotFound 3372
InvalidIntegrationStateFault 3372
Sessões interativas 3373
— tipos de dados — 3373

Sessão 3373
SessionCommand 3376
Declaração 3376
StatementOutput 3377
StatementOutputData 3377
ConnectionsList 3378
— operações — 3378
CreateSession (create_session) 3378
StopSession (stop_session) 3382
DeleteSession (delete_session) 3383
GetSession (get_session) 3384
ListSessions (list_sessions) 3384
RunStatement (run_statement) 3385
CancelStatement (cancel_statement) 3386
getStatement (get_statement) 3387
ListStatations (list_statations) 3388
DevEndpoints 3389
— tipos de dados — 3389
DevEndpoint 3389
DevEndpointCustomLibraries 3394
— operações — 3394
CreateDevEndpoint (create_dev_endpoint) 3395
UpdateDevEndpoint (update_dev_endpoint) 3400
DeleteDevEndpoint (delete_dev_endpoint) 3402
GetDevEndpoint (get_dev_endpoint) 3402
GetDevEndpoints (get_dev_endpoints) 3403
BatchGetDevEndpoints (batch_get_dev_endpoints) 3404
ListDevEndpoints (list_dev_endpoints) 3405
Registro de esquemas 3406
— tipos de dados — 3406
RegistryId 3407
RegistryListItem 3407
MetadataInfo 3408
OtherMetadataValueListItem 3408
SchemaListItem 3409
SchemaVersionListItem 3410

MetadataKeyValuePair 3410
SchemaVersionErrorItem 3411
ErrorDetails 3411
SchemaVersionNumber 3411
SchemaId 3412
— operações — 3412
CreateRegistry (create_registry) 3413
CreateSchema (create_schema) 3414
GetSchema (get_schema) 3419
ListSchemaVersions (list_schema_versions) 3421
GetSchemaVersion (get_schema_version) 3422
GetSchemaVersionsDiff (get_schema_versions_diff) 3423
ListRegistries (list_registries) 3424
ListSchemas (list_schemas) 3425
RegisterSchemaVersion (register_schema_version) 3426
UpdateSchema (update_schema) 3428
CheckSchemaVersionValidity (check_schema_version_validity) 3429
UpdateRegistry (update_registry) 3430
GetSchemaByDefinition (get_schema_by_definition) 3431
GetRegistry (get_registry) 3433
PutSchemaVersionMetadata (put_schema_version_metadata) 3434
QuerySchemaVersionMetadata (query_schema_version_metadata) 3435
RemoveSchemaVersionMetadata (remove_schema_version_metadata) 3437
DeleteRegistry (delete_registry) 3439
DeleteSchema (delete_schema) 3440
DeleteSchemaVersions (Python: delete_schema_versions) 3441
Fluxos de trabalho 3442
— tipos de dados — 3442
JobNodeDetails 3443
CrawlerNodeDetails 3443
TriggerNodeDetails 3443
Crawl 3443
Nó 3444
Borda 3445
Fluxo de trabalho 3445
WorkflowGraph 3447

WorkflowRun 3447
WorkflowRunStatistics 3448
StartingEventBatchCondition 3449
Blueprint 3450
BlueprintDetails 3451
LastActiveDefinition 3451
BlueprintRun 3452
— operações — 3453
CreateWorkflow (create_workflow) 3454
UpdateWorkflow (update_workflow) 3455
DeleteWorkflow (delete_workflow) 3457
GetWorkflow (get_workflow) 3457
ListWorkflows (list_workflows) 3458
BatchGetWorkflows (batch_get_workflows) 3459
GetWorkflowRun (get_workflow_run) 3460
GetWorkflowRuns (get_workflow_runs) 3460
GetWorkflowRunProperties (get_workflow_run_properties) 3461
PutWorkflowRunProperties (put_workflow_run_properties) 3462
CreateBlueprint (create_blueprint) 3464
UpdateBlueprint (update_blueprint) 3465
DeleteBlueprint (delete_blueprint) 3466
ListBlueprints (list_blueprints) 3466
BatchGetBlueprints (batch_get_blueprints) 3467
StartBlueprintRun (start_blueprint_run) 3468
GetBlueprintRun (get_blueprint_run) 3469
GetBlueprintRuns (get_blueprint_runs) 3470
StartWorkflowRun (start_workflow_run) 3471
StopWorkflowRun (stop_workflow_run) 3472
ResumeWorkflowRun (resume_workflow_run) 3472
Perfis de uso 3474
— tipos de dados — 3474
ProfileConfiguration 3474
ConfigurationObject 3474
UsageProfileDefinition 3475
— operações — 3476
CreateUsageProfile (create_usage_profile) 3476

GetUsageProfile (get_usage_profile) ... 3477
UpdateUsageProfile (update_usage_profile) ... 3478
DeleteUsageProfile (delete_usage_profile) ... 3479
ListUsageProfiles (list_usage_profiles) ... 3480
Machine learning ... 3480
— tipos de dados — ... 3481
TransformParameters ... 3481
EvaluationMetrics ... 3482
MLTransform ... 3482
FindMatchesParameters ... 3486
FindMatchesMetrics ... 3487
ConfusionMatrix ... 3488
GlueTable ... 3489
TaskRun ... 3490
TransformFilterCriteria ... 3491
TransformSortCriteria ... 3492
TaskRunFilterCriteria ... 3493
TaskRunSortCriteria ... 3493
TaskRunProperties ... 3494
FindMatchesTaskRunProperties ... 3494
ImportLabelsTaskRunProperties ... 3495
ExportLabelsTaskRunProperties ... 3495
LabelingSetGenerationTaskRunProperties ... 3495
SchemaColumn ... 3496
TransformEncryption ... 3496
MLUserDataEncryption ... 3497
ColumnImportance ... 3497
— operações — ... 3498
CreateMLTransform (create_ml_transform) ... 3498
UpdateMLTransform (update_ml_transform) ... 3502
DeleteMLTransform (delete_ml_transform) ... 3505
GetMLTransform (get_ml_transform) ... 3505
GetMLTransforms (get_ml_transforms) ... 3508
ListMLTransforms (list_ml_transforms) ... 3509
StartMLEvaluationTaskRun (start_ml_evaluation_task_run) ... 3511
StartMLLabelingSetGenerationTaskRun (start_ml_labeling_set_generation_task_run) ... 3512

GetMLTaskRun (get_ml_task_run) 3513
GetMLTaskRuns (get_ml_task_runs) 3514
CancelMLTaskRun (cancel_ml_task_run) 3516
StartExportLabelsTaskRun (start_export_labels_task_run) 3517
StartImportLabelsTaskRun (start_import_labels_task_run) 3518
Data Quality 3519
— tipos de dados — 3519
DataSource 3520
DataQualityRulesetListDetails 3520
DataQualityTargetTable 3521
DataQualityRulesetEvaluationRunDescription 3522
DataQualityRulesetEvaluationRunFilter 3522
DataQualityEvaluationRunAdditionalRunOptions 3523
DataQualityRuleRecommendationRunDescription 3523
DataQualityRuleRecommendationRunFilter 3524
DataQualityResult 3524
DataQualityAnalyzerResult 3526
DataQualityObservation 3527
MetricBasedObservation 3527
DataQualityMetricValues 3528
DataQualityRuleResult 3528
DataQualityResultDescription 3529
DataQualityResultFilterCriteria 3530
DataQualityRulesetFilterCriteria 3531
DataQualityAggregatedMetrics 3531
StatisticAnnotation 3532
TimestampedInclusionAnnotation 3533
AnnotationError 3533
DatapointInclusionAnnotation 3533
StatisticSummaryList 3534
StatisticSummary 3534
RunIdentifier 3535
StatisticModelResult 3536
— operações — 3537
Ação StartDataQualityRulesetEvaluationRun (start_data_quality_ruleset_evaluation_run) .. 3538
CancelDataQualityRulesetEvaluationRun (cancel_data_quality_ruleset_evaluation_run) 3539

GetDataQualityRulesetEvaluationRun (get_data_quality_ruleset_evaluation_run) 3540
ListDataQualityRulesetEvaluationRuns (list_data_quality_ruleset_evaluation_runs) 3542
StartDataQualityRuleRecommendationRun (start_data_quality_rule_recommendation_run) 3543
CancelDataQualityRuleRecommendationRun
(cancel_data_quality_rule_recommendation_run) 3545
GetDataQualityRuleRecommendationRun (get_data_quality_rule_recommendation_run) .. 3545
ListDataQualityRuleRecommendationRuns (list_data_quality_rule_recommendation_runs) 3547
GetDataQualityResult (get_data_quality_result) 3548
BatchGetDataQualityResult (batch_get_data_quality_result) 3550
ListDataQualityResults (list_data_quality_results) 3551
CreateDataQualityRuleset (create_data_quality_ruleset) 3552
DeleteDataQualityRuleset (delete_data_quality_ruleset) 3554
GetDataQualityRuleset (get_data_quality_ruleset) 3554
ListDataQualityRulesets (list_data_quality_rulesets) 3556
UpdateDataQualityRuleset (update_data_quality_ruleset) 3557
ListDataQualityStatistics (list_data_quality_statistics) 3558
TimestampFilter 3559
CreateDataQualityRulesetRequest 3559
GetDataQualityRulesetResponse 3560
GetDataQualityResultResponse 3562
StartDataQualityRuleRecommendationRunRequest 3563
GetDataQualityRuleRecommendationRunResponse 3564
BatchPutDataQualityStatisticAnnotation (batch_put_data_quality_statistic_annotation) 3566
GetDataQualityModel (get_data_quality_model) 3567
GetDataQualityModelResult (get_data_quality_model_result) 3568
ListDataQualityStatisticAnnotations (list_data_quality_statistic_annotations) 3569
PutDataQualityProfileAnnotation (put_data_quality_profile_annotation) 3570
Dados sigilosos 3570
— tipos de dados — 3570
CustomEntityType 3571
— operações — 3571
CreateCustomEntityType (create_custom_entity_type) 3571
DeleteCustomEntityType (delete_custom_entity_type) 3573
GetCustomEntityType (get_custom_entity_type) 3574
BatchGetCustomEntityTypes (batch_get_custom_entity_types) 3575
ListCustomEntityTypes (list_custom_entity_types) 3575

APIs de Tags 3576
— tipos de dados — 3576
Tag 3576
— operações — 3577
TagResource (tag_resource) 3577
UntagResource (untag_resource) 3578
GetTags (get_tags) 3579
Tipos de dados comuns 3579
Tag 3579
DecimalNumber 3580
ErrorDetail 3580
PropertyPredicate 3581
ResourceUri 3581
ColumnStatistics 3581
ColumnStatisticsError 3582
ColumnError 3582
ColumnStatisticsData 3583
BooleanColumnStatisticsData 3584
DateColumnStatisticsData 3584
DecimalColumnStatisticsData 3585
DoubleColumnStatisticsData 3585
LongColumnStatisticsData 3586
StringColumnStatisticsData 3586
BinaryColumnStatisticsData 3587
Padrões de string 3587
Exceções 3590
AccessDeniedException 3590
AlreadyExistsException 3590
ConcurrentModificationException 3590
ConcurrentRunsExceededException 3590
CrawlerNotRunningException 3591
CrawlerRunningException 3591
CrawlerStoppingException 3591
EntityNotFoundException 3591
FederationSourceException 3592
FederationSourceRetryableException 3592

GlueEncryptionException ... 3592
IdempotentParameterMismatchException ... 3593
IllegalWorkflowStateException ... 3593
InternalServiceException ... 3593
InvalidExecutionEngineException ... 3593
InvalidInputException ... 3594
InvalidStateException ... 3594
InvalidTaskStatusTransitionException ... 3594
JobDefinitionErrorException ... 3595
JobRunInTerminalStateException ... 3595
JobRunInvalidStateTransitionException ... 3595
JobRunNotInTerminalStateException ... 3596
LateRunnerException ... 3596
NoScheduleException ... 3596
OperationTimeoutException ... 3596
ResourceNotReadyException ... 3597
ResourceNumberLimitExceededException ... 3597
SchedulerNotRunningException ... 3597
SchedulerRunningException ... 3597
SchedulerTransitioningException ... 3598
UnrecognizedRunnerException ... 3598
ValidationException ... 3598
VersionMismatchException ... 3598
Exemplos de códigos de API do AWS Glue ... 3600
Conceitos básicos ... 3610
Olá, AWS Glue ... 3611
Conheça os conceitos básicos ... 3621
Ações ... 3757
Segurança ... 3901
Proteção de dados ... 3902
Criptografar dados em repouso ... 3902
Criptografia de dados em trânsito ... 3920
Conformidade com os FIPS ... 3921
Gerenciamento de chaves ... 3921
Dependência do AWS Glue de outros produtos da AWS ... 3922
Endpoints de desenvolvimento ... 3922

Gerenciamento de identidade e acesso 3923
Público 3924
Autenticação com identidades 3925
Gerenciar acesso usando políticas 3928
Como o AWS Glue funciona com IAM 3931
Configurar permissões do KMS para o AWS Glue 3939
Exemplos de política de controle de acesso do AWS Glue 3972
Conceder políticas gerenciadas pela AWS 3999
Especificar ARNs de recursos do AWS Glue 4008
Concessão de acesso entre contas 4017
Solução de problemas 4024
Modelos de controle de acesso do AWS Lake Formation 4026
Como usar AWS Glue com AWS Lake Formation para acesso total à tabela 4027
Lake Formation para o FGAC 4039
Usar Concessão de Acesso do Amazon S3 com o AWS Glue 4052
Como o AWS Glue funciona com a Concessão de Acesso do S3 4052
Considerações sobre a Concessão de Acesso do S3 com o AWS Glue 4053
Configurar a Concessão de Acesso do S3 com o AWS Glue 4054
Registro e monitoramento 4056
Validação de conformidade 4057
Resiliência 4058
Segurança da infraestrutura 4059
Configurar VPC endpoints de interface (AWS PrivateLink) para AWS Glue 4059
Configurar Amazon VPCs compartilhadas 4062
Solução de problemas de AWS Glue 4063
Reunir informações sobre a solução de problemas do AWS Glue 4063
Solução de problemas de erros no Spark 4064
Erro: Resource unavailable (Recurso indisponível) 4065
Erro: Could not find S3 endpoint or NAT gateway for subnetId in VPC (Não foi possível encontrar o endpoint do S3 nem o gateway NAT para subnetId na VPC) 4066
Erro: Inbound rule in security group required (A regra de entrada no grupo de segurança é obrigatória) 4066
Erro: Outbound rule in security group required (A regra de saída no grupo de segurança é obrigatória) 4066
Erro: falha na execução do trabalho porque o perfil passado deveria receber as permissões de assumir o perfil para o serviço AWS Glue 4067

Erro: a ação DescribeVpcEndpoints não está autorizada. Não foi possível validar o ID da VPC vpc-id 4067
Erro: a ação DescribeRouteTables não está autorizada. Não é possível validar o ID da sub-rede Subnet-id no ID da VPC vpc-id 4067
Erro: Failed to call ec2:DescribeSubnets (Falha ao chamar ec2:DescribeSubnets) 4067
Erro: Failed to call ec2:DescribeSecurityGroups (Falha ao chamar ec2:DescribeSecurityGroups) 4067
Erro: Could not find subnet for AZ (Não foi possível encontrar uma sub-rede para zona de disponibilidade) 4068
Erro: Job run exception when writing to a JDBC target (Exceção de execução de trabalho ao gravar um destino JDBC) 4068
Erro: Amazon S3: a operação não é válida para a classe de armazenamento do objeto 4069
Erro: Amazon S3 timeout (Tempo limite do Amazon S3) 4069
Erro: Amazon S3 access denied (Acesso negado ao Amazon S3) 4069
Erro: Amazon S3 access key ID does not exist (O ID da chave de acesso do Amazon S3 não existe) 4069
Erro: falha na execução do trabalho ao acessar o Amazon S3 com um URI `s3a://` 4070
Erro: Amazon S3 service token expired (O token do serviço do Amazon S3 expirou) 4072
Erro: No private DNS for network interface found (Nenhum DNS privado foi encontrado na interface de rede) 4072
Erro: Development endpoint provisioning failed (Falha no provisionamento do endpoint de desenvolvimento) 4072
Erro: Notebook server CREATE_FAILED (Servidor de cadernos com status CREATE_FAILED) 4073
Erro: Local notebook fails to start (Falha ao iniciar o caderno local) 4073
Erro: Running crawler failed (Falha na execução do crawler) 4073
Erro: Partitions were not updated (As partições não foram atualizadas) 4074
Erro: Job bookmark update failed due to version mismatch (A atualização do marcador de trabalho falhou devido à incompatibilidade da versão) 4074
Erro: A job is reprocessing data when job bookmarks are enabled (Um trabalho está reprocessando dados quando marcadores do trabalho estão habilitados) 4075
Erro: comportamento de failover entre VPCs no AWS Glue 4076
Erros do crawler ao usar permissões do Lake Formation 4077
Erro: The S3 location: s3://examplepath is not registered (O local do S3: s3://examplepath não está registrado) 4077

Erro: User/Role is not authorized to perform: lakeformation:GetDataAccess on resource (O usuário/função não está autorizado(a) a executar lakeformation:GetDataAccess no recurso) 4077
Erro: Insufficient Lake Formation permission(s) on (Database name: exampleDatabase, Table Name: exampleTable) (Permissão(ões) do Lake Formation insuficiente(s) em (Nome do banco de dados: exampleDatabase, Nome da tabela: exampleTable)) 4078
Erro: Insufficient Lake Formation permission(s) on s3://examplepath (Permissão(ões) insuficiente(s) do Lake Formation em s3://examplepath) 4078
Perguntas frequentes sobre a configuração do crawler usando as credenciais do Lake Formation 4079
Solucionar problemas de erros do Ray 4080
Inspecionar logs de tarefas do Ray 4080
Solucionar de problemas de erros do Ray 4081
Exceções de machine learning do AWS Glue 4083
CancelMLTaskRunActivity 4083
CreateMLTaskRunActivity 4083
DeleteMLTransformActivity 4084
GetMLTaskRunActivity 4085
GetMLTaskRunsActivity 4085
GetMLTransformActivity 4085
GetMLTransformsActivity 4085
GetSaveLocationForTransformArtifactActivity 4086
GetTaskRunArtifactActivity 4086
PublishMLTransformModelActivity 4087
PullLatestMLTransformModelActivity 4087
PutJobMetadataForMLTransformActivity 4088
StartExportLabelsTaskRunActivity 4089
StartImportLabelsTaskRunActivity 4089
StartMLEvaluationTaskRunActivity 4090
StartMLLabelingSetGenerationTaskRunActivity 4091
UpdateMLTransformActivity 4091
Cotas do AWS Glue 4092
Aprimorar a performance do AWS Glue 4094
Estratégias de ajuste para seu tipo de trabalho 4094
Melhorar a performance do Spark 4094
Otimizando leituras com o pushdown 4095

Pushdown de predicados em arquivos armazenados no Amazon S3 4095
Pushdown ao trabalhar com fontes JDBC 4096
Notas e limitações para pushdown no AWS Glue 4099
Usando o escalonamento automático para AWS Glue 4100
Requisitos 4101
Habilitando o Auto Scaling em AWS Glue Studio 1855
Habilitando o Auto Scaling com o ou AWS CLI SDK 1856
Habilitar o Auto Scaling com sessões interativas 4103
Dicas e considerações 4103
Monitoramento do Auto Scaling com métricas da Amazon CloudWatch 4104
Monitoramento do Auto Scaling com Amazon Logs CloudWatch 4105
Monitoramento do Auto Scaling com o Spark UI 4106
Monitorando o uso da execução de tarefas do Auto Scaling DPU 4107
Limitações 4107
Particionar workloads com execução limitada 4107
Habilitar o particionamento de workloads 4108
Configurar um acionador do AWS Glue para executar o trabalho automaticamente 4109
Problemas conhecidos 4110
Impedir acesso a dados entre trabalhos 4110
Histórico de documentação 4113
Atualizações anteriores 4179
Glossário da AWS 4181

O que é o AWS Glue?

O AWS Glue é um serviço de integração de dados com tecnologia sem servidor que facilita aos usuários de análise a descoberta, preparação, transferência e integração de dados de várias fontes. Você pode usá-lo para análise, machine learning e desenvolvimento de aplicações. Também inclui outras ferramentas de produtividade e operações de dados para criação, execução de trabalhos e implementação de fluxos de trabalho de negócios.

Com o AWS Glue, você pode detectar e se conectar a mais de 70 fontes de dados diversas e gerenciar seus dados em um catálogo de dados centralizado. Você pode criar, executar e monitorar visualmente pipelines de extração, transformação e carregamento (ETL) para carregar dados em seus data lakes. Além disso, é possível pesquisar e consultar imediatamente os dados catalogados usando o Amazon Athena, o Amazon EMR e o Amazon Redshift Spectrum.

O AWS Glue consolida os principais recursos de integração de dados em um único serviço. Isso inclui descoberta de dados, ETL moderno, limpeza, transformação e catalogação centralizada. Também conta com tecnologia sem servidor, o que significa que não há infraestrutura para gerenciar. Com suporte flexível para todas as workloads, como ETL, ELT e transmissão em um único serviço, o AWS Glue oferece suporte a usuários em várias workloads e tipos de usuários.

Além disso, o AWS Glue facilita a integração de dados em sua arquitetura. Ele se integra aos serviços de análise da AWS e a data lakes do Amazon S3. O AWS Glue tem interfaces de integração e ferramentas de criação de trabalhos que são descomplicadas para todos os usuários, de desenvolvedores a usuários corporativos, com soluções personalizadas para conjuntos variados de habilidades técnicas.

Com a capacidade de escalar sob demanda, AWS Glue ajuda você a se concentrar em atividades de alto valor que maximizam o valor de seus dados. Ele pode ser escalado para qualquer tamanho de dados e oferece suporte a todos os tipos de dados e variações de esquema. Para aumentar a agilidade e otimizar custos, o AWS Glue fornece alta disponibilidade integrada e cobrança com pagamento conforme o uso.

Para obter informações sobre preços, consulte AWS Glue preços.

AWS Glue Studio

O AWS Glue Studio é uma interface gráfica que facilita a criação, a execução e o monitoramento de trabalhos de integração de dados no AWS Glue. Você pode compor visualmente fluxos de trabalho

de transformação de dados e executá-los perfeitamente no mecanismo de ETL com tecnologia sem servidor baseado no Apache Spark do AWS Glue.

Com o AWS Glue Studio, você pode criar e gerenciar trabalhos que coletam, transformam e limpam dados. Use também o AWS Glue Studio para solucionar problemas e editar scripts de trabalho.

Tópicos

- Recursos do AWS Glue
- Aprender sobre inovações no AWS Glue
- Conceitos básicos do AWS Glue
- Como acessar o AWS Glue
- Serviços relacionados

Recursos do AWS Glue

Os recursos do AWS Glue se enquadram em três categorias principais:

- Descobrir e organizar dados
- Transformar, preparar e limpar dados para análise
- Criar e monitorar pipelines de dados

Descobrir e organizar dados

- Unifique e pesquise em vários armazenamentos de dados: armazene, indexe e pesquise em várias fontes e coletores de dados catalogando todos os seus dados na AWS.
- Descubra dados automaticamente: use os crawlers do AWS Glue para inferir automaticamente as informações do esquema e integrá-las ao AWS Glue Data Catalog.
- Gerencie esquemas e permissões: valide e controle o acesso a bancos de dados e tabelas.
- Conecte-se a uma ampla variedade de fontes de dados: acesse várias fontes de dados, tanto on-premises como na AWS, usando conexões do AWS Glue para criar seu data lake.

Transformar, preparar e limpar dados para análise

- Transforme visualmente dados com uma interface de tela de trabalho: defina seu processo de ETL no editor de trabalhos visuais e gere automaticamente o código para extrair, transformar e carregar dados.
- Crie pipelines de ETL complexos com agendamento de tarefas simples: invoque trabalhos do AWS Glue em um cronograma, sob demanda ou com base em um evento.
- Limpe e transforme a transmissão de dados em trânsito: possibilite o consumo contínuo de dados, limpe-os e transforme-os em trânsito. Isso os disponibiliza para análise em segundos no datastore de destino.
- Elimine a duplicação e limpe dados com machine learning integrado: limpe e prepare dados para análise sem se tornar um especialista em machine learning usando o recurso `FindMatches`. Esse recurso elimina a duplicação e encontra registros que são correspondências imperfeitas entre si.
- Blocos de anotação de trabalho integrados: os blocos de anotação de trabalho do AWS Glue fornecem blocos de anotação com tecnologia sem servidor com configuração mínima no AWS Glue para que você comece a usar rapidamente.
- Edite, depure e teste o código ETL: com as sessões interativas do AWS Glue, você pode explorar e preparar dados de forma interativa. Você pode explorar, experimentar e processar dados de forma interativa usando o IDE ou o bloco de anotações de sua preferência.
- Defina, detecte e corrija dados sigilosos: a detecção de dados sigilosos AWS Glue permite definir, identificar e processar dados sigilosos no pipeline de dados e no data lake.

Criar e monitorar pipelines de dados

- Escale automaticamente de acordo com a workload: de maneira dinâmica, aumente e diminua verticalmente a escala dos recursos de acordo com a workload. Isso atribui operadores a trabalhos somente quando necessário.
- Automatize trabalhos com acionadores baseados em eventos: inicie os crawlers ou trabalhos do AWS Glue com acionadores baseados em eventos e crie uma cadeia de trabalhos e crawlers dependentes.
- Execute e monitore trabalhos: Execute trabalhos do AWS Glue com o mecanismo de sua escolha, Spark ou Ray. Monitore-os com ferramentas de monitoramento automatizadas, insights de execução de trabalhos do AWS Glue e o AWS CloudTrail. Aprimore o seu monitoramento de trabalhos apoiados pelo Spark com a interface do usuário do Apache Spark.
- Defina fluxos de trabalho para atividades de ETL e integração: defina fluxos de trabalho para ETL e atividades de integração para vários crawlers, trabalhos e acionadores.

Aprender sobre inovações no AWS Glue

Saiba mais sobre as inovações mais recentes no AWS Glue e ouça como os clientes usam o AWS Glue para permitir a preparação de dados de autoatendimento em toda a organização.

Saiba mais sobre como os clientes escalam o AWS Glue além da configuração tradicional e como eles configuram o AWS Glue para monitoramento de trabalho e a performance.

Conceitos básicos do AWS Glue

Recomendamos que você inicie por estas seções:

- Visão geral do uso do AWS Glue
- Conceitos do AWS Glue
- Configurar permissões do IAM para o AWS Glue
- Conceitos básicos do AWS Glue Data Catalog
- Criar trabalhos no AWS Glue
- Conceitos básicos das sessões interativas do AWS Glue
- Orquestração no AWS Glue

Como acessar o AWS Glue

Você pode criar, visualizar e gerenciar seus trabalhos do AWS Glue usando as seguintes interfaces:

- Console do AWS Glue: fornece uma interface da Web para você criar, visualizar e gerenciar trabalhos do AWS Glue. Para acessar o console, acesse AWS Glue.
- AWS Glue Studio: fornece uma interface gráfica para criar e editar seus trabalhos do AWS Glue visualmente. Para ter mais informações, consulte Criar trabalhos ETL visuais com o AWS Glue Studio.
- Seção sobre o AWS Glue na referência da AWS CLI: fornece comandos da AWS CLI que você pode usar com o AWS Glue. Para obter mais informações, consulte a referência da AWS CLI para o AWS Glue.
- API do AWS Glue: fornece uma referência de API completa para desenvolvedores. Para obter mais informações, consulte a API do AWS Glue.

Serviços relacionados

Os usuários do AWS Glue também utilizam:

- AWS Lake Formation : serviço que é uma camada de autorização que fornece controle de acesso detalhado a recursos do AWS Glue Data Catalog.
- AWS Glue DataBrew : uma ferramenta de preparação de dados visuais que pode ser usada para limpar e normalizar dados sem escrever nenhum código.

AWS Glue: como funciona

O AWS Glue usa outros produtos da AWS para orquestrar seus trabalhos de ETL (extração, transformação e carregamento) para criar data warehouses e data lakes e gerar transmissões de saída. O AWS Glue chama operações de API para transformar seus dados, criar logs de runtime, armazenar a lógica do trabalho e criar notificações para ajudar você a monitorar as execuções de trabalhos. O console do AWS Glue conecta esses serviços em um aplicativo gerenciado, para que você possa se concentrar na criação e no monitoramento do seu trabalho de ETL. O console executa operações de desenvolvimento de trabalhos e administrativas em seu nome. Você fornece credenciais e outras propriedades para que o AWS Glue acesse suas fontes de dados e grave nos destinos de dados.

O AWS Glue provisiona e gerencia os recursos necessários para executar sua workload. Não é necessário criar a infraestrutura para uma ferramenta de ETL porque o AWS Glue faz isso por você. Quando recursos são necessários, o AWS Glue usa uma instância do grupo de instâncias para executar sua workload e reduzir o tempo de inicialização.

Com o AWS Glue, você cria trabalhos usando definições de tabela no Data Catalog. Os trabalhos consistem em scripts com as instruções que executam as tarefas de transformação de dados desejadas. Você usa gatilhos para iniciar trabalhos em uma programação ou como resultado de um evento especificado. Você determina onde seus dados de destino residirão e quais dados de origem que preencherão seu destino. Com base em suas entradas, o AWS Glue transforma os dados do formato de origem para o de destino. Como alternativa, também é possível fornecer scripts personalizados no console do AWS Glue ou na API para processar os dados de acordo com seus requisitos específicos.

Fontes e destinos de dados

O AWS Glue para Sparks permite que você leia e grave dados de vários sistemas e bancos de dados, incluindo:

- Amazon S3
- Amazon DynamoDB
- Amazon Redshift
- Amazon Relational Database Service (Amazon RDS)
- Bancos de dados acessíveis a JDBC de terceiros

- MongoDB e Amazon DocumentDB (compatível com MongoDB)
- Outros conectores do Marketplace e plug-ins do Apache Spark

Streams de dados

O AWS Glue para Sparks pode transmitir dados dos seguintes sistemas:

- Amazon Kinesis Data Streams
- Apache Kafka

O AWS Glue está disponível em diversas regiões da AWS. Para obter mais informações, consulte Regiões e endpoints do AWS no Referência geral da Amazon Web Services.

Tópicos

- Trabalhos de ETL com tecnologia sem servidor executados em isolamento
- Conceitos do AWS Glue
- Componentes do AWS Glue
- AWS Glue para Spark e AWS Glue para Ray
- Converter esquemas semi-estruturados em esquemas relacionais com o AWS Glue
- Sistemas de tipos do AWS Glue

Trabalhos de ETL com tecnologia sem servidor executados em isolamento

O AWS Glue executa trabalhos de ETL em um ambiente de tecnologia sem servidor com sua escolha de mecanismo, Spark ou Ray. O AWS Glue executa esses trabalhos em recursos virtuais que ele provisiona e gerencia na sua própria conta de serviço.

O AWS Glue é projetado para fazer o seguinte:

- Diferenciar dados de clientes.
- Proteger os dados do cliente em trânsito e em repouso.
- Acesse os dados dos clientes apenas quando necessário, em resposta às solicitações deles, usando credenciais temporárias com escopo ou com o consentimento dos clientes para funções do IAM na conta deles.

Durante o provisionamento de um trabalho de ETL, você fornece fontes de dados de entrada e destinos de dados de saída na sua nuvem virtual privada (VPC). Além disso, você fornece a função do IAM, o ID da VPC, o ID da sub-rede e o grupo de segurança necessários para acessar fontes e destinos de dados. Para cada tupla (ID da conta do cliente, perfil do IAM, ID da sub-rede e grupo de segurança), o AWS Glue cria um novo ambiente, que é isolado na rede, e um nível de gerenciamento de todos os outros ambientes dentro da conta de serviço do AWS Glue.

Você cria e configura recursos do AWS Glue, como catálogos de dados, trabalhos e rastreadores em sua conta AWS. Esses recursos são então associados ao perfil do IAM e às configurações de rede (sub-rede e grupo de segurança) que você especifica durante o processo de criação.

O AWS Glue cria interfaces de rede elástica na sua sub-rede usando endereços IP privados. Os trabalhos usam essas interfaces de rede elástica para acessar as fontes de dados e os destinos de dados. O tráfego de entrada e saída e dentro do ambiente de execução do trabalho é regido pelas políticas de VPC e de rede com uma exceção: as chamadas feitas para as bibliotecas do AWS Glue podem transmitir tráfego para as operações da API do AWS Glue por meio da VPC do AWS Glue. Todas as chamadas de API do AWS Glue são registradas. Dessa forma, os proprietários de dados podem auditar o acesso da API habilitando o AWS CloudTrail, que fornece logs de auditoria à sua conta.

Os ambientes gerenciados pelo AWS Glue que executam seus trabalhos de ETL são protegidos com as mesmas práticas de segurança seguidas por outros serviços da AWS. Para obter uma visão geral das práticas e responsabilidades de segurança compartilhadas, consulte o whitepaper Introduction to AWS Security Processes.

Conceitos do AWS Glue

O AWS Glue é um serviço ETL (Extrair, transformar, carregar) totalmente gerenciado que permite mover dados com facilidade entre diferentes fontes de dados e destinos. Os principais componentes são:

- Catálogo de dados: um armazenamento de metadados que contém definições de tabelas, definições de tarefas e outras informações de controle para seus fluxos de trabalho de ETL.
- Crawlers: programas que se conectam a fontes de dados, inferem esquemas de dados e criam definições de tabelas de metadados no Catálogo de Dados.
- Trabalhos de ETL: a lógica de negócios para extrair dados de fontes, transformá-los usando scripts do Apache Spark e carregá-los em destinos.

- Acionadores: mecanismos para iniciar a execução de trabalhos com base em agendas ou eventos.

O fluxo de trabalho típico envolve:

1. Definir fontes e destinos de dados no Data Catalog.
2. Usar crawlers para preencher o catálogo de dados com metadados de tabela de fontes de dados.
3. Definir tarefas de ETL com scripts de transformação para mover e processar dados.
4. Executar trabalhos sob demanda ou com base em acionadores.
5. Monitorar o desempenho de trabalhos usando painéis.

O diagrama a seguir mostra a arquitetura de um ambiente do AWS Glue.

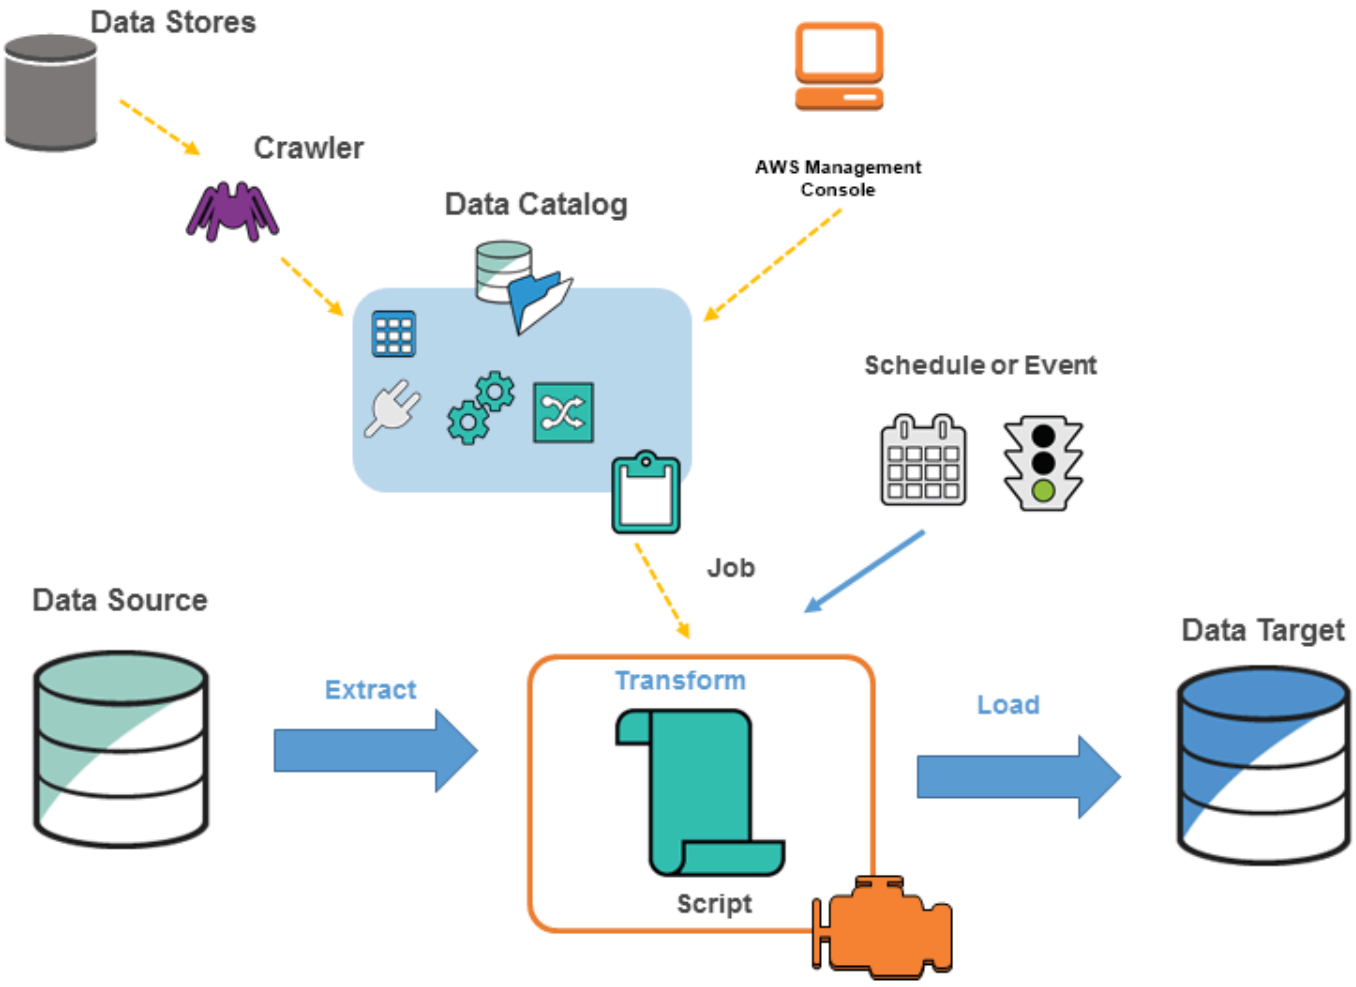

Você define os trabalhos no AWS Glue para atender aos requisitos de extração, transformação e carregamento (ETL) de dados de uma fonte de dados para um destino de dados. Você pode realizar as seguintes ações:

- Para fontes de armazenamento de dados, defina um crawler para preencher seu AWS Glue Data Catalog com definições da tabela de metadados. Você aponta seu crawler para um armazenamento de dados e ele cria definições de tabela no Data Catalog. Para fontes de transmissão, defina manualmente as tabelas do Data Catalog e especifique as propriedades de fluxo de dados.

  Além das definições de tabela, o AWS Glue Data Catalog contém outros metadados necessários para definir trabalhos de ETL. Usar esses metadados ao definir um trabalho de transformação dos seus dados.
- O AWS Glue pode gerar um script para transformar seus dados. Se preferir, você pode fornecer o script no console ou na API do AWS Glue.
- É possível executar trabalhos sob demanda ou configurá-los para iniciar quando um determinado gatilho for acionado. Os gatilhos podem ser programações ou eventos baseados em tempo.

  Quando seu trabalho é executado, um script extrai os dados da sua fonte de dados, transforma esses dados e os carrega no seu destino de dados. O script é executado em um ambiente do Apache Spark no AWS Glue.

> **Important**
>
> As tabelas e os bancos de dados contidos no AWS Glue são objetos no AWS Glue Data Catalog. Eles contêm metadados;, e não dados de um armazenamento físico.

Dados baseados em texto, como CSVs, devem ser codificados em **`UTF-8`** para que o AWS Glue processe-os com êxito. Para obter mais informações, consulte UTF-8 na Wikipédia.

Terminologia do AWS Glue

O AWS Glue depende da interação de vários componentes para criar e gerenciar o fluxo de trabalho de extração, transformação e carregamento (ETL).

AWS Glue Data Catalog

O armazenamento persistente de metadados no AWS Glue. Ele contém definições de tabela, definições de trabalho e outras informações de controle para o gerenciamento do ambiente do AWS Glue. Cada conta da AWS tem um AWS Glue Data Catalog por região.

Classificador

Determina o esquema dos seus dados. O AWS Glue fornece classificadores para tipos de arquivo comuns, como CSV, JSON, XML, AVRO e outros. Ele também fornece classificadores para sistemas comuns de gerenciamento do banco de dados relacional usando uma conexão JDBC. Você pode escrever seu próprio classificador usando um padrão grok ou especificando uma linha de tag em um documento XML.

Conexão

Um objeto do Data Catalog que contém as propriedades necessárias para se conectar a um armazenamento de dados específico.

Crawler

Um programa que se conecta a um armazenamento de dados (origem ou destino), passa por uma lista prioritária de classificadores para determinar o esquema dos dados e cria tabelas de metadados no AWS Glue Data Catalog.

Banco de dados

Um conjunto de definições da tabela associada do Data Catalog organizadas em um grupo lógico.

Datastore, fonte de dados, destino de dados

Um datastore é um repositório para armazenar seus dados persistentemente. Os exemplos incluem buckets do Amazon S3 e bancos de dados relacionais. Uma fonte de dados é um datastore que é usado como entrada para um processo ou transformação. Um destino de dados é um datastore no qual um processo ou transformação grava.

Endpoint de desenvolvimento

Um ambiente que pode ser usado para desenvolver e testar seus scripts de ETL do AWS Glue.

Quadro dinâmico

Uma tabela distribuída que oferece suporte a dados aninhados, como estruturas e matrizes. Cada registro é autodescritivo, projetado para flexibilidade de esquema com dados semiestruturados. Cada registro contém os dados e o esquema que descreve esses dados. Você pode usar quadros dinâmicos e DataFrames do Apache Spark em seus scripts de ETL, bem como converter entre eles. Os quadros dinâmicos fornecem um conjunto de transformações avançadas para limpeza de dados e ETL.

Trabalho

A lógica de negócios que é necessária para executar o trabalho de ETL. Ela é composta por um script de transformação, fonte de dados e destinos de dados. As execuções de trabalho são iniciadas por gatilhos que podem ser programados ou acionados por eventos.

Painel de performance do trabalho

O AWS Glue fornece um painel de execução abrangente para seus trabalhos de ETL. O painel exibe informações sobre execuções de trabalhos a partir de um período de tempo específico.

Interface do bloco de anotações

Uma experiência aprimorada de bloco de anotações com configuração com um clique para facilitar a criação de trabalhos e a exploração de dados. O bloco de anotações e as conexões são configurados automaticamente para você. Você pode usar a interface de caderno baseada na Juypter Notebook para desenvolver, depurar e implantar interativamente scripts e fluxos de trabalho usando a infraestrutura Apache Spark de ETL com tecnologia sem servidor do AWS Glue. Você pode realizar também consultas ad-hoc, análise de dados e visualização (por exemplo, tabelas e gráficos) no ambiente do bloco de anotações.

Script

Código que extrai dados de origens, transforma esses dados e os carrega em destinos. O AWS Glue gera scripts PySpark ou Scala.

Tabela

A definição de metadados que representa seus dados. Não importa se os seus dados estão em um arquivo do Amazon Simple Storage Service (Amazon S3), uma tabela do Amazon Relational Database Service (Amazon RDS) ou em outro conjunto de dados, uma tabela definirá o esquema

dos seus dados. Uma tabela no AWS Glue Data Catalog consiste em nomes de colunas, definições de tipos de dados, informações de partição e outros metadados relacionados a um conjunto de dados de base. O esquema de dados é representado na sua definição da tabela do AWS Glue. Os dados reais permanecem no seu armazenamento de dados original, em um arquivo ou uma tabela de banco de dados relacional. O AWS Glue cataloga seus arquivos e tabelas de banco de dados relacional no AWS Glue Data Catalog. Eles são usados como fontes e destinos quando você cria um trabalho de ETL.

Transformação

A lógica de código que é usada para manipular seus dados em um formato diferente.

Trigger

Inicia um trabalho de ETL. Os gatilhos podem ser definidos com base em um horário/evento programado.

Editor de trabalho visual

O editor visual de tarefas é uma interface gráfica que facilita a criação, a execução e o monitoramento de tarefas de extração, transformação e carregamento (ETL) em AWS Glue. Você pode compor visualmente fluxos de trabalho de transformação de dados e executá-los perfeitamente no mecanismo de ETL com tecnologia sem servidor no Apache Spark do AWS Glue e inspecionar o esquema e os resultados de dados em cada etapa do trabalho.

Operador

Com o AWS Glue, você só paga pelo tempo que seu trabalho de ETL leva para ser executado. Não há recursos para gerenciar, nenhum custo inicial e você não será cobrado pelo tempo de inicialização ou desligamento. É cobrada uma taxa por hora com base no número de unidades de processamento de dados (ou DPUs) usadas para executar seu trabalho de ETL. Uma única unidade de processamento de dados (DPU) também é chamada de operador. O AWS Glue vem com três tipos de operador para ajudá-lo a selecionar a configuração que atenda aos requisitos de latência e custo do trabalho. Os operadores vêm nas configurações Standard (Padrão), G.1X, G.2X e G.025X

Componentes do AWS Glue

O AWS Glue fornece um console e operações de API para configurar e gerenciar sua workload de extração, transformação e carregamento (ETL). Você pode usar operações de API por meio de

vários SDKs específicos de linguagem e da AWS Command Line Interface (AWS CLI). Para obter informações sobre como usar a AWS CLI, consulte a Referência do comando da AWS CLI.

O AWS Glue usa o AWS Glue Data Catalog para armazenar metadados relacionado às fontes de dados, transformações e destinos. O Data Catalog é uma substituição inicial do Apache Hive Metastore. O AWS Glue Jobs system fornece uma infraestrutura gerenciada para definir, programar e executar operações de ETL nos seus dados. Para obter mais informações sobre a API do AWS Glue, consulte API AWS Glue.

Console do AWS Glue

O console do AWS Glue é usado para definir e orquestrar seu fluxo de trabalho de ETL. O console chama várias operações de API no AWS Glue Data Catalog e no AWS Glue Jobs system para executar as seguintes tarefas:

- Definir objetos do AWS Glue, como trabalhos, tabelas, crawlers e conexões.
- Programas quando os crawlers serão executados.
- Definir eventos ou programações para gatilhos de trabalho.
- Pesquisar e filtrar listas de objetos do AWS Glue.
- Editar scripts de transformação.

AWS Glue Data Catalog

O AWS Glue Data Catalog é o armazenamento de metadados técnicos persistentes na Cloud AWS.

Cada conta da AWS tem um AWS Glue Data Catalog por região da AWS. Cada Data Catalog é uma coleção altamente escalável de tabelas organizadas em bancos de dados. Uma tabela é uma representação de metadados de uma coleção de dados estruturados ou semiestruturados armazenados em fontes como Amazon RDS, Apache Hadoop Distributed File System, Amazon OpenSearch Service e outros. O AWS Glue Data Catalog fornece um repositório uniforme onde sistemas diferentes podem armazenar e encontrar metadados para acompanhar os dados em silos de dados. Você pode usar os metadados para consultar e transformar esses dados de maneira consistente em uma ampla variedade de aplicativos.

Você usa o Catálogo de Dados junto com as políticas AWS Identity and Access Management e o Lake Formation para controlar o acesso às tabelas e bancos de dados. Ao fazer isso, você pode permitir que diferentes grupos em sua empresa publiquem dados com segurança em toda a organização, protegendo informações confidenciais de maneira altamente granular.

O Data Catalog, juntamente com CloudTrail e Lake Formation, também fornece recursos abrangentes de auditoria e governança, com rastreamento de alterações de esquema e controles de acesso a dados. Isso ajuda a garantir que os dados não sejam modificados inadequadamente ou compartilhados inadvertidamente.

Para obter informações sobre como proteger e auditar o AWS Glue Data Catalog, consulte:

- AWS Lake Formation: para obter mais informações, consulte O que é o AWS Lake Formation? no Guia do desenvolvedor do AWS Lake Formation.
- CloudTrail — Para obter mais informações, consulte O que é CloudTrail? no Guia do usuário do AWS CloudTrail.

A seguir, estão outros produtos da AWS e projetos de código aberto que usam o AWS Glue Data Catalog:

- Amazon Athena: para obter mais informações, consulte Noções básicas de tabelas, bancos de dados e o Data Catalog no Manual do usuário do Amazon Athena.
- Amazon Redshift Spectrum: para obter mais informações, consulte Usar o Amazon Redshift Spectrum para consultar dados externos no Guia do desenvolvedor de banco de dados do Amazon Redshift.
- Amazon EMR: para obter mais informações, consulte Usar políticas com base em recursos para acesso do Amazon EMR ao AWS Glue Data Catalog no Guia de gerenciamento do Amazon EMR.
- Cliente do AWS Glue Data Catalog para o Apache Hive Metastore: para obter mais informações sobre esse projeto do GitHub, consulte Cliente do AWS Glue Data Catalog para o Apache Hive Metastore.

Crawlers e classificadores do AWS Glue

Com o AWS Glue, você também pode configurar os crawlers capazes de verificar dados em todos os tipos de repositórios, classificá-los, extrair informações de esquema deles e armazenar os metadados automaticamente no AWS Glue Data Catalog. O AWS Glue Data Catalog pode ser usado para guiar operações de ETL.

Para obter mais informações sobre como configurar crawlers e classificadores, consulte Usar crawlers para preencher o catálogo de dados . Para obter mais informações sobre como programar crawlers e classificadores usando a API do AWS Glue, consulte API de crawlers e classificadores.

Operações de ETL no AWS Glue

Ao usar os metadados no Data Catalog, o AWS Glue pode gerar automaticamente os scripts Scala ou PySpark (API do Python para Apache Spark) com extensões do AWS Glue que podem ser usadas e modificadas para executar várias operações de ETL. Por exemplo, você pode extrair, limpar e transformar dados brutos e, em seguida, armazenar o resultado em um repositório diferente onde ele poderá ser consultado e analisado. Esse script pode converter um arquivo CSV em um formulário relacional e salvá-lo no Amazon Redshift.

Para obter mais informações sobre como usar os recursos de ETL do AWS Glue, consulte Programar scripts do Spark.

ETL de streaming no AWS Glue

O AWS Glue permite executar operações de ETL em dados de transmissão usando trabalhos em execução contínua. O ETL de transmissão do AWS Glue é criado no mecanismo Apache Spark Structured Streaming e pode ingerir transmissões do Amazon Kinesis Data Streams, do Apache Kafka e do Amazon Managed Streaming for Apache Kafka (Amazon MSK). O ETL de transmissão pode limpar e transformar dados de transmissão e carregá-los no Amazon S3 ou em armazenamentos de dados JDBC. Use o ETL de streaming no AWS Glue para processar dados de eventos, como streams de IoT, streams de cliques e logs de rede.

Se você conhecer o esquema da fonte dos dados de transmissão, poderá especificá-lo em uma tabela do Data Catalog. Caso contrário, você pode habilitar a detecção de esquemas no trabalho de ETL de transmissão. Em seguida, o trabalho determina automaticamente o esquema dos dados recebidos.

O trabalho de ETL de transmissão pode usar tanto as transformações nativas do AWS Glue quanto as transformações nativas do Apache Spark Structured Streaming. Para obter mais informações, consulte Operations on streaming DataFrames/Datasets (Operações em transmissão de dataframes/conjuntos de dados) no site do Apache Spark.

Para ter mais informações, consulte the section called “Trabalhos de transmissão de ETL”.

O sistema de trabalhos do AWS Glue

O AWS Glue Jobs system fornece infraestrutura gerenciada para orquestrar seu fluxo de trabalho de ETL. Você pode criar trabalhos no AWS Glue que automatizam os scripts usados para extrair,

transformar e transferir dados para diferentes locais. Os trabalhos podem ser programados e encadeados, ou podem ser acionados por eventos como a chegada de novos dados.

Para obter mais informações sobre como usar o AWS Glue Jobs system, consulte Como monitorar o AWS Glue. Para obter informações sobre como programar usando a API do AWS Glue Jobs system, consulte API de trabalhos.

Componentes do Visual ETL

O AWS Glue permite criar tarefas de ETL por meio de uma tela visual que você pode manipular.

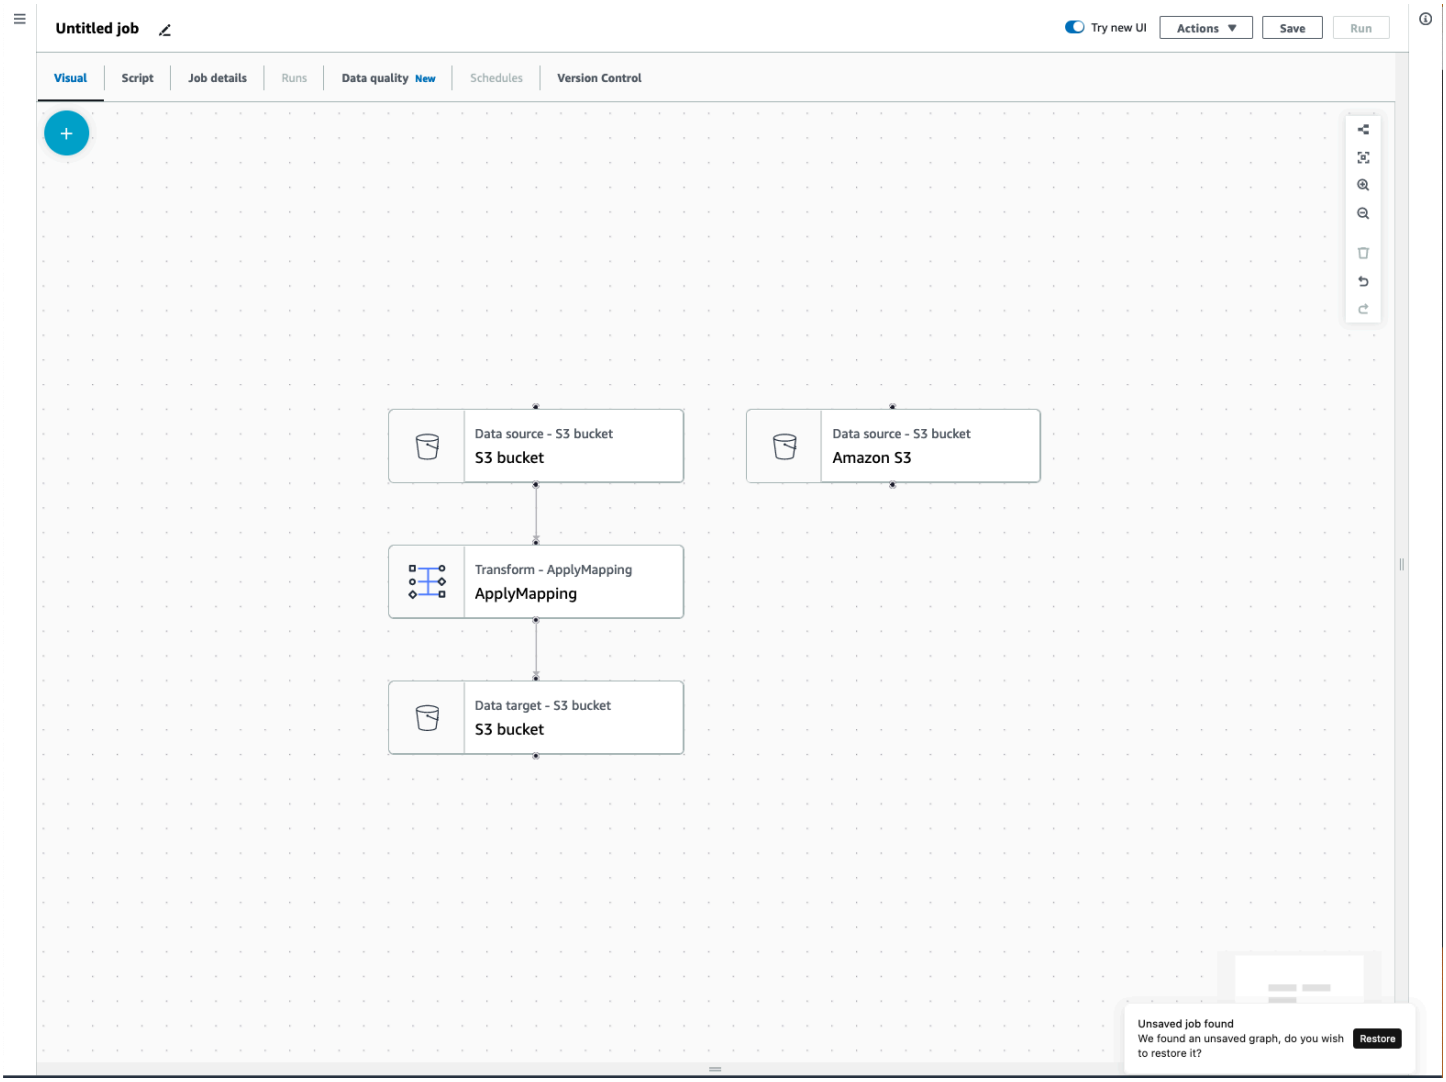

Menu de trabalhos de ETL

As opções do menu na parte superior da tela permitem que você acesse as várias visualizações e detalhes de configuração sobre o seu trabalho.

- Visual: a tela do editor de trabalhos visual. Aqui, você pode adicionar nós para criar um trabalho.
- Script: a representação do script da sua tarefa de ETL. O AWS Glue gera o script com base na representação visual da sua tarefa. Você também pode editar seu script ou baixá-lo.

> **Note**
>
> Se você optar por editar o script, a experiência de criação do trabalho será permanentemente convertida em um modo somente de script. Depois disso, você não poderá mais usar o editor visual para editar o trabalho. Você deve adicionar todas as fontes, transformações e destinos de trabalhos, e fazer todas as alterações necessárias com o editor visual antes de escolher editar o script.

- Detalhes do trabalho: a guia Detalhes do trabalho permite que você configure seu trabalho definindo as propriedades do trabalho. Há propriedades básicas, como nome e descrição da sua tarefa, perfil do IAM, tipo de tarefa, versão do AWS Glue, idioma, tipo de operador, número de operadores, marcador de tarefa, execução flexível, número de retiradas e tempo limite de tarefa, e há propriedades avançadas, como conexões, bibliotecas, parâmetros da tarefa e tags.
- Execuções: depois que seu trabalho for executado, essa guia poderá ser acessada para visualizar suas execuções de trabalhos anteriores.
- Qualidade dos dados: qualidade dos dados avalia e monitora a qualidade dos dados. Você pode aprender mais sobre como usar a qualidade de dados nessa guia e adicionar uma transformação de qualidade de dados ao seu trabalho.
- Agendamentos: os trabalhos que você agendou aparecem nessa guia. Se não houver agendamentos anexados a esse trabalho, essa guia não estará acessível.
- Controle de versão: você pode usar o Git com seu trabalho configurando seu trabalho em um repositório Git.

Painéis do Visual ETL

Quando você trabalha na tela, vários painéis estão disponíveis para ajudá-lo a configurar seus nós ou ajudá-lo a visualizar seus dados e visualizar o esquema de saída.

- Propriedades: o painel Propriedades aparece quando você escolhe um nó na tela.
- Visualização de dados: painel Visualização de dados fornece uma visualização prévia da saída de dados para que você possa tomar decisões antes de executar seu trabalho e examinar sua saída.

- Esquema de saída: a guia Esquema de saída permite que você visualize e edite o esquema dos seus nós de transformação.

Redimensionar painéis

Você pode redimensionar o painel Propriedades no lado direito da tela e o painel inferior, que contém as guias Visualização de dados e Esquema de saída, clicando na borda do painel e arrastando-a para a esquerda e para a direita ou para cima e para baixo.

- Painel de propriedades: redimensione o painel de propriedades clicando e arrastando a borda da tela no lado direito da tela e arrastando-a para a esquerda para expandir sua largura. Por padrão, o painel é reduzido e, quando um nó é selecionado, o painel de propriedades se abre em seu tamanho padrão.
- Visualização de dados e painel Esquema de saída: redimensione o painel inferior clicando e arrastando a borda inferior na parte inferior da tela e arraste-a para cima para expandir sua altura. Por padrão, o painel é reduzido e, quando um nó é selecionado, o painel de inferior se abre em seu tamanho padrão.

Tela Trabalho

Você pode adicionar, remover e mover/reordenar nós diretamente na tela do Visual ETL. Pense nisso como seu espaço de trabalho para criar um trabalho de ETL totalmente funcional que começa com uma fonte de dados e pode terminar com um destino de dados.

Ao trabalhar com nós na tela, você tem uma barra de ferramentas que pode ajudá-lo a ampliar e reduzir, remover nós, criar ou editar conexões entre nós, alterar a orientação do fluxo de trabalho e desfazer ou refazer uma ação.

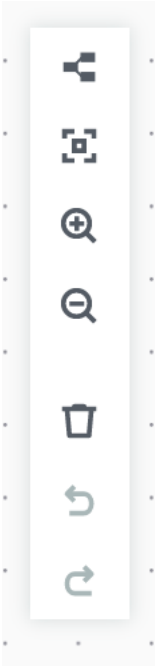

A barra de ferramentas flutuante está ancorada no canto superior direito da tela e contém várias imagens que realizam ações:

- Ícone de layout: o primeiro ícone na barra de ferramentas é o ícone de layout. Por padrão, a direção dos trabalhos visuais é de cima para baixo. Ele reorganiza a direção do seu trabalho visual organizando os nós horizontalmente da esquerda para a direita. Clicar novamente no ícone do layout altera a direção de cima para baixo.
- Ícone de recentralização: o ícone de recentralização altera a visualização da tela ao centralizá-la. Você pode usar isso com trabalhos grandes para voltar à posição central.
- Ícone de ampliação de zoom: o ícone de ampliação de zoom aumenta o tamanho dos nós na tela.
- Ícone de redução de zoom: o ícone de redução de zoom reduz o tamanho dos nós na tela.
- Ícone da lixeira: o ícone de lixeira remove um nó de trabalho visual. Você deve primeiro selecionar um nó.
- Ícone de desfazer: o ícone de desfazer reverte a última ação realizada no trabalho visual.
- Ícone de refazer: o ícone de refazer repete a última ação realizada no trabalho visual.

Usar o minimapa

Painel de recursos

O painel de recursos contém todas as fontes de dados, ações de transformação e conexões disponíveis para você. Abra o painel de recursos na tela clicando no ícone “+”. Isso abrirá o painel de recursos.

Para fechar o painel de recursos, clique no X no canto superior direito do painel de recursos. Isso ocultará o painel até que você esteja pronto para abri-lo novamente.

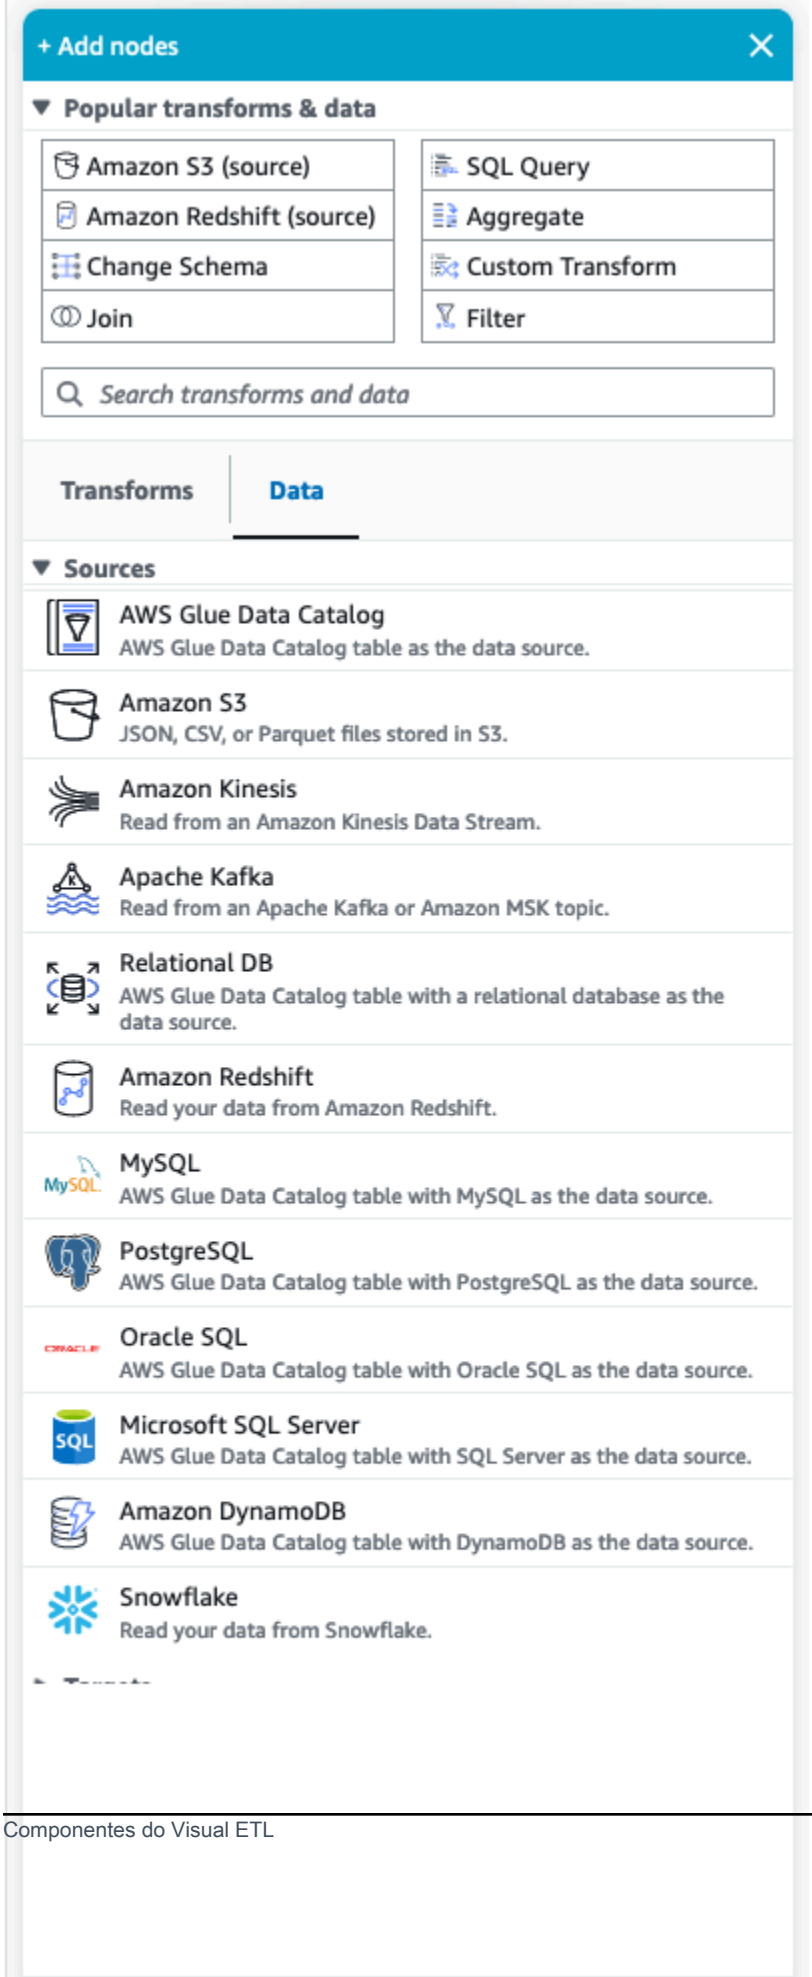
+ Add nodes
Popular transforms & data
Amazon S3 (source)
Amazon Redshift (source)
Change Schema
Join
SQL Query
Aggregate
Custom Transform
Filter
Search transforms and data
Transforms
Data
Sources
AWS Glue Data Catalog
AWS Glue Data Catalog table as the data source.
Amazon S3
JSON, CSV, or Parquet files 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.

Transformações e dados populares

Na parte superior do painel, há uma coleção de transformações e dados populares. Esses nós costumam ser usados no AWS Glue. Escolha um para adicioná-lo à tela. Você também pode ocultar as Transformações e dados populares clicando no triângulo ao lado do título Transformações e dados populares.

Abaixo da seção Transformações e dados populares, você pode pesquisar transformações e nós de fonte de dados. Os resultados aparecem à medida que você digita. Quanto mais letras você adicionar à sua consulta de pesquisa, menor ficará a lista de resultados. Os resultados da pesquisa são preenchidos a partir do nome e/ou descrição do nó. Escolha o nó para adicioná-lo à sua tela.

Transformações e dados

Há duas guias que organizam os nós em Transformações e Dados.

Transformações: quando você escolhe a guia Transformações, todas as transformações disponíveis podem ser selecionadas. Escolha uma transformação para adicioná-la à tela. Você também pode escolher Adicionar transformação na parte inferior da lista Transformações, o que abrirá uma nova página na documentação para criar Transformações visuais personalizadas. Seguir as etapas permitirá que você crie suas próprias transformações. Suas transformações aparecerão na lista de transformações disponíveis.

Dados: a guia de dados contém todos os nós de Fontes e Destinos. Você pode ocultar as Origens e os Destinos clicando no triângulo ao lado do título Origens ou Destinos. Você pode exibir as Origens e os Destinos clicando novamente no triângulo. Escolha um nó de origem ou de destino para adicioná-lo à tela. Você também pode escolher Gerenciar conexões para adicionar uma nova conexão. Isso abrirá a página Conectores no console.

AWS Glue para Spark e AWS Glue para Ray

No AWS Glue on Apache Spark (AWS Glue ETL), você pode usar o PySpark para escrever código do Python para lidar com dados em grande escala. O Spark é uma solução conhecida para esse problema, mas engenheiros de dados com experiência focada em Python podem achar que a transição não é intuitiva. O modelo DataFrame do Spark não é perfeitamente "phytônico", o que reflete a linguagem Scala e o runtime Java em que ele se baseia.

No AWS Glue, você pode usar trabalhos de shell do Python para executar integrações de dados nativos do Python. Esses trabalhos são executados em uma única instância do Amazon EC2 e são

limitados pela capacidade dessa instância. Isso restringe o throughput dos dados que você pode processar e sua manutenção se torna cara ao lidar com big data.

O AWS Glue para Ray permite que você aumente verticalmente a escala das workloads do Python sem investimentos substanciais para aprender o Spark. Você pode aproveitar certos cenários nos quais o Ray tem uma performance melhor. Oferecendo a você uma escolha, é possível usar os pontos fortes tanto do Spark quanto do Ray.

O AWS Glue ETL e o AWS Glue para Ray são diferentes internamente, portanto, são compatíveis com atributos diferentes. Verifique documentação para determinas quais são as configurações compatíveis.

O que é AWS Glue para Ray?

O Ray é uma estrutura de computação distribuída de código aberto que você pode usar para aumentar verticalmente a escala das workloads, com foco no Python. Para obter mais informações sobre o Ray, consulte o site do Ray. AWS Glue Os trabalhos e as sessões interativas do Ray permitem que você use o Ray no AWS Glue.

Você pode usar o AWS Glue para Ray para escrever scripts do Python para cálculos que serão executados em paralelo em várias máquinas. Em trabalhos e sessões interativas do Ray, você pode usar bibliotecas conhecidas do Python, como a pandas, para facilitar escrita e execução das workloads. Para obter mais informações sobre os conjuntos de dados do Ray, consulte Conjuntos de dados do Ray na documentação do Ray. Para obter mais informações sobre o pandas, consulte o site do pandas.

Ao usar o AWS Glue para Ray, você pode executar os fluxos de trabalho de pandas em big data em escala corporativa, com apenas algumas linhas de código. Você pode criar um trabalho do Ray no console do AWS Glue ou no AWS SDK. Você também pode abrir uma sessão interativa do AWS Glue para executar o código em um ambiente sem servidor do Ray. Trabalhos visuais no AWS Glue Studio ainda não são compatíveis.

Os trabalhos do AWS Glue para Ray permitem que você execute um script de acordo com uma agenda ou em resposta a um evento do Amazon EventBridge. As trabalhos armazenam informações de log e estatísticas de monitoramento no CloudWatch, as quais permitem que você entenda a integridade e a confiabilidade do seu script. Para obter mais informações sobre como usar o sistema de trabalhos do AWS Glue, consulte the section called “Trabalhar com trabalhos do Ray”.

O Ray automatiza o trabalho de escalação de código do Python distribuindo o processamento por um cluster de máquinas que ele reconfigura em tempo real, com base na carga. Isso pode resultar em

uma melhor performance, em termos financeiros, para determinadas workloads. Com os trabalhos do Ray, incorporamos nativamente auto scaling ao modelo de trabalho do AWS Glue, para que você possa aproveitar totalmente esse recurso. Os trabalhos do Ray são executados no AWS Graviton, resultando em uma performance geral superior em termos de preço.

Além da economia de custos, você pode usar o auto scaling nativo para executar workloads do Ray sem investir tempo em manutenção, ajuste e administração de clusters. Você pode usar bibliotecas conhecidas de código aberto, prontas para uso, como pandas e AWS SDK for pandas. Isso melhora a velocidade de iteração enquanto você está desenvolvendo no AWS Glue para Ray. Ao usar o AWS Glue para Ray, você poderá desenvolver e executar rapidamente workloads de integração de dados com eficiência de custos.

Converter esquemas semi-estruturados em esquemas relacionais com o AWS Glue

É comum querer converter dados semiestruturados em tabelas relacionais. Conceitualmente, você está nivelando um esquema hierárquico para um esquema relacional. O AWS Glue pode realizar essa conversão para você rapidamente.

Os dados semiestruturados normalmente contêm marcação para identificar entidades nos dados. Ele pode ter estruturas de dados aninhadas sem um esquema fixo. Para obter mais informações sobre dados semiestruturados, consulte Dados semiestruturados na Wikipédia.

Os dados relacionais são representados por tabelas que consistem em linhas e colunas. As relações entre tabelas podem ser representadas por uma relação de chave primária (PK) para chave externa (FK). Para obter mais informações, consulte Banco de dados relacional na Wikipédia.

O AWS Glue usa crawlers para inferir esquemas para dados semiestruturados. Em seguida, ele transforma os dados em um esquema relacional usando um trabalho de ETL (extração, transformação e carregamento). Por exemplo, você pode desejar analisar dados JSON desde os arquivos de origem do Amazon Simple Storage Service (Amazon S3) até as tabelas do Amazon Relational Database Service (Amazon RDS). Saber como o AWS Glue lida com as diferenças entre esquemas pode ajudar você a entender o processo de transformação.

Este diagrama mostra como o AWS Glue transforma um esquema semiestruturado em um esquema relacional.

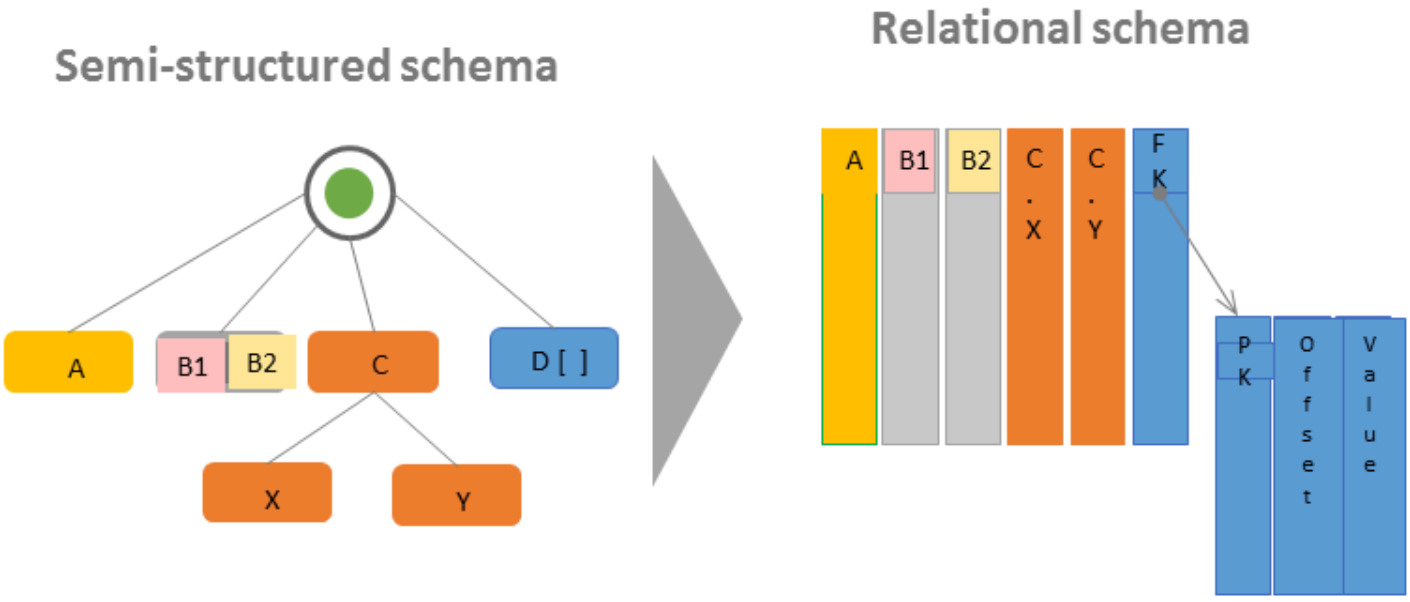

O diagrama ilustra o seguinte:

- O valor único `A` converte-se diretamente em uma coluna relacional.
- O par de valores `B1` e `B2` se convertem em duas colunas relacionais.
- A estrutura `C`, com `X` e `Y` filhos, converte-se em duas colunas relacionais.
- A matriz `D[]` se converte em uma coluna relacional com uma chave externa (FK) que aponta para outra tabela relacional. Junto com uma chave primária (PK), a segunda tabela relacional apresenta colunas que contêm o deslocamento e o valor dos itens na matriz.

Sistemas de tipos do AWS Glue

O AWS Glue usa sistemas de vários tipos para fornecer uma interface versátil em sistemas de dados que armazenam dados de maneiras muito diferentes. Este documento fornece esclarecimentos sobre sistemas do tipo AWS Glue e padrões de dados.

Tipos de AWS Glue Data Catalog

O Data Catalog é um registro de tabelas e campos armazenados em vários sistemas de dados, um metastore. Quando componentes do AWS Glue, como crawlers do AWS Glue e trabalhos do AWS Glue com Spark, gravam no Data Catalog, eles fazem isso com um sistema de tipos interno para rastrear os tipos de campos. Esses valores são mostrados na coluna Tipo de dados do esquema de tabela no console do AWS Glue. Esse sistema de tipos é baseado no sistema de tipos do Apache Hive. Para obter mais informações sobre o sistema de tipos do Apache Hive, consulte Tipos na wiki do Apache Hive. Para obter mais informações sobre tipos específicos e suporte, exemplos são fornecidos no console do AWS Glue, como parte do Schema Builder.

Validação, compatibilidade e outros usos

O Data Catalog não valida tipos gravados em campos de tipo. Quando os componentes do AWS Glue leem e gravam no Data Catalog, eles são compatíveis entre si. AWS Os componentes de Glue também visam preservar um alto grau de compatibilidade com os tipos do Hive. Porém, os componentes do AWS Glue não garantem a compatibilidade com todos os tipos do Hive. Isso permite a interoperabilidade com ferramentas como o Athena DDL ao trabalhar com tabelas no Data Catalog.

Como o Data Catalog não valida tipos, outros serviços podem usar o Data Catalog para rastrear tipos usando sistemas estritamente conformes com o sistema do tipos do Hive ou qualquer outro sistema.

Tipos em scripts do AWS Glue com Spark

Quando um script do AWS Glue with Spark interpreta ou transforma um conjunto de dados, fornecemos o `DynamicFrame`, uma representação na memória do conjunto de dados conforme ele é usado em seu script. O objetivo de um `DynamicFrame` é semelhante ao do `DataFrame` do Spark: ele modela o conjunto de dados para que o Spark possa agendar e executar transformações nos dados. Garantimos que a representação de tipo do `DynamicFrame` seja intercompatível com o `DataFrame`, fornecendo os métodos `toDF` e `fromDF`.

Se as informações de tipo puderem ser inferidas ou fornecidas a um `DataFrame`, elas poderão ser inferidas ou fornecidas a um `DynamicFrame`, a menos documentado o contrário. Quando fornecemos leitores ou gravadores otimizados para formatos de dados específicos, se o Spark puder ler ou gravar seus dados, nossos leitores e gravadores fornecidos poderão fazê-lo, sujeito às limitações documentadas. Para obter mais informações sobre leitores e gravadores, consulte the section called “Opções de formato de dados”.

O tipo Escolha

Os `DynamicFrames` fornecem um mecanismo para modelar campos em um conjunto de dados cujo valor pode ter tipos inconsistentes em disco entre as linhas. Por exemplo, um campo pode conter um número armazenado como uma string em determinadas linhas e um número inteiro em outras. Esse mecanismo é um tipo de memória denominado `Choice`. Fornecemos transformações, como o método `ResolveChoice`, para resolver as colunas de Escolha em um tipo concreto. O ETL do AWS GLue não gravará o tipo Escolha no Data Catalog durante o curso normal da operação; os tipos Escolha só existem no contexto dos modelos de memória DynamicFrame de conjuntos de dados. Para obter um exemplo do uso do tipo Escolha, consulte the section called “Exemplo de preparo de dados”.

Tipos de crawler do AWS Glue

Os crawlers visam produzir um esquema consistente e utilizável para seu conjunto de dados e, em seguida, armazená-lo no Data Catalog para uso em outros componentes do AWS Glue e do Athena. Os crawlers lidam com os tipos conforme descrito na seção anterior sobre o Data Catalog, the section called “Tipos de AWS Glue Data Catalog”. Para produzir cenários utilizáveis do tipo "Escolha", em que uma coluna contém valores de dois ou mais tipos, os crawlers criam um tipo de `struct` que modela os tipos possíveis.

Conceitos básicos do AWS Glue

As seções a seguir fornecem informações sobre como configurar o AWS Glue. Nem todas as seções de configuração são necessárias para começar a usar o AWS Glue. Você pode usar as instruções, conforme necessário, para configurar permissões do IAM, criptografia e DNS (se estiver usando um ambiente de VPC para acessar armazenamentos de dados ou se estiver usando sessões interativas).

Tópicos

- Visão geral do uso do AWS Glue
- Configurar permissões do IAM para o AWS Glue
- Configurar perfis de uso do AWS Glue
- Conceitos básicos da AWS Glue Data Catalog
- Configurar o acesso de rede aos armazenamentos de dados
- Configurar criptografia no AWS Glue
- Configurar redes para desenvolvimento para o AWS Glue

Visão geral do uso do AWS Glue

Com o AWS Glue, você armazena metadados no AWS Glue Data Catalog. Você usa esses metadados para orquestrar trabalhos de ETL que transformam fontes de dados e carregam o data warehouse ou o data lake. As etapas a seguir descrevem o fluxo de trabalho geral e algumas das opções que você faz ao trabalhar com o AWS Glue.

> **Note**
>
> É possível realizar as etapas a seguir ou criar um fluxo de trabalho que execute automaticamente as etapas 1 a 3. Para ter mais informações, consulte the section called “Realizar atividades de ETL complexas usando esquemas e fluxos de trabalho”.

1. Preencher o AWS Glue Data Catalog com definições de tabela.

   No console, para armazenamentos de dados persistentes, é possível adicionar um crawler para preencher o AWS Glue Data Catalog. Você pode iniciar o assistente Add crawler na lista de

tabelas ou na lista de crawlers. Você escolhe um ou mais armazenamentos de dados para o seu crawler acessar. Você também pode criar uma programação para determinar a frequência de execução do seu crawler. Para streams de dados, é possível criar manualmente a definição de tabela e definir propriedades de stream.

Se preferir, você pode fornecer um classificador personalizado que infere o esquema dos seus dados. Você pode criar classificadores personalizados usando um padrão grok, No entanto, o AWS Glue fornece classificadores integrados que são usados automaticamente pelos crawlers quando um classificador personalizado não reconhece seus dados. Ao definir um crawler, você não precisa selecionar um classificador. Para obter mais informações sobre classificadores no AWS Glue, consulte Definir e gerenciar classificadores.

O crawling de alguns tipos de armazenamento de dados requer uma conexão que forneça informações de autenticação e local. Se necessário, você pode criar uma conexão que fornece essas informações necessárias no console do AWS Glue.

O crawler lê seu armazenamento de dados e cria definições de dados e tabelas nomeadas no AWS Glue Data Catalog. Estas tabelas são organizadas em um banco de dados de sua escolha. Você também pode preencher o Data Catalog com tabelas criadas manualmente. Com esse método, você fornece o esquema e outros metadados para criar definições de tabela no Data Catalog. Como esse método pode ser um pouco entediante e propenso a erros, muitas vezes é melhor deixar que o crawler crie as definições da tabela.

Para obter mais informações sobre como preencher o AWS Glue Data Catalog com definições de tabela, consulte Criar tabelas.

2. Defina um trabalho que descreva a transformação de dados de origem para dados de destino.

   Geralmente, para criar um trabalho, você precisa fazer as seguintes escolhas:

   - Escolha uma tabela do AWS Glue Data Catalog para ser a origem do trabalho. Seu trabalho usa essa definição de tabela para acessar a fonte de dados e interpretar o formato dos dados.
   - Escolha uma tabela ou um local do AWS Glue Data Catalog para ser o destino do trabalho. Seu trabalho usa essas informações para acessar seu armazenamento de dados.
   - Instrua o AWS Glue a gerar um script para transformar sua origem em destino. O AWS Glue gera o código para chamar transformações integradas a fim de converter dados de seu esquema de origem no formato do esquema de destino. Essas transformações executam operações como cópia de dados, renomeação de colunas e filtragem de dados para transformar os dados conforme necessário. Você pode modificar esse script no console do AWS Glue.

Para obter mais informações sobre como definir trabalhos no AWS Glue, consulte Criar trabalhos ETL visuais com o AWS Glue Studio.

3. Execute seu trabalho para transformar seus dados.

   Você pode executar seu trabalho sob demanda, ou iniciá-lo com base em um destes tipos de gatilho:

   - Um gatilho baseado em uma programação cron.
   - Um gatilho baseado em eventos. Por exemplo, a conclusão bem-sucedida de outro trabalho pode iniciar um trabalho do AWS Glue.
   - Um gatilho que inicia um trabalho sob demanda.

   Para obter mais informações sobre gatilhos no AWS Glue, consulte Iniciar trabalhos e crawlers usando acionadores.

4. Monitore seus crawlers programados e trabalhos acionados.

   Use o console do AWS Glue para visualizar o seguinte:

   - Detalhes e erros de execução do trabalho.
   - Detalhes e erros de execução do crawler.
   - Todas as notificações sobre atividades do AWS Glue

   Para obter mais informações sobre como monitorar crawlers e trabalhos no AWS Glue, consulte Como monitorar o AWS Glue.

Configurar permissões do IAM para o AWS Glue

As instruções neste tópico ajudam você a configurar rapidamente as permissões AWS Identity and Access Management (IAM) para o AWS Glue. Você concluirá as seguintes tarefas:

- Conceda às suas identidades do IAM acesso aos recursos do AWS Glue.
- Crie um perfil de serviço para executar trabalhos, acessar dados e executar tarefas de qualidade do AWS Glue Data Quality.

Para obter instruções detalhadas que você pode usar para personalizar as permissões do IAM para o AWS Glue, consulte Configurar permissões do KMS para o AWS Glue.

Para configurar as permissões do IAM para AWS Glue no AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Conceitos básicos.
3. Em Preparar sua conta para o AWS Glue, escolha Configurar permissões do IAM.
4. Escolha as identidades do IAM (perfis ou usuários) às quais você deseja conceder permissões do AWS Glue. O AWS Glue anexa a política gerenciada `AWSGlueConsoleFullAccess` a essas identidades. Você pode pular essa etapa se quiser definir essas permissões manualmente ou se quiser definir apenas um perfil de serviço padrão.
5. Escolha Próximo.
6. Escolha o nível de acesso ao Amazon S3 de que os perfis e usuários precisam. As opções escolhidas nessa etapa são aplicadas a todas as identidades selecionadas.

   a. Em Escolher locais do S3, escolha os locais do Amazon S3 aos quais você deseja conceder acesso.

   b. Em seguida, selecione se as identidades devem ter acesso de Somente leitura (recomendado) ou de Leitura e gravação aos locais que você selecionou anteriormente. O AWS Glue adiciona políticas de permissões às identidades com base na combinação dos locais e das permissões de leitura ou gravação que você seleciona.

      A tabela a seguir mostra as permissões que o AWS Glue anexa para acesso ao Amazon S3.

Se você escolher...	O AWS Glue anexará...
Nenhuma alteração	Nenhuma alteração. O AWS Glue não fará nenhuma alteração nas permissões da sua identidade.
Conceder acesso a locais específicos do Amazon S3 (somente leitura)	A política gerenciada pelo cliente, `AWSGlueConsole-S3-read-only-policy` , concede acesso a locais específicos do Amazon S3 com permissões somente leitura. `{`

Se você escolher...	O AWS Glue anexará...

	{
	"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:Reso
	urceAccount":"0000000000"
	}
	}
	}
	]
	}

Se você escolher...	O AWS Glue anexará...
Conceder acesso a locais específicos do Amazon S3 (leitura e gravação)	O `AWSGlueConsole-S3-read-and-write-policy` concede acesso a locais específicos do Amazon S3 com permissões de leitura e gravação. `{ "Version": "2012-10-17", "Statement": [{ "Effect": "Allow", "Action": ["s3:GetObject", "s3:PutObject"], "Resource": ["arn:aws:s3:::aes-siem-00000000000-log/*", "arn:aws:s3:::aes-siem-00000000000-snapshot/*", "arn:aws:s3:::aes-siem-00000000000-log", "arn:aws:s3:::aes-siem-00000000000-snapshot"], "Condition": { "StringEquals": { "aws:ResourceAccount":"00000000000" } } }] }`

7. Escolha Próximo.

8. Escolha perfil de serviço padrão do AWS Glue para sua conta. Um perfil de serviço é um perfil do IAM que é o AWS Glue usada para acessar recursos em outros serviços da AWS em seu nome. Para obter mais informações, consulte Perfis de serviço do AWS Glue.

   - Ao escolher perfil de serviço padrão do AWS Glue, o AWS Glue cria um novo perfil do IAM na sua Conta da AWS denominado `AWSGlueServiceRole` com as seguintes políticas gerenciadas anexadas. Se sua conta já tiver um perfil do IAM denomiado `AWSGlueServiceRole`, o AWS Glue anexa essas políticas ao perfil existente.
     - AWSGlueServiceRole: esta política gerenciada é necessária para que o AWS Glue possa acessar e gerenciar recursos em seu nome. Ela permite ao AWS Glue criar, atualizar e excluir vários recursos, como AWS Glue trabalhos, crawlers e conexões. Também concede permissões ao AWS Glue para acessar logs Amazon CloudWatch para fins de registro em log. Para começar, recomendamos usar essa política para aprender a usar o AWS Glue. À medida que você se familiarizar com o AWS Glue, poderá criar políticas que permitem ajustar o acesso aos recursos conforme necessário.
     - AWSGlueConsoleFullAccess: esta política gerenciada concede acesso total ao serviço do AWS Glue por meio do AWS Management Console. Esta política concede permissões para realizar qualquer operação dentro do AWS Glue, permitindo que você crie, modifique e exclua qualquer recurso do AWS Glue conforme necessário. No entanto, é importante observar que ela não concede permissões para acessar os armazenamentos de dados subjacentes ou outros serviços da AWS que possam estar envolvidos no processo de ETL. Devido ao amplo escopo das permissões concedidas pela política do `AWSGlueConsoleFullAccess`, ela deve ser atribuída com cautela e seguindo o princípio do privilégio mínimo. Geralmente, é recomendável criar e usar políticas mais granulares adaptadas a casos de uso e requisitos específicos sempre que possível.
     - AWSGlueConsole-S3-read-only-policy: esta política permite que o AWS Glue leia dados de buckets específicos do Amazon S3, mas não concede permissões para gravar ou modificar dados no Amazon S3 ou

       AWSGlueConsole-S3-read-and-write: esta política permite que o AWS Glue leia e grave dados em buckets específicos do Amazon S3 como parte do processo de ETL.
   - Quando você escolhe um perfil do IAM existente, o AWS Glue o define como padrão, mas não adiciona a ele nenhuma permissão do `AWSGlueServiceRole`. Verifique se você configurou o perfil a ser usado como um perfil de serviço do AWS Glue. Para obter mais informações, consulte Etapa 1: criar uma política do IAM para o serviço AWS Glue e Etapa 2: criar um perfil do IAM para o AWS Glue.

9. Escolha Próximo.
10. Por fim, revise as permissões que você selecionou e escolha Aplicar alterações. Ao aplicar as alterações, o AWS Glue adiciona permissões do IAM às identidades que você selecionou. Você pode visualizar ou modificar as novas permissões no console do IAM em https://console.aws.amazon.com/iam/.

Você agora concluiu a configuração de permissões mínimas do IAM para o AWS Glue. Em um ambiente de produção, recomendamos que você se familiarize com o Segurança no AWS Glue e o Gerenciamento de identidade e acesso do AWS Glue para ajudar a proteger os recursos da AWS para seu caso de uso.

Próximas etapas

Agora que tem as permissões do IAM configuradas, você pode explorar os seguintes tópicos para começar a usar o AWS Glue:

- Introdução ao AWS Glue no AWS Skill Builder
- Conceitos básicos da AWS Glue Data Catalog

Configuração do AWS Glue Studio

Conclua as tarefas nesta seção ao usar o AWS Glue para o Visual ETL pela primeira vez:

Tópicos

- Revisar as permissões do IAM necessárias para o usuário do AWS Glue Studio
- Revise IAM as permissões necessárias para ETL trabalhos
- Configurar permissões do IAM para o AWS Glue Studio
- Configurar uma VPC para seu trabalho de ETL

Revisar as permissões do IAM necessárias para o usuário do AWS Glue Studio

Para usar AWS Glue Studio, o usuário deve ter acesso a vários recursos da AWS. O usuário deve ser capaz de visualizar e selecionar buckets do Amazon S3, políticas e funções do IAM e objetos do AWS Glue Data Catalog.

Permissões de serviço do AWS Glue

O AWS Glue Studio usa as ações e recursos do serviço do AWS Glue. Seu usuário precisa de permissões sobre essas ações e recursos para usar com eficiência o AWS Glue Studio. Você pode conceder ao usuário do AWS Glue Studio a política gerenciada `AWSGlueConsoleFullAccess` ou criar uma política personalizada com um conjunto menor de permissões.

> **Important**
>
> De acordo com as práticas recomendadas de segurança, recomenda-se restringir o acesso enrijecendo políticas para restringir ainda mais o acesso ao bucket do Amazon S3 e grupos de logs do Amazon CloudWatch. Para obter um exemplo de política do Amazon S3, consulte Gravar políticas do IAM: como conceder acesso a um bucket do Amazon S3.

Criação de políticas do IAM personalizadas para o AWS Glue Studio

Você pode criar uma política personalizada com um conjunto menor de permissões para o AWS Glue Studio. A política pode conceder permissões para um subconjunto de objetos ou ações. Use as seguintes informações ao criar uma política personalizada.

Para usar as APIs do AWS Glue Studio, inclua `glue:UseGlueStudio` na política de ação em suas permissões do IAM. O uso de `glue:UseGlueStudio` permitirá que você acesse todas as ações do AWS Glue Studio mesmo quando mais ações forem adicionadas à API no decorrer do tempo.

Para obter mais informações sobre as ações definidas pelo AWS Glue, consulte Ações definidas pelo AWS Glue.

Preparação de dados em autoria de ações

- SendRecipeAction
- GetRecipeAction

Ações do gráfico acíclico dirigido (DAG)

- CreateDag
- UpdateDag
- GetDag
- DeleteDag

Ações de trabalho

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

Ações de execução de trabalho

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

Ações do esquema

- GetSchema
- GetInferredSchema

Ações de banco de dados

- GetDatabases

Ações de planejamento

- GetPlan

Ações de tabela

- SearchTables
- GetTables
- GetTables

Ações de conexão

- CreateConnection
- DeleteConnection
- UpdateConnection
- GetConnections
- GetConnection

Ações de mapeamento

- GetMapping

Ações do proxy do S3

- ListBuckets
- ListObjectsV2
- GetBucketLocation

Ações de configuração de segurança

- GetSecurityConfigurations

Ações de script

- CreateScript (diferente da API de mesmo nome no AWS Glue)

Acesso às APIs do AWS Glue Studio

Para acessar o AWS Glue Studio, adicione `glue:UseGlueStudio` na lista de políticas de ações nas permissões do IAM.

No exemplo abaixo, `glue:UseGlueStudio` está incluído na política de ação, mas as APIs do AWS Glue Studio não estão identificadas individualmente. Isso ocorre porque ao incluir `glue:UseGlueStudio`, você recebe automaticamente acesso às APIs internas sem precisar especificar as APIs individuais do AWS Glue Studio nas permissões do IAM.

No exemplo, as políticas adicionais de ação listadas (p. ex., `glue:SearchTables`) não são APIs do AWS Glue Studio, portanto, será necessário incluí-las nas permissões do IAM, conforme necessário. Você também pode incluir ações do Amazon S3 Proxy para especificar o nível de acesso do Amazon S3 a ser concedido. O exemplo de política abaixo fornece acesso para abrir o AWS Glue Studio, criar um trabalho visual e salvá-lo/executá-lo se o perfil do IAM selecionado tiver acesso suficiente.

```
{
    "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"
                    ]
                }
            }
        }
    ]
}
```

Permissões de visualização de dados e caderno

As visualizações de dados e os cadernos permitem que você veja uma amostra dos seus dados em qualquer estágio do trabalho (leitura, transformação, gravação), sem precisar executar o trabalho. Você especifica uma função do AWS Identity and Access Management (IAM) para a AWS Glue Studio para usar ao acessar os dados. As funções do IAM destinam-se a poder ser assumidas e não têm credenciais de longo prazo padrão, como uma senha ou chaves de acesso, associadas

a ela. Em vez disso, quando o AWS Glue Studio assume a função, o IAM fornece credenciais de segurança temporárias.

Para garantir que as visualizações de dados e os comandos do caderno funcionem corretamente, use uma função que tenha um nome que comece com a string `AWSGlueServiceRole`. Se você escolher usar um nome diferente para a função, será necessário adicionar a permissão `iam:passrole` e configurar uma política para a função no IAM. Para ter mais informações, consulte Criar uma política do IAM para funções não nomeadas “AWSGlueServiceRole*”.

> **Warning**
>
> Se uma função conceder a permissão `iam:passrole` a um caderno e você implementar o encadeamento de funções, um usuário pode inadvertidamente obter acesso ao caderno. No momento, não há auditoria implementada que permita monitorar quais usuários receberam acesso ao caderno.

Caso queira negar a uma identidade do IAM a capacidade de criar sessões de pré-visualização de dados, consulte o exemplo para the section called “Negação da capacidade de criar sessões de pré-visualização de dados para uma identidade”.

Permissões Amazon CloudWatch

É possível monitorar os trabalhos do AWS Glue Studio usando o Amazon CloudWatch, o qual coleta e processa dados brutos do AWS Glue e os transforma em métricas legíveis quase em tempo real. Por padrão, os dados de métricas do AWS Glue são enviados para o CloudWatch automaticamente. Para obter mais informações, consulte O que é o Amazon CloudWatch? no Manual do usuário do Amazon CloudWatch e Métricas do AWS Glue no Guia do desenvolvedor do AWS Glue.

Para acessar os painéis do CloudWatch, o usuário que acessa o AWS Glue Studio precisa de um dos seguintes:

- A política `AdministratorAccess`
- A política `CloudWatchFullAccess`
- Uma política personalizada que inclui uma ou mais destas permissões específicas:
  - `cloudwatch:GetDashboard` e `cloudwatch:ListDashboards` para visualizar painéis
  - `cloudwatch:PutDashboard` para criar ou modificar painéis
  - `cloudwatch:DeleteDashboards` para excluir painéis

Para obter mais informações sobre como alterar as permissões de um usuário do IAM usando políticas, consulte Alterar permissões de um usuário do IAM no Manual do usuário do IAM.

Revise IAM as permissões necessárias para ETL trabalhos

Quando você cria um trabalho usando AWS Glue Studio, o trabalho pressupõe as permissões da IAM função que você especifica ao criá-la. Essa IAM função deve ter permissão para extrair dados de sua fonte de dados, gravar dados em seu destino e acessar AWS Glue recursos.

O nome da função que você cria para o trabalho deve começar com a string `AWSGlueServiceRole` para que ela seja usada corretamente pelo AWS Glue Studio. Por exemplo, você pode nomear sua função`AWSGlueServiceRole-FlightDataJob`.

Permissões de origem e destino dos dados

Uma AWS Glue Studio O trabalho deve ter acesso ao Amazon S3 para todas as fontes, destinos, scripts e diretórios temporários que você usa em seu trabalho. Você pode criar uma política para fornecer acesso minucioso a recursos específicos do Amazon S3.

- As fontes de dados exigem permissões `s3:ListBucket` e `s3:GetObject`.
- Os destinos de dados exigem permissões `s3:ListBucket`, `s3:PutObject` e `s3:DeleteObject`.

> **Note**
>
> Sua IAM política precisa considerar os buckets específicos usados `s3:GetObject` para hospedar as AWS Glue transformações.
> Os compartimentos a seguir pertencem à conta de AWS serviço e podem ser lidos em todo o mundo. Esses buckets servem como um repositório para o código-fonte pertinente a um subconjunto de transformações acessíveis por meio do editor visual. AWS Glue Studio As permissões no bucket são configuradas para negar qualquer outra API ação no bucket. Qualquer pessoa pode ler os scripts que fornecemos para as transformações, mas ninguém fora da nossa equipe de serviço pode "colocar" nada neles. Quando seu AWS Glue trabalho é executado, esse arquivo é extraído como uma importação local para que o arquivo seja baixado para o contêiner local. Depois disso, não há mais comunicação com essa conta.

Região: Nome do bucket

- 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- aws-glue-studio-transforms -2 prod-ap-south
- ap-southeast-1 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- -1 aws-glue-studio-transforms prod-ca-central
- ca-west-1: -915795495192- aws-glue-studio-transforms -1 prod-ca-west
- eu-central-1: -56037323 2017- -1 aws-glue-studio-transforms prod-eu-central
- eu-central-2: -907358657121- -2 aws-glue-studio-transforms prod-eu-central
- eu-north-1: -312557305497- aws-glue-studio-transforms -1 prod-eu-north
- eu-south-1: -939684186351- aws-glue-studio-transforms -1 prod-eu-south
- eu-south-2: -239737454084- aws-glue-studio-transforms -2 prod-eu-south
- eu-west-1: -244479516193- aws-glue-studio-transforms -1 prod-eu-west
- eu-west-2: -804222392271- aws-glue-studio-transforms -2 prod-eu-west
- eu-west-3: -371299348807- -3 aws-glue-studio-transforms prod-eu-west
- il-central-1: -806964611811- -1 aws-glue-studio-transforms prod-il-central
- me-central-1: -733304270342- -1 aws-glue-studio-transforms prod-me-central
- me-south-1: -112120182341- aws-glue-studio-transforms -1 prod-me-south
- sa-east-1: -881619130292- aws-glue-studio-transforms -1 prod-sa-east
- us-east-1: -510798373988- -1 aws-glue-studio-transforms prod-us-east
- us-east-2: -251189692203- -2 aws-glue-studio-transforms prod-us-east
- us-west-1: -593230150239- -1 aws-glue-studio-transforms prod-us-west
- us-west-2: -818035625594- -2 aws-glue-studio-transforms prod-us-west
- ap-northeast-1: -200493242866- -1 aws-glue-studio-transforms prod-ap-northeast
- cn-norte-1: -071033555442- -1 aws-glue-studio-transforms prod-cn-north

- cn-noroeste-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

Se você escolher Amazon Redshift como fonte de dados, poderá fornecer uma função para as permissões do cluster. Os trabalhos executados em um Amazon Redshift cluster emitem comandos que acessam o Amazon S3 para armazenamento temporário usando credenciais temporárias. Se o trabalho for executado por mais de uma hora, essas credenciais expirarão, fazendo com que o trabalho falhe. Para evitar esse problema, você pode atribuir uma função ao próprio cluster do Amazon Redshift que concede as permissões necessárias aos trabalhos utilizando credenciais temporárias. Para obter mais informações, consulte Mover dados de e para o Amazon RedShift no Guia do desenvolvedor do AWS Glue .

Se o trabalho usar fontes de dados ou destinos diferentes do Amazon S3, você deverá anexar as permissões necessárias à IAM função usada pelo trabalho para acessar essas fontes e destinos de dados. Para obter mais informações, consulte Configurar seu ambiente para acessar armazenamentos de dados no Guia do desenvolvedor do AWS Glue .

Se você estiver usando conectores e conexões para seu armazenamento de dados, precisará de permissões adicionais, conforme descrito em the section called “Permissões necessárias para usar conectores”.

Permissões necessárias para excluir trabalhos

Em AWS Glue Studio você pode selecionar vários trabalhos no console para excluir. Para executar essa ação, você deve ter a permissão `glue:BatchDeleteJob`. Isso é diferente do AWS Glue console, que requer a `glue:DeleteJob` permissão para excluir trabalhos.

AWS Key Management Service permissões

Se você planeja acessar fontes e destinos do Amazon S3 que usam criptografia do lado do servidor com AWS Key Management Service (AWS KMS), anexe uma política ao AWS Glue Studio função usada pela tarefa que permite que a tarefa decodifique os dados. A função de trabalho precisa das permissões `kms:ReEncrypt`, `kms:GenerateDataKey` e `kms:DescribeKey`. Além disso, a função de trabalho precisa da `kms:Decrypt` permissão para carregar ou baixar um objeto do Amazon S3 criptografado com uma chave mestra AWS KMS do cliente ()CMK.

Há taxas adicionais pelo uso AWS KMS CMKs. Para obter mais informações, consulte AWS Key Management Service Conceitos - Chaves mestras do cliente (CMKs) e AWS Key Management Service preços no Guia do AWS Key Management Service desenvolvedor.

Permissões necessárias para usar conectores

Se você estiver usando um AWS Glue Conector personalizado e conexão para acessar um armazenamento de dados, a função usada para executar o AWS Glue ETLo trabalho precisa de permissões adicionais anexadas:

- A política AWS gerenciada `AmazonEC2ContainerRegistryReadOnly` para acessar os conectores adquiridos AWS Marketplace em.
- As permissões `glue:GetJob` e `glue:GetJobs`.
- AWS Secrets Manager permissões para acessar segredos que são usados com conexões. Consulte Exemplo: Permissão para recuperar valores secretos, por exemplo, IAM políticas.

Se suas receitas AWS Glue ETLO trabalho é executado em uma Amazon VPC em execução eVPC, em seguida, VPC deve ser configurado conforme descrito emthe section called “Configurar uma VPC para seu trabalho de ETL”.

Configurar permissões do IAM para o AWS Glue Studio

Você pode criar as funções e atribuir políticas a usuários e a funções de trabalho usando o usuário administrador da AWS.

Você pode usar a política gerenciada pela AWS AWSGlueConsoleFullAccess para fornecer as permissões necessárias para usar o console do AWS Glue Studio.

Para criar sua própria política, siga as etapas documentadas em Criar uma política do IAM para o serviço do AWS Glue no Guia do desenvolvedor do AWS Glue. Inclua as permissões do IAM descritas anteriormente em Revisar as permissões do IAM necessárias para o usuário do AWS Glue Studio.

Tópicos

- Anexar políticas ao usuário do AWS Glue Studio
- Criar uma política do IAM para funções não nomeadas “AWSGlueServiceRole*”

Anexar políticas ao usuário do AWS Glue Studio

Qualquer usuário do AWS que fizer login no console do AWS Glue Studio deverá ter permissões para acessar recursos específicos. Você fornece essas permissões associando políticas do IAM ao usuário.

Para anexar a política gerenciada AWSGlueConsoleFullAccess a um usuário

1. Faça login no AWS Management Console e abra o console do IAM em https://console.aws.amazon.com/iam/.
2. No painel de navegação, escolha Políticas.
3. Na lista de políticas, marque a caixa de seleção ao lado da política AWSGlueConsoleFullAccess. Você pode usar o menu Filtro e a caixa de pesquisa para filtrar a lista de políticas.
4. Selecione Ações da política e escolha Anexar.
5. Escolha o usuário ao qual a política será anexada. Você pode usar o menu Filter (Filtro) e a caixa de pesquisa para filtrar a lista de entidades principais. Depois de escolher o usuário ao qual a política será anexada, selecione Attach policy.
6. Repita as etapas anteriores para anexar políticas adicionais ao usuário conforme necessário.

Criar uma política do IAM para funções não nomeadas “AWSGlueServiceRole*”

Para configurar uma política do IAM para funções usadas pelo AWS Glue Studio

1. Faça login no AWS Management Console e abra o console do IAM em https://console.aws.amazon.com/iam/.
2. Adicione uma nova política do IAM. É possível adicionar a uma política existente ou criar uma nova política em linha do IAM. Para criar uma política do IAM:
    1. Escolha Policies (Políticas) e depois Create Policy (Criar política). Se aparecer um botão Get Started, selecione-o e, em seguida, Create Policy.
    2. Próximo a Create Your Own Policy, escolha Select.
    3. Em Nome da política, digite qualquer valor que seja mais fácil para você consultar mais tarde. Você também pode digitar um texto descritivo em Descrição.
    4. Em Documento de política, digite uma instrução com o seguinte formato e escolha Criar política:
3. Copie e cole os blocos a seguir na política na matriz “Statement”, substituindo *my-interactive-session-role-prefix* pelo prefixo de todos os perfis comuns a serem associados com as permissões para o AWS Glue.

```
{
    "Action": [
        "iam:PassRole"
```

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

Aqui está o exemplo completo com os arrays Version and Statement incluídos na política

```
{
  "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. Para habilitar a política para um usuário, escolha Usuários.
5. Escolha o usuário do para o qual você deseja anexar a política.

Configurar uma VPC para seu trabalho de ETL

O Amazon Virtual Private Cloud (Amazon VPC) permite definir uma rede virtual em sua própria área isolada logicamente na Nuvem AWS, conhecida como uma nuvem privada virtual (VPC). Você

pode iniciar os recursos da AWS, como as instâncias, na VPC. Sua VPC assemelha-se a uma rede tradicional que você poderia operar no seu próprio data center, com os benefícios de usar a infraestrutura escalável da AWS. É possível configurar seu VPC, selecionar o intervalo de endereços IP dele, criar sub-redes e definir tabelas de rotas, gateways de rede e configurações de segurança. Você pode se conectar às suas instâncias na VPC. É possível conectar a VPC a seu próprio data center corporativo, tornando a Nuvem AWS uma extensão do seu data center. Para proteger os recursos em cada sub-rede, você pode usar várias camadas de segurança, incluindo grupos de segurança e listas de controle de acesso de rede. Para obter mais informações, consulte o Manual do usuário da Amazon VPC.

Você pode configurar os trabalhos de ETL do AWS Glue para serem executados em uma VPC ao usar conectores. Você deve configurar a VPC para o seguinte, conforme necessário:

- Acesso à rede pública para armazenamentos de dados fora da AWS. Todos os armazenamentos de dados acessados pelo trabalho devem estar disponíveis na sub-rede da VPC.
- Se o seu trabalho precisar acessar recursos da VPC e a Internet pública, a VPC precisará conter uma instância de gateway de conversão de endereços de rede (NAT).

  Para obter mais informações, consulte Configurar seu ambiente para acessar armazenamentos de dados no Guia do desenvolvedor do AWS Glue.

Conceitos básicos de cadernos no AWS Glue Studio

Ao iniciar um caderno por meio do AWS Glue Studio, todas as etapas de configuração são feitas para você, para que você possa explorar seus dados e começar a desenvolver seu script de trabalho após apenas alguns segundos.

As seções a seguir descrevem como criar um perfil e conceder as permissões apropriadas para usar cadernos do AWS Glue Studio para trabalhos de ETL.

Para obter mais informações sobre as ações definidas pelo AWS Glue, consulte Ações definidas pelo AWS Glue.

Tópicos

- Conceder permissões para a função do IAM

Conceder permissões para a função do IAM

A configuração do AWS Glue Studio é um pré-requisito para usar cadernos.

Para usar cadernos no AWS Glue, seu perfil exige o seguinte:

- Uma relação de confiança com o AWS Glue para a ação `sts:AssumeRole`, além de `sts:TagSession` se você quiser usar marcação.
- Uma política do IAM contendo todas as permissões para cadernos, AWS Glue e sessões interativas.
- Uma política do IAM para uma função de transmissão, pois a função precisa ser capaz de repassar ela própria do caderno para sessões interativas.

Por exemplo, ao criar um novo perfil, você pode adicionar uma política gerenciada padrão do AWS como `AWSGlueConsoleFullAccessRole` a função, e depois adicionar uma nova política para as operações do caderno e outra para a política PassRole do IAM.

Ações necessárias para uma relação de confiança com o AWS Glue

Ao iniciar uma sessão de caderno, deve adicionar `sts:AssumeRole` ao relacionamento de confiança da função que é repassada ao caderno. Se a sessão incluir etiquetas, você também deve repassar a ação `sts:TagSession`. Sem essas ações, a sessão do caderno não pode começar.

Por exemplo:

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

Políticas contendo permissões do IAM para cadernos

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para os cadernos. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

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

É possível usar as seguintes políticas do IAM para permitir acesso a recursos específicos:

- AwsGlueSessionUserRestrictedNotebookServiceRole: fornece acesso total a todos os recursos do AWS Glue, exceto para sessões. Permite que os usuários criem e usem somente as sessões de caderno que estejam associadas ao usuário. Essa política também inclui outras permissões exigidas pelo AWS Glue para gerenciar recursos do AWS Glue em outros serviços da AWS.
- AwsGlueSessionUserRestrictedNotebookPolicy: fornece permissões que permitem que os usuários criem e usem somente as sessões de caderno associadas ao usuário. Essa política também inclui permissões para permitir explicitamente que os usuários transmitam uma função de sessão restrita do AWS Glue.

Política do IAM para uma aprovar um perfil

Quando você cria um caderno com uma função, essa função é transmitida para sessões interativas, de modo que a mesma função possa ser usada em ambos os lugares. Por isso, a permissão `iam:PassRole` precisa fazer parte da política da função.

Crie uma nova política para seu perfil usando o exemplo a seguir. Substitua o número da conta e pelo seu próprio e pelo nome do perfil.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": "iam:PassRole",
            "Resource": "arn:aws:iam::090000000210:role/<role_name>"
        }
    ]
}
```

Configurar perfis de uso do AWS Glue

Uma das principais vantagens de usar uma plataforma em nuvem é a flexibilidade. No entanto, com a facilidade de criação de recursos computacionais, surge o risco de aumentar os custos da nuvem quando eles não são gerenciados e não possuem barreiras. Como resultado, os administradores precisam evitar altos custos de infraestrutura e, ao mesmo tempo, permitir que os usuários trabalhem sem atritos desnecessários.

Com perfis de uso do AWS Glue, os administradores podem criar diversas classes de usuários na conta, como equipes de desenvolvedores, testadores e de produto. Cada perfil é um conjunto exclusivo de parâmetros que podem ser atribuídos a diferentes tipos de usuários. Por exemplo, os desenvolvedores podem precisar de mais trabalhadores e ter um número maior de trabalhadores máximo, enquanto as equipes de produto podem precisar de menos trabalhadores e de um valor menor de tempo limite ou tempo limite de inatividade.

Exemplo de comportamento de trabalhos e execuções de trabalhos

Suponha que um trabalho seja criado pelo usuário A com o perfil A. O trabalho é salvo com determinados valores de parâmetros. O usuário B com perfil B tentará executar o trabalho.

Quando o usuário A criou o trabalho, se ele não definiu um número específico de trabalhadores, o conjunto padrão no perfil do usuário A foi aplicado e salvo com as definições do trabalho.

Quando o usuário B executa o trabalho, ele é executado com os valores que foram salvos para ele. Se o perfil do usuário B for mais restritivo e não puder ser executado com tantos trabalhadores, a execução do trabalho falhará.

Perfil de uso como recurso

Um perfil de uso do AWS Glue é um recurso identificado por um nome do recurso da Amazon (ARN). Todos os controles padrão do IAM (Identity and Access Management) se aplicam, incluindo autorização baseada em ações e recursos. Os administradores devem atualizar a política do IAM dos usuários que criam recursos do AWS Glue, concedendo acesso a eles para usar os perfis.

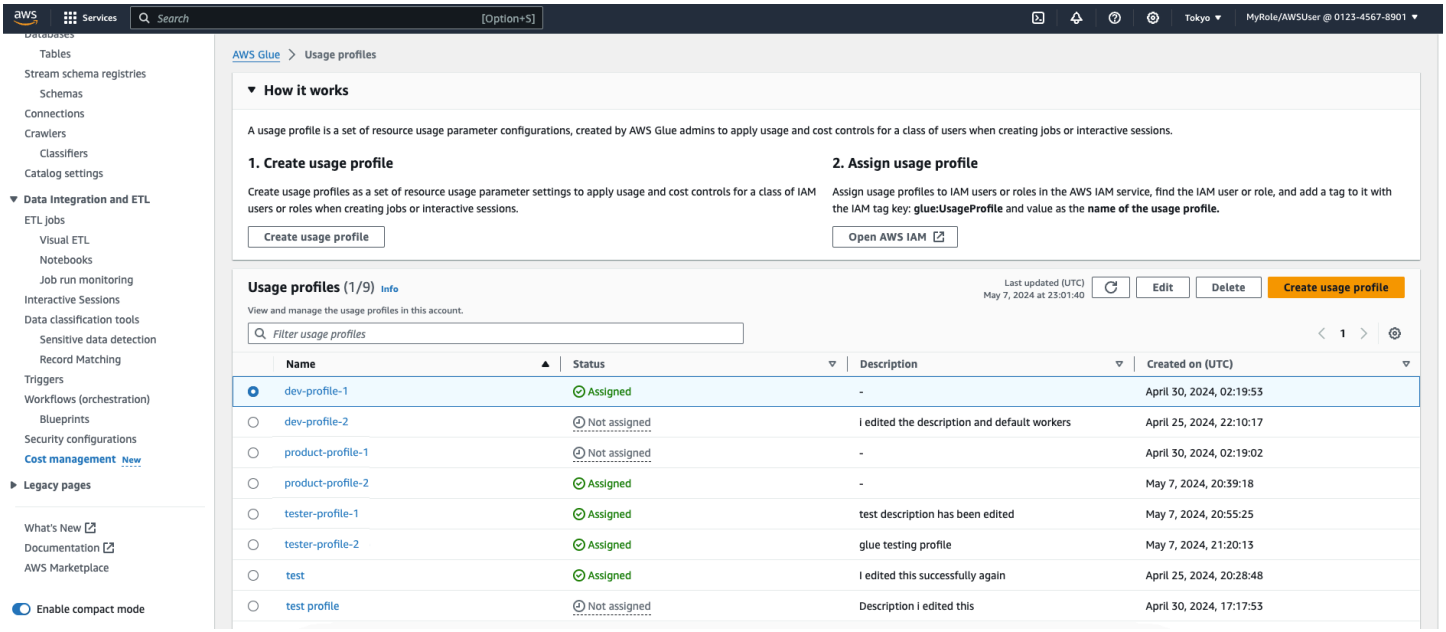

Tópicos

- Criação e gerenciamento de perfis de uso
- Perfis de uso e tarefas

Criação e gerenciamento de perfis de uso

Criação de um perfil de uso do AWS Glue

Os administradores devem criar perfis de uso e depois atribuí-los aos diversos usuários. Ao criar um perfil de uso, você especifica valores padrão, bem como um intervalo de valores permitidos para vários parâmetros de tarefa e sessão. Você deve configurar ao menos um parâmetro para tarefas ou sessões interativas. É possível personalizar o valor padrão a ser usado quando um valor de

parâmetro não for fornecido para a tarefa e/ou configurar um limite de intervalo ou um conjunto de valores permitidos para validação se um usuário fornecer um valor de parâmetro ao usar esse perfil.

Os padrões são uma prática recomendada definida pelo administrador para auxiliar os autores da tarefa. Quando um usuário cria uma nova tarefa e não define um valor de tempo limite, o sistema aplicará o tempo limite padrão do perfil de uso. Se o autor não tiver um perfil, o sistema vai aplicar os padrões de serviço do AWS Glue e salvá-los na definição de tarefa. No runtime, o AWS Glue aplica os limites definidos no perfil (mínimo, máximo, operadores permitidos).

Após a configuração de um parâmetro, todos os outros parâmetros serão opcionais. Os parâmetros passíveis de personalização para tarefas ou sessões interativas são:

- Número de operadores: restrinja o número de operadores para evitar o uso excessivo dos recursos computacionais. É possível definir um valor padrão, mínimo e máximo. O mínimo é 1.
- Tipo de operador: restrinja os tipos de operadores relevantes para suas workloads. Você pode definir um tipo padrão e permitir tipos de operador para um perfil de usuário.
- Tempo limite: defina o tempo máximo durante o qual uma tarefa ou sessão interativa pode ser executada e consumir recursos antes de ser encerrada. Configure valores de tempo limite para evitar tarefas de longa duração.

  É possível definir um valor padrão, mínimo e máximo em minutos. O mínimo é de 1 (minuto). Embora o tempo limite padrão do AWS Glue seja de 2.880 minutos, você pode definir qualquer valor padrão no perfil de uso.

  Uma prática recomendada é a definição de um valor para “padrão”. Esse valor será usado para a criação da tarefa ou da sessão se o usuário não tiver definido nenhum valor.
- Tempo limite de inatividade: defina o número de minutos em que uma sessão interativa fica inativa antes de expirar após a execução de uma célula. Defina o tempo limite de inatividade para que as sessões interativas sejam encerradas após a conclusão da tarefa. O intervalo de tempo limite de inatividade deverá estar dentro do limite do tempo limite.

  É possível definir um valor padrão, mínimo e máximo em minutos. O mínimo é de 1 (minuto). Embora o tempo limite padrão do AWS Glue seja de 2.880 minutos, você pode definir qualquer valor padrão no perfil de uso.

  Uma prática recomendada é a definição de um valor para “padrão”. Esse valor será usado para a criação da sessão se o usuário não tiver definido nenhum valor.

Para criar um perfil de uso do AWS Glue como administrador (console)

1. No menu de navegação à esquerda, escolha Gerenciamento de custos.
2. Escolha Criar perfil de uso.
3. Insira o Nome do perfil de uso para o perfil de uso.
4. Insira uma descrição opcional que ajudará outras pessoas a reconhecer a finalidade do perfil de uso.
5. Defina pelo menos um parâmetro no perfil. Qualquer campo no formulário é um parâmetro. Por exemplo, o tempo limite mínimo de inatividade da sessão.
6. Defina qualquer tag opcional que seja aplicável ao perfil de uso.
7. Escolha Salvar.

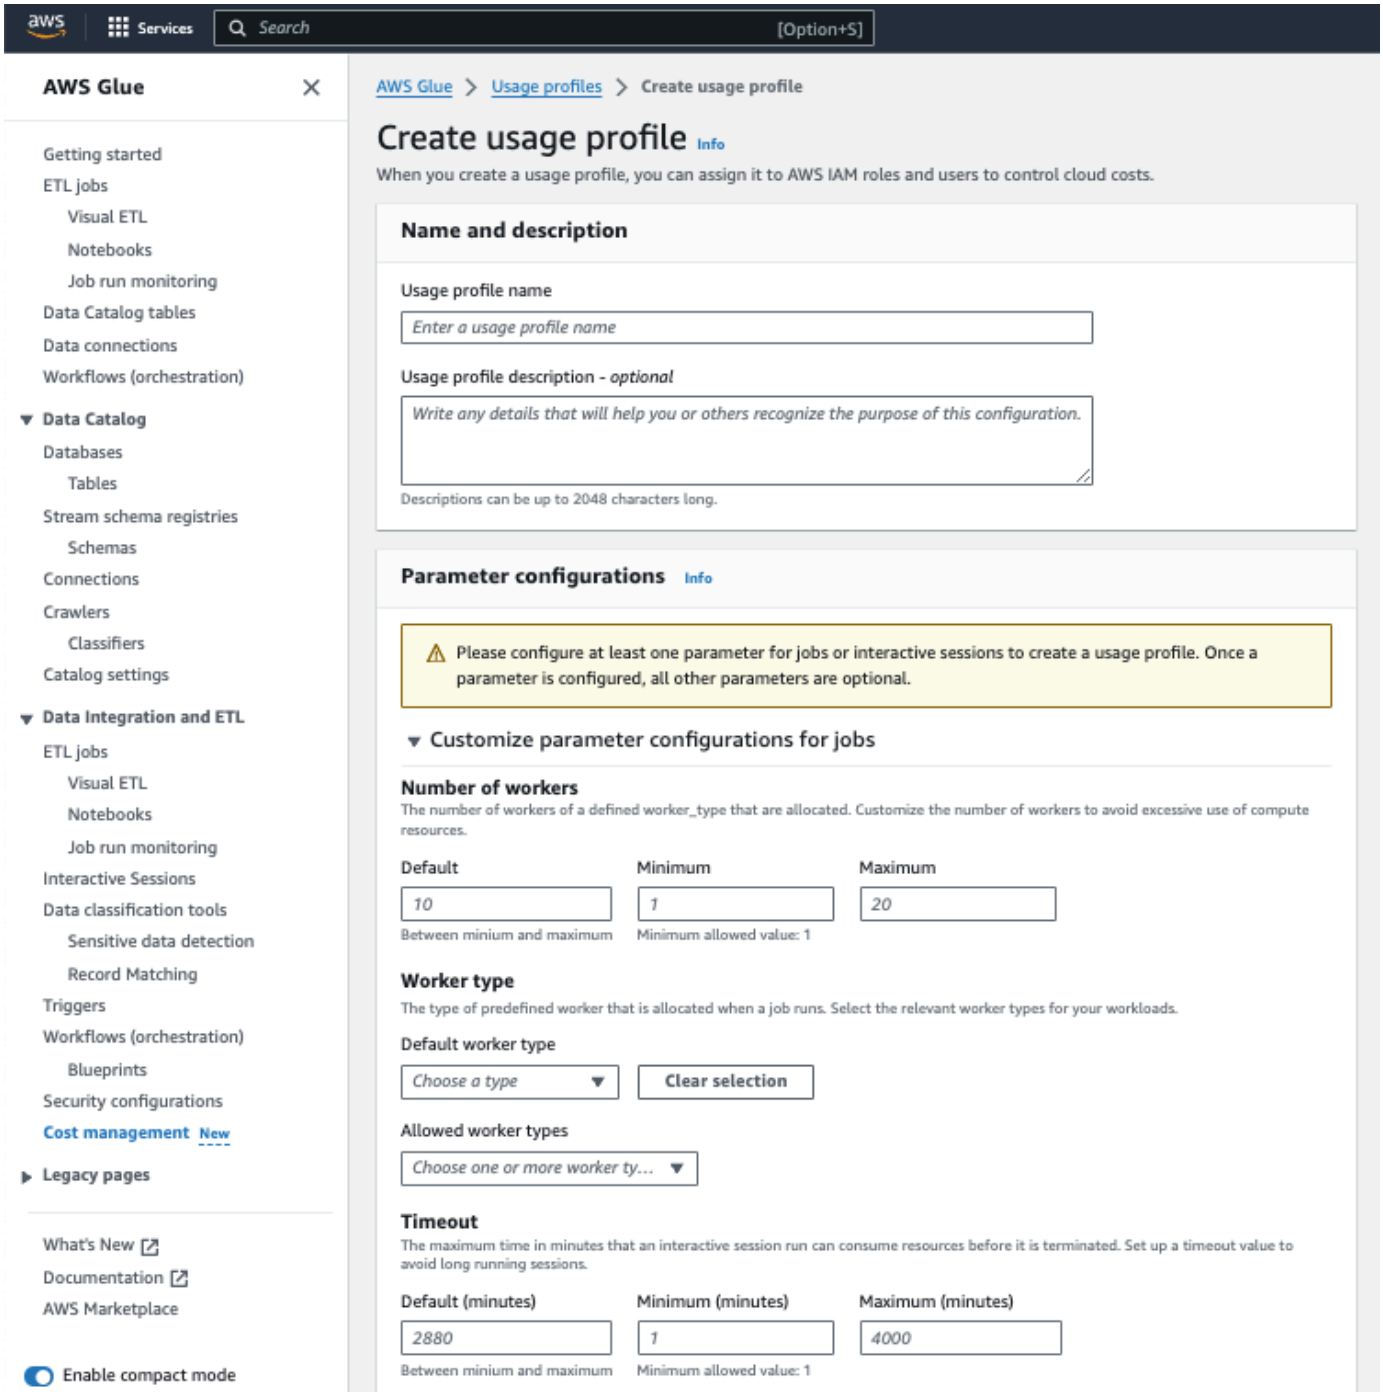

Para criar um novo perfil de uso (AWS CLI)

1. Insira o comando da a seguir.

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

no qual config.json pode definir valores de parâmetros para sessões interativas (`SessionConfiguration`) e tarefas (`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. Insira o comando a seguir para visualizar o perfil de uso criado:

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

A resposta:

```
{
    "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"
}
```

Comandos adicionais de CLI usados para gerenciar perfis de uso:

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

Editar um perfil de uso

Para alterar os valores do parâmetro do perfil para tarefas e sessões interativas, os administradores podem editar os perfis de uso que eles criaram.

Para editar um perfil de uso:

Para editar um perfil de uso do AWS Glue como administrador (console)

1. No menu de navegação à esquerda, escolha Gerenciamento de custos.

2. Escolha um perfil de uso para o qual você tenha permissões para editar e escolha Editar.
3. Faça as alterações necessárias no perfil. Por padrão, os parâmetros que já têm valores serão expandidos.
4. Escolha Salvar edições.

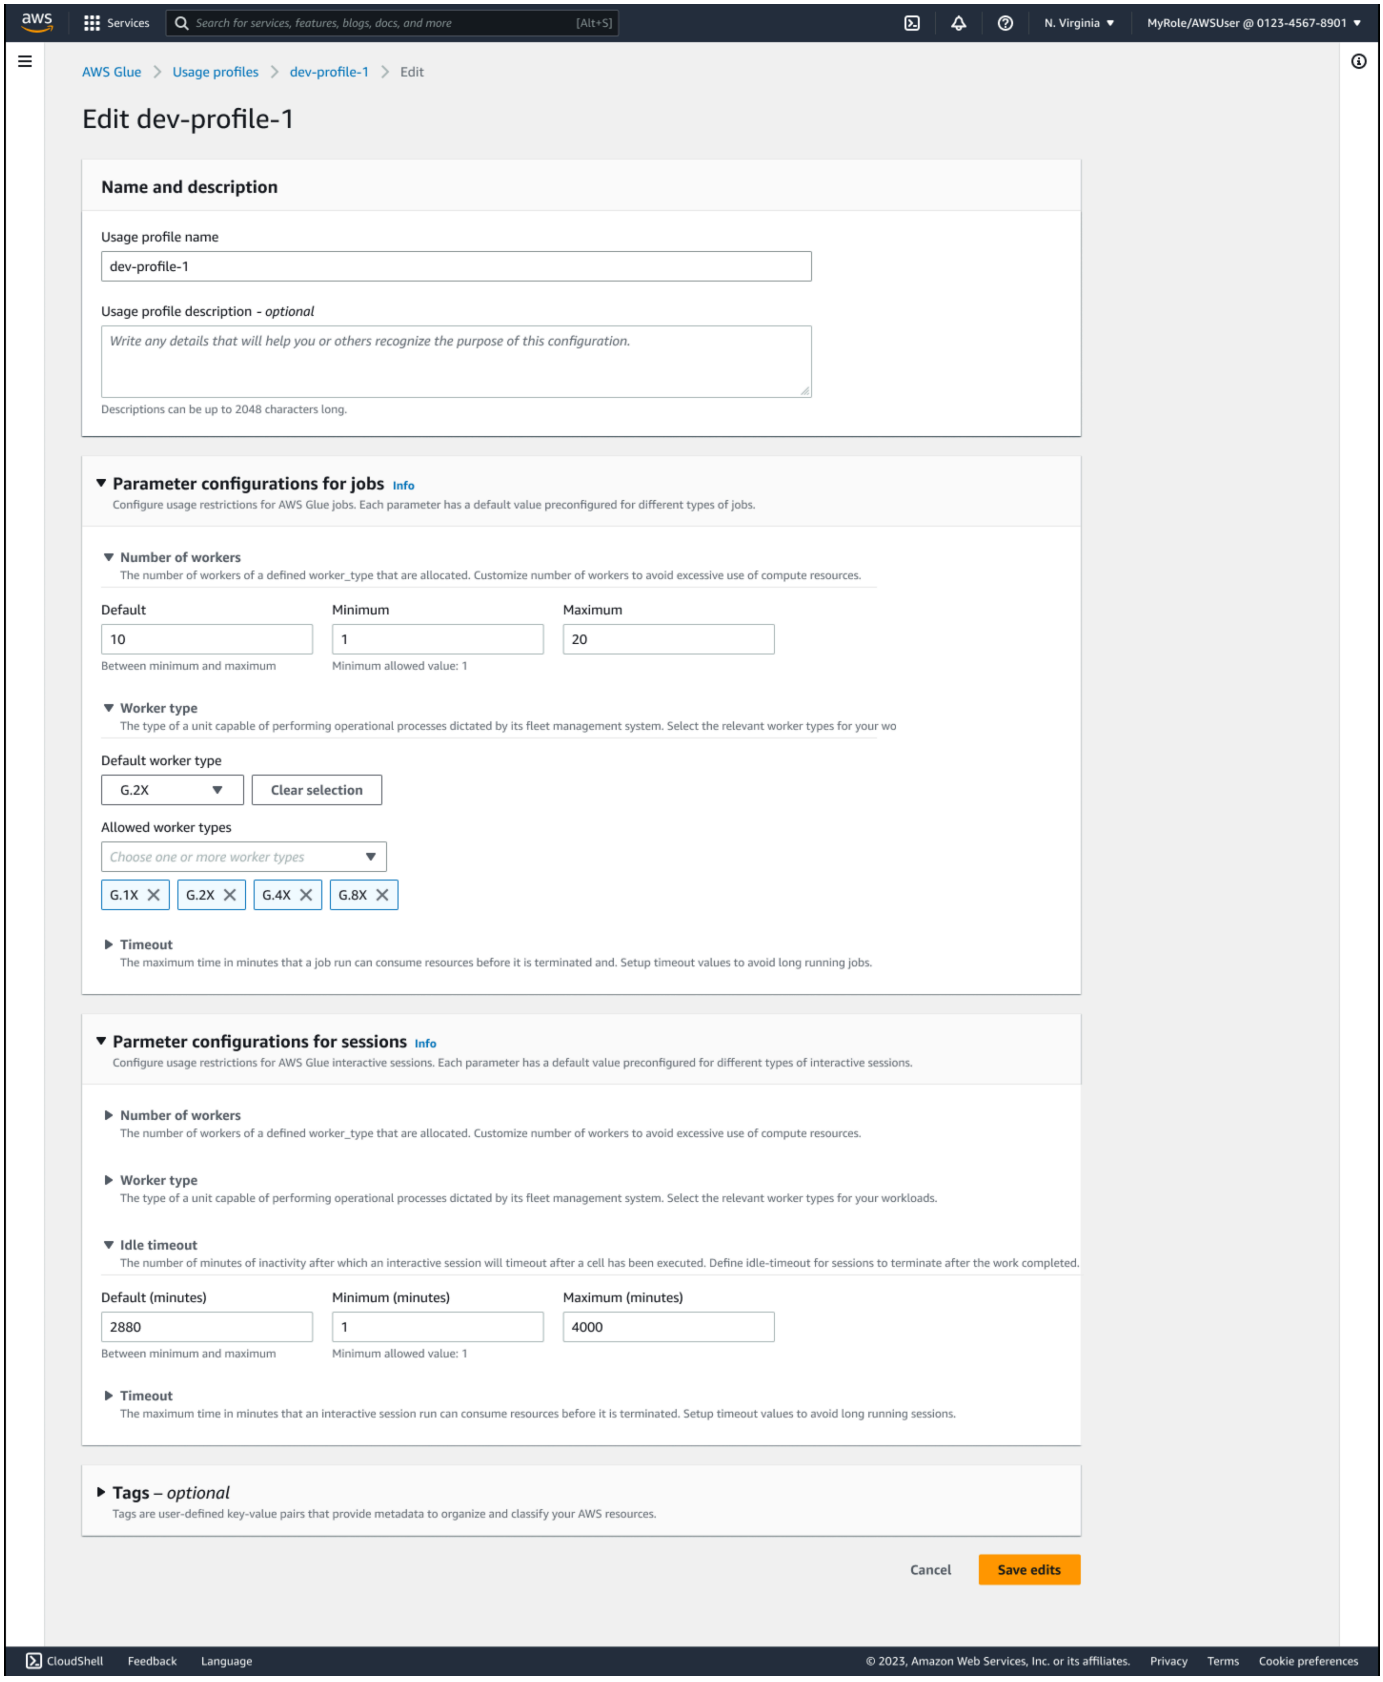
Services
Search for services, features, blogs, docs, and more [Alt+S]
N. Virginia
MyRole/AWSUser @ 0123-4567-8901
AWS Glue > Usage profiles > dev-profile-1 > Edit
Edit dev-profile-1
Name and description
Usage profile name
dev-profile-1
Usage profile description - optional
Write any details that will 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
10
Between minimum and maximum
Minimum
1
Minimum allowed value: 1
Maximum
20
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)
2880
Between minimum and maximum
Minimum (minutes)
1
Minimum allowed value: 1
Maximum (minutes)
4000
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

Para editar um perfil de uso (AWS CLI)

- Insira o comando da a seguir. A mesma sintaxe de arquivo `--configuration` é usada conforme apresentado acima no comando criar.

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

  no qual config.json define valores de parâmetros para sessões interativas (`SessionConfiguration`) e tarefas (`JobConfiguration`):

Atribuição de um perfil de uso

A coluna Status de utilização na página Perfis de uso mostra se um perfil de uso está ou não atribuído a usuários. Passar o mouse sobre o status mostra as entidades atribuídas do IAM.

O administrador pode atribuir um perfil de uso do AWS Glue aos usuários/perfis que criarem recursos do AWS Glue. A atribuição de um perfil é uma combinação de duas ações:

- Atualizar a tag de usuário/perfil do IAM com a chave `glue:UsageProfile` e, em seguida
- Atualizar a política do IAM do usuário/perfil.

Para usuários que usam o AWS Glue Studio para criar tarefas/sessões interativas, o administrador marca com tags os seguintes perfis:

- Para restrições em tarefas, o administrador marca o perfil de console conectado.
- Para restrições em sessões interativas, o administrador marca com tag o perfil que o usuário fornece ao criar o notebook.

Veja a seguir um exemplo de política que o administrador precisa atualizar nos usuários/perfis do IAM que criam recursos do AWS Glue:

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

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

O AWS Glue valida solicitações de tarefa, execução de tarefa e sessões com base nos valores especificados no perfil de uso do AWS Glue e gera uma exceção se a solicitação não for permitida. Para APIs síncronas, haverá o lançamento de um erro para o usuário. Para caminhos assíncronos, o sistema criará uma execução de tarefa com falha com a mensagem de erro de que o parâmetro de entrada está fora do intervalo permitido para o perfil atribuído do usuário/perfil.

Para atribuir um perfil de uso a um usuário/perfil:

1. Abra o console do Identity and Access Management (IAM).
2. No painel de navegação à esquerda, escolha Usuários ou Perfis.
3. Escolha um usuário ou um perfil.
4. Escolha a guia Tags.
5. Selecione Adicionar nova tag
6. Adicione uma tag com a Chave de `glue:UsageProfile` e o Valor do nome do seu perfil de uso.
7. Selecione Save changes (Salvar alterações)

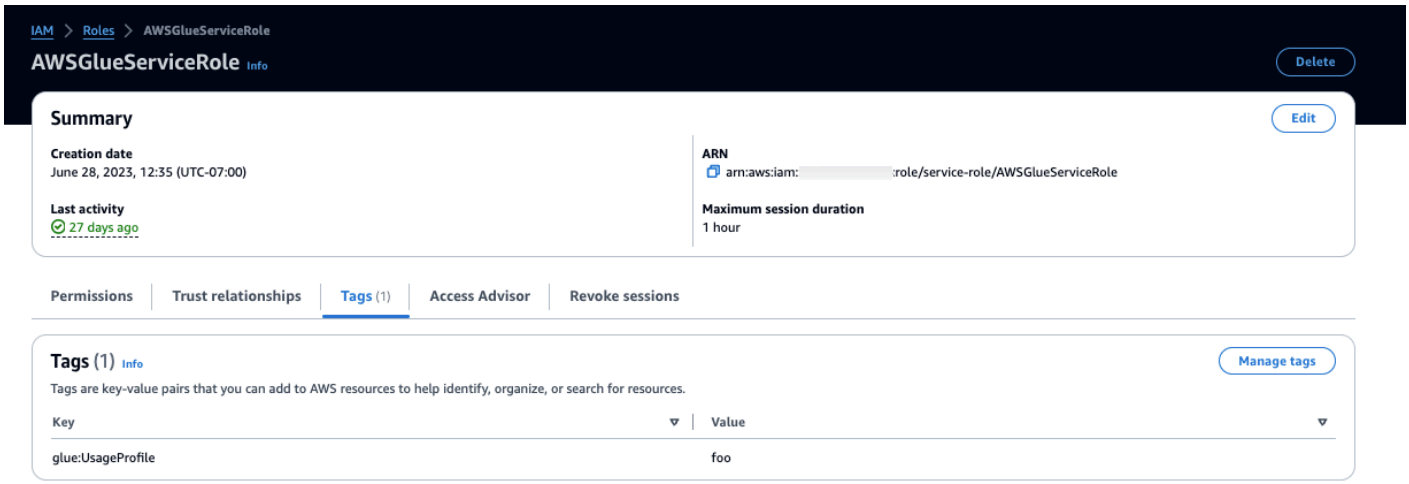

Visualizar seu perfil de uso atribuído

Os usuários podem visualizar seus perfis de uso atribuídos e usá-los ao fazer chamadas de API para criar recursos de tarefa e sessão do AWS Glue ou ao iniciar uma tarefa.

As permissões de perfil são fornecidas nas políticas do IAM. O usuário poderá visualizar o perfil desde que a política de chamadas tenha a permissão `glue:UsageProfile`. Caso contrário, você receberá um erro de acesso negado.

Para visualizar um perfil de uso atribuído:

1. No menu de navegação à esquerda, escolha Gerenciamento de custos.
2. Escolha um perfil de uso para o qual você tenha permissões de visualizar.

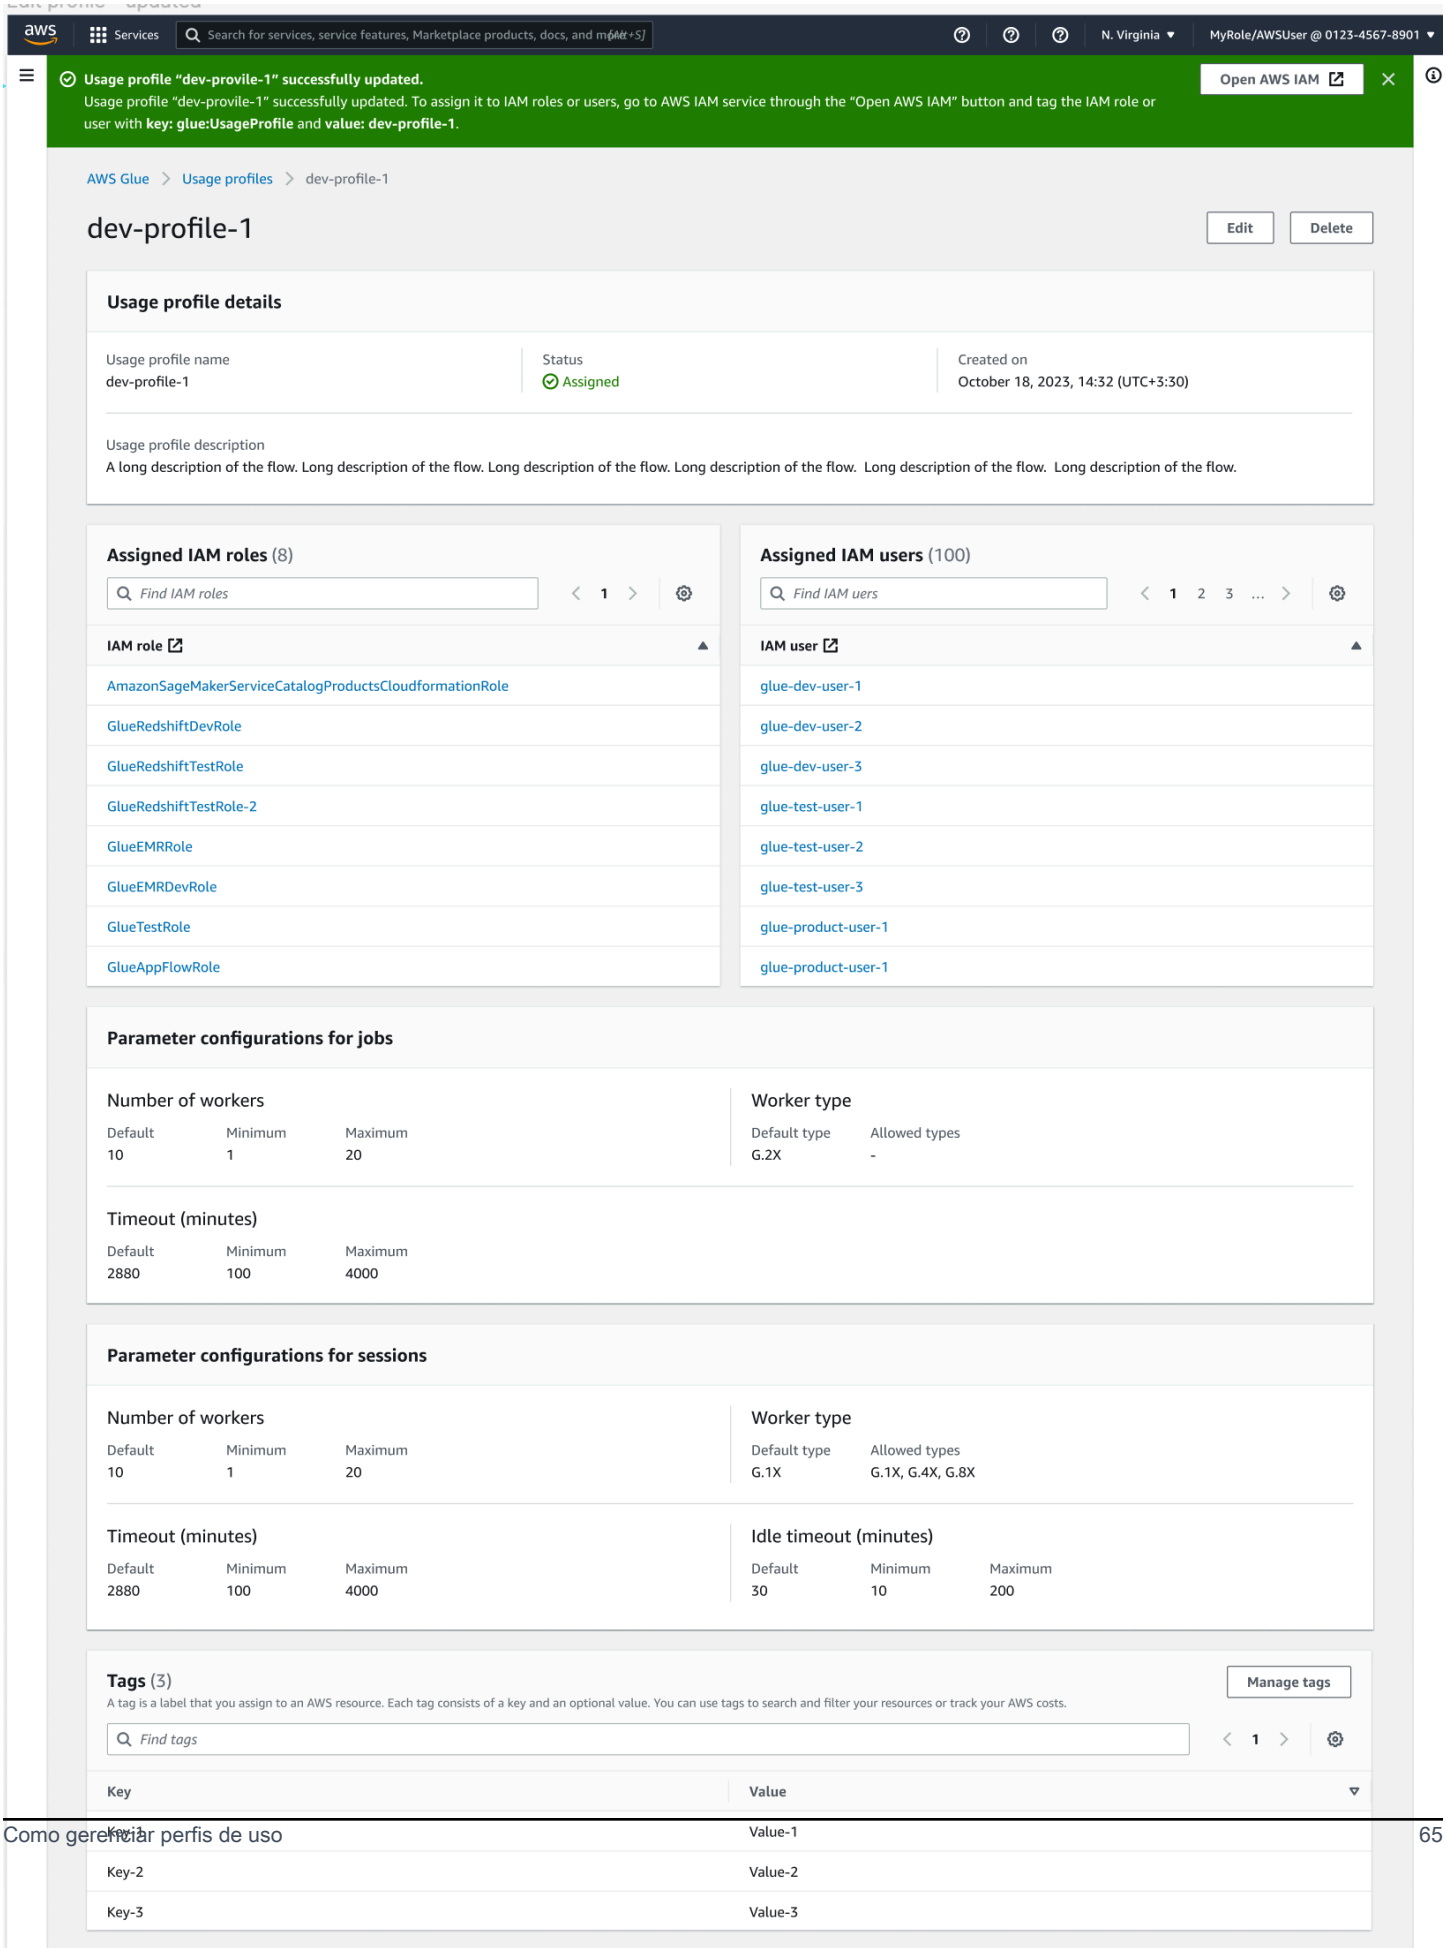
Services
Search for services, service features, Marketplace products, docs, and more [Alt+S]
N. Virginia
MyRole/AWSUser @ 0123-4567-8901
Usage profile "dev-provile-1" successfully updated.
Usage profile "dev-provile-1" successfully updated. To assign it to IAM roles or users, go to AWS IAM service through 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
Edit
Delete
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. Long description of the flow.
Assigned IAM roles (8)
Find IAM roles
IAM role
AmazonSageMakerServiceCatalogProductsCloudformationRole
GlueRedshiftDevRole
GlueRedshiftTestRole
GlueRedshiftTestRole-2
GlueEMRRole
GlueEMRDevRole
GlueTestRole
GlueAppFlowRole
Assigned IAM users (100)
Find IAM uers
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 10
Minimum 1
Maximum 20
Worker type
Default type G.2X
Allowed types -
Timeout (minutes)
Default 2880
Minimum 100
Maximum 4000
Parameter configurations for sessions
Number of workers
Default 10
Minimum 1
Maximum 20
Worker type
Default type G.1X
Allowed types G.1X, G.4X, G.8X
Timeout (minutes)
Default 2880
Minimum 100
Maximum 4000
Idle timeout (minutes)
Default 30
Minimum 10
Maximum 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.
Manage tags
Find tags
Key
Value
Key-1
Value-1
Key-2
Value-2
Key-3
Value-3

Perfis de uso e tarefas

Criação de tarefas com perfis de uso

Ao criar tarefas, os limites e padrões definidos em seu perfil de uso serão aplicados. Seu perfil será atribuído à tarefa quando ela for salva.

Execução de tarefas com perfis de uso

Quando você inicia uma execução de tarefa, o AWS Glue impõe os limites definidos no perfil do chamador. Se não houver um chamador direto, o Glue aplicará os limites do perfil atribuído à tarefa pelo autor.

> **Note**
>
> Quando uma tarefa for executada com base em um cronograma (por fluxos de trabalho do AWS Glue ou acionadores do AWS Glue), o sistema aplicará o perfil atribuído à tarefa pelo autor.
> Quando uma tarefa for executada por um serviço externo (Step Functions, MWAA) ou por uma API `StartJobRun`, o sistema aplicará o limite do perfil do chamador.

Para fluxos de trabalho do AWS Glue ou acionadores do AWS Glue: é necessário atualizar tarefas preexistentes para salvar o novo nome do perfil, de modo que os limites do perfil (mínimo, máximo e operadores permitidos) sejam aplicados em runtime para execuções programadas.

Visualização de um perfil de uso atribuído a tarefas

Para visualizar o perfil atribuído às suas tarefas (que será usado em runtime com fluxos de trabalho do AWS Glue ou acionadores do AWS Glue programados), você pode consultar a guia Detalhes da tarefa. Você também pode ver o perfil usado em execuções anteriores na guia de detalhes de execuções de tarefas.

Atualizar ou excluir um perfil de uso anexado a uma tarefa

O perfil atribuído a uma tarefa é alterado após a atualização. Se o autor não tiver um perfil de uso atribuído, qualquer perfil anteriormente anexado à tarefa será removido dele.

Conceitos básicos da AWS Glue Data Catalog

O AWS Glue Data Catalog é seu armazenamento persistente de metadados técnicos. É um serviço gerenciado que você pode usar para armazenar, anotar e compartilhar metadados na Nuvem AWS. Para ter mais informações, consulte AWS Glue Data Catalog.

O console do AWS Glue e algumas interfaces do usuário foram atualizadas recentemente.

Visão geral

É possível usar este tutorial para criar o primeiro Catálogo de dados AWS Glue, que usa um bucket do Amazon S3 como origem de dados.

Neste tutorial, você fará o seguinte usando o console do AWS Glue:

1. Criar um banco de dados.
2. Criar uma tabela
3. Usar um bucket do Amazon S3 como fonte de dados

Após concluir essas etapas, você terá usado com êxito um bucket do Amazon S3 como fonte de dados para preencher o Catálogo de dado AWS Glue.

Etapa 1: criar um banco de dados

Para começar, faça login no AWS Management Console e abra o console do AWS Glue.

Para criar um banco de dados usando o console do AWS Glue:

1. No console do AWS Glue, escolha Databases (Bancos de dados) em Data catalog (Catálogo de dados) no menu à esquerda.
2. Selecione Adicionar banco de dados.
3. Na página Criar um banco de dados, insira um nome para o banco de dados. Na seção Localização - opcional, defina a localização do URI para uso pelos clientes do catálogo de dados. Se não souber, você poderá continuar com a criação do banco de dados.
4. (Opcional). Insira uma descrição para o banco de dados.
5. Selecione Criar banco de dados.

Parabéns, você acabou de configurar seu primeiro banco de dados usando o console AWS Glue. Seu novo banco de dados aparecerá na lista de bancos de dados disponíveis. Você pode editar o banco de dados escolhendo o nome do banco de dados no painel Bancos de dados.

Próximas etapas

Outras formas de criar um banco de dados:

Você acabou de criar um banco de dados usando o console AWS Glue, mas existem outras maneiras de criar um banco de dados:

- Você pode usar crawlers para criar um banco de dados e tabelas para você automaticamente. Para configurar um banco de dados usando crawlers, consulteTrabalhar com crawlers no console AWS Glue.
- Você pode usar os modelos AWS CloudFormation. Consulte Criar recursos AWS Glue usando modelos AWS Glue Data Catalog.
- Você também pode criar um banco de dados usando as AWS Glueoperações de API do banco de dados.

  Para criar um banco de dados usando a operação `create`, estruture a solicitação, incluindo os parâmetros `DatabaseInput` (obrigatórios).

  Por exemplo:

  Veja a seguir exemplos de como você pode usar a CLI, Boto3 ou DDL para definir uma tabela com base no mesmo arquivo flight_data.csv do bucket do S3 usado no tutorial.

  CLI

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

  Boto3

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

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

```
)
```

Para obter mais informações sobre os tipos de dados, estrutura e operações da API do banco de dados, consulte API do banco de dados.

Próximas etapas

Na próxima seção, você criará uma tabela e adicionará essa tabela ao banco de dados.

Você também pode explorar as configurações e permissões do seu Catálogo de dados. Consulte Trabalhar com configurações de catálogo de dados no console AWS Glue.

Etapa 2. Criar uma tabela

Nesta etapa, você cria uma tabela usando o console AWS Glue.

1. No console AWS Glue, escolha Tables (Tabelas) no menu à esquerda.
2. Escolha Add table (Adicionar tabela).
3. Defina as propriedades da tabela inserindo um nome para a tabela em Table details (Detalhes da tabela).
4. No seção Databases (Banco de dados), escolha no menu suspenso o banco de dados que criou na Etapa 1.
5. Na seção Add a data store (Adicionar um datastore), a opção S3 será selecionada por padrão como o tipo de fonte.
6. Em Data is located in (Dados localizados em), escolha Specified path in another account (Caminho especificado em outra conta).
7. Copie e cole o caminho para o campo de entrada Include path (Incluir caminho):

   ```
   s3://crawler-public-us-west-2/flight/2016/csv/
   ```
8. Na seção Data format (Formato de dados), para Classification (Classificação), escolha CSV e para Delimiter (Delimitador), escolha comma (,) (vírgula [,]). Escolha Próximo.
9. Será solicitado que você defina um esquema. O esquema define a estrutura e o formato de um registro de dados. Selecione Add column (Adicionar coluna). (Para obter mais informações, consulte Schema registries (Registros de esquema).
10. Especifique as propriedades da coluna:

a. Insira um nome de coluna.
b. Para o Column type (Tipo de coluna), 'string' já está selecionada por padrão.
c. Para o Column number (Número da coluna), 'string' já está selecionada por padrão.
d. Escolha Adicionar.

11. Você é solicitado a adicionar índices de partição. Isso é opcional. Para pular esta etapa, escolha, escolha Next (Próximo).
12. Um resumo das propriedades da tabela é exibido. Se tudo estiver conforme o esperado, escolha Criar. Caso contrário, escolha Voltar e faça edições conforme for necessário.

Parabéns, você criou uma tabela manualmente e a associou a um banco de dados. Sua tabela recém-criada aparecerá no painel Tabelas. No painel, você pode modificar e gerenciar suas tabelas.

Para obter mais informações, consulte Working with Tables (Trabalhar com tabelas) no console AWS Glue.

Next steps (Próximas etapas)

Next steps (Próximas etapas)

Agora que o Catálogo de dados está preenchido, você pode começar a criar trabalhos no AWS Glue. Consulte Criar trabalhos de ETL visual com o AWS Glue Studio.

Além de usar o console, há outras maneiras de definir tabelas no Catálogo de dados, incluindo:

- Criar e executar um crawler
- Adicionar classificadores a um crawler no AWS Glue
- Usar a API da tabelaAWS Glue
- Usar o modelo AWS Glue Data Catalog
- Migrar um metastore do Apache Hive
- Usar o AWS CLI, Boto3 ou linguagem de definição de dados (DDL)

  Veja a seguir exemplos de como você pode usar a CLI, Boto3 ou DDL para definir uma tabela com base no mesmo arquivo flight_data.csv do bucket do S3 usado no tutorial.

  Consulte a documentação sobre como estruturar um comando AWS CLI. O exemplo de CLI contém a sintaxe JSON para o valor '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.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'
    }
    }
)
```

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')
```

Configurar o acesso de rede aos armazenamentos de dados

Para executar trabalhos de extração, transformação e carregamento (ETL), o AWS Glue precisa de acesso aos armazenamentos de dados. Se não for necessário executar um trabalho na sub-rede da sua nuvem privada virtual (VPC), por exemplo: transformação de dados do Amazon S3 para o Amazon S3, nenhuma configuração adicional será necessária.

Se for necessário executar um trabalho na sub-rede de sua VPC, por exemplo, transformar dados de um armazenamento de dados JDBC em uma sub-rede privada, o AWS Glue configurará interfaces de rede elástica que permitem que os trabalhos se conectem com segurança a outros recursos dentro da sua VPC. Cada interface de rede elástica recebe um endereço IP privado do intervalo de endereços IP na sub-rede que você especificou. Nenhum endereço IP público atribuído. Grupos de segurança especificados na conexão do AWS Glue são aplicados a cada uma das interfaces de rede elásticas. Para ter mais informações, consulte Configurar um Amazon VPC para conexões JDBC aos armazenamentos de dados do Amazon RDS desde o AWS Glue.

Todos os armazenamentos de dados JDBC acessados pelo trabalho devem estar disponíveis na sub-rede da VPC. Para acessar o Amazon S3 na sua VPC, é necessário ter um endpoint da VPC. Se o seu trabalho precisar acessar recursos da VPC e a Internet pública, a VPC precisará conter uma instância de gateway NAT (Network Address Translation).

Um trabalho ou endpoint de desenvolvimento pode acessar somente uma VPC (e sub-rede) por vez. Se você precisar acessar armazenamentos de dados em várias VPCs, as opções são as seguintes:

- Use o emparelhamento de VPCs para acessar os armazenamentos de dados. Para obter mais informações sobre o emparelhamento de VPCs, consulte Conceitos básicos sobre o emparelhamento de VPCs
- Use um bucket do Amazon S3 como um local de armazenamento intermediário. Divida o trabalho em dois, com a saída do Amazon S3 do trabalho 1 como a entrada do trabalho 2.

Para obter detalhes sobre como conectar a um armazenamento de dados do Amazon Redshift usando o Amazon VPC, consulte the section called “Configurar o Redshift”.

Para obter detalhes sobre como conectar a um armazenamento de dados do Amazon RDS usando o Amazon VPC, consulte the section called “Configurar um Amazon VPC para conectar aos armazenamentos de dados do Amazon RDS”.

Depois que as regras necessárias são definidas no Amazon VPC, você cria uma conexão no AWS Glue com as propriedades necessárias para conectar com seus armazenamentos de dados. Para obter mais informações sobre a conexão, consulte Conectar a dados.

> **Note**
>
> Configure seu ambiente de DNS para o AWS Glue. Para ter mais informações, consulte Configurar o DNS na VPC.

Tópicos

- Configurar uma VPC para se conectar ao PyPI para AWS Glue
- Configurar o DNS na VPC

Configurar uma VPC para se conectar ao PyPI para AWS Glue

O Python Package Index (PyPI) é um repositório de software para a linguagem de programação Python. Este tópico aborda os detalhes necessários para oferecer suporte ao uso de pacotes instalados pelo pip (conforme especificado pelo criador da sessão usando o sinalizador `--additional-python-modules`).

O uso de sessões interativas do AWS Glue com um conector resulta no uso da rede VPC por meio da sub-rede especificada para o conector. Consequentemente, os serviços do AWS e outros destinos de rede não estão disponíveis, a menos que você defina uma configuração especial.

As resoluções para esse problema incluem:

- Uso de um gateway da internet que seja acessível por sua sessão.
- Configuração e uso de um bucket S3 com um repositório PyPI/simple contendo o fechamento transitivo das dependências de um conjunto de pacotes.
- Uso de um repositório CodeArtifact que está espelhando o PyPI e anexado à sua VPC.

Configuração de um gateway da Internet

Os aspectos técnicos são detalhados em Casos de uso do gateway NAT, mas observe esses requisitos para usar o `--additional-python-modules`. Especificamente, o `--additional-`

`python-modules` requer acesso ao pypi.org, que é determinado pela configuração da sua VPC. Observe os seguintes requisitos:

1. A exigência de instalar módulos adicionais do python via pip install para uma sessão do usuário. Se a sessão usar um conector, sua configuração poderá ser afetada.
2. Quando um conector está sendo usado com o `--additional-python-modules`, quando a sessão é iniciada, a sub-rede associada aos `PhysicalConnectionRequirements` do conector deve fornecer um caminho de rede para alcançar pypi.org.
3. Você deve determinar se sua configuração está correta ou não.

Configurar um bucket do Amazon S3 para hospedar um repositório PyPI/simple de destino

Este exemplo configura um espelho PyPI no Amazon S3 para um conjunto de pacotes e suas dependências.

Para configurar o espelho PyPI para um conjunto de pacotes:

```
# pip download all the dependencies
pip download -d s3pypi --only-binary :all: plotly gglplot
pip download -d s3pypi --platform manylinux_2_17_x86_64 --only-binary :all: psycopg2-
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/*
```

Se você já tiver um repositório de artefatos existente, ele terá um URL de índice para uso do pip que você pode fornecer no lugar do URL de exemplo para o bucket do Amazon S3, conforme descrito acima.

Para usar o index-url personalizado, com alguns pacotes de exemplo:

```
%%configure
{
    "--additional-python-modules": "psycopg2_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"
}
```

Configurar um espelho CodeArtifact de pypi conectado à sua VPC

Para configurar um espelho:

1. Crie um repositório na mesma região da sub-rede usada pelo conector.

   Selecione `Public upstream repositories` e escolha `pypi-store`.
2. Forneça acesso ao repositório da VPC para a sub-rede.
3. Especifique o `--index-url` correto usando o `python-modules-installer-option`.

```
%%configure
{
    "--additional-python-modules": "psycopg2_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"
}
```

Para obter mais informações, consulte Use CodeArtifact from a VPC.

Configurar o DNS na VPC

Domain Name System (DNS) é um padrão por meio do qual os nomes usados na Internet são determinados de acordo com os endereços IP correspondentes. Um nome de host do DNS denomina exclusivamente um computador e consiste em um nome de host e em um nome de domínio. Os servidores DNS determinam os nomes do host DNS de acordo com os endereços IP correspondentes.

Para configurar o DNS na sua VPC, certifique-se de que os nomes de host do DNS e a resolução de DNS estão habilitados na VPC. Os atributos de rede `enableDnsHostnames` e `enableDnsSupport` da VPC precisam ser definidos como `true`. Para visualizar e modificar esses atributos, acesse o console da VPC em https://console.aws.amazon.com/vpc/.

Para obter mais informações, consulte Como usar o DNS com sua VPC. Além disso, é possível usar a AWS CLI e chamar o comando modify-vpc-attribute para configurar os atributos de rede da VPC.

> **Note**
>
> Se você estiver usando o Route 53, confirme se a sua configuração não substitui os atributos de rede do DNS.

Configurar criptografia no AWS Glue

O seguinte exemplo de fluxo de trabalho destaca as opções a serem configuradas quando você usa criptografia com AWS Glue. O exemplo demonstra o uso de chaves específicas do AWS Key Management Service (AWS KMS), mas você pode escolher outras configurações com base nas suas necessidades específicas. Esse fluxo de trabalho destaca apenas as opções que pertencem a criptografia ao configurar o AWS Glue.

1. Se o usuário do console do AWS Glue não usar uma política de permissões que permita todas as operações de API do AWS Glue (por exemplo, `"glue:*"`), verifique se as seguintes ações são permitidas:
   - `"glue:GetDataCatalogEncryptionSettings"`
   - `"glue:PutDataCatalogEncryptionSettings"`
   - `"glue:CreateSecurityConfiguration"`
   - `"glue:GetSecurityConfiguration"`
   - `"glue:GetSecurityConfigurations"`
   - `"glue:DeleteSecurityConfiguration"`
2. Qualquer cliente que acesse ou grave em um catálogo criptografado, ou seja, qualquer usuário do console, crawler, trabalho ou endpoint de desenvolvimento, precisa das permissões a seguir.

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

3. Qualquer usuário ou função que acesse uma senha de conexão criptografada precisa das permissões a seguir.

```
{
 "Version": "2012-10-17",
```

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

4. A função de qualquer trabalho de extração, transformação e carregamento (ETL) que grave dados criptografados no Amazon S3 precisa das permissões a seguir.

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

5. Qualquer crawler ou trabalho de ETL que grave Amazon CloudWatch Logs criptografados requer as permissões a seguir nas políticas de chave e do IAM.

   Na política de chave (não na política do 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>"
```

```
 }
```

Para obter mais informações sobre políticas de chave, consulte Usar políticas de chave no AWS KMS no Guia do desenvolvedor do AWS Key Management Service.

Na política do IAM, anexe a permissão `logs:AssociateKmsKey`:

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

6. Qualquer trabalho de ETL que use um marcador de trabalho criptografado precisa das permissões a seguir.

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

7. No console do AWS Glue, selecione Settings (Configurações) no painel de navegação.
   a. Na página Data catalog settings (Configurações do catálogo de dados), criptografe o Data Catalog selecionando Metadata encryption (Criptografia de metadados). Essa opção criptografa todos os objetos no Data Catalog com a chave do AWS KMS que você escolher.
   b. Em Chave do AWS KMS, escolha aws/glue. Também é possível escolher uma chave do AWS KMS criada por você.

> **Important**
>
> O AWS Glue só oferece suporte a chaves mestras do cliente (CMKs) simétricas. A lista de chaves do AWS KMS exibe apenas chaves simétricas. No entanto, se você selecionar Escolher um ARN de chave AWS KMS, o console permitirá que você insira um ARN para qualquer tipo de chave. Certifique-se de inserir apenas ARNs para chaves simétricas.

Quando a criptografia estiver habilitada, o cliente que estiver acessando o Data Catalog deverá ter permissões do AWS KMS.

8. No painel de navegação, escolha Security configurations (Configurações de segurança). Uma configuração de segurança é um conjunto de propriedades de segurança que pode ser usado para configurar processos do AWS Glue. Em seguida, escolha Add security configuration (Adicionar configuração de segurança). Na configuração, escolha qualquer uma das opções a seguir:

   a. Selecione S3 encryption (Criptografia do S3). Para Encryption mode (Modo de criptografia), escolha SSE-KMS. Para a chave do AWS KMS, escolha aws/s3 (certifique-se de que o usuário tenha permissão para usar essa chave). Isso permite que os dados gravados pelo trabalho no Amazon S3 usem a chave do AWS KMS do AWS Glue gerenciada pela AWS.

   b. Selecione CloudWatch logs encryption (Criptografia do CloudWatch Logs) e escolha uma CMK. (Verifique se o usuário tem permissão para usar essa chave). Para obter mais informações, consulte Criptografar dados de log no CloudWatch Logs usando o AWS KMS no Guia do desenvolvedor do AWS Key Management Service.

      > **Important**
      >
      > O AWS Glue só oferece suporte a chaves mestras do cliente (CMKs) simétricas. A lista de chaves do AWS KMS exibe apenas chaves simétricas. No entanto, se você selecionar Escolher um ARN de chave AWS KMS, o console permitirá que você insira um ARN para qualquer tipo de chave. Certifique-se de inserir apenas ARNs para chaves simétricas.

   c. Selecione Advanced properties (Propriedades avançadas) e Job bookmark encryption (Criptografia do marcador de trabalho). Para a chave do AWS KMS, escolha aws/glue (certifique-se de que o usuário tenha permissão para usar essa chave). Isso habilita a

criptografia de marcadores de trabalho gravados no Amazon S3 com a chave do AWS KMS do AWS Glue.

9. No painel de navegação, escolha Connections.
   a. Escolha Add connection (Adicionar conexão) para criar uma conexão com o armazenamento de dados JDBC (Java Database Connectivity) que é o destino do seu trabalho de ETL.
   b. Para garantir que a criptografia do Secure Sockets Layer (SSL) seja usada, selecione Require SSL connection (Exigir conexão SSL) e teste a conexão.
10. No painel de navegação, escolha Tarefas.
    a. Escolha Add job (Adicionar trabalho) para criar um trabalho que transforme dados.
    b. Na definição de tarefa, escolha a configuração de segurança que você criou.
11. No console do AWS Glue, execute o trabalho sob demanda. Verifique se os dados do Amazon S3 e os CloudWatch Logs gravados pelo trabalho, e os marcadores de trabalho, estão criptografados.

Configurar redes para desenvolvimento para o AWS Glue

Para executar seus scripts de extração, transformação e carregamento (ETL) com o AWS Glue, você pode desenvolvê-los e testá-los usando um endpoint de desenvolvimento. Os endpoints de desenvolvimento não são suportados para uso com trabalhos do AWS Glue versão 2.0. Para as versões 2.0 e posteriores, o método de desenvolvimento preferido é usar o Jupyter Notebook com um dos kernels AWS Glue. Para ter mais informações, consulte the section called “Conceitos básicos das sessões interativas do AWS Glue”.

Configurar a rede para um endpoint de desenvolvimento

Ao configurar um endpoint de desenvolvimento, você especifica uma nuvem virtual privada (VPC), uma sub-rede e security groups.

> **Note**
>
> Configure seu ambiente de DNS para o AWS Glue. Para ter mais informações, consulte Configurar o DNS na VPC.

Para permitir que o AWS Glue acesse os recursos necessários, adicione uma linha na tabela de rotas da sua sub-rede para associar uma lista de prefixos para o Amazon S3 ao endpoint da VPC.

É necessário um ID de lista de prefixos para criar uma regra de grupo de segurança de saída que permita que o tráfego de uma VPC acesse um produto da AWS por meio de um endpoint da VPC. Para facilitar a conexão com um servidor de cadernos associado a esse endpoint de desenvolvimento, na máquina local, adicione uma linha à tabela de rotas para incluir um ID de gateway da Internet. Para obter mais informações, consulte VPC Endpoints. Atualize a tabela de rotas da sub-rede de modo que ela fique semelhante a esta tabela:

Destination (Destino)	Destino		
10.0.0.0/16	local		
pl-id para o Amazon S3	vpce-id		
0.0.0.0/0	igw-xxxx		

Para permitir que o AWS Glue se comunique entre seus componentes, especifique um grupo de segurança com uma regra de entrada de autorreferência para todas as portas TCP. Ao criar uma regra de autorreferência, você pode restringir a origem ao mesmo security group na VPC e fechá-la para todas as redes. O security group padrão para sua VPC pode já conter uma regra de entrada de autorreferenciada para ALL Traffic.

Para configurar um security group

1. Faça login no AWS Management Console e abra o console do Amazon EC2 em https://console.aws.amazon.com/ec2/.
2. No painel de navegação esquerdo, escolha Security Groups.
3. Escolha um security group existente na lista ou Create Security Group para usar com o endpoint de desenvolvimento.
4. No painel do security group, navegue até a guia Inbound.
5. Adicione uma regra de autorreferência para permitir que os componentes do AWS Glue se comuniquem. Especificamente, adicione ou confirme que existe uma regra de Type `All TCP`, que Protocol é `TCP`, Port Range inclui todas as portas e Source e Group ID apresentam o mesmo nome de security group.

   A regra de entrada é semelhante a esta:

Tipo	Protocolo	Intervalo de portas	Origem
Todos os TCP	TCP	0–65535	*security-group*

Veja a seguir um exemplo de uma regra de entrada de autorreferência:

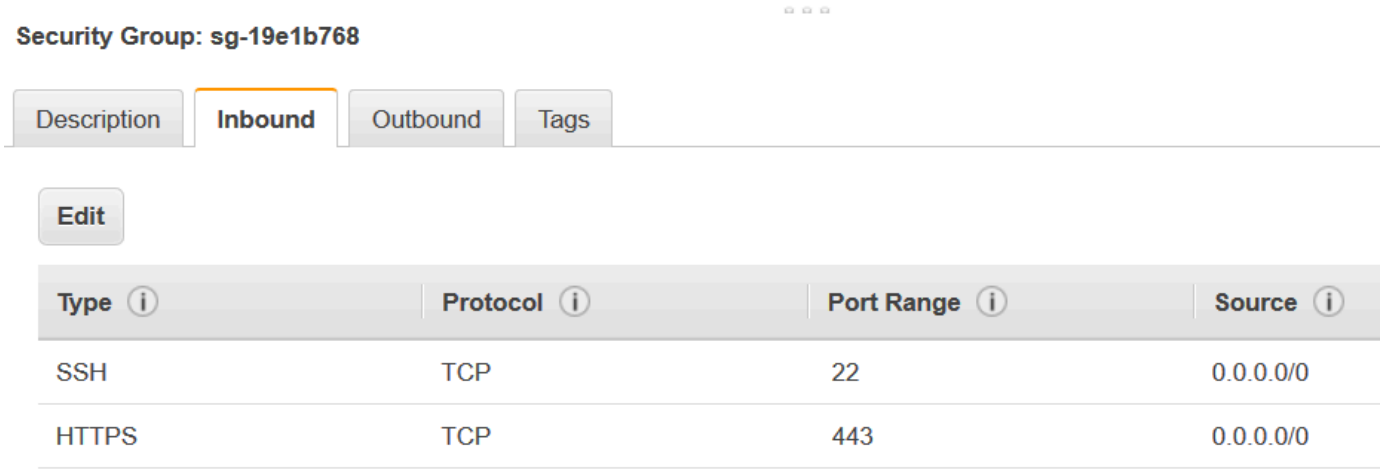

6. Adicione uma regra para o tráfego de saída também. Abra um tráfego de saída para todas as portas ou crie uma regra de autorreferência de Type `All TCP`. Protocol deve ser `TCP`, Port Range deve incluir todas as portas e Source e Group ID devem apresentar o mesmo nome de security group.

   A regra de saída é semelhante a uma dessas regras:

Tipo	Protocolo	Intervalo de portas	Destination (Destino)
Todos os TCP	TCP	0–65535	*security-group*
Todo o tráfego	ALL	ALL	0.0.0.0/0

Configurar o Amazon EC2 para um servidor de cadernos

Com um endpoint de desenvolvimento, você pode criar um servidor de caderno para testar seus scripts de ETL com cadernos Jupyter. Para ativar a comunicação com seu notebook, especifique um security group com regras de entrada para HTTPS (porta 443) e SSH (porta 22). Verifique se a origem da regra é 0.0.0.0/0 ou o endereço IP da máquina que está se conectando ao notebook.

Para configurar um security group

1. Faça login no AWS Management Console e abra o console do Amazon EC2 em https://console.aws.amazon.com/ec2/.
2. No painel de navegação esquerdo, escolha Security Groups.
3. Escolha um security group existente na lista ou Create Security Group para usar com o servidor de notebook. O security group associado ao seu endpoint de desenvolvimento também é usado para criar seu servidor de notebook.
4. No painel do security group, navegue até a guia Inbound.
5. Adicione regras de entrada semelhantes a esta:

Tipo	Protocolo	Intervalo de portas	Origem
SSH	TCP	22	0.0.0.0/0
HTTPS	TCP	443	0.0.0.0/0

Veja a seguir um exemplo das regras de entrada para o security group:

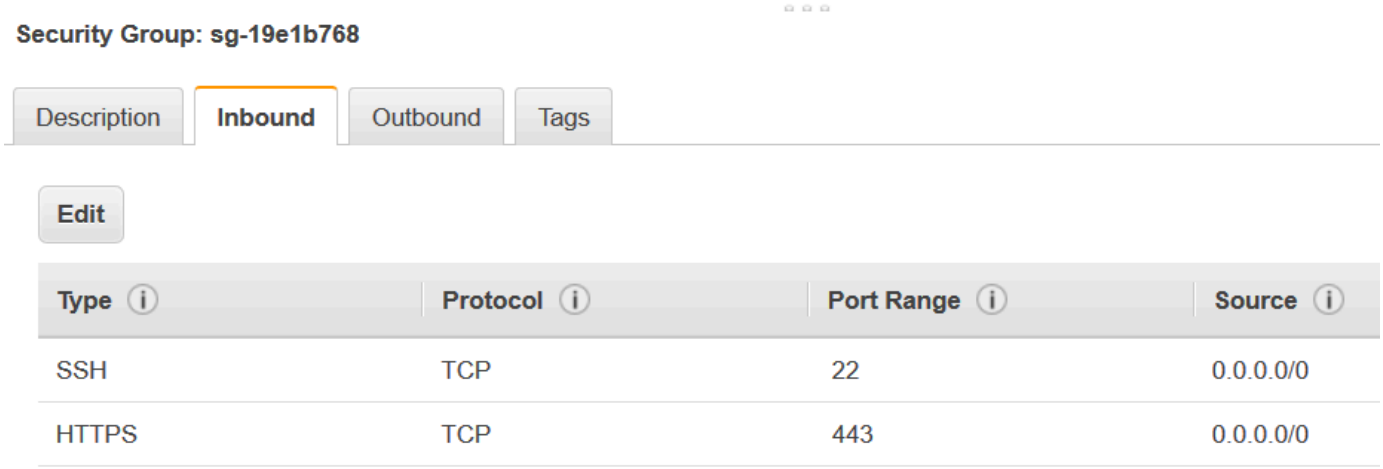

Descoberta e catalogação de dados no AWS Glue

O AWS Glue Data Catalog é um repositório centralizado que armazena metadados sobre os conjuntos de dados da sua organização. Ele funciona como um índice para métricas de localização, esquema e runtime das suas fontes de dados. Os metadados são armazenados em tabelas de metadados, onde cada tabela representa um único armazenamento de dados.

O Catálogo de Dados pode ser preenchido com a ajuda de um crawler, que verifica automaticamente suas fontes de dados e extrai metadados. Um crawler pode se conectar a fontes de dados internas (baseadas na AWS) e externas à AWS.

Para obter mais informações sobre as fontes de dados compatíveis, consulte Fontes de dados compatíveis para crawling.

Também é possível criar tabelas no Catálogo de Dados manualmente definindo a estrutura da tabela, o esquema e a estrutura de particionamento de acordo com seus requisitos específicos.

Para obter mais informações sobre como criar manualmente tabelas de bancos de dados, consulte Definir metadados manualmente.

Use as informações no Catálogo de Dados para criar e monitorar seus trabalhos de ETL. O Catálogo de Dados se integra a outros serviços de analytics da AWS, fornecendo uma visão unificada das fontes de dados e facilitando o gerenciamento e a análise de dados.

- Amazon Athena: armazene e consulte metadados da tabela no Catálogo de Dados para os dados do Amazon S3 usando SQL.
- AWS Lake Formation: defina e gerencie centralmente políticas refinadas de acesso a dados e audite o acesso aos dados.
- Amazon EMR: acesse fontes de dados definidas no Catálogo de Dados para processamento de big data.
- Amazon SageMaker AI: crie, treine e implemente modelos de machine learning com rapidez e confiança.

Principais recursos do Catálogo de Dados

A seguir estão os principais aspectos do Catálogo de Dados.

Repositório de metadados

O Catálogo de Dados atua como um repositório central de metadados, armazenando informações sobre a localização, o esquema e as propriedades das suas fontes de dados. Esses metadados são organizados em bancos de dados e tabelas de forma semelhante a um catálogo de banco de dados relacional tradicional.

Descoberta automática de dados

Os Crawler do AWS Glues podem descobrir e catalogar automaticamente fontes de dados novas ou atualizadas, reduzindo a sobrecarga do gerenciamento manual de metadados e garantindo que seu Catálogo de Dados permaneça atualizado. Ao catalogar suas fontes de dados, o Catálogo de Dados facilita que usuários e aplicações descubram e entendam os ativos de dados disponíveis em sua organização, promovendo a reutilização e a colaboração de dados.

O catálogo de dados oferece suporte a uma ampla variedade de fontes de dados, incluindo Amazon S3, Amazon RDS, Amazon Redshift, Apache Hive e muito mais. Ele pode inferir e armazenar automaticamente metadados dessas fontes usando Crawler do AWS Glues.

Para obter mais informações, consulte Usar crawlers para preencher o catálogo de dados .

Gerenciamento de esquemas

O Catálogo de Dados captura e gerencia automaticamente o esquema de suas fontes de dados, incluindo inferência, evolução e controle de versão do esquema. É possível atualizar os esquemas e as partições no Catálogo de Dados usando trabalhos do AWS Glue ETL.

Otimização de tabelas

Para obter uma melhor performance de leitura por serviços de analytics da AWS, como o Amazon Athena e o Amazon EMR e trabalhos de ETL do AWS Glue, o Catálogo de Dados oferece compactação gerenciada (um processo que compacta pequenos objetos do Amazon S3 em objetos maiores) para tabelas do Iceberg no Catálogo de Dados. Você pode usar o console do AWS Glue, o console do AWS Lake Formation, a AWS CLI ou a API da AWS para habilitar ou desabilitar a compactação de tabelas individuais do Iceberg que estão no Catálogo de Dados.

Para obter mais informações, consulte Otimizar tabelas Iceberg.

Estatísticas de colunas

Você pode calcular estatísticas em nível de coluna para tabelas do Catálogo de Dados em formatos de dados como Parquet, ORC, JSON, ION, CSV e XML sem precisar configurar

pipelines de dados adicionais. As estatísticas de colunas ajudam você a entender os perfis de dados obtendo insights sobre os valores em uma coluna. O Catálogo de Dados possibilita a geração de estatísticas para valores de colunas, como valor mínimo, valor máximo, valores nulos totais, valores distintos totais, comprimento médio dos valores e ocorrências totais de valores reais.

Para obter mais informações, consulte Otimizar a performance da consulta usando estatísticas de coluna.

Linhagem de dados

O Catálogo de Dados mantém um registro das transformações e operações realizadas em seus dados, fornecendo informações sobre a linhagem de dados. Essas informações de linhagem são valiosas para auditoria, conformidade e compreensão da proveniência dos dados.

Integração com outros serviços da AWS

O catálogo de dados se integra perfeitamente a outros serviços da AWS, como AWS Lake Formation, Amazon Athena, Amazon Redshift Spectrum e Amazon EMR. Essa integração permite que você consulte e analise dados em vários armazenamentos de dados usando uma camada de metadados única e consistente.

Segurança e controle de acesso

O AWS Glue se integra ao AWS Lake Formation para oferecer suporte ao controle de acesso refinado aos recursos do Catálogo de Dados, permitindo que você gerencie permissões e proteja o acesso aos seus ativos de dados com base nas políticas e requisitos da sua organização. O AWS Glue se integra ao AWS Key Management Service (AWS KMS) para criptografar metadados armazenados no Catálogo de Dados.

Tópicos

- Preencher o AWS Glue Data Catalog
- Preencher e gerenciar tabelas transacionais
- Gerenciar o Catálogo de Dados
- Acessar o Catálogo de Dados
- Práticas recomendadas do Catálogo de Dados do AWS Glue
- Monitorar métricas de uso do Catálogo de Dados do Amazon CloudWatch
- Registro de esquemas do AWS Glue

Preencher o AWS Glue Data Catalog

É possível preencher o AWS Glue Data Catalog usando os seguintes métodos:

- Crawler do AWS Glue: um Crawler do AWS Glue pode descobrir e catalogar automaticamente fontes de dados, como bancos de dados, data lakes e dados de streaming. Os crawlers são o método mais comum e recomendado para preencher o Catálogo de Dados, pois eles podem descobrir e inferir automaticamente metadados de uma ampla variedade de fontes de dados.
- Adicionar metadados manualmente: é possível definir manualmente bancos de dados, tabelas e detalhes de conexão e adicioná-los ao Catálogo de Dados usando o console do AWS Glue, o console do Lake Formation, a AWS CLI ou as APIs do AWS Glue. A entrada manual é útil quando você deseja catalogar fontes de dados que não podem ser obtidas por crawling.
- Integração com outros serviços da AWS: é possível preencher o catálogo de dados com metadados de serviços como o AWS Lake Formation e o Amazon Athena. Esses serviços podem descobrir e registrar fontes de dados no Catálogo de Dados.
- Preencher a partir de um repositório de metadados existente: se você tiver um repositório de metadados existente, como o Apache Hive Metastore, poderá usar o AWS Glue para importar esses metadados para o Catálogo de Dados. Para obter mais informações, consulte Migração entre o Hive Metastore e o AWS Glue Data Catalog no GitHub.

Tópicos

- Usar crawlers para preencher o catálogo de dados
- Definir metadados manualmente
- Integração a outros serviços da AWS
- Configurações do Catálogo de Dados

Usar crawlers para preencher o catálogo de dados

Você pode usar um Crawler do AWS Glue para preencher o AWS Glue Data Catalog com bancos de dados e tabelas. Este é o principal método usado pela maioria dos usuários do AWS Glue. Um crawler pode rastrear vários armazenamentos de dados em uma única execução. Após a conclusão, o crawler cria ou atualiza uma ou mais tabelas no Data Catalog. As tarefas de extração, transformação e carregamento (ETL) que você define no AWS Glue usam essas tabelas do Data Catalog como fontes e destinos. O trabalho de ETL lê e grava os armazenamentos de dados que são especificados nas tabelas do Data Catalog de fonte e de destino.

Fluxo de trabalho

O seguinte diagrama de fluxo de trabalho mostra como os crawlers do AWS Glue interagem com os armazenamentos de dados e outros elementos para preencher o Data Catalog.

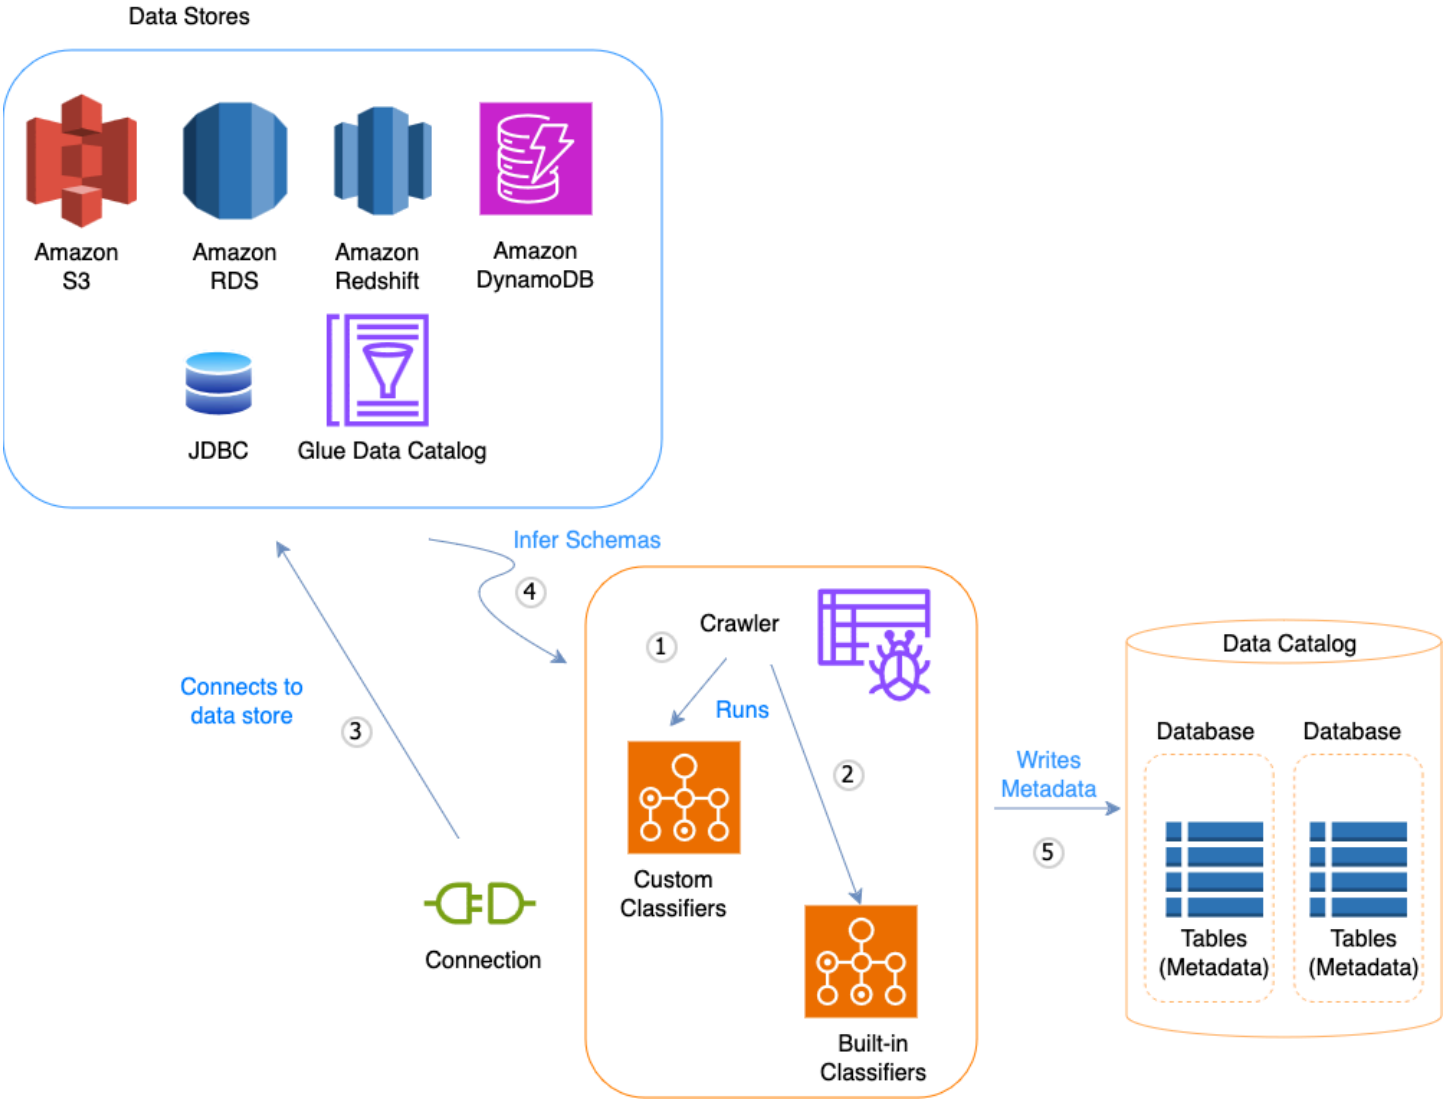

Veja a seguir o fluxo de trabalho geral sobre como um crawler preenche o AWS Glue Data Catalog:

1. Um crawler executa todos os classificadores personalizados que você escolhe para inferir o formato e o esquema dos seus dados. Você fornece o código para classificadores personalizados, e eles são executados na ordem especificada.

   O primeiro classificador personalizado a reconhecer com sucesso a estrutura de dados é usado para criar um esquema. Os classificadores personalizados em posições inferiores na lista são ignorados.

2. Se nenhum classificador personalizado corresponder ao esquema dos seus dados, os classificadores integrados tentarão reconhecê-lo. Um exemplo de um classificador integrado é um que reconhece JSON.
3. O crawler se conecta ao armazenamento de dados. Alguns armazenamentos de dados requerem propriedades de conexão para o acesso ao crawler.
4. O esquema inferido é criado para os seus dados.
5. O crawler grava os metadados no Data Catalog. Uma definição de tabela contém metadados sobre os dados no seu armazenamento de dados. A tabela é gravada em um banco de dados, que é um contêiner de tabelas no Data Catalog. Os atributos de uma tabela incluem a classificação, que é um rótulo criado pelo classificador que inferiu o esquema da tabela.

Tópicos

- Como funcionam os crawlers
- Como um crawler determina quando criar partições?
- Fontes de dados compatíveis para crawling
- Pré-requisitos do crawler
- Definir e gerenciar classificadores
- Configurar um crawler
- Programar um crawler
- Visualizar resultados e detalhes do crawler
- Personalizar o comportamento do Crawler
- Tutorial: Adicionar um crawler do AWS Glue

Como funcionam os crawlers

Quando um crawler é executado, ele obtém as ações a seguir para interrogar um armazenamento de dados:

- Classifica dados para determinar o formato, o esquema e as propriedades associadas de dados brutos – Você pode configurar os resultados de classificação criando um classificador personalizado.
- Agrupa dados em tabelas ou partições – Os dados são agrupados com base na heurística do crawler.

- Grava metadados no Data Catalog: você pode configurar como o crawler adiciona, atualiza e exclui tabelas e partições.

Ao definir um crawler, você escolhe um ou mais classificadores que avaliam o formato dos seus dados para inferir um esquema. Quando o crawler é executado, o primeiro classificador da sua lista a reconhecer com sucesso seu armazenamento de dados é usado para criar um esquema para a sua tabela. Você pode usar classificadores integrados ou definir o seu próprio. Você define os classificadores personalizados em uma operação separada, antes de definir os rastreamentos. O AWS Glue fornece classificadores integrados para inferir esquemas de arquivos comuns com formatos que incluem JSON, CSV e Apache Avro. Para ver a lista atual de classificadores integrados no AWS Glue, consulte Classificadores integrados.

As tabelas de metadados que um crawler cria ficam contidas em um banco de dados quando você define um crawler. Se o seu crawler não especificar um banco de dados, suas tabelas serão colocadas no banco de dados padrão. Além disso, cada tabela possui uma coluna de classificação preenchida pelo primeiro classificador que reconheceu com sucesso o armazenamento de dados.

Se o arquivo rastreado estiver compactado, o crawler precisará fazer download dele para processá-lo. Quando um crawler é executado, ele interroga os arquivos para determinar seu formato e tipo de compactação e grava essas propriedades no Data Catalog. Alguns formatos de arquivo (por exemplo, Apache Parquet) permitem que você compacte partes do arquivo à medida que ele é gravado. Para esses arquivos, os dados compactados são um componente interno do arquivo e o AWS Glue não preenche a propriedade `compressionType` quando grava tabelas no Data Catalog. Por outro lado, se um arquivo inteiro for compactado por um algoritmo de compactação (por exemplo, gzip), a propriedade `compressionType` será preenchida quando as tabelas forem gravadas no Data Catalog.

O crawler gera os nomes das tabelas que ele cria. Os nomes das tabelas armazenadas no AWS Glue Data Catalog obedecem a estas regras:

- São permitidos somente caracteres alfanuméricos e sublinhados (_).
- Prefixos personalizados não podem conter mais do que 64 caracteres.
- O comprimento máximo do nome não pode ser superior a 128 caracteres. O crawler trunca nomes gerados para ajustá-los de acordo com o limite.
- Se forem encontrados nomes de tabelas duplicados, o crawler adicionará um sufixo de string hash a esse nome.

Se seu crawler for executado mais de uma vez (talvez em uma programação), ele procurará arquivos ou tabelas novos ou alterados no seu armazenamento de dados. A saída do crawler inclui novas tabelas e partições encontradas desde a execução anterior.

Como um crawler determina quando criar partições?

Quando um crawler do AWS Glue examina o armazenamento de dados do Amazon S3 e detecta várias pastas em um bucket, ele determina a raiz de uma tabela na estrutura de pastas e quais pastas são partições de uma tabela. O nome da tabela é baseado no prefixo do Amazon S3 ou no nome da pasta. Você fornece um Include path (caminho de inclusão) que indica o nível da pasta a ser rastreada. Quando a maioria dos esquemas em um nível de pasta é semelhante, o crawler cria partições de uma tabela em vez de duas tabelas separadas. Para influenciar o crawler a criar tabelas separadas, adicione a pasta raiz de cada tabela como um repositório de dados separado ao definir o crawler.

Por exemplo, considere a seguinte estrutura de pastas do Amazon S3.

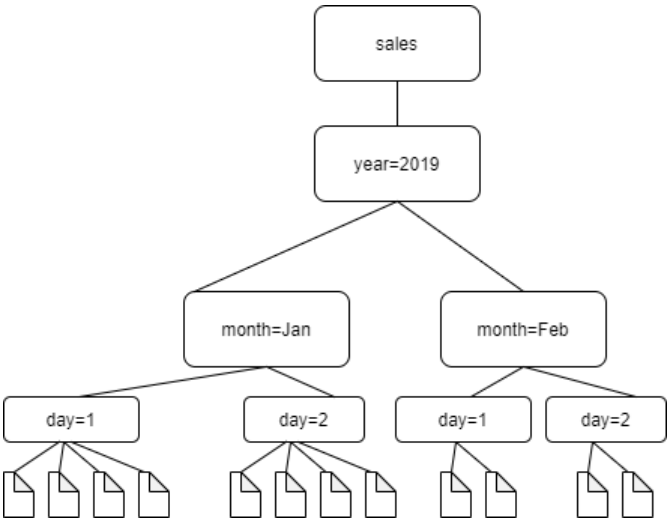

Os caminhos para as quatro pastas de nível mais baixo são os seguintes:

```
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
```

Suponha que o destino do crawler esteja definido em `Sales` e que todos os arquivos no `day=`*n* têm o mesmo formato (por exemplo, JSON, não criptografado) e têm os mesmos esquemas, ou esquemas muito semelhantes. O crawler criará uma única tabela com quatro partições, com chaves de partição `year`, `month` e `day`.

No exemplo a seguir, considere a seguinte estrutura do Amazon S3:

```
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
```

Se os esquemas para arquivos em `table1` e `table2` forem semelhantes e um único armazenamento de dados estiver definido no crawler com Include path (Caminho de inclusão) `s3://bucket01/folder1/`, o crawler cria uma única tabela com duas colunas de chave de partição. A primeira coluna de chave de partição contém `table1` e `table2`, e a segunda coluna de chave de partição contém `partition1` a `partition3` para a partição da `table1` e `partition4` e `partition5` para a partição da `table2`. Para criar duas tabelas separadas, defina o crawler com dois armazenamentos de dados. Neste exemplo, defina o primeiro Include path (Caminho de inclusão) como `s3://bucket01/folder1/table1/`, e o segundo como `s3://bucket01/folder1/table2`.

> **Note**
>
> No Amazon Athena, cada tabela corresponde a um prefixo do Amazon S3 com todos os objetos nele. Se os objetos têm diferentes esquemas, o Athena não reconhece os objetos diferentes no mesmo prefixo como tabelas separadas. Isso pode acontecer se um crawler criar várias tabelas a partir do mesmo prefixo do Amazon S3. Isso pode levar a consultas no Athena que retornam zero resultados. Para que o Athena reconheça e consulte corretamente as tabelas, crie o crawler com um Include path (Caminho de inclusão) separado para cada esquema de tabela diferente na estrutura de pastas do Amazon S3. Para obter mais informações, consulte Práticas recomendadas ao usar o Athena com o AWS Glue e este artigo da Central de Conhecimento da AWS.

Fontes de dados compatíveis para crawling

Os crawlers podem rastrear os seguintes armazenamentos de dados baseados em arquivos e baseados em tabelas.

Tipo de acesso que o crawler usa	Armazenamentos de dados
Cliente nativo	• Amazon Simple Storage Service (Amazon S3) • Amazon DynamoDB • Lago Delta 2.0.x • Apache Iceberg 1.5 • Apache Hudi 0.14
JDBC	Amazon Redshift Snowflake No Amazon Relational Database Service (Amazon RDS) ou externo ao Amazon RDS: • Amazon Aurora • MariaDB • Microsoft SQL Server • MySQL • Oracle • PostgreSQL
Cliente MongoDB	• MongoDB • MongoDB Atlas • Amazon DocumentDB (compatível com MongoDB)

> **Note**
>
> Atualmente, o AWS Glue não é compatível com crawlers para streams de dados.

Para armazenamentos de dados JDBC, MongoDB, MongoDB Atlas e Amazon DocumentDB (compatível com MongoDB), você deve especificar uma conexão do AWS Glue que o crawler possa usar para se conectar ao datastore. Para o Amazon S3, você pode especificar opcionalmente

uma conexão do tipo Network (Rede). Uma conexão é um objeto do Data Catalog que armazena informações de conexão, como credenciais, URL, informações da Amazon Virtual Private Cloud e muito mais. Para ter mais informações, consulte Conectar a dados.

As seguintes versões de drivers são compatíveis com o crawler:

Produto	Driver compatível com crawler
PostgreSQL	42.2.1
Amazon Aurora	O mesmo que os drivers de crawler nativos
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
MongoDB Atlas	4.7.2

Veja a seguir observações sobre os vários armazenamentos de dados.

Amazon S3

Você pode escolher rastrear um caminho na sua conta ou em outra. Se todos os arquivos do Amazon S3 em uma pasta tiverem o mesmo esquema, o crawler criará uma tabela. Além disso, se o objeto do Amazon S3 for particionado, apenas uma tabela de metadados será criada e as informações da partição serão adicionadas ao Data Catalog para essa tabela.

Amazon S3 e Amazon DynamoDB

Os crawlers usam uma função do AWS Identity and Access Management (IAM) para conceder permissão de acesso aos armazenamentos de dados. A função que você transmite ao crawler

precisa ter permissão para acessar os caminhos do Amazon S3 e as tabelas do Amazon DynamoDB que serão rastreados.

Amazon DynamoDB

Ao definir um crawler usando o console do AWS Glue, você especifica uma tabela do DynamoDB. Se você estiver usando a API do AWS Glue, pode especificar uma lista de tabelas. Você pode optar por rastrear apenas uma pequena amostra dos dados, para reduzir os tempos de execução do crawler.

Delta Lake

Para cada datastore Delta Lake, é necessário especificar como criar tabelas do Delta:

- Criar tabelas nativas: permite a integração com mecanismos de consulta compatíveis com consultas diretas ao log de transações do Delta. Para obter mais informações, consulte Consultar tabelas do Delta Lake.
- Criar tabelas de link simbólico: crie uma pasta `_symlink_manifest` com arquivos de manifesto particionados pelas chaves de partição com base nos parâmetros de configuração especificados.

Iceberg

Para cada datastore do Iceberg, você especifica um caminho do Amazon S3 que contém os metadados para as tabelas do Iceberg. Se o crawler descobrir metadados da tabela do Iceberg, ele os registrará no catálogo de dados. Você pode definir uma agenda para que o crawler mantenha as tabelas atualizadas.

Você pode definir esses parâmetros para o datastore:

- Exclusões: permite que você pule determinadas pastas.
- Profundidade máxima de travessia: define o limite de profundidade que o crawler pode percorrer no bucket do Amazon S3. A profundidade de travessia máxima padrão é 10 e a profundidade máxima que você pode definir é 20.

Hudi

Para cada datastore do Hudi, você especifica um caminho do Amazon S3 que contém os metadados para as tabelas do Hudi. Se o crawler descobrir metadados da tabela do Hudi, ele os registrará no catálogo de dados. Você pode definir uma agenda para que o crawler mantenha as tabelas atualizadas.

Você pode definir esses parâmetros para o datastore:

- Exclusões: permite que você pule determinadas pastas.
- Profundidade máxima de travessia: define o limite de profundidade que o crawler pode percorrer no bucket do Amazon S3. A profundidade de travessia máxima padrão é 10 e a profundidade máxima que você pode definir é 20.

> **Note**
>
> As colunas de timestamp tendo `millis` como tipos lógicos serão interpretadas como `bigint`, devido a uma incompatibilidade com o Hudi 0.13.1 e os tipos de timestamp. Uma resolução pode ser fornecida na próxima versão do Hudi.

As tabelas do Hudi são categorizadas da seguinte forma, com implicações específicas para cada uma delas:

- Copy on Write (CoW): os dados são armazenados em um formato colunar (Parquet) e cada atualização cria uma nova versão dos arquivos durante uma gravação.
- Merge on Read (MoR): os dados são armazenados usando uma combinação de formatos colunares (Parquet) e baseados em linha (Avro). As atualizações são registradas em arquivos delta baseados em linha e são compactadas conforme necessário para criar novas versões dos arquivos colunares.

Com conjuntos de dados CoW, sempre que há uma atualização para um registro, o arquivo que contém o registro é regravado com os valores atualizados. Com um conjunto de dados MoR, sempre que há uma atualização, o Hudi grava apenas a linha do registro alterado. MoR é mais adequado para cargas de trabalho com maior volume de gravações ou alterações e menor volume de leituras. O tipo CoW é mais adequado para workloads com maior volume de leituras em dados que mudam com menos frequência.

O Hudi oferece três tipos de consulta para acessar os dados:

- Consultas de snapshot: consultas que veem o snapshot mais recente da tabela a partir de uma determinada ação de confirmação ou compactação. Para tabelas MoR, as consultas de snapshot expõem o estado mais recente da tabela mesclando os arquivos base e delta da fatia de arquivo mais recente no momento da consulta.
- Consultas incrementais: as consultas veem somente os novos dados gravados na tabela, a partir de uma determinada confirmação/compactação. Desse modo, os streams de alteração são fornecidos para habilitar pipelines de dados incrementais.

- Ler consultas otimizadas: para tabelas de MoR, as consultas veem os dados mais recentes compactados. Para tabelas CoW, as consultas veem os dados mais recentes confirmados.

Para tabelas Copy-On-Write, os crawlers criam uma única tabela no catálogo de dados com o serde ReadOptimized `org.apache.hudi.hadoop.HoodieParquetInputFormat`.

Para tabelas Merge-On-Read, o crawler cria duas tabelas no catálogo de dados para o mesmo local da tabela:

- Uma tabela com sufixo `_ro` que usa o serde ReadOptimized `org.apache.hudi.hadoop.HoodieParquetInputFormat`.
- Uma tabela com sufixo `_rt` que usa o serde RealTime permitindo consultas instantâneas: `org.apache.hudi.hadoop.realtime.HoodieParquetRealtimeInputFormat`.

MongoDB e Amazon DocumentDB (compatível com MongoDB)

O MongoDB versões 3.2 e posteriores são compatíveis. Você pode optar por rastrear apenas uma pequena amostra dos dados, para reduzir os tempos de execução do crawler.

Banco de dados relacional

A autenticação é realizada com um nome de usuário e senha do banco de dados. Dependendo do tipo de mecanismo de banco de dados, você pode escolher quais objetos são rastreados, como bancos de dados, esquemas e tabelas.

Snowflake

O crawler JDBC do Snowflake é compatível com crawling da tabela, da tabela externa, da visão e da visão materializada. A definição de visão materializada não será preenchida.

Em tabelas externas do Snowflake, o crawler só fará o rastreamento se apontar para um local do Amazon S3. Além do esquema da tabela, o crawler também rastreará o local, o formato do arquivo e a saída do Amazon S3 como parâmetros da tabela do Data Catalog. Observe que as informações de partição da tabela externa particionada não são preenchidas.

Atualmente, o ETL não é compatível com tabelas do Data Catalog criadas usando o crawler do Snowflake.

Pré-requisitos do crawler

O crawler assume as permissões da função do AWS Identity and Access Management (IAM) que você especificou ao defini-lo. Essa função do IAM precisa ter permissões para extrair dados do

seu armazenamento de dados e gravar no Data Catalog. O console do AWS Glue lista somente as funções do IAM com uma política de confiança anexada para o serviço da entidade principal AWS Glue. No console, você também pode criar uma função do IAM com uma política do IAM para acessar o armazenamento de dados do Amazon S3 que é acessado pelo crawler. Para obter mais informações sobre como fornecer funções ao AWS Glue, consulte Políticas baseadas em identidade para Glue AWS.

> **Note**
>
> Para fazer o crawling de um armazenamento de dados do Delta Lake, é necessário ter permissões de leitura/gravação para o local do Amazon S3.

Para o crawler, você pode criar uma função e anexar as seguintes políticas:

- A política `AWSGlueServiceRole` gerenciada pela AWS, que concede as permissões necessárias no Data Catalog
- Uma política em linha que concede permissões na origem dos dados.
- Uma política em linha que concede permissões `iam:PassRole` no perfil.

Uma abordagem mais rápida é permitir que o assistente do crawler do console do AWS Glue crie uma função para você. A função que ele cria é especificamente para o crawler e inclui a política `AWSGlueServiceRole` gerenciada pela AWS e mais a política em linha necessária para a origem dos dados especificada.

Se você especificar uma função existente para um crawler, certifique-se de que ela inclua a política `AWSGlueServiceRole` ou equivalente (ou uma versão dessa política com um escopo reduzido), além das políticas em linha necessárias. Por exemplo, para um armazenamento de dados do Amazon S3, a política em linha seria, no mínimo, a seguinte:

```
{
   "Version": "2012-10-17",
    "Statement": [
        {
          "Effect": "Allow",
          "Action": [
              "s3:GetObject"
          ],
```

```
            "Resource": [
                "arn:aws:s3:::bucket/object*"
            ]
        }
    ]
}
```

Para um armazenamento de dados do Amazon DynamoDB, a política seria, no mínimo, a seguinte:

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

E ainda, se o crawler ler os dados do Amazon S3 criptografados pelo AWS Key Management Service (AWS KMS), a função do IAM AWS KMS deverá ter permissão de descriptografia na chave do . Para ter mais informações, consulte Etapa 2: criar um perfil do IAM para o AWS Glue.

Definir e gerenciar classificadores

Um classificador lê os dados em uma armazenamento de dados. Se reconhecer o formato dos dados, ele gerará um esquema. O classificador também retornará um número de certeza para indicar o nível de certeza referente ao reconhecimento do formato.

O AWS Glue fornece um conjunto de classificadores integrados, mas você também pode criar classificadores personalizados. O AWS Glue invoca classificadores personalizados primeiro, na ordem especificada na definição do crawler. Dependendo dos resultados retornados dos classificadores personalizados, o AWS Glue também poderá invocar classificadores integrados. Se um classificador retornar `certainty=1.0` durante o processamento, ele indicará que está 100% certo sobre a criação do esquema correto. Em seguida, o AWS Glue usa a saída desse classificador.

Se nenhum classificador retornar `certainty=1.0`, o AWS Glue usará a saída do classificador que tiver a maior certeza. Se nenhum classificador retornar uma certeza maior que `0.0`, o AWS Glue retornará a string de classificação padrão `UNKNOWN`.

Quando devo usar um classificador?

Você deve usar classificadores ao fazer crawling em um armazenamento de dados para definir tabelas de metadados no AWS Glue Data Catalog. Você pode configurar seu crawler com um conjunto de classificadores ordenados. Quando o crawler invoca um classificador, o classificador determina se os dados são reconhecidos. Se o classificador não puder reconhecer os dados ou não estiver 100% certo, o crawler chamará o próximo classificador na lista para tentar reconhecer os dados.

Para obter mais informações sobre como criar um classificador usando o console do AWS Glue, consulte Criar classificadores usando o console do AWS Glue.

Classificadores personalizados

A saída de um classificador inclui uma string que indica a classificação ou o formato do arquivo (por exemplo, `json`) e o esquema dele. Para classificadores personalizados, você define a lógica de criação do esquema com base no tipo de classificador. Os tipos de classificadores incluem a definição de esquemas com base em padrões grok, tags XML e caminhos JSON.

Se você alterar uma definição de classificador, os dados que foram rastreados anteriormente usando o classificador não serão reclassificados. Um crawler monitora os dados rastreados anteriormente. Novos dados são classificados com o classificador atualizado, o que pode resultar em um esquema atualizado. Se o esquema de seus dados evoluiu, atualize o classificador para considerar quaisquer alterações de esquema quando o crawler for executado. Para reclassificar dados para corrigir um classificador incorreto, crie um novo crawler com o classificador atualizado.

Para obter mais informações sobre como criar classificadores personalizados no AWS Glue, consulte Escrever classificadores personalizados para diversos formatos de dados.

> **Note**
>
> Se seu formato de dados for reconhecido por um dos classificadores integrados, você não precisará criar um classificador personalizado.

Classificadores integrados

O AWS Glue fornece classificadores integrados para vários formatos, incluindo JSON, CSV, logs da web e diversos sistemas de banco de dados.

Se o AWS Glue não encontrar um classificador personalizado adequado para o formato de dados de entrada com 100% de certeza, ele invocará os classificadores integrados na ordem exibida na tabela a seguir. Os classificadores integrados retornam um resultado para indicar se o formato é correspondente (`certainty=1.0`) ou não (`certainty=0.0`). O primeiro classificador que tiver `certainty=1.0` fornecerá a string de classificação e o esquema para uma tabela de metadados no Data Catalog.

Tipo de classificador	String de classificação	Observações
Apache Avro	`avro`	Lê o esquema no início do arquivo para determinar o formato.
Apache ORC	`orc`	Lê os metadados do arquivo para determinar o formato.
Apache Parquet	`parquet`	Lê o esquema no final do arquivo para determinar o formato.
JSON	`json`	Lê o início do arquivo para determinar o formato.
JSON binário	`bson`	Lê o início do arquivo para determinar o formato.
XML	`xml`	Lê o início do arquivo para determinar o formato. O AWS Glue determina o esquema de tabela com base em tags XML no documento. Para obter informações sobre como criar um classificador XML personalizado para especificar linhas no documento, consulte Gravar classificadores XML personalizados.
Amazon Ion	`ion`	Lê o início do arquivo para determinar o formato.

Tipo de classificador	String de classificação	Observações
Log do Apache combinado	`combined_apache`	Determina os formatos de log por meio de um padrão grok.
Log do Apache	`apache`	Determina os formatos de log por meio de um padrão grok.
Log de kernel do Linux	`linux_kernel`	Determina os formatos de log por meio de um padrão grok.
Log da Microsoft	`microsoft_log`	Determina os formatos de log por meio de um padrão grok.
Log do Ruby	`ruby_logger`	Lê o início do arquivo para determinar o formato.
Log do Squid 3.x	`squid`	Lê o início do arquivo para determinar o formato.
Log de monitoramento do Redis	`redismonlog`	Lê o início do arquivo para determinar o formato.
Log do Redis	`redislog`	Lê o início do arquivo para determinar o formato.
CSV	`csv`	Verifica os seguintes delimitadores: vírgula (,), pipe (|), tabulação (\t), ponto e vírgula (;) e Ctrl+A (\u0001). Ctrl+A é o caractere de controle Unicode para `Start Of Heading`.
Amazon Redshift	`redshift`	Usa conexão JDBC para importar metadados.
MySQL	`mysql`	Usa conexão JDBC para importar metadados.
PostgreSQL	`postgresql`	Usa conexão JDBC para importar metadados.
Banco de dados Oracle	`oracle`	Usa conexão JDBC para importar metadados.
Microsoft SQL Server	`sqlserver`	Usa conexão JDBC para importar metadados.

Tipo de classificador	String de classificação	Observações
Amazon DynamoDB	`dynamodb`	Lê dados da tabela do DynamoDB.

Os arquivos nos seguintes formatos compactados podem ser classificados:

- (com suporte para arquivos ZIP contendo apenas um arquivo). Observe que o formato Zip não tem bom suporte em outros serviços (por causa do arquivamento).
- BZIP
- GZIP
- LZ4
- Snappy (compatível com os formatos Snappy Standard e Snappy de Hadoop nativo)

Classificador CSV integrado

O classificador CSV integrado analisa o conteúdo do arquivo CSV para determinar o esquema de uma tabela do AWS Glue. Esse classificador verifica os seguintes delimitadores:

- Vírgula (,)
- Barra vertical (|)
- Tabulação (\t)
- Ponto e vírgula (;)
- Ctrl+A (\u0001)

  Ctrl+A é o caractere de controle Unicode para `Start Of Heading`.

Para ser classificado como CSV, o esquema da tabela deve ter pelo menos duas colunas e duas linhas de dados. O classificador CSV usa um número de heurística para determinar se um cabeçalho está presente em um determinado arquivo. Se o classificador não puder determinar um cabeçalho a partir da primeira linha de dados, os cabeçalhos das colunas serão exibidos como `col1`, `col2`, `col3` e assim por diante. O classificador CSV integrado determina se é necessário inferir um cabeçalho avaliando as seguintes características do arquivo:

- Cada coluna em um possível cabeçalho é analisada como um tipo de dados STRING.
- Exceto pela última coluna, todas as colunas em um possível cabeçalho têm conteúdo com menos de 150 caracteres. Para permitir um delimitador final, a última coluna pode ficar vazia em todo o arquivo.
- Cada coluna em um possível cabeçalho deve atender aos requisitos do AWS Glue `regex` para um nome de coluna.
- A linha de cabeçalho deve ser suficientemente diferente das linhas de dados. Para determinar isso, uma ou mais linhas devem ser analisadas como diferentes do tipo STRING. Se todas as colunas forem do tipo STRING, a primeira linha de dados não será suficientemente diferente das linhas subsequentes a serem usadas como cabeçalho.

> **Note**
>
> Se o classificador CSV integrado não criar sua tabela do AWS Glue como você deseja, é possível usar uma das seguintes alternativas:
>
> - Altere os nomes das colunas no Data Catalog, defina `SchemaChangePolicy` como LOG e a configuração de saída da partição como `InheritFromTable` para futuras execuções do crawler.
> - Crie um classificador grok personalizado para analisar os dados e atribuir as colunas desejadas.
> - O classificador CSV integrado cria tabelas fazendo referência ao `LazySimpleSerDe` como a biblioteca de serialização, que é uma boa opção para inferência de tipos. No entanto, se os dados CSV contiverem strings entre aspas, edite a definição da tabela e altere a biblioteca SerDe para `OpenCSVSerDe`. Ajuste os tipos inferidos para STRING, defina `SchemaChangePolicy` como LOG e defina a configuração de saída das partições como `InheritFromTable` para futuras execuções do crawler. Para mais informações sobre bibliotecas SerDe, consulte Referência de SerDe no Manual do usuário do Amazon Athena.

Escrever classificadores personalizados para diversos formatos de dados

Você pode fornecer um classificador personalizado para classificar seus dados no AWS Glue. Você pode criar um classificador personalizado usando um padrão grok, uma tag XML, JavaScript Object Notation (JSON) ou valores separados por vírgula (CSV). Um crawler do AWS Glue chama um

classificador personalizado. Se o classificador reconhecer os dados, ele retornará a classificação e o esquema dos dados ao crawler. Você precisará definir um classificador personalizado se seus dados não coincidirem com os classificadores integrados ou se você quiser personalizar as tabelas criadas pelo crawler.

Para obter mais informações sobre como criar um classificador usando o console do AWS Glue, consulte Criar classificadores usando o console do AWS Glue.

O AWS Glue executa os classificadores personalizados antes dos classificadores integrados, na ordem que você especificar. Quando um crawler encontra um classificador que corresponde aos dados, o esquema e a string de classificação são usados na definição das tabelas gravadas no seu AWS Glue Data Catalog.

Tópicos

- Gravar classificadores grok personalizados
- Gravar classificadores XML personalizados
- Gravar classificadores JSON personalizados
- Gravar classificadores CSV personalizados

Gravar classificadores grok personalizados

Grok é uma ferramenta usada para analisar dados textuais em um determinado padrão de correspondência. Um padrão grok é um conjunto nomeado de expressões regulares (regex) que são usadas para corresponder dados uma linha por vez. O AWS Glue usa padrões grok usa para inferir o esquema dos seus dados. Quando um padrão grok corresponde aos seus dados, o AWS Glue usa esse padrão para determinar a estrutura dos seus dados e mapeá-los em campos.

O AWS Glue fornece vários padrões integrados. Se preferir, você pode definir o seu próprio padrão. Você pode criar um padrão grok usando padrões integrados e personalizados na definição do seu classificador personalizado. Você pode adaptar um padrão grok para classificar formatos de arquivos de texto personalizados.

> **Note**
>
> Classificadores grok personalizados do AWS Glue usam a biblioteca de serialização `GrokSerDe` para tabelas criadas no AWS Glue Data Catalog. Se você estiver usando o AWS Glue Data Catalog com o Amazon Athena, Amazon EMR ou Redshift Spectrum, verifique a

documentação sobre esses serviços para obter informações sobre o suporte do `GrokSerDe`. Atualmente, você pode encontrar problemas ao consultar tabelas criadas com o `GrokSerDe` no Amazon EMR e Redshift Spectrum.

Veja a seguir a sintaxe básica dos componentes de um padrão grok:

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

Os dados que correspondem ao `PATTERN` nomeado são mapeados para a coluna `field-name` no esquema, com um tipo de dados padrão de `string`. Se preferir, o tipo de dados para o campo pode ser convertido em `byte`, `boolean`, `double`, `short`, `int`, `long` ou `float` no esquema resultante.

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

Por exemplo, para converter um campo `num` para um tipo de dados `int`, você pode usar esse padrão:

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

Os padrões podem ser compostos por outros padrões. Por exemplo, você pode ter um padrão para um time stamp `SYSLOG` que é definido por padrões de mês, dia e horário, como `Feb 1 06:25:43`. Para esses dados, você pode definir o padrão a seguir:

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

> **Note**
>
> Os padrões grok podem processar somente uma linha por vez. Padrões de várias linhas não são compatíveis. Além disso, as quebras de linha dentro de um padrão não são compatíveis.

Valores personalizados para o classificador grok

Ao definir um classificador grok, forneça os seguintes valores para criar o classificador personalizado.

Nome

Nome do classificador.

Classificação

A string de texto que é escrita para explicar o formato dos dados que serão classificados, por exemplo, `special-logs`.

Padrão grok

O conjunto dos padrões que são aplicados ao armazenamento de dados para determinar se há uma correspondência. Esses são AWS Gluepadrões integrados do e todos os outros padrões personalizados que você definir.

Veja a seguir um exemplo de padrão grok.

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

Quando os dados correspondem a `TIMESTAMP_ISO8601`, uma coluna de esquema `timestamp` é criada. O comportamento é semelhante para os outros padrões nomeados no exemplo.

Padrões personalizados

Padrões personalizados opcionais que você define. Esses padrões são referenciados pelo padrão grok que classifica os seus dados. Você pode referenciar esses padrões personalizados no padrão grok aplicado aos seus dados. Cada padrão de componente personalizado deve estar em uma linha separada. A sintaxe de expressões regulares (regex) é usada para definir o padrão.

Veja a seguir um exemplo de uso dos padrões personalizados:

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

O primeiro padrão nomeado personalizado, `CRAWLERLOGLEVEL`, é uma combinação quando os dados correspondem a uma das strings enumeradas. O segundo padrão personalizado, `MESSAGEPREFIX`, tenta corresponder a uma string de prefixo de mensagem.

O AWS Glue rastreia o horário de criação, o horário da última atualização e a versão do seu classificador.

Padrões integrados

O AWS Glue fornece vários padrões comuns que você pode usar para criar um classificador personalizado. Você adiciona um padrão nomeado ao `grok pattern` em uma definição de classificador.

A lista a seguir contém uma linha para cada padrão. Em cada linha, o nome do padrão é seguido da sua respectiva definição. A sintaxe de expressões regulares (regex) é usada na definição do padrão.

```
#<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])(?:(?:25[0-5]|2[0-4][0-9]|[0-1]?[0-9]{1,2})[.](?:25[0-5]|2[0-4][0-9]|
[0-1]?[0-9]{1,2})[.](?:25[0-5]|2[0-4][0-9]|[0-1]?[0-9]{1,2})[.](?:25[0-5]|2[0-4][0-9]|
[0-1]?[0-9]{1,2}))(?![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 (?:(?:[0-5]?[0-9]|60)(?:[:.,][0-9]+)?)
 TIME (?!<[0-9])%{HOUR}:%{MINUTE}(?::%{SECOND})(?![0-9])
 # datestamp 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)?)
```

Gravar classificadores XML personalizados

XML define a estrutura de um documento com o uso de tags no arquivo. Com um classificador XML personalizado, você pode especificar o nome de tag usado para definir uma linha.

Valores de classificador personalizados para um classificador XML

Ao definir um classificador XML, você fornece os seguintes valores para que o AWS Glue crie o classificador. O campo de classificação deste classificador é definido como `xml`.

Nome

Nome do classificador.

Etiqueta de linha

O nome da tag XML que define uma linha de tabela no documento XML, sem colchetes angulares < >. O nome precisa estar em conformidade com as regras XML para tags.

> **Note**
>
> O elemento que contém os dados da linha não pode ser um elemento vazio de fechamento automático. Por exemplo, esse elemento vazio não é analisado pelo AWS Glue:

```
<row att1=”xx” att2=”yy” />
```

Os elementos vazios podem ser escritos da seguinte forma:

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

O AWS Glue rastreia o horário de criação, o horário da última atualização e a versão do seu classificador.

Por exemplo, digamos que você tenha o arquivo XML a seguir. Para criar uma tabela do AWS Glue que contenha apenas colunas para autor e título, crie um classificador no console do AWS Glue com Row tag (Tag de linha) como `AnyCompany`. Em seguida, adicione e execute um crawler que use esse classificador personalizado.

```
<?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>
```

Gravar classificadores JSON personalizados

JSON é um formato de intercâmbio de dados. Ele define estruturas de dados com pares de nome e valor ou uma lista de valores ordenada. Com um classificador JSON personalizado, você pode especificar o caminho JSON de uma estrutura de dados usada para definir o esquema da sua tabela.

Valores do classificador personalizado no AWS Glue

Ao definir um classificador JSON, você fornece os seguintes valores para que o AWS Glue crie esse classificador. O campo de classificação deste classificador é definido como `json`.

Nome

Nome do classificador.

Caminho JSON

Um caminho JSON que aponta para um objeto usado para definir um esquema de tabela. O caminho JSON pode ser escrito na notação de pontos ou de colchetes. Os operadores a seguir são aceitos:

Descrição
Elemento raiz de um objeto JSON. Inicia todas as expressões de caminho
Caracteres curinga. Disponíveis em qualquer lugar, um nome ou número são necessários no caminho JSON.
Filho com notação de pontos. Especifica um campo filho em um objeto JSON.
Filho com notação de colchetes. Especifica campo filho em um objeto JSON. Somente um único campo filho pode ser especificado.
Índice de matriz. Especifica o valor de uma matriz por índice.

O AWS Glue rastreia o horário de criação, o horário da última atualização e a versão do seu classificador.

Example Usar um classificador JSON para extrair registros de uma matriz

Suponha que seus dados JSON sejam uma matriz de registros. Por exemplo, as primeiras linhas do seu arquivo podem ter a aparência a seguir:

```
[
  {
```

```
    "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"
  }
]
```

Ao executar um crawler utilizando o classificador JSON integrado, o arquivo inteiro é usado para definir o esquema. Como você não especifica um caminho JSON, o crawler trata os dados como um objeto, ou seja, apenas uma matriz. Por exemplo, o esquema pode ser parecido com a seguinte:

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

No entanto, para criar um esquema baseado em cada registro da matriz JSON, crie um classificador JSON personalizado e especifique o caminho JSON como `$[*]`. Quando você especifica esse caminho JSON, o classificador interroga todos os 12 registros na matriz para determinar o esquema. O esquema resultante contém campos separados para cada objeto, semelhante ao exemplo a seguir:

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

Example Usar um classificador JSON para examinar somente partes de um arquivo

Suponha que seus dados JSON sigam o padrão do arquivo JSON de exemplo `s3://awsglue-datasets/examples/us-legislators/all/areas.json` obtido no site http://everypolitician.org/. Exemplos de objetos no arquivo JSON têm a seguinte aparência:

```
{
  "type": "constituency",
  "id": "ocd-division\/country:us\/state:ak",
  "name": "Alaska"
}
{
  "type": "constituency",
  "identifiers": [
    {
      "scheme": "dmoz",
      "identifier": "Regional\/North_America\/United_States\/Alaska\/"
    },
    {
      "scheme": "freebase",
      "identifier": "\/m\/0hjy"
    },
    {
      "scheme": "fips",
      "identifier": "US02"
    },
    {
      "scheme": "quora",
      "identifier": "Alaska-state"
    },
    {
      "scheme": "britannica",
      "identifier": "place\/Alaska"
    },
    {
      "scheme": "wikidata",
      "identifier": "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"
}
```

Ao executar um crawler utilizando o classificador JSON integrado, o arquivo inteiro é usado para criar o esquema. Seu esquema poderá ser semelhante a este:

```
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
```

No entanto, para criar um esquema usando apenas o objeto "`id`", crie um classificador JSON personalizado e especifique o caminho JSON como `$.id`. Em seguida, o esquema será baseado somente no campo "`id`":

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

As primeiras linhas de dados extraídas com este esquema têm esta aparência:

```
{"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"}
```

Para criar um esquema baseado em um objeto altamente aninhado, como "`identifier`", no arquivo JSON, você pode criar um classificador JSON personalizado e especificar o caminho JSON como `$.identifiers[*].identifier`. Embora o esquema seja parecido com o exemplo anterior, ele é baseado em um objeto diferente no arquivo JSON.

O esquema é semelhante ao seguinte:

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

Listar as primeiras linhas de dados da tabela mostra que o esquema é baseado nos dados no objeto "`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"}
```

Para criar uma tabela com base em outro objeto altamente aninhado, como o campo "`name`" na matriz "`other_names`" do arquivo JSON, você pode criar um classificador JSON personalizado e especificar o caminho JSON como `$.other_names[*].name`. Embora o esquema seja parecido com o exemplo anterior, ele é baseado em um objeto diferente no arquivo JSON. O esquema é semelhante ao seguinte:

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

Listar as primeiras linhas de dados na tabela mostra que isto esta baseado nos dados no objeto "`name`" na matriz "`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": "#######"}
```

Gravar classificadores CSV personalizados

Os classificadores CSV personalizados permitem que você especifique tipos de dados para cada coluna no campo de classificador CSV personalizado. É possível especificar o tipo de dados de cada coluna separando-o por uma vírgula. Ao especificar os tipos de dados, é possível substituir os tipos de dados inferidos dos crawlers e garantir que os dados sejam classificados adequadamente.

Você pode definir o SerDe para processamento de CSV no classificador, que será aplicado no catálogo de dados.

Ao criar um classificador personalizado, você também pode reutilizar o classificador para diferentes crawlers.

- Para arquivos csv somente com cabeçalhos (sem dados), esses arquivos serão classificados como UNKNOWN (DESCONHECIDOS), pois não são fornecidas informações suficientes. Se você especificar que o CSV “tem cabeçalhos” na opção Column headings (Cabeçalhos das colunas) e fornecer os tipos de dados, poderemos classificar esses arquivos corretamente.

Você pode usar um classificador CSV personalizado para inferir o esquema de vários tipos de dados CSV. Os atributos personalizados que podem ser fornecidos ao classificador incluem delimitadores, uma opção de SerDe CSV, opções sobre o cabeçalho e se determinadas validações dos dados devem ser executadas.

Valores do classificador personalizado no AWS Glue

Ao definir um classificador CSV, você fornece os seguintes valores para que o AWS Glue crie esse classificador. O campo de classificação deste classificador é definido como `csv`.

Nome do classificador

Nome do classificador.

SerDe CSV

Define o SerDe para processamento de CSV no classificador, que será aplicado no catálogo de dados. As opções são Open SerDe CSV, Lazy Simple SerDe e Nenhum. Você pode especificar o valor Nenhum quando quiser que o crawler faça a detecção.

Delimitador de coluna

Um símbolo personalizado para indicar o que separa cada entrada de coluna na linha. Forneça um caractere Unicode. Se você não conseguir digitar seu delimitador, poderá copiá-lo e colá-lo. Isso funciona para caracteres imprimíveis, incluindo os que não são compatíveis com seu sistema (normalmente exibidos como □).

Símbolo de cotação

Um símbolo personalizado para indicar o que combina o conteúdo em um único valor da coluna. Deve ser diferente do delimitador de coluna. Forneça um caractere Unicode. Se você não conseguir digitar seu delimitador, poderá copiá-lo e colá-lo. Isso funciona para caracteres imprimíveis, incluindo os que não são compatíveis com seu sistema (normalmente exibidos como □).

Cabeçalhos de coluna

Indica o comportamento de como cabeçalhos de coluna devem ser detectados no arquivo CSV. Se o seu arquivo CSV personalizado tem cabeçalhos de coluna, insira uma lista de cabeçalhos de coluna delimitados por vírgula.

Opções de processamento: permitir arquivos com uma única coluna

Habilita o processamento de arquivos que contêm apenas uma coluna.

Opções de processamento: remover espaço em branco antes de identificar os valores de coluna

Especifica se os valores devem ser removidos antes de identificar o tipo dos valores de coluna.

Tipos de dados personalizados: opcional

Insira o tipo de dados personalizado separado por uma vírgula. Especifica os tipos de dados personalizados no arquivo CSV. O tipo de dados personalizado deve ser um tipo de dados válido. Os tipos de dados válidos são: “BINARY”, “BOOLEAN”, “DATE”, “DECIMAL”, “DOUBLE”,

"FLOAT", "INT", "LONG", "SHORT", "STRING", "TIMESTAMP". Tipos de dados inválidos exibirão um erro.

Criar classificadores usando o console do AWS Glue

Um classificador determina o esquema dos seus dados. Você pode escrever um classificador personalizado e apontá-lo para o AWS Glue.

Criar classificadores

Para adicionar um classificador no console do AWS Glue, escolha Add classifier. Ao definir um classificador, você precisa fornecer valores para o seguinte:

- Classifier name (Nome do classificador): forneça um nome exclusivo para o seu classificador.
- Classifier type (Tipo do classificador): o tipo de classificação das tabelas inferidas pelo classificador.
- Last updated (Última atualização): a hora em que o classificador foi atualizado pela última vez.

Nome do classificador

Forneça um nome exclusivo para o seu classificador.

Tipo de classificador

Escolha o tipo de classificador a ser criado.

Dependendo do tipo de classificador escolhido, configure as seguintes propriedades para o classificador:

Grok

- Classificação

  Descreva o formato ou tipo de dados que serão classificados ou forneça um rótulo personalizado.
- Padrão grok

  Isso é usado na análise de dados em um esquema estruturado. O padrão grok é composto por padrões nomeados que descrevem o formato do seu armazenamento de dados. Você

escreve esse padrão grok usando os padrões integrados nomeados fornecidos pelo AWS Glue e os padrões personalizados incluídos no campo Custom patterns. Embora os resultados do depurador grok possam não corresponder exatamente aos resultados do AWS Glue, sugerimos que você teste seu padrão usando alguns dados de amostra com um depurador grok. Você pode encontrar os depuradores grok na web. Os padrões integrados nomeados fornecidos pelo AWS Glue são geralmente compatíveis com os padrões grok disponíveis na web.

Crie o seu padrão grok adicionando padrões nomeados de forma interativa e verifique seus resultados em um depurador. Ao fazer isso, você garante que seus dados poderão ser analisados quando o crawler do AWS Glue executar seu padrão grok.

- Padrões personalizados

  Para os classificadores grok, estes são elementos fundamentais para o Grok pattern que você escreveu. Quando os padrões integrados não conseguirem analisar seus dados, você precisará escrever um padrão personalizado. Esses padrões personalizados são definidos neste campo e referenciados em Grok pattern. Cada padrão personalizado é definido em uma linha separada. Assim como os padrões integrados, ele consiste em uma definição de padrão nomeado que usa a sintaxe de expressões regulares (regex).

  Por exemplo, o nome `MESSAGEPREFIX` a seguir apresenta uma definição de expressão regular a ser aplicada aos seus dados para determinar se eles seguem o padrão.

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

XML

- Etiqueta de linha

  Para classificadores XML, este é o nome da tag XML que define uma linha de tabela no documento XML. Digite o nome sem colchetes angulares < >. O nome precisa estar em conformidade com as regras XML para tags.

  Para ter mais informações, consulte Gravar classificadores XML personalizados.

JSON

- Caminho JSON

Para os classificadores JSON, este é o caminho JSON para o objeto, a matriz ou o valor que definem uma linha da tabela que está sendo criada. Digite o nome na sintaxe JSON de ponto ou colchete usando os operadores do AWS Glue compatíveis.

Para obter mais informações, consulte a lista de operadores em Gravar classificadores JSON personalizados.

CSV

- Delimitador de coluna

  Um único caractere ou símbolo para indicar o que separa cada entrada de coluna na linha. Escolha o delimitador da lista, ou escolha `Other` para inserir um delimitador personalizado.

- Símbolo de cotação

  Um único caractere ou símbolo para indicar o que combina o conteúdo em um único valor de coluna. Deve ser diferente do delimitador de coluna. Escolha o símbolo de aspas na lista, ou escolha `Other` para inserir um caractere de aspas personalizado.

- Cabeçalhos de coluna

  Indica o comportamento de como cabeçalhos de coluna devem ser detectados no arquivo CSV. Você pode escolher `Has headings`, `No headings` ou `Detect headings`. Se o seu arquivo CSV personalizado tem cabeçalhos de coluna, insira uma lista de cabeçalhos de coluna delimitados por vírgula.

- Permitir arquivos com uma única coluna

  Para serem classificados como CSV, os dados devem ter pelo menos duas colunas e duas linhas de dados. Use esta opção para permitir o processamento de arquivos que contenham apenas uma coluna.

- Remover espaço em branco antes de identificar os valores de coluna

  Esta opção especifica se os valores devem ser removidos antes de identificar o tipo dos valores de coluna.

- Tipo de dados personalizado

(Opcional) Insira tipos de dados personalizados em uma lista delimitada por vírgulas. Os tipos de dados válidos são: “BINARY”, “BOOLEAN”, “DATE”, “DECIMAL”, “DOUBLE”, “FLOAT”, “INT”, “LONG”, “SHORT”, “STRING”, “TIMESTAMP”.

- Serde CSV

  (Opcional): um SerDe para processamento de CSV no classificador, que será aplicado no catálogo de dados. Escolha entre `Open CSV SerDe`, `Lazy Simple SerDe`, ou `None`. Você pode especificar o valor `None` quando quiser que o crawler faça a detecção.

Para ter mais informações, consulte Escrever classificadores personalizados para diversos formatos de dados.

Visualizar classificadores

Para ver uma lista com todos os classificadores que você criou, abra o console do AWS Glue em https://console.aws.amazon.com/glue/ e escolha a guia Classifiers (Classificadores).

A lista exibe as seguintes propriedades sobre cada classificador:

- Classifier (Classificador): o nome do classificador. Ao criar um classificador, você precisa fornecer um nome para ele.
- Classification (Classificação): o tipo de classificação das tabelas inferidas pelo classificador.
- Last updated (Última atualização): a hora em que o classificador foi atualizado pela última vez.

Gerenciar classificadores

Na lista Classifiers no console do AWS Glue, você pode adicionar, editar e excluir classificadores. Para ver mais detalhes sobre um classificador, escolha o nome dele na lista. Os detalhes incluem as informações que você definiu quando criou o classificador.

Configurar um crawler

Um crawler acessa seu armazenamento de dados, identifica metadados e cria definições de tabela do AWS Glue Data Catalog. O painel Crawlers no console do AWS Glue lista todos os crawlers que você cria. A lista exibe status e métricas da última execução do seu crawler.

Este tópico contém o processo passo a passo de configuração de um crawler. Ele abrange aspectos essenciais, como configurar os parâmetros do crawler, definir as fontes de dados a receberem um crawl, configurar a segurança e gerenciar os dados submetidos a crawling.

Tópicos

- Etapa 1: configurar propriedades do crawler
- Etapa 2: escolher as fontes de dados e os classificadores
- Etapa 3: Defina as configurações de segurança
- Etapa 4: configurar a saída e o agendamento
- Etapa 5: analisar e criar

Etapa 1: configurar propriedades do crawler

Para configurar um crawler

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/. Escolha Crawlers no painel de navegação.
2. Escolha Adicionar crawler e siga as instruções no assistente Adicionar crawler. O assistente orientará você pelas etapas necessárias para criar um crawler. Se quiser adicionar classificadores personalizados para definir o esquema, consulte Definir e gerenciar classificadores.
3. Insira um nome e uma descrição (opcional) para o crawler. Opcionalmente, você pode marcar o crawler com uma Tag key (Chave de tag) e um Tag value (Valor de tag) opcional. Depois de serem criadas, as chaves de tag são somente leitura. Use as tags em alguns recursos para ajudar a organizá-los e identificá-los. Para obter mais informações, consulte tags da AWS no AWS Glue.

   Nome

   O nome pode conter letras (A a Z), números (0 a 9), hifens (-) ou sublinhados (_), e pode ter até 255 caracteres.

   Descrição

   A descrição pode ter até 2048 caracteres.

Tags

Use tags para organizar e identificar os recursos. Para obter mais informações, consulte as informações a seguir.

- Etiquetas da AWS no AWS Glue

Etapa 2: escolher as fontes de dados e os classificadores

Em seguida, configure as fontes de dados e os classificadores do crawler.

Para obter mais informações sobre as fontes de dados compatíveis, consulte Fontes de dados compatíveis para crawling.

Configuração da fonte de dados

Selecione a opção apropriada para Seus dados já estão mapeados para AWS Glue mesas? escolha “Ainda não” ou “Sim”. A opção "Ainda não" está selecionada por padrão.

O crawler pode acessar armazenamentos de dados diretamente como a fonte do crawl ou pode usar tabelas existentes no Data Catalog como a fonte. Se o crawler usa tabelas de catálogos existentes, ele rastreia os armazenamentos de dados que são especificados por essas tabelas do catálogo.

- Se ainda não estiverem: selecione uma ou mais fontes de dados a serem rastreadas. Um rastreador pode rastrear vários armazenamentos de dados de diferentes tipos (Amazon S3 e assim por diante). JDBC

  Você só pode configurar um datastore por vez. Depois de fornecer as informações de conexão, incluir caminhos e excluir padrões, você terá a opção de adicionar outro datastore.
- Sim: Selecione tabelas existentes do seu AWS Glue Catálogo de dados. As tabelas do catálogo especificam os armazenamentos de dados a serem rastreados. O crawler pode rastrear somente tabelas do catálogo em uma única execução; ele não pode misturar outros tipos de origem.

  Um motivo comum para especificar uma tabela de catálogo como fonte é quando você cria a tabela manualmente (pois você já conhece a estrutura do datastore) e deseja que um crawler a mantenha atualizada, incluindo a adição de novas partições. Para ver uma discussão de outros motivos, consulte Atualizar tabelas do Data Catalog criadas manualmente usando crawlers.

Quando você especifica tabelas existentes como o tipo de fonte do crawler, as seguintes condições se aplicam:

- O nome do banco de dados é opcional.
- Somente tabelas de catálogo que especificam armazenamentos de dados do Amazon S3, do Amazon DynamoDB ou do Delta Lake são permitidas.
- Nenhuma tabela de catálogo nova é criada quando o crawler é executado. As tabelas existentes são atualizadas conforme necessário, incluindo a adição de novas partições.
- Os objetos excluídos encontrados nos armazenamentos de dados são ignorados; nenhuma tabela de catálogo é excluída. Em vez disso, o crawler grava uma mensagem de log. (`SchemaChangePolicy.DeleteBehavior=LOG`)
- A opção de configuração do crawler para criar um único esquema para cada caminho do Amazon S3 é habilitada por padrão e não pode ser desabilitada. (`TableGroupingPolicy=CombineCompatibleSchemas`) Para obter mais informações, consulte Criar um esquema único para cada caminho de inclusão do Amazon S3.
- Você não pode misturar as tabelas de catálogo como uma fonte com nenhum outro tipo de fonte (por exemplo, Amazon S3 ou Amazon DynamoDB).

Para usar tabelas Delta, primeiro crie uma tabela Delta usando Athena DDL ou o. AWS Glue API

Usando o Athena, defina a localização da sua pasta Amazon S3 e o tipo de tabela como ". DELTA

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

Usando o AWS Glue API, especifique o tipo de tabela no mapa de parâmetros da tabela. Os parâmetros da tabela precisam incluir o par chave/valor a seguir. Para obter mais informações sobre como criar uma tabela, consulte a documentação do Boto3 para create_table.

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

Fontes de dados

Selecione ou adicione a lista de fontes de dados a serem varridas pelo crawler.

(Opcional) Se você escolher JDBC como fonte de dados, poderá usar seus próprios JDBC drivers ao especificar o acesso à conexão em que as informações do driver são armazenadas.

Incluir o caminho

Ao avaliar o que incluir ou excluir em um crawling, o crawler começa pelo caminho de inclusão obrigatório. Para o Amazon S3, o MongoDB, o MongoDB Atlas, o Amazon DocumentDB (compatível com MongoDB) e armazenamentos de dados relacionais, você deve especificar um caminho de inclusão.

Para um datastore do Amazon S3

Escolha se deseja especificar um caminho na sua conta ou em uma conta diferente e depois procure e escolha um caminho do Amazon S3.

Para armazenamentos de dados do Amazon S3, a sintaxe de inclusão de caminho é `bucket-name/folder-name/file-name.ext`. Para rastrear todos os objetos em um bucket, você especifica apenas o nome do bucket no caminho de inclusão. O padrão de exclusão é relativo ao caminho de inclusão

Para um datastore do Delta Lake

Especifique um ou mais caminhos do Amazon S3 para tabelas Delta como s3://*bucket*/*prefix*/*object*.

Para um datastore do Iceberg ou do Hudi

Especifique um ou mais caminhos do Amazon S3 que contêm pastas com metadados da tabela Iceberg ou Hudi como s3://*bucket*/*prefix*.

Para armazenamentos de dados Iceberg e Hudi, a pasta Iceberg/Hudi pode estar localizada em uma pasta secundária da pasta raiz. O crawler examinará todas as pastas abaixo de um caminho para uma pasta do Hudi.

Para um armazenamento JDBC de dados

Digite *<database>*/*<schema>*/*<table>* ou *<database>*/*<table>*, dependendo do produto do banco de dados. O Oracle Database e o My SQL não oferecem suporte ao esquema no caminho. Você pode substituir o caractere de porcentagem (%) por *<schema>* ou *<table>*. Por exemplo, para um banco de dados Oracle com um identificador de sistema (SID) de`orcl`, insira `orcl/%` para importar todas as tabelas às quais o usuário nomeado na conexão tem acesso.

> **Important**
>
> Este campo diferencia letras maiúsculas de minúsculas.

> **Note**
>
> Se você optar por trazer suas próprias versões de JDBC driver, AWS Glue os rastreadores consumirão recursos em AWS Glue trabalhos e buckets do Amazon S3 para garantir que o driver fornecido seja executado em seu ambiente. O uso adicional de recursos será refletido em sua conta. Os motoristas estão limitados às propriedades descritas em Adicionar um AWS Glue conexão.

Para um datastore MongoDB, MangoDB Atlas ou Amazon DocumentDB

Para o MongoDB, o MongoDB Atlas e o Amazon DocumentDB (compatível com MongoDB), a sintaxe é `database/collection`.

Para armazenamentos de JDBC dados, a sintaxe é `database-name/schema-name/table-name` ou`database-name/table-name`. A sintaxe depende de o mecanismo de banco de dados ser compatível com esquemas dentro de um banco de dados. Por exemplo, para mecanismos de banco de dados como My SQL ou Oracle, não especifique um `schema-name` em seu caminho de inclusão. Você pode substituir o sinal de porcentagem (`%`) por um esquema ou tabela no caminho de inclusão para representar todos os esquemas ou todas as tabelas em um banco de dados. Não é possível substituir o sinal de porcentagem (`%`) do banco de dados no caminho de inclusão.

Profundidade transversal máxima (somente para armazenamentos de dados do Iceberg ou do Hudi)

A profundidade máxima de caminhos do Amazon S3 que o crawler pode percorrer para descobrir a pasta de metadados do Iceberg ou do Hudi no caminho do Amazon S3. O objetivo desse parâmetro é limitar o run time do crawler. O valor padrão é 10 e o máximo é 20.

Padrões de exclusão

Eles permitem que você exclua determinados arquivos ou tabelas do rastreamento. O caminho de exclusão é relativo ao caminho de inclusão. Por exemplo, para excluir uma tabela em seu armazenamento de JDBC dados, digite o nome da tabela no caminho de exclusão.

Um rastreador se conecta a um armazenamento de JDBC dados usando um AWS Glue conexão que contém uma string de JDBC URI conexão. O rastreador só tem acesso aos objetos no

mecanismo de banco de dados usando o nome de JDBC usuário e a senha no AWS Glue conexão. O rastreador só pode criar tabelas que ele possa acessar por meio da JDBC conexão. Depois que o rastreador acessa o mecanismo de banco de dados com o JDBCURI, o caminho de inclusão é usado para determinar quais tabelas no mecanismo de banco de dados são criadas no Catálogo de Dados. Por exemplo, com MySQL, se você especificar um caminho de inclusão de`MyDatabase/%`, todas as tabelas `MyDatabase` contidas nele serão criadas no Catálogo de Dados. Ao acessar o Amazon Redshift, se você especificar um caminho de inclusão de `MyDatabase/%`, todas as tabelas dentro de todos os esquemas para o banco de dados `MyDatabase` serão criadas no Data Catalog. Se você especificar um caminho de inclusão de `MyDatabase/MySchema/%`, todas as tabelas no banco de dados `MyDatabase` e o esquema `MySchema` serão criados.

Depois de especificar um caminho de inclusão, você pode excluir objetos do rastreamento que o seu caminho de inclusão incluiria especificando um ou mais padrões de exclusão `glob` no estilo Unix. Esses padrões são aplicados ao seu caminho de inclusão para determinar quais objetos serão excluídos. Esses padrões também são armazenados como uma propriedade de tabelas criadas pelo crawler. AWS Glue PySpark extensões`create_dynamic_frame.from_catalog`, como ler as propriedades da tabela e excluir objetos definidos pelo padrão de exclusão.

AWS Glue suporta os seguintes `glob` padrões no padrão de exclusão.

Padrão de exclusão	Descrição
`*.csv`	Corresponde a um caminho do Amazon S3 que representa um nome de objeto na pasta atual que termina em `.csv`
`*.*`	Corresponde a todos os nomes de objetos que contêm um ponto
`*.{csv,avro}`	Corresponde aos nomes de objetos que terminam em `.csv` ou `.avro`
`foo.?`	Corresponde aos nomes de objetos que começam com `foo.` seguidos por uma extensão de caractere único

Padrão de exclusão	Descrição
`myfolder/*`	Corresponde a objetos em um nível de subpasta de `myfolder`, como `/myfolder/mysource`
`myfolder/*/*`	Corresponde a objetos em dois níveis de subpastas de `myfolder`, como `/myfolder/mysource/data`
`myfolder/**`	Corresponde a objetos em todas as subpastas `myfolder`, por exemplo, `/myfolder/mysource/mydata` e `/myfolder/mysource/data`
`myfolder**`	Corresponde a subpasta `myfolder` bem como aos arquivos abaixo de `myfolder`, por exemplo, `/myfolder` e `/myfolder/mydata.txt`
`Market*`	Combina tabelas em um JDBC banco de dados com nomes que começam com`Market`, como `Market_us` e `Market_fr`

AWS Glue interpreta padrões de `glob` exclusão da seguinte forma:

- O caractere de barra (`/`) é o delimitador que separa as chaves do Amazon S3 em uma hierarquia de pastas.
- O caractere de asterisco (`*`) corresponde a zero ou mais caracteres de um componente de nome sem cruzar limites da pasta.
- Um asterisco duplo (`**`) corresponde a zero ou mais caracteres cruzando limites de pasta ou esquema.
- O caractere de ponto de interrogação (`?`) corresponde a exatamente um caractere de um componente de nome.

- O caractere de barra invertida (\) é usado para realizar o escape de caracteres que não podem ser interpretados como caracteres especiais. A expressão `\\` corresponde a uma única barra invertida, e `\{` corresponde a uma chave esquerda.
- Os colchetes `[ ]` criam uma expressão que corresponde a um único caractere de um componente de nome fora de um conjunto de caracteres. Por exemplo, `[abc]` corresponde a `a`, `b` ou `c`. O hífen (`-`) pode ser usado para especificar um intervalo, portanto, `[a-z]` especifica um intervalo correspondente de `a` a `z` (de inclusão). Esses formatos podem ser combinados, portanto, [`abce-g`] corresponde a `a`, `b`, `c`, `e`, `f` ou `g`. Se o caractere depois do colchete (`[`) for um ponto de exclamação (`!`), a expressão de colchetes será negada. Por exemplo, `[!a-c]` corresponde a qualquer caractere, exceto `a`, `b` ou `c`.

  Em uma expressão de colchetes, os caracteres `*`, `?` e `\` se correspondentes entre si. O caractere de hífen (`-`) corresponde a si mesmo se for o primeiro caractere dentro de colchetes ou o primeiro caractere após `!` quando você estiver fazendo uma negação.
- As chaves (`{ }`) englobam um grupo de subpadrões, e o grupo será correspondente se houver correspondência com qualquer subpadrão no grupo. Um caractere de vírgula (`,`) é usado para separar os subpadrões. Grupos não podem ser aninhados.
- Os caracteres de ponto inicial ou final em nomes de arquivos são tratados como caracteres normais nas operações de correspondência. Por exemplo, o padrão de exclusão `*` corresponde ao nome do arquivo `.hidden`.

Example Padrões de exclusão do Amazon S3

Cada padrão de exclusão é avaliado em comparação com o caminho de inclusão. Por exemplo, digamos que você tenha a seguinte estrutura de diretórios do Amazon S3:

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

Dado o caminho de inclusão `s3://mybucket/myfolder/`, estes são alguns resultados de amostra para padrões de exclusão:

Padrão de exclusão	Resultados
`departments/**`	Exclui todos os arquivos e pastas abaixo de `departments` e inclui a pasta `employees` e seus respectivos arquivos
`departments/market*`	Exclui `market-us.json` , `market-emea.json` e `market-ap.json`
`**.csv`	Exclui todos os objetos abaixo de `myfolder` com nomes que terminam em `.csv`
`employees/*.csv`	Exclui todos os arquivos `.csv` na pasta `employees`

Example Excluir um subconjunto de partições do Amazon S3

Suponha que seus dados sejam particionados por dia, de modo que cada dia em um ano esteja em uma partição diferente do Amazon S3. Para janeiro de 2015, há 31 partições. Agora, para rastrear dados apenas na primeira semana de janeiro, é necessário excluir todas as partições, exceto os dias 1 a 7:

```
2015/01/{[!0],0[8-9]}**, 2015/0[2-9]/**, 2015/1[0-2]/**
```

Analise as partes deste padrão glob. A primeira parte, `2015/01/{[!0],0[8-9]}**`, exclui todos os dias que não começam com um "0", além dos dias 08 e 09 do mês 01 no ano 2015. Observe que "**" é usado como o sufixo para o padrão de número do dia e ultrapassa os limites de pasta para as pastas de nível inferior. Se "*" for usado, os níveis mais baixos da pasta não serão excluídos.

A segunda parte, `2015/0[2-9]/**`, exclui os dias do mês 02 ao mês 09, no ano 2015.

A terceira parte, `2015/1[0-2]/**`, exclui os dias do mês 10, 11 e 12, no ano 2015.

Example JDBCexcluir padrões

Suponha que você esteja rastreando um JDBC banco de dados com a seguinte estrutura de esquema:

```
MyDatabase/MySchema/
   HR_us
   HR_fr
   Employees_Table
   Finance
   Market_US_Table
   Market_EMEA_Table
   Market_AP_Table
```

Dado o caminho de inclusão `MyDatabase/MySchema/%`, estes são alguns resultados de amostra para padrões de exclusão:

Padrão de exclusão	Resultados
`HR*`	Exclui as tabelas com nomes que começam com `HR`
`Market_*`	Exclui as tabelas com nomes que começam com `Market_`
`**_Table`	Exclui todas as tabelas com nomes que terminam em `_Table`

Parâmetros adicionais de fonte do crawler

Cada tipo de fonte requer um conjunto diferente de parâmetros adicionais.

Conexão

Selecione ou adicione um AWS Glue conexão. Para obter informações sobre conexões, consulte Conectar a dados.

Metadados adicionais - opcionais (para armazenamentos JDBC de dados)

Selecione propriedades de metadados adicionais para o crawler rastrear.

- Comentários: rastreie os comentários associados no nível da tabela e no nível da coluna.

- Tipos brutos: mantenha os tipos de dados brutos das colunas da tabela em metadados adicionais. Como comportamento padrão, o crawler traduz os tipos de dados brutos em tipos compatíveis com o Hive.

JDBCNome da classe do driver - opcional (para armazenamentos JDBC de dados)

Digite um nome de classe de JDBC driver personalizado para o rastreador se conectar à fonte de dados:

- Postgres: org.postgresql.Driver
- MeuSQL: 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
- SQLServidor: com.microsoft.sqlserver.jdbc. SQLServerDriver

JDBCCaminho do driver S3 - opcional (para armazenamentos JDBC de dados)

Escolha um caminho existente do Amazon S3 para um arquivo `.jar`. É aqui que o `.jar` arquivo será armazenado ao usar um JDBC driver personalizado para o rastreador se conectar à fonte de dados.

Habilitar a amostragem de dados (somente para o armazenamentos de dados Amazon DynamoDB, MongoDB e MongoDB Atlas e Amazon DocumentDB)

Selecione se deseja rastrear somente uma amostra de dados. Se essa opção não for selecionada, a tabela inteira será rastreada. A verificação de todos os registros pode levar muito tempo quando a tabela não é de throughput alto.

Criar tabelas para consultas (somente para armazenamentos de dados do Delta Lake)

Selecione como você deseja criar as tabelas do Delta Lake:

- Create Native tables (Criar tabelas nativas): permite a integração com mecanismos de consulta compatíveis com consulta direta ao log de transações do Delta.
- Create Symlink tables (Criar tabelas de link simbólico): Crie uma pasta manifesto de link simbólico com arquivos de manifesto particionados pelas chaves de partição, com base nos parâmetros de configuração especificados.

Scanning rate (Taxa de varredura): opcional (somente para armazenamentos de dados do DynamoDB)

Especifique a porcentagem das unidades de capacidade de leitura da tabela do DynamoDB a serem usadas pelo crawler. Unidades de capacidade de leitura é um termo definido pelo

DynamoDB e é um valor numérico que atua como limitador de taxa para o número de leituras que podem ser executadas nessa tabela por segundo. Insira um valor entre 0,1 e 1,5. Se não for especificado, o padrão será de 0,5 para tabelas provisionadas e 1/4 da capacidade máxima configurada para tabelas sob demanda. Observe que somente o modo de capacidade provisionada deve ser usado com AWS Glue rastreadores.

> **Note**
>
> Para armazenamentos de dados do DynamoDB, defina o modo de capacidade provisionada para processar leituras e gravações em suas tabelas. O AWS Glue rastreador não deve ser usado com o modo de capacidade sob demanda.

Conexão de rede - opcional (para armazenamentos de dados de destino Amazon S3, Delta, Iceberg, Hudi e Catalog)

Opcionalmente, inclua uma conexão de rede para usar com esse destino do Amazon S3. Observe que cada crawler é limitado a uma conexão de rede, portanto, qualquer outro destino do Amazon S3 também usará a mesma conexão (ou nenhuma, se deixada em branco).

Para obter informações sobre conexões, consulte Conectar a dados.

Amostra apenas um subconjunto de arquivos e tamanho da amostra (somente para armazenamentos de dados do Amazon S3)

Especifique o número de arquivos em cada pasta de folha a serem rastreados durante o crawling de arquivos de amostra em um conjunto de dados. Quando esse recurso é ativado, em vez de realizar o crawling em todos os arquivos neste conjunto de dados, o crawler seleciona aleatoriamente alguns arquivos em cada pasta de folha para rastrear.

O crawler de amostragem é mais adequado para clientes que têm conhecimento prévio sobre seus formatos de dados e sabem que os esquemas em suas pastas não são alterados. Ativar esse recurso reduzirá significativamente o runtime do crawler.

Um valor válido é um número inteiro entre 1 e 249. Se não for especificado, todos os arquivos serão rastreados.

Execuções subsequentes do crawler

Esse campo é um campo global que afeta todas as fontes de dados do Amazon S3.

- Crawl all sub-folders (Rastrear todas as subpastas): rastrear todas as pastas novamente a cada rastreamento subsequente.
- Crawl new sub-folders only (Rastrear somente novas subpastas): somente as pastas do Amazon S3 que foram adicionadas desde o último rastreamento serão rastreadas. Se os esquemas forem compatíveis, novas partições serão adicionadas às tabelas existentes. Para obter mais informações, consulte the section called “Programar crawls incrementais”.
- Crawl based on events (Rastreamento com base em eventos): depende dos eventos do Amazon S3 para controlar quais pastas rastrear. Para obter mais informações, consulte Acelerar crawls usando notificações de eventos do Amazon S3.

Custom classifiers (Classificadores personalizados) - opcionais

Defina classificadores personalizados antes de definir crawlers. Um classificador verifica se determinado arquivo está em um formato que pode ser processado pelo crawler. Se estiver, o classificador cria um esquema na forma de um objeto `StructType` que corresponde a esse formato de dados.

Para obter mais informações, consulte Definir e gerenciar classificadores.

Etapa 3: Defina as configurações de segurança

IAM role (Perfil do IAM)

O crawler assume essa função. Ele deve ter permissões para a política `AWSGlueServiceRole` gerenciada pela AWS. Para fontes do Amazon S3 e do DynamoDB, ele também deve ter permissões para acessar o datastore. Se o crawler ler os dados do Amazon S3 criptografados pelo AWS Key Management Service (AWS KMS), a função do IAM deverá ter permissão de descriptografia na chave do AWS KMS.

Para um datastore do Amazon S3, permissões adicionais anexadas à função seriam semelhantes às seguintes:

```
{
   "Version": "2012-10-17",
    "Statement": [
        {
          "Effect": "Allow",
          "Action": [
              "s3:GetObject",
              "s3:PutObject"
```

```
            ],
            "Resource": [
                "arn:aws:s3:::bucket/object*"
            ]
        }
    ]
}
```

Para um datastore do Amazon DynamoDB, permissões adicionais anexadas à função seriam semelhantes às seguintes:

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

Para adicionar seu próprio driver JDBC, permissões adicionais precisam ser adicionadas.

- Conceda permissões para as seguintes ações: `CreateJob`, `DeleteJob`, `GetJob`, `GetJobRun`, `StartJobRun`.
- Conceda permissões para as ações do Amazon S3: `s3:DeleteObjects`, `s3:GetObject`, `s3:ListBucket`, `s3:PutObject`.

> **Note**
>
> `s3:ListBucket` não é necessário se a política de buckets do Amazon S3 estiver desabilitada.

- Conceda acesso de entidade principal de serviço a bucket/pasta na política do Amazon S3.

Exemplo de política do 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"
            ]
        }
    ]
}
```

O AWS Glue cria as pastas a seguir (`_crawler` e `_glue_job_crawler`) no mesmo nível do driver JDBC no bucket do Amazon S3. Por exemplo, se o caminho do driver for `<s3-path/driver_folder/driver.jar>`, as seguintes pastas serão criadas se ainda não existirem:

- <s3-path/driver_folder/_crawler>
- <s3-path/driver_folder/_glue_job_crawler>

Opcionalmente, você pode adicionar uma configuração de segurança para um crawler para especificar opções de criptografia em repouso.

Para ter mais informações, consulte Etapa 2: criar um perfil do IAM para o AWS Glue e Gerenciamento de identidade e acesso do AWS Glue.

Lake Formation configuration (Configuração do Lake Formation) - opcional

Permita que o crawler use credenciais do Lake Formation para fazer crawling na fonte de dados.

Marcar Use Lake Formation credentials for crawling S3 data source (Usar credenciais do Lake Formation para rastrear a fonte de dados do S3) permitirá que o crawler use as credenciais do Lake Formation para rastrear a fonte de dados. Se a fonte de dados pertencer a outra conta, você

deve fornecer a ID da conta registrada. Senão, o crawler rastreará somente as fontes de dados associadas à conta. Aplicável somente às fontes de dados do Amazon S3 e do Data Catalog.

Configuração de segurança - opcional

As configurações incluem configurações de segurança. Para obter mais informações, consulte as informações a seguir.

- Criptografar dados gravados pelo AWS Glue

> **Note**
>
> Depois que uma configuração de segurança for definida em um crawler, você poderá alterá-la, mas não poderá removê-la. Para reduzir o nível de segurança em um crawler, defina explicitamente o recurso de segurança como `DISABLED` dentro da sua configuração ou crie um novo crawler.

Etapa 4: configurar a saída e o agendamento

Configuração da saída

As opções incluem como o crawler deve lidar com alterações detectadas do esquema, com a exclusão de objetos no datastore e muito mais. Para ter mais informações, consulte Personalizar o comportamento do Crawler.

Programação do crawler

Você pode executar o crawler sob demanda ou definir uma agenda baseada em hora para os crawlers e os trabalhos no AWS Glue. A definição dessas programações usa a sintaxe cron semelhante à do Unix. Para ter mais informações, consulte Programar um crawler.

Etapa 5: analisar e criar

Revise as configurações do crawler que você definiu e crie o crawler.

Programar um crawler

Você pode executar um crawler do AWS Glue sob demanda ou por meio de uma programação regular. Ao configurar um crawler com base em uma programação, é possível especificar certas restrições (por exemplo: a frequência de execução do crawler, em quais dias da semana ele será

executado e a que horas). É possível criar esses agendamentos personalizados no formato cron. Para obter mais informações, consulte cron na Wikipédia.

Ao configurar a programação de um crawler, você precisa considerar os recursos e as limitações do cron. Por exemplo, se você optar por executar seu crawler no dia 31 de cada mês, lembre-se de que alguns meses não têm 31 dias.

Tópicos

- Criar uma programação de crawler
- Criar uma programação para um crawler existente

Criar uma programação de crawler

É possível criar uma programação para o crawler usando o console do AWS Glue ou a AWS CLI.

AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Crawlers no painel de navegação.
3. Siga as etapas 1 a 3 na seção Configurar um crawler.
4. Em Etapa 4: configurar a saída e o agendamento, escolha uma Programação de crawler para definir a frequência da execução. Você tem a opção de executar o crawler de hora em hora, diariamente, semanalmente, mensalmente ou pode definir uma programação personalizada usando expressões cron.

   Uma expressão cron é uma string que representa um padrão de agendamento, consistindo em seis campos separados por espaços: * * * * * <minute> <hour> <day of month> <month> <day of week> <year>

   Por exemplo, para executar uma tarefa todos os dias à meia-noite, a expressão cron é: 0 0 * * ? *

   Para obter mais informações, consulte Expressões cron.
5. Revise as configurações do crawler que você configurou e crie o crawler para ser executado de acordo com uma programação.

AWS CLI

```
aws glue create-crawler
 --name myCrawler \
 --role AWSGlueServiceRole-myCrawler  \
 --targets '{"S3Targets":[{Path="s3://amzn-s3-demo-bucket/"}]}' \
 --schedule cron(15 12 * * ? *)
```

Para obter mais informações sobre como usar o cron para programar trabalhos e crawlers, consulte Programações baseadas em hora para trabalhos e crawlers.

Criar uma programação para um crawler existente

Siga estas etapas para configurar uma programação recorrente para um crawler existente.

AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Crawlers no painel de navegação.
3. Escolha um crawler que você deseja programar na lista disponível.
4. Escolha Editar no menu Ações.
5. Role para baixo até a Etapa 4: definir saída e agendamento e escolha Editar.
6. Atualize a programação do seu crawler em Programação de crawlers.
7. Selecione Atualizar.

AWS CLI

Use o seguinte comando da CLI para atualizar uma configuração de crawler:

```
aws glue update-crawler-schedule
   --crawler-name myCrawler
   --schedule cron(15 12 * * ? *)
```

Visualizar resultados e detalhes do crawler

Depois que o crawler é executado com êxito, ele cria definições de tabela no Data Catalog. Escolha Tables (Tabelas) no painel de navegação para ver as tabelas criadas pelo seu crawler no banco de dados que você especificou.

Você pode exibir informações relacionadas ao próprio crawler da seguinte forma:

- A página Crawlers no console do AWS Glue exibe as seguintes propriedades para um crawler:

Propriedade	Descrição
Nome	Ao criar um crawler, você precisa atribuir a ele um nome único.
Status	Um crawler pode estar pronto, sendo iniciado, interrompido, programado ou com a programação em pausa. Um crawler em execução progride desde o início até a interrupção. Você pode retomar ou pausar uma programação vinculada a um crawler.
Schedule (Programação)	Você pode optar por executar seu crawler sob demanda ou escolher a frequência desejada usando uma programação. Para obter mais informações sobre como programar um crawler, consulte Programar um crawler.
Last run (Última execução)	A data e a hora da última vez em que o crawler foi executado.
Log (Log)	Links para todos os logs disponíveis referente s à última execução do crawler.
Tables changes from last run (Alterações de tabelas desde a última execução)	A quantidade das tabelas no AWS Glue Data Catalog que foram atualizadas pela última execução do crawler.

- Para exibir o histórico de um crawler, escolha Crawlers no painel de navegação para ver os crawlers que você criou. Escolha um crawler na lista de crawlers disponíveis. Você pode ver as propriedades do crawler e o histórico do crawler na guia Crawler runs (Execuções de crawler).

A guia Crawler runs (Execuções de crawler) exibe informações sobre cada vez que o crawler foi executado, incluindo Start time (UTC) (Horário inicial [UTC]), End time (UTC) (Horário final [UTC]), Duration (Duração), Status (Status), DPU hours (Horas de DPU) e Table changes (Alterações de tabela).

A guia de execuções do crawler exibe apenas os crawls que ocorreram desde a data de lançamento do atributo de histórico do crawler e só retém os crawls por 12 meses. Crawls mais antigos não serão retornados.

- Para ver informações adicionais, escolha uma guia na página de detalhes do crawler. Cada guia exibirá informações relacionadas ao crawler.
  - Schedule (Cronograma): todas as programações criadas para o crawler estarão visíveis aqui.
  - Data sources (Fontes de dados): todas as fontes de dados rastreadas pelo crawler estarão visíveis aqui.
  - Classifiers (Classificadores): todos os classificadores atribuídos ao crawler estarão visíveis aqui.
  - Tags (Tags): todas as tags criadas e atribuídas a um recurso do AWS estarão visíveis aqui.

Parâmetros definidos nas tabelas do Data Catalog pelo crawler

Essas propriedades da tabela são definidas pelos crawlers do AWS Glue. Esperamos que os usuários consumam as propriedades `classification` e `compressionType`. Outras propriedades, incluindo estimativas de tamanho de tabela, são usadas para cálculos internos e não garantimos sua precisão ou aplicabilidade aos casos de uso do cliente. Alterar esses parâmetros pode alterar o comportamento do crawler. Não oferecemos suporte a esse fluxo de trabalho.

Propriedade da chave	Valor da propriedade
`UPDATED_BY_CRAWLER`	Nome do crawler que está executando a atualização.
`connectionName`	O nome da conexão no Data Catalog para o crawler usado para conexão com o armazenamento de dados.
`recordCount`	Estime a contagem de registros na tabela com base nos tamanhos e cabeçalhos dos arquivos.

Propriedade da chave	Valor da propriedade
`skip.header.line.count`	Linhas ignoradas para pular o cabeçalho. Definido em tabelas classificadas como CSV.
`CrawlerSchemaSerializerVersion`	Para uso interno
`classification`	Formato dos dados, inferido pelo crawler. Para obter mais informações sobre os formatos de dados aceitos pelos crawlers do AWS Glue, consulte the section called “Classificadores integrados”.
`CrawlerSchemaDeserializerVersion`	Para uso interno
`sizeKey`	Tamanho combinado dos arquivos na tabela com crawling.
`averageRecordSize`	O tamanho médio da linha na tabela, em bytes.
`compressionType`	Tipo de compressão usada nos dados da tabela. Para obter mais informações sobre os tipos de compressão aceitos pelos crawlers do AWS Glue, consulte the section called “Classificadores integrados”.
`typeOfData`	`file`, `table` ou `view`.
`objectCount`	Número de objetos no caminho do Amazon S3 para a tabela.

Essas propriedades adicionais da tabela são definidas por crawlers do AWS Glue para armazenamentos de dados do Snowflake.

Propriedade da chave	Valor da propriedade
`aws:RawTableLastAltered`	Registra o timestamp da última alteração da tabela do Snowflake.

Propriedade da chave	Valor da propriedade
`ViewOriginalText`	Visualizar a instrução SQL.
`ViewExpandedText`	Visualizar a instrução SQL codificada no formato Base64.
`ExternalTable:S3Location`	O local do Amazon S3 da tabela externa do Snowflake.
`ExternalTable:FileFormat`	O formato do arquivo do Amazon S3 da tabela externa do Snowflake.

Essas propriedades adicionais da tabela são definidas por crawlers do AWS Glue para armazenamentos de dados do tipo JDBC, como Amazon Redshift, Microsoft SQL Server, MySQL, PostgreSQL e Oracle.

Propriedade da chave	Valor da propriedade
`aws:RawType`	Quando um crawler armazena os dados no Dta Catalog, ele converte os tipos de dados em tipos compatíveis com o Hive, o que, muitas vezes, faz com que as informações sobre o tipo de dados nativo sejam perdidas. O crawler gera o parâmetro `aws:RawType` para fornecer o tipo de dados de nível nativo.
`aws:RawColumnComment`	Se um comentário estiver associado a uma coluna no banco de dados, o crawler gera o comentário correspondente na tabela do catálogo. A string de comentários é truncada em 255 bytes. O Microsoft SQL Server não oferece suporte para comentários.
`aws:RawTableComment`	Se um comentário estiver associado a uma tabela no banco de dados, o crawler gera o comentário correspondente na tabela do catálogo. A string de comentários é truncada em 255 bytes.

Propriedade da chave	Valor da propriedade
	O Microsoft SQL Server não oferece suporte para comentários.

Personalizar o comportamento do Crawler

Ao configurar um Crawler do AWS Glue, há várias opções para definir o comportamento do seu crawler.

- Crawls incrementais: é possível configurar um crawler para executar crawls incrementais para adicionar somente novas partições ao esquema da tabela.
- Índices de partição: um crawler cria índices de partição para destinos do Amazon S3 e do Delta Lake por padrão para fornecer uma pesquisa eficiente para partições específicas.
- Acelerar o tempo do crawl usando eventos do Amazon S3: é possível configurar um crawler para usar eventos do Amazon S3 a fim de identificar as alterações entre dois crawls listando todos os arquivos da subpasta que disparou o evento em vez de listar o destino completo do Amazon S3 ou do Catálogo de dados.
- Manipulação de alterações no esquema: você pode impedir que um crawler faça qualquer alteração no esquema existente. Você pode usar o AWS Management Console ou a API do AWS Glue para configurar como o seu crawler processa determinados tipos de alterações.
- Um único esquema para vários caminhos do Amazon S3: você pode configurar um crawler para criar um único esquema para cada caminho do S3, se os dados forem compatíveis.
- Localização da tabela e níveis de particionamento: a opção de crawler no nível da tabela fornece a flexibilidade de informar ao crawler onde as tabelas estão localizadas e como você deseja que as partições sejam criadas.
- Limite da tabela: é possível especificar o número máximo de tabelas que o crawler tem permissão para criar especificando um limite da tabela.
- Credenciais do AWS Lake Formation: é possível configurar um crawler para usar credenciais do Lake Formation para acessar um datastore do Amazon S3 ou uma tabela do Catálogo de dados com uma localização subjacente do Amazon S3 dentro da mesma Conta da AWS ou de outra Conta da AWS.

Para obter mais informações sobre como usar o console do AWS Glue para adicionar um crawler, consulte Configurar um crawler.

Tópicos

- Programar crawls incrementais para adicionar novas partições
- Gerar índices de partição
- Como impedir que o crawler altere um esquema existente
- Criar um esquema único para cada caminho de inclusão do Amazon S3
- Especificar o local da tabela e o nível de particionamento
- Especificar o número máximo de tabelas que o crawler pode criar
- Configurar um crawler para usar credenciais do Lake Formation
- Acelerar crawls usando notificações de eventos do Amazon S3

Programar crawls incrementais para adicionar novas partições

É possível configurar crawls incrementais de uma execução do Crawler do AWS Glue para adicionar somente novas partições ao esquema da tabela. Quando o crawler é executado pela primeira vez, ele executa um crawl completo para processar toda a fonte de dados para registrar o esquema completo e todas as partições existentes no AWS Glue Data Catalog.

Os crawls subsequentes após o crawl completo inicial serão incrementais, em que o crawler identifica e adiciona somente as novas partições que foram introduzidas desde o crawl anterior. Essa abordagem resulta em tempos de crawl mais rápidos, pois o crawler não precisa mais processar toda a fonte de dados para cada execução, mas se concentra apenas nas novas partições.

> **Note**
>
> Os crawls incrementais não detectam modificações ou exclusões de partições existentes. Essa configuração é mais adequada para fontes de dados com um esquema estável. Se ocorrer uma única alteração importante no esquema, é recomendável configurar temporariamente o crawler para realizar um crawl completo a fim de capturar o novo esquema com precisão e, em seguida, voltar ao modo de crawling incremental.

O diagrama a seguir mostra que, com a configuração de crawl incremental ativada, o crawler detectará e adicionará somente a pasta recém-adicionada, month=March, ao catálogo.

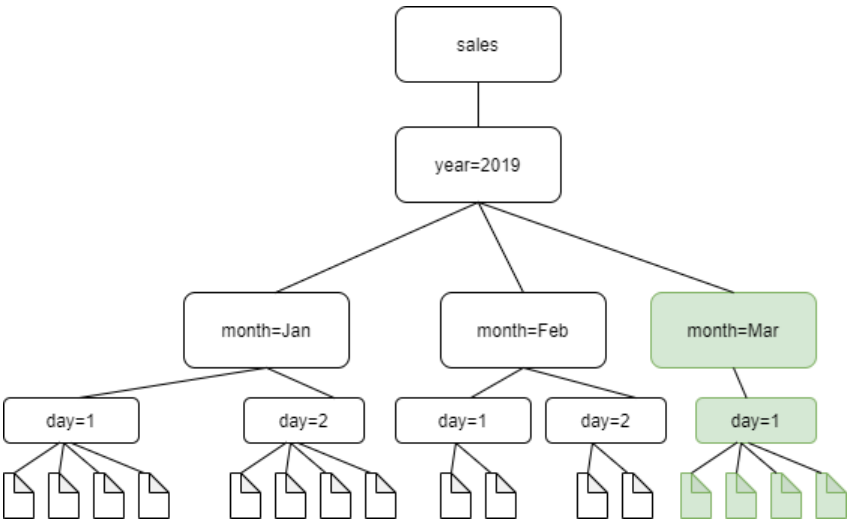

Siga estas etapas para atualizar seu crawler para realizar crawls incrementais:

AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Crawlers no Catálogo de dados.
3. Escolha um crawler que você deseja configurar para fazer o crawl incrementalmente.
4. Selecione a opção Editar.
5. Escolha a Etapa 2. Escolha as fontes de dados e os classificadores.
6. Escolha a fonte de dados em que você deseja fazer o crawl incrementalmente.
7. Selecione a opção Editar.
8. Escolha Fazer crawl somente em novas subpastas em Execuções subsequentes do crawler.
9. Selecione Atualizar.

Para criar uma programação para um crawler, consulte the section called “Programar um crawler”.

AWS CLI

```
aws glue update-crawler \
 --name myCrawler \
 --recrawl-policy RecrawlBehavior=CRAWL_NEW_FOLDERS_ONLY \
 --schema-change-policy UpdateBehavior=LOG,DeleteBehavior=LOG
```

Notas e restrições

Quando essa opção está ativada, não é possível alterar os armazenamentos de dados de destino do Amazon S3 ao editar o crawler. Essa opção afeta determinadas definições de configuração do crawler. Quando ativada, ela força o comportamento de atualização e de exclusão do crawler para `LOG`. Isto significa que:

- Se descobrir objetos nos quais os esquemas não são compatíveis, o crawler não adicionará os objetos no Catálogo de Dados e adicionará esse detalhe como um log no CloudWatch Logs.
- Ele não atualizará objetos excluídos no Catálogo de dados.

Gerar índices de partição

O Catálogo de dados é compatível com a criação de índices de partição para fornecer uma pesquisa eficiente de partições específicas. Para obter mais informações, consulte Criar índices de partição. O crawler do AWS Glue cria índices de partição para destinos do Amazon S3 e do Delta Lake por padrão.

AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Crawlers no Catálogo de dados.
3. Quando você define um crawler, a opção Criar índices de partição automaticamente é habilitada por padrão em Opções avançadas na página Definir saída e programação.

   Para desabilitar essa opção, você pode desmarcar a caixa de seleção Criar índices de partição automaticamente no console.
4. Conclua a configuração do crawler e escolha Criar crawler.

AWS CLI

Também é possível desabilitar essa opção usando a AWS CLI, defina o `CreatePartitionIndex` no parâmetro `configuration`. O valor padrão é true.

```
aws glue update-crawler \
    --name myCrawler \
    --configuration '{"Version": 1.0, "CreatePartitionIndex": false }'
```

Notas de uso para índices de partição

- As tabelas criadas pelo crawler não têm a variável `partition_filtering.enabled` por padrão. Para obter mais informações, consulte AWS Glue partition indexing and filtering.
- A criação de índices de partição para partições criptografadas não é compatível.

Como impedir que o crawler altere um esquema existente

Você pode impedir que os Crawler do AWS Glues façam qualquer alteração de esquema no Catálogo de Dados quando eles são executados. Por padrão, os crawlers atualizam o esquema no Catálogo de Dados para corresponder à fonte de dados que está recebendo um crawl. No entanto, em alguns casos, talvez você queira impedir que o Crawler modifique o esquema existente, especialmente se transformou ou limpou os dados e não quer que o esquema original substitua as alterações.

Siga estas etapas para configurar seu crawler para não substituir o esquema existente em uma definição de tabela.

AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Crawlers no Catálogo de dados.
3. Escolha um crawler na lista e escolha Editar.
4. Escolha Etapa 4: definir a saída e a programação.
5. Em Opções avançadas, escolha Adicionar somente novas colunas ou Ignorar a alteração e não atualizar a tabela no Catálogo de Dados.
6. Também é possível definir uma opção de configuração para Atualizar todas as partições novas e existentes com metadados da tabela. Isso define os esquemas de partição que serão herdados da tabela.
7. Selecione Atualizar.

AWS CLI

O exemplo a seguir mostra como configurar um crawler para não alterar o esquema existente, apenas adicionar novas colunas:

```
aws glue update-crawler \
  --name myCrawler \
  --configuration '{"Version": 1.0, "CrawlerOutput": {"Tables":
 {"AddOrUpdateBehavior": "MergeNewColumns"}}}'
```

O exemplo a seguir mostra como configurar um crawler para não alterar o esquema existente e não adicionar novas colunas:

```
aws glue update-crawler \
  --name myCrawler \
  --schema-change-policy UpdateBehavior=LOG \
  --configuration '{"Version": 1.0, "CrawlerOutput": {"Partitions":
 { "AddOrUpdateBehavior": "InheritFromTable" }}}'
```

API

Se você não quiser que um esquema de tabela seja alterado quando um crawler for executado, defina a política de alteração de esquema como `LOG`.

Quando você configura o crawler usando a API, defina os seguintes parâmetros:

- Defina o campo `UpdateBehavior` na estrutura `SchemaChangePolicy` para `LOG`.
- Defina o campo `Configuration` com uma representação de string do objeto JSON a seguir na API do crawler, por exemplo:

```
{
   "Version": 1.0,
   "CrawlerOutput": {
      "Partitions": { "AddOrUpdateBehavior": "InheritFromTable" }
   }
}
```

Criar um esquema único para cada caminho de inclusão do Amazon S3

Por padrão, quando um crawler define tabelas para dados armazenados no Amazon S3, ele considera a compatibilidade dos dados e a similaridade do esquema. Os fatores de compatibilidade de dados que ele considera incluem: se os dados são do mesmo formato (por exemplo, JSON), do

mesmo tipo de compactação (por exemplo, GZIP), a estrutura do caminho do Amazon S3 e outros atributos de dados. Similaridade de esquema é uma medida de até que ponto os esquemas de objetos do Amazon S3 separados são semelhantes.

Para ajudar a ilustrar essa opção, suponha que você defina um crawler com um caminho de inclusão `s3://amzn-s3-demo-bucket/table1/`. Quando o crawler é executado, ele localiza dois arquivos JSON com as seguintes características:

- Arquivo 1: `S3://amzn-s3-demo-bucket/table1/year=2017/data1.json`
- Conteúdo do arquivo: `{“A”: 1, “B”: 2}`
- Esquema: `A:int, B:int`

- Arquivo 2: `S3://amzn-s3-demo-bucket/table1/year=2018/data2.json`
- Conteúdo do arquivo: `{“C”: 3, “D”: 4}`
- Esquema: `C: int, D: int`

Por padrão, o crawler cria duas tabelas, chamadas `year_2017` e `year_2018`, porque os esquemas não são suficientemente semelhantes. No entanto, se a opção Create a single schema for each S3 path (Criar um único esquema para cada caminho do S3) for selecionada, e se os dados forem compatíveis, o crawler criará uma tabela. A tabela tem o esquema `A:int,B:int,C:int,D:int` e `partitionKey year:string`.

AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Crawlers no Catálogo de dados.
3. Ao configurar um novo crawler, em Saída e programação, selecione a opção Criar um único esquema para cada caminho do S3 em Opções avançadas.

AWS CLI

Você pode configurar um crawler para `CombineCompatibleSchemas` em uma definição de tabela comum quando possível. Com essa opção, o crawler ainda considera a compatibilidade dos dados, mas ignora a semelhança dos esquemas específicos ao avaliar objetos do Amazon S3 no caminho de inclusão especificado.

Quando você configurar o crawler usando a AWS CLI, defina a seguinte opção de configuração:

```
aws glue update-crawler \
   --name myCrawler \
   --configuration '{"Version": 1.0, "Grouping": {"TableGroupingPolicy":
 "CombineCompatibleSchemas" }}'
```

API

Quando você configurar o crawler usando a API, defina a seguinte opção de configuração:

Defina o campo `Configuration` com uma representação de string do objeto JSON a seguir na API do crawler, por exemplo:

```
{
   "Version": 1.0,
   "Grouping": {
      "TableGroupingPolicy": "CombineCompatibleSchemas" }
}
```

Especificar o local da tabela e o nível de particionamento

Por padrão, quando um crawler define tabelas para dados armazenados no Amazon S3, ele tenta mesclar esquemas e criar tabelas de nível superior (`year=2019`). Em alguns casos, você pode esperar que o crawler crie uma tabela para a pasta `month=Jan`, mas em vez disso, o crawler cria uma partição desde o momento em que uma pasta irmã (`month=Mar`) tenha sido mesclada na mesma tabela.

A opção de crawler no nível da tabela fornece a flexibilidade de informar ao crawler onde as tabelas estão localizadas e como você deseja que as partições sejam criadas. Quando você especifica um Table level (Nível da tabela), ela é criada nesse nível absoluto a partir do bucket do Amazon S3.

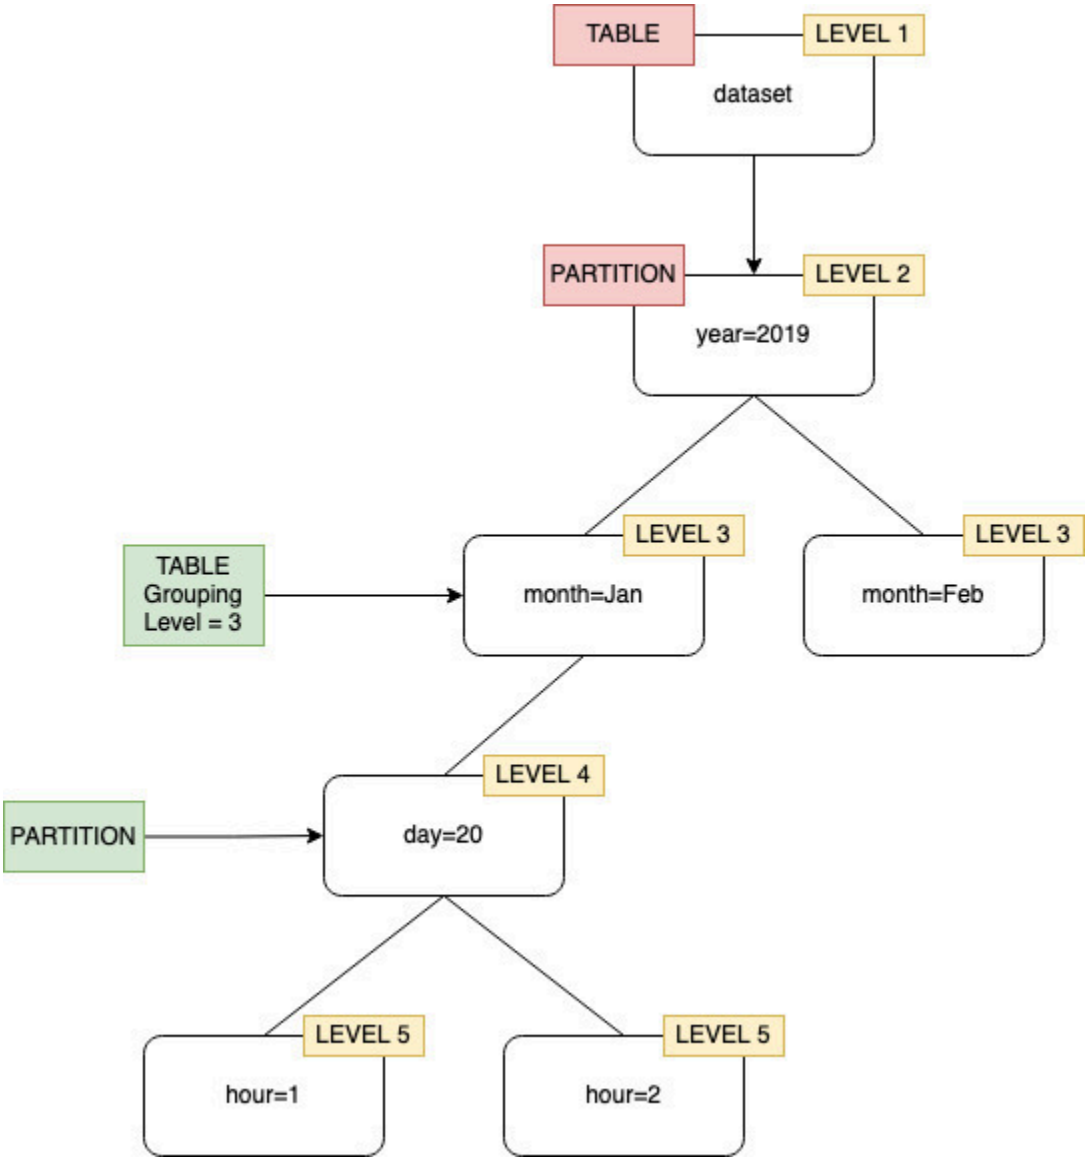

Ao configurar o crawler no console, você pode especificar um valor para a opção Table level (Nível da tabela) do Crawler. O valor deve ser um inteiro positivo que indica o local da tabela (o nível absoluto no conjunto de dados). O nível para a pasta de nível superior é um. Por exemplo, para o caminho `mydataset/year/month/day/hour`, se o nível for definido como três, a tabela será criada no local `mydataset/year/month`.

AWS Management Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Crawlers no Catálogo de dados.

3. Ao configurar um crawler, em Saída e programação, escolha Nível da tabela em Opções avançadas.

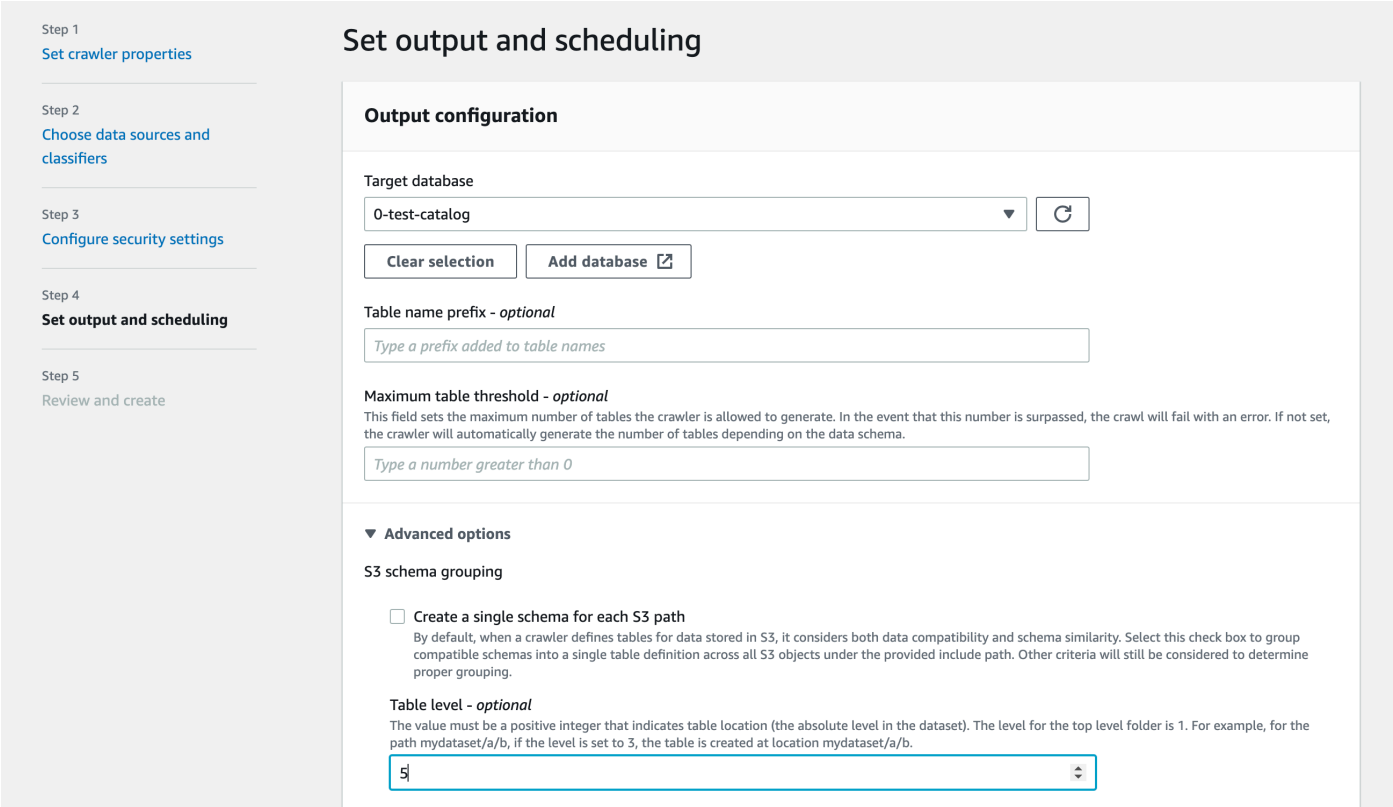

AWS CLI

Ao configurar o crawler usando o AWS CLI, defina o parâmetro `configuration` conforme mostrado no código de exemplo:

```
aws glue update-crawler \
  --name myCrawler \
  --configuration '{"Version": 1.0, "Grouping": { "TableLevelConfiguration": 2 }}'
```

API

Quando você configurar o crawler usando a API, defina o campo `Configuration` com uma representação de string do objeto JSON a seguir, por exemplo:

```
configuration = jsonencode(
{
   "Version": 1.0,
   "Grouping": {
```

```
            TableLevelConfiguration = 2
        }
})
```

CloudFormation

Neste exemplo, você define a opção Table level (Nível da tabela) disponível no console dentro do modelo do CloudFormation:

```
"Configuration": "{
    \"Version\":1.0,
    \"Grouping\":{\"TableLevelConfiguration\":2}
}"
```

Especificar o número máximo de tabelas que o crawler pode criar

Opcionalmente, você pode especificar o número máximo de tabelas que o crawler pode criar especificando um `TableThreshold` por meio do console do AWS Glue ou a AWS CLI. Se as tabelas detectadas pelo crawler durante o rastreamento forem maiores que esse valor de entrada, o rastreamento falhará e nenhum dado será gravado no Data Catalog.

Esse parâmetro é útil quando as tabelas que seriam detectadas e criadas pelo crawler são muito maiores do que o esperado. Pode haver vários motivos para isso, por exemplo:

- Ao usar um trabalho do AWS Glue para preencher seus locais do Amazon S3, você pode acabar com arquivos vazios no mesmo nível de uma pasta. Nesses casos, quando você executa um crawler nesse local do Amazon S3, o crawler cria várias tabelas devido a arquivos e pastas presentes no mesmo nível.
- Se você não configurar `"TableGroupingPolicy": "CombineCompatibleSchemas"`, pode acabar com mais tabelas do que o esperado.

Você especifica o `TableThreshold` como um valor inteiro maior que 0. Esse valor é configurado para cada crawler. Ou seja, esse valor é considerado para cada rastreamento. Por exemplo: um crawler tem o valor `TableThreshold` definido como 5. Em cada rastreamento, o AWS Glue vai comparar o número de tabelas detectadas com esse valor limite da tabela (5). Se o número de tabelas detectadas for menor que 5, o AWS Glue vai gravar as tabelas no Data Catalog. Caso contrário, o rastreamento falhará sem gravar no Data Catalog.

AWS Management Console

Para definir **`TableThreshold`** usando o AWS Management Console:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Ao configurar um crawler, em Saída e programação, defina o Limite máximo da tabela para o número de tabelas que o crawler pode gerar.

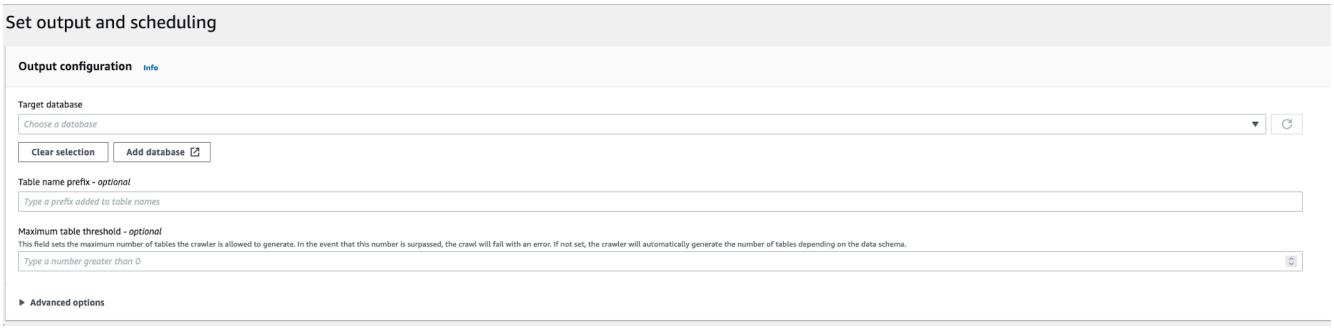

AWS CLI

Para definir `TableThreshold` usando a AWS CLI:

```
aws glue update-crawler \
    --name myCrawler \
    --configuration '{"Version": 1.0, "CrawlerOutput": {"Tables":
 { "TableThreshold": 5 }}}'
```

API

Para definir `TableThreshold` usando a API:

```
"{"Version":1.0,
"CrawlerOutput":
{"Tables":{"AddOrUpdateBehavior":"MergeNewColumns",
"TableThreshold":5}}}";
```

As mensagens de erro são registradas para ajudar você a identificar os caminhos da tabela e a limpar seus dados. Exemplo: faça login em sua conta se o crawler falhar porque a contagem da tabela foi maior do que o valor limite da tabela fornecido:

```
Table Threshold value = 28, Tables detected - 29
```

No CloudWatch, registramos em log todas as localizações de tabelas detectadas como uma mensagem INFO. Um erro é registrado como o motivo da falha.

```
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.
```

Configurar um crawler para usar credenciais do Lake Formation

Você pode configurar um crawler para usar credenciais do AWS Lake Formation para acessar um datastore do Amazon S3 ou uma tabela do Data Catalog com uma localização subjacente do Amazon S3 dentro da mesma Conta da AWS ou de outra Conta da AWS. Você pode configurar uma tabela existente do Data Catalog como o destino do crawler, se o crawler e a tabela do Data Catalog residirem na mesma conta. No momento, é permitido ter somente um destino de catálogo com apenas uma tabela de catálogo ao usar uma tabela do Catálogo de dados como destino do crawler.

> **Note**
>
> Ao definir uma tabela do Data Catalog como um destino de crawler, certifique-se de que a localização subjacente da tabela do Data Catalog seja um local do Amazon S3. Os crawlers que usam credenciais do Lake Formation são compatíveis somente com destinos do Data Catalog com localizações subjacentes do Amazon S3.

Configuração exigida quando o crawler e a localização registrada do Amazon S3 ou a tabela do Data Catalog residem na mesma conta (crawling na conta)

Para permitir que o crawler acesse um datastore ou uma tabela do Data Catalog usando as credenciais do Lake Formation, você precisa registrar a localização dos dados com o Lake Formation. Além disso, o perfil do IAM do crawler deve ter permissões para ler os dados do destino no qual o bucket do Amazon S3 está registrado.

Você pode concluir as seguintes etapas de configuração usando o AWS Management Console ou a AWS Command Line Interface (AWS CLI).

AWS Management Console

1. Antes de configurar um crawler para acessar a fonte do crawler, registre a localização dos dados do datastore ou do Data Catalog com o Lake Formation. No console do Lake Formation (https://console.aws.amazon.com/lakeformation/), registre uma localização do Amazon S3 como a localização raiz do seu data lake na Conta da AWS na qual o crawler está definido. Para obter mais informações, consulte Registering an Amazon S3 location (Registrar um local do Amazon S3).
2. Conceda permissões de Data location (Localização de dados) ao perfil do IAM que é usado para a execução do crawler, de modo que o rastreador possa ler os dados do destino no Lake Formation. Para obter mais informações, consulte Granting data location permissions (same account) (Conceder permissões de localização de dados [mesma conta]).
3. Conceda permissões de acesso ao perfil do crawler (`Create`) para o banco de dados, que é especificado como o banco de dados de saída. Para obter mais informações, consulte Granting database permissions using the Lake Formation console and the named resource method (Conceder permissões de banco de dados usando o console do Lake Formation e o método de recurso nomeado).
4. No console do IAM (https://console.aws.amazon.com/iam/), crie um perfil do IAM para o crawler. Adicione a política `lakeformation:GetDataAccess` ao perfil.
5. No console do AWS Glue (https://console.aws.amazon.com/glue/), ao configurar o crawler, selecione a opção Use Lake Formation credentials for crawling Amazon S3 data source (Usar credenciais do Lake Formation para crawling da fonte de dados do Amazon S3).

> **Note**
>
> O campo accountId é opcional para crawling na conta.

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": ""
  }
}'
```

Configuração exigida quando o crawler e a localização registrada do Amazon S3 residem em contas diferentes (crawling entre contas)

Para permitir que o crawler acesse um datastore em uma conta diferente usando as credenciais do Lake Formation, primeiro você deve registrar a localização de dados do Amazon S3 com o Lake

Formation. Em seguida, você concede permissões de localização de dados à conta do crawler conforme as etapas a seguir.

Você pode concluir as seguintes etapas usando o AWS Management Console ou a AWS CLI.

AWS Management Console

1. Na conta em que a localização do Amazon S3 está registrada (conta B):
   a. Registre um caminho do Amazon S3 no Lake Formation. Para obter mais informações, consulte Registering an Amazon S3 location (Registrando um local do Amazon S3).
   b. Conceda permissões de Data location (Localização de dados) para a conta (conta A) na qual o crawler será executado. Para obter mais informações, consulte Granting data location permissions (Conceder permissões de localização de dados).
   c. Crie um banco de dados vazio no Lake Formation com a localização subjacente como o local de destino do Amazon S3. Para obter mais informações, consulte Creating a database (Criar um banco de dados).
   d. Conceda à conta A (a conta na qual o crawler será executado) acesso ao banco de dados que você criou na etapa anterior. Para obter mais informações, consulte Granting database permissions (Conceder permissões de banco de dados).
2. Na conta em que o crawler é criado e será executado (conta A):
   a. Ao usar o console da AWS RAM, aceite o banco de dados que foi compartilhado da conta externa (conta B). Para obter mais informações, consulte Aceitar um convite de compartilhamento de recursos do AWS Resource Access Manager.
   b. Crie um perfil do IAM para o crawler. Adicione a política `lakeformation:GetDataAccess` ao perfil.
   c. No console do Lake Formation (https://console.aws.amazon.com/lakeformation/), conceda permissões de Data location (Localização dos dados) na localização de destino do Amazon S3 para o perfil do IAM usado para a execução do crawler, de modo que o crawler possa ler os dados do destino no Lake Formation. Para obter mais informações, consulte Granting data location permissions (Conceder permissões de localização de dados).
   d. Crie um link de recurso no banco de dados compartilhado. Para obter mais informações, consulte Create a resource link (Criar um link de recurso).
   e. Conceda permissões de acesso ao perfil do crawler (`Create`) no banco de dados compartilhado e (`Describe`) no link do recurso. O link do recurso é especificado na saída do crawler.

f. No console do AWS Glue (https://console.aws.amazon.com/glue/), ao configurar o crawler, selecione a opção Use Lake Formation credentials for crawling Amazon S3 data source (Usar credenciais do Lake Formation para crawling da fonte de dados do Amazon S3).

   Para crawling entre contas, especifique o ID da Conta da AWS na qual a localização de destino do Amazon S3 está registrada no Lake Formation. O campo accountId é opcional para crawling na conta.

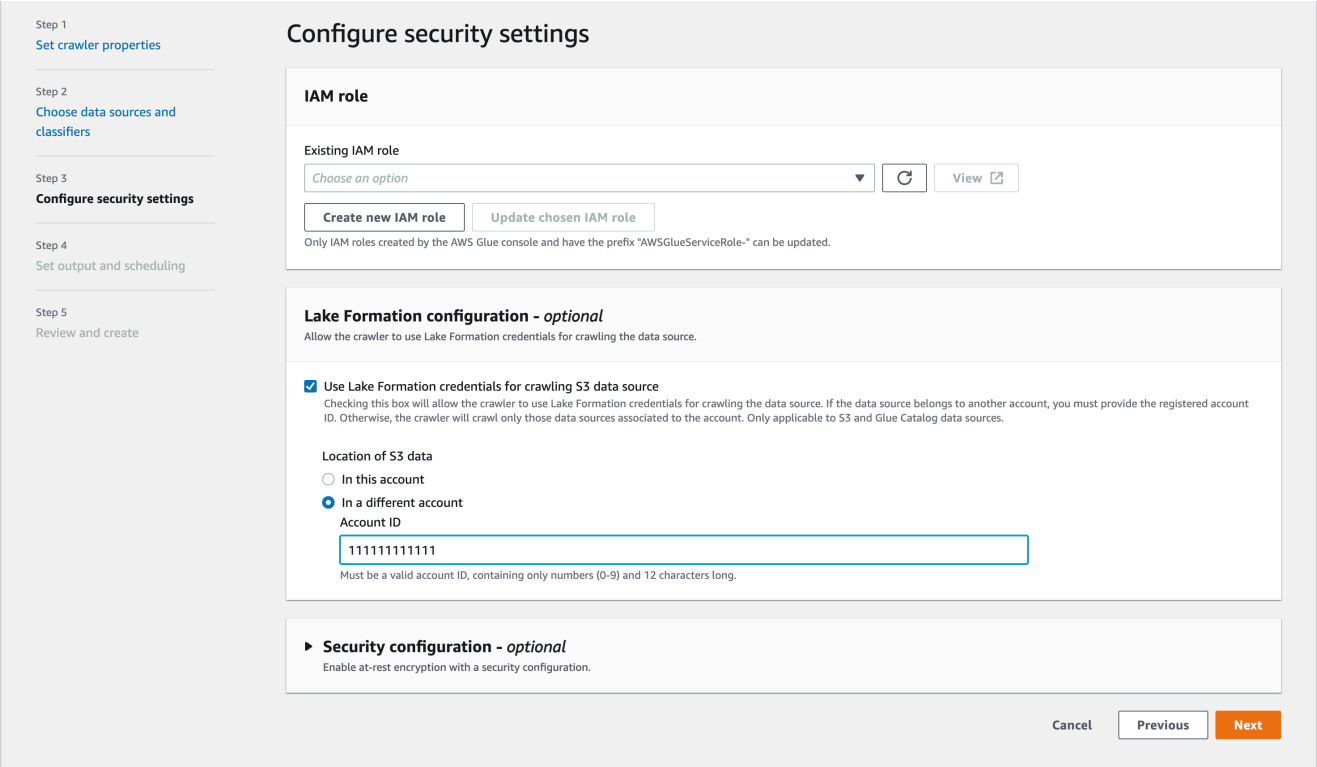

AWS CLI

```
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

- Um crawler que use credenciais do Lake Formation é compatível somente com destinos do Amazon S3 e do Data Catalog.
- Para destinos que utilizam o fornecimento de credenciais do Lake Formation, as localizações subjacentes do Amazon S3 devem pertencer ao mesmo bucket. Por exemplo, os clientes podem usar vários destinos (s3://amzn-s3-demo-bucket1/folder1, s3://amzn-s3-demo-bucket1/folder2), desde que todos os locais de destino estejam no mesmo bucket (amzn-s3-demo-bucket1). Não é permitido especificar buckets diferentes (s3://amzn-s3-demo-bucket1/folder1, s3://amzn-s3-demo-bucket2/folder2).

- No momento, só é permitido ter um destino de catálogo com uma só tabela de catálogo para crawlers de destino do Data Catalog.

Acelerar crawls usando notificações de eventos do Amazon S3

Em vez de listar os objetos de um destino do Amazon S3 ou do Data Catalog, você pode configurar o crawler para usar eventos do Amazon S3 para localizar quaisquer alterações. Esse recurso melhora o tempo de recrawl usando eventos do Amazon S3 para identificar as alterações entre dois crawls listando todos os arquivos da subpasta que disparou o evento em vez de listar o destino completo do Amazon S3 ou do Data Catalog.

O primeiro crawl lista todos os objetos do Amazon S3 do destino. Após o primeiro crawling bem-sucedido, você pode optar pelo recrawling manualmente ou em um cronograma definido. O crawler listará apenas os objetos desses eventos em vez de listar todos os objetos.

Quando o destino é uma tabela do Catálogo de dados, o crawler atualiza as tabelas existentes no Catálogo de dados com as alterações (por exemplo, partições extras em uma tabela).

As vantagens de migrar para um crawler baseado em eventos do Amazon S3 são:

- Uma recuperação mais rápida, pois a listagem de todos os objetos do destino não é necessária, em vez disso, a listagem de pastas específicas é feita onde os objetos são adicionados ou excluídos.
- Uma redução no custo geral de crawl à medida que a listagem de pastas específicas é feita onde os objetos são adicionados ou excluídos.

O crawl de eventos do Amazon S3 é executado consumindo eventos do Amazon S3 da fila SQS com base na programação do crawler. Não haverá custo se não houver eventos na fila. Os eventos do Amazon S3 podem ser configurados para ir diretamente para a fila SQS ou nos casos em que vários consumidores precisam do mesmo evento, uma combinação de SNS e SQS. Para obter mais informações, consulte the section called “Configurar sua conta para notificações de eventos do Amazon S3”.

Depois de criar e configurar o crawler no modo de evento, o primeiro crawl é executado no modo de listagem fazendo uma listagem completa do destino do Amazon S3 ou do Data Catalog. O log a seguir confirma a operação do crawl consumindo eventos do Amazon S3 após o primeiro crawl bem-

sucedido: "The crawl is running by consuming Amazon S3 events." (O crawl está sendo executado consumindo eventos do Amazon S3).

Depois de criar o crawl de eventos do Amazon S3 e atualizar as propriedades do crawler que podem afetar o crawl, o crawl opera no modo de lista e o seguinte log é adicionado: "Crawl is not running in S3 event mode" (O crawl não está sendo executado no modo de evento S3).

> **Note**
>
> O número máximo de mensagens a serem consumidas é 100 mil mensagens por operação de crawl.

Considerações e limitações

As considerações e limitações apresentadas a seguir se aplicam ao configurar um crawler para usar notificações de eventos do Amazon S3 na descoberta de alterações.

- Aspectos relevantes do comportamento ao lidar com partições excluídas

  Ao usar crawlers de eventos do Amazon S3 com as tabelas do Catálogo de Dados:

  - Se você excluir uma partição usando a chamada de API `DeletePartition`, também deverá excluir todos os objetos do S3 contidos nessa partição e selecionar a opção Todos os eventos de remoção de objetos ao configurar as notificações de eventos do S3. Se os eventos de exclusão não estiverem configurados, o crawler recriará a partição excluída na próxima execução.
- O crawler só é compatível com um único destino, tanto para destinos do Amazon S3 quanto do Data Catalog.
- Não há suporte para SQS na VPC privada.
- Não há suporte para amostragem do Amazon S3.
- O destino do crawler deve ser uma pasta para um destino do Amazon S3 ou uma ou mais tabelas do AWS Glue Data Catalog para um destino do Data Catalog.
- Não há suporte para o curinga de caminho ‘everything’ (tudo): s3: //%
- Para um destino do Data Catalog, todas as tabelas de catálogo devem apontar para o mesmo bucket do Amazon S3 para o modo de evento do Amazon S3.

- Para um destino do Data Catalog, uma tabela de catálogo não deve apontar para uma localização no Amazon S3 no formato Delta Lake (contendo pastas _symlink ou conferindo o `InputFormat` da tabela do catálogo).

Tópicos

- Configurar sua conta para notificações de eventos do Amazon S3
- Configurar um crawler de notificações de eventos do Amazon S3 para um destino do Amazon S3
- Configurar um crawler para notificações de eventos do Amazon S3 para uma tabela do Catálogo de dados

Configurar sua conta para notificações de eventos do Amazon S3

Complete as tarefas de configuração a seguir. Observe que os valores entre parênteses fazem referência às definições configuráveis do script.

1. É necessário configurar notificações de eventos para seu bucket do Amazon S3.

   Para obter mais informações, consulte Notificações de eventos do Amazon S3.
2. Para usar o crawler baseado em eventos do Amazon S3, você deve habilitar a notificação de eventos no bucket do Amazon S3 com eventos filtrados do prefixo que é o mesmo que o destino do S3 e armazenado no SQS. Você pode configurar o SQS e a notificação de eventos por meio do console seguindo as etapas em Passo a passo: configuração de um bucket para notificações.
3. Adicione a política de SQS a seguir à função usada pelo crawler.

```
{
    "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"
        }
    ]
}
```

Configurar um crawler de notificações de eventos do Amazon S3 para um destino do Amazon S3

Siga estas etapas para configurar um crawler para notificações de eventos do Amazon S3 para um destino do Amazon S3 usando o AWS Management Console ou a AWS CLI.

AWS Management Console

1. Faça login no AWS Management Console e abra o console do GuardDuty em https://console.aws.amazon.com/guardduty/.
2. Defina as propriedades do crawler. Para obter mais informações, consulte Definir opções de configuração do crawler no console do AWS Glue.
3. Na seção Configuração da fonte de dados, é perguntado a você se Os dados já estão mapeados para tabelas do AWS Glue?

   A opção Not yet (Ainda não) já estará selecionada por padrão. Isso ocorre porque você está usando uma fonte de dados do Amazon S3 e os dados ainda não estão mapeados para as tabelas do AWS Glue.
4. Na seção Data sources (Fontes de dados), escolha Add a data source (Adicionar uma fonte de dados).

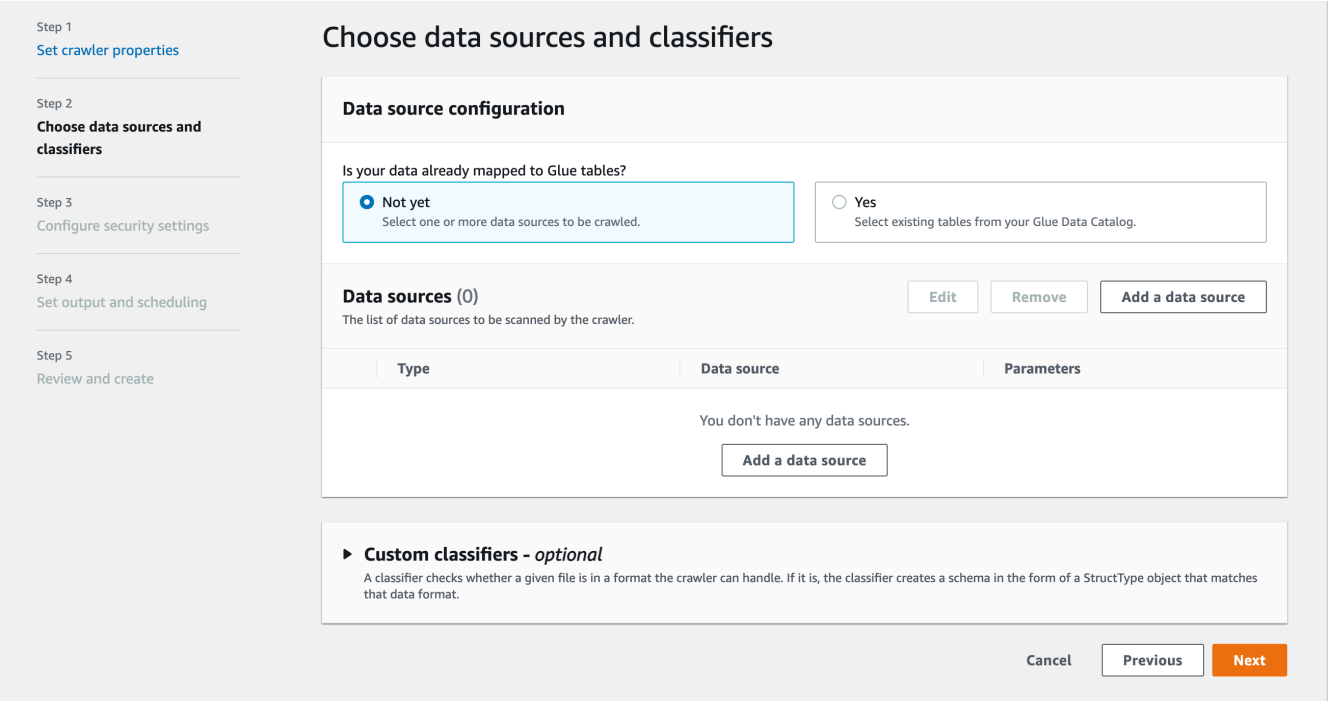

5. No modal Add data source (Adicionar origem dos dados), configure a fonte de dados do Amazon S3:

   - Data source (Fonte de dados): o Amazon S3 é selecionado por padrão.
   - Network connection (Conexão de rede) (opcional): escolha Add new connection (Adicionar nova conexão).
   - Location of Amazon S3 data (Local de dados do Amazon S3): a opção In this account (Nesta conta) será selecionado por padrão.
   - Amazon S3 path (Caminho do Amazon S3): especifique o caminho do Amazon S3 no qual pastas e arquivos são rastreados.
   - Subsequent crawler runs (Execuções subsequentes do crawler): escolha Crawl based on events (Rastreamento baseado em eventos) para usar notificações de eventos do Amazon S3 para seu crawler.
   - Include SQS ARN (Incluir ARN de SQS): especifique os parâmetros do armazenamento de dados, incluindo um ARN válido do SQS. (Por exemplo, `arn:aws:sqs:region:account:sqs`).
   - Include dead-letter SQS ARN (Incluir ARN de mensagens não entregues do SQS) (opcional): especifique um ARN válido de mensagens não entregues do SQS na Amazon. (Por exemplo, `arn:aws:sqs:region:account:deadLetterQueue`).
   - Escolha Add an Amazon S3 data source (Adicionar uma fonte de dados do Amazon S3).

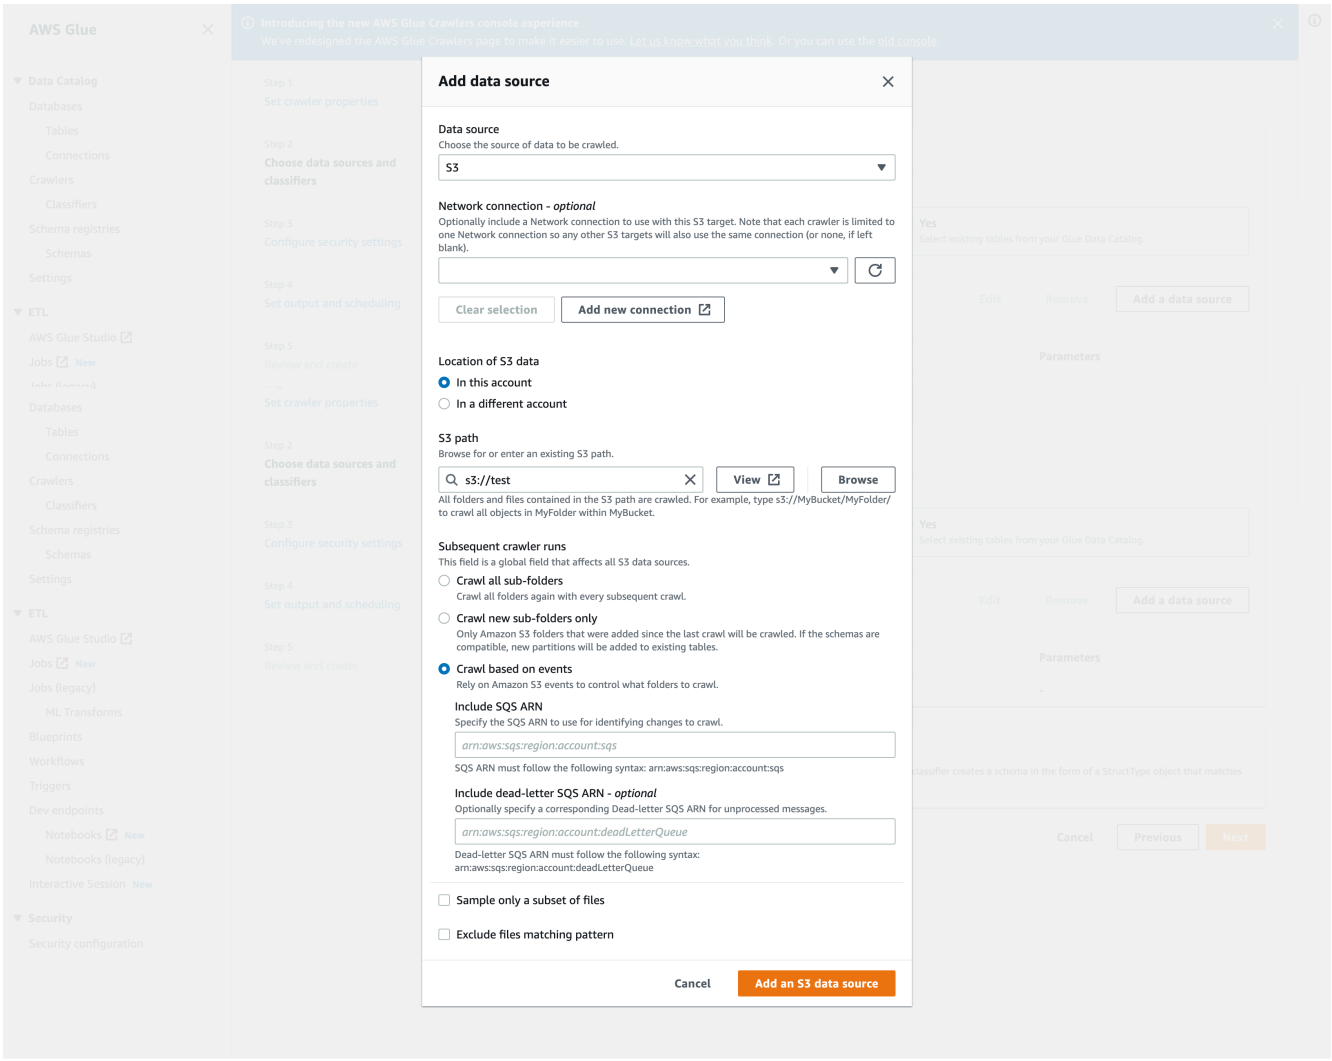

AWS CLI

O exemplo a seguir é uma chamada da AWS CLI do Amazon S3 para configurar um crawler para usar notificações de eventos para fazer crawl em um bucket de destino do 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"}]}'
```

Configurar um crawler para notificações de eventos do Amazon S3 para uma tabela do Catálogo de dados

Quando você tiver uma tabela do Catálogo de dados, configure um crawler para fornecer notificações de eventos do Amazon S3 usando o console do AWS Glue:

1. Defina as propriedades do crawler. Para obter mais informações, consulte Definir opções de configuração do crawler no console do AWS Glue.
2. Na seção Configuração da fonte de dados, é perguntado a você se Os dados já estão mapeados para tabelas do AWS Glue?

   Selecione Yes (Sim) para selecionar as tabelas existentes do Data Catalog como fonte de dados.
3. Na seção Glue tables (Tabelas do Glue), escolha Add tables (Adicionar tabelas).

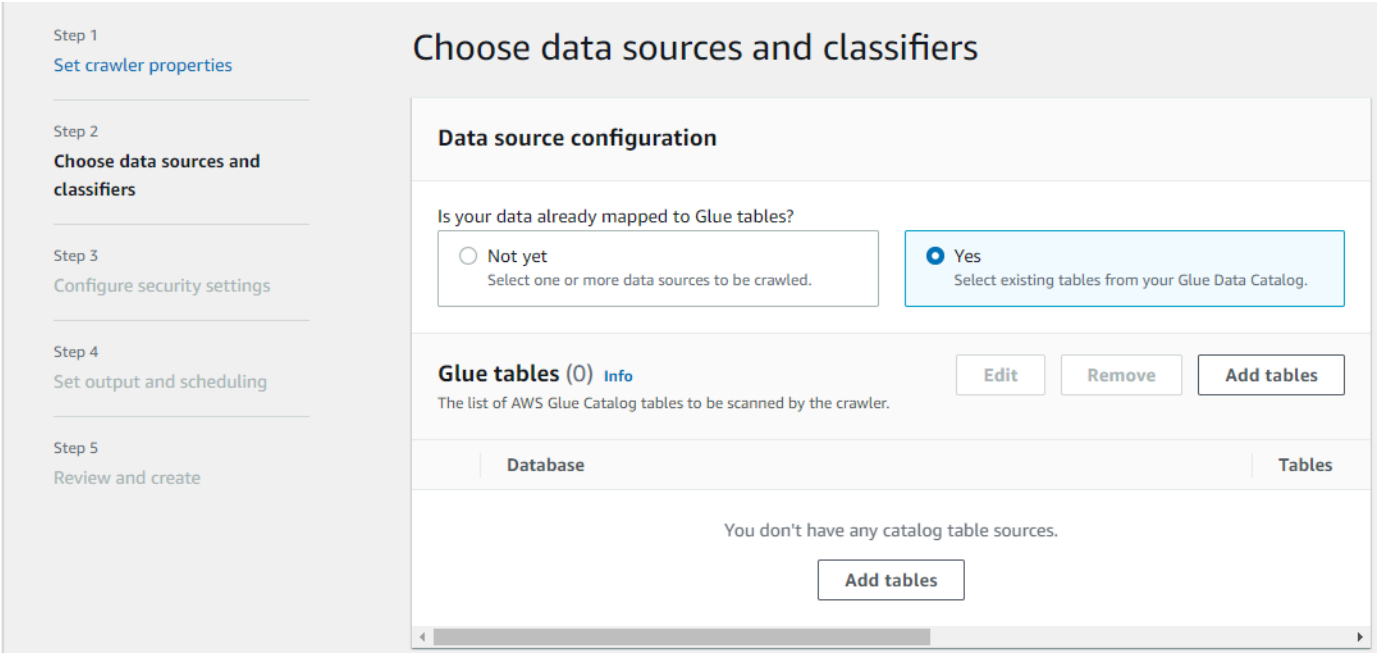

4. No modal Add table (Adicionar tabela), configure o banco de dados e as tabelas:

   - Network connection (Conexão de rede) (opcional): escolha Add new connection (Adicionar nova conexão).
   - Database (Banco de dados): selecione um banco de dados no Data Catalog.

- Tables (Tabelas): selecione uma ou mais tabelas desse banco de dados no Data Catalog.
- Subsequent crawler runs (Execuções subsequentes do crawler): escolha Crawl based on events (Rastreamento baseado em eventos) para usar notificações de eventos do Amazon S3 para seu crawler.
- Include SQS ARN (Incluir ARN de SQS): especifique os parâmetros do armazenamento de dados, incluindo um ARN válido do SQS. (Por exemplo, `arn:aws:sqs:region:account:sqs`).
- Include dead-letter SQS ARN (Incluir ARN de mensagens não entregues do SQS) (opcional): especifique um ARN válido de mensagens não entregues do SQS na Amazon. (Por exemplo, `arn:aws:sqs:region:account:deadLetterQueue`).
- Selecione a opção Confirmar.

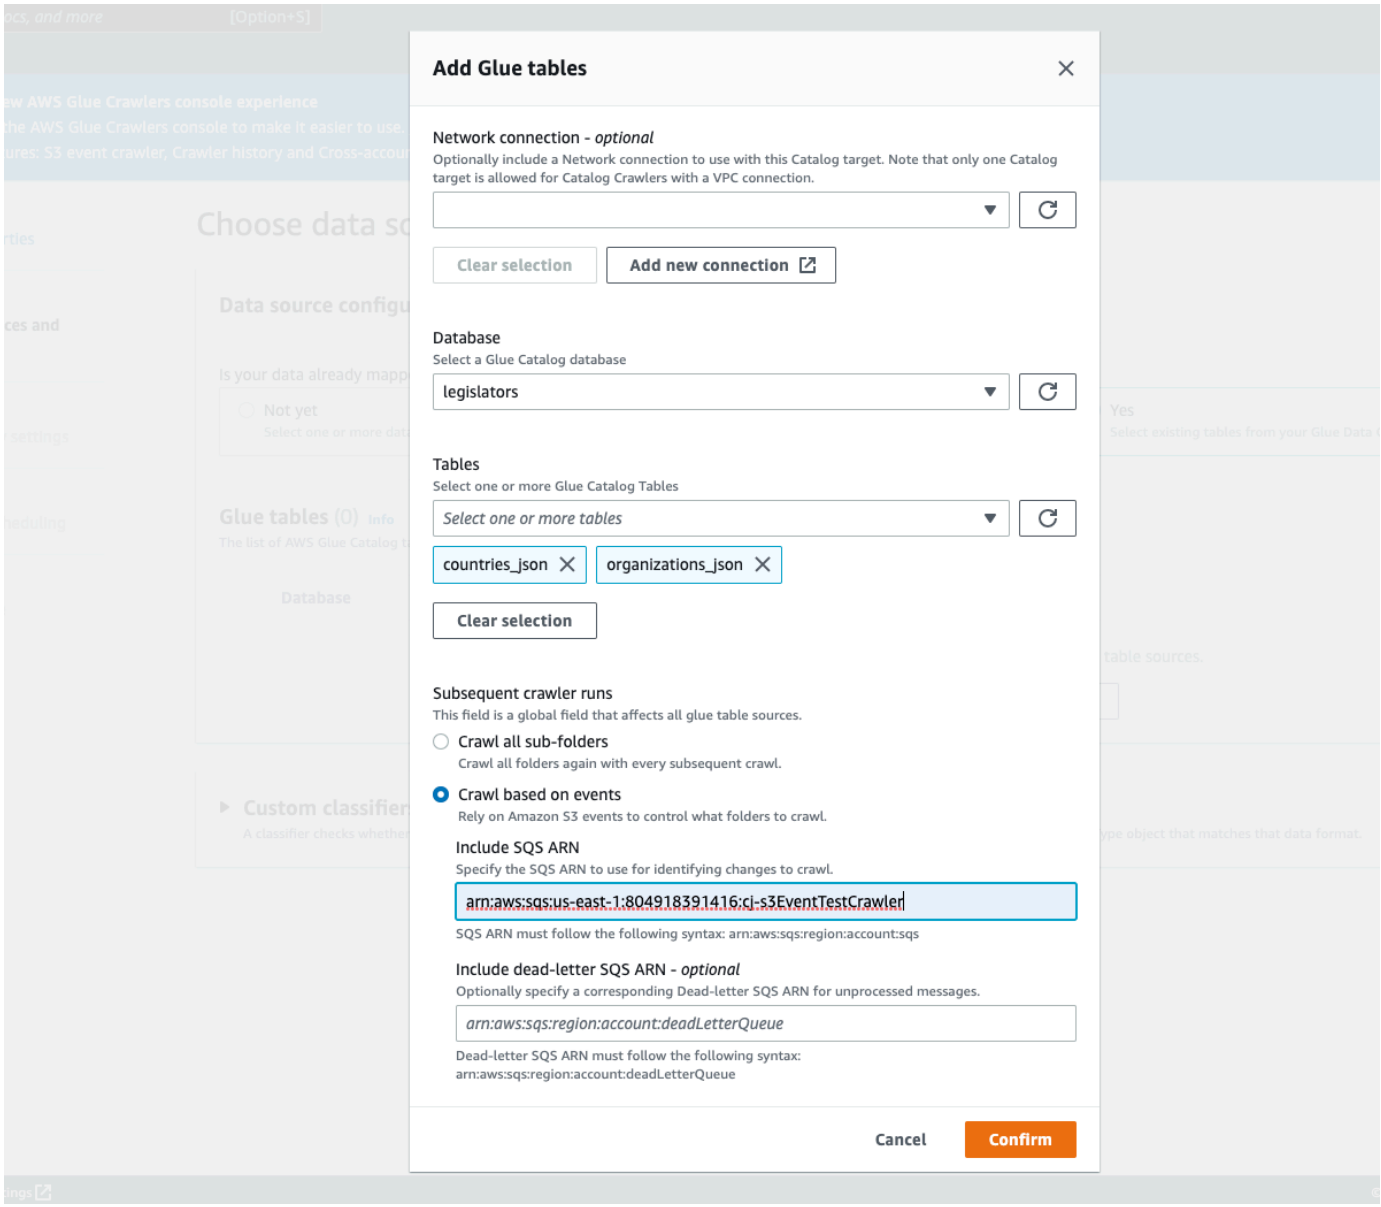

Tutorial: Adicionar um crawler do AWS Glue

Para este cenário do AWS Glue, será solicitado que você analise os dados de chegada das principais transportadoras aéreas para calcular a popularidade dos aeroportos de partida mês a mês. Você tem dados de voos do ano de 2016 no formato CSV armazenados no Amazon S3. Antes de transformar e analisar seus dados, você cataloga seus metadados no AWS Glue Data Catalog.

Neste tutorial, vamos adicionar um crawler que infere metadados desses logs de voos no Amazon S3 e cria uma tabela no Data Catalog.

Tópicos

- Pré-requisitos
- Etapa 1: Adicionar um crawler
- Etapa 2: Executar o crawler
- Etapa 3: Exibir objetos do AWS Glue Data Catalog

Pré-requisitos

Este tutorial pressupõe que você tem uma conta da AWS e acesso ao AWS Glue.

Etapa 1: Adicionar um crawler

Use estas etapas para configurar e executar um crawler que extrai os metadados de um arquivo CSV armazenado no Amazon S3.

Para criar um crawler que lê arquivos armazenados no Amazon S3

1. No console de serviço do AWS Glue, no menu do lado esquerdo, selecione Crawlers.
2. Na página Crawlers, escolha Create crawler (Criar crawler). Isso inicia uma série de páginas que solicitam os detalhes do crawler.

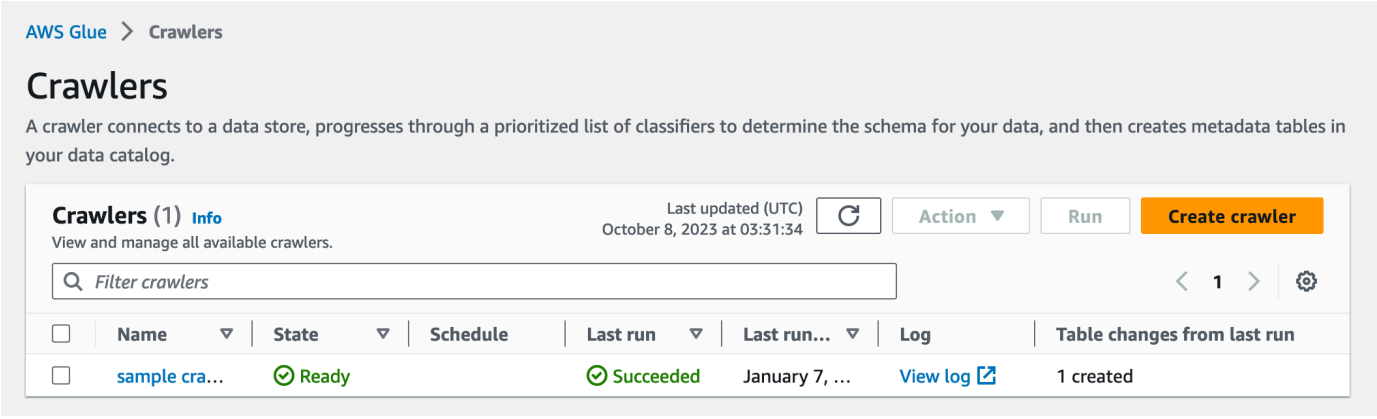

3. No campo de nome do crawler, insira **`Flights Data Crawler`** e, em seguida, escolha Next (Próximo).

   Crawlers invocam classificadores para inferir o esquema dos seus dados. Este tutorial usa o classificador integrado para CSV por padrão.
4. Para o tipo de origem do crawler, escolha Data stores (Armazenamentos de dados) e, em seguida, Next (Próximo).

5. Agora, vamos apontar o crawler para os seus dados. Na página Add a data store (Adicionar um armazenamento de dados), escolha o armazenamento de dados do Amazon S3. Este tutorial não usa uma conexão, então deixe o campo Connection (Conexão) em branco, se estiver visível.

   Na opção Crawl data in (Rastrear dados em), escolha Specified path in another account (Caminho especificado em outra conta). Em Include path (Incluir o caminho), insira o caminho em que o crawler pode encontrar os dados de voos, que é **`s3://crawler-public-us-east-1/flight/2016/csv`**. Depois de inserir o caminho, o título desse campo muda para Include path (Incluir o caminho). Escolha Próximo.

6. É possível rastrear vários armazenamentos de dados com um único crawler. No entanto, neste tutorial, estamos usando apenas um único armazenamento de dados, então escolha No (Não) e, depois, escolha Next (Próximo).

7. O crawler precisa de permissões para acessar o armazenamento de dados e criar objetos no AWS Glue Data Catalog. Para configurar essas permissões, escolha Create an IAM role (Criar uma função do IAM). O nome da função do IAM começa com `AWSGlueServiceRole-` e, no campo, insira a última parte do nome da função. Insira **`CrawlerTutorial`** e escolha Next (Próximo).

   > **Note**
   >
   > Para criar uma função do IAM, seu usuário da AWS deve ter as permissões `CreateRole`, `CreatePolicy` e `AttachRolePolicy`.

   O assistente cria uma função do IAM denominada `AWSGlueServiceRole-CrawlerTutorial`, anexa a política gerenciada pela AWS `AWSGlueServiceRole` a essa função e adiciona uma política embutida que permite acesso de leitura ao local do Amazon S3 `s3://crawler-public-us-east-1/flight/2016/csv`.

8. Crie uma programação para o crawler. Em Frequency (Frequência), escolha Run on demand (Executar sob demanda) e, depois, escolha Next (Próximo).

9. Os crawlers criam tabelas no Data Catalog. As tabelas são contidas em um banco de dados no Data Catalog. Primeiro, escolha Add database (Adicionar banco de dados) para criar um banco de dados. Na janela pop-up, insira **`test-flights-db`** no nome do banco de dados e escolha Create (Criar).

Em seguida, insira **`flights`** em Prefix added to tables (Prefixo adicionado às tabelas). Use os valores padrão para o restante das opções e escolha Next (Próximo).

10. Verifique as opções que você escolheu no assistente Add crawler (Adicionar crawler). Se você vir algum erro, pode escolher Back (Voltar) para retornar às páginas anteriores e fazer alterações.

    Depois de revisar as informações, escolha Finish (Finalizar) para criar o crawler.

Etapa 2: Executar o crawler

Depois de criar um crawler, o assistente o envia para a página de exibição de crawlers. Como você cria o crawler com uma programação sob demanda, você tem a opção de executá-lo.

Para executar o crawler

1. O banner próximo à parte superior dessa página permite que você saiba que o crawler foi criado e pergunta se você deseja executá-lo agora. Escolha Run it now? (Executá-lo agora?) para executar o crawler.

   O banner muda para mostrar as mensagens “Attempting to run” (Tentativa de execução) e “Running” (Em execução) para o crawler. Depois que o crawler começa a ser executado, o banner desaparece e a exibição do crawler é atualizada para mostrar o status “Starting” (Iniciando) para o crawler. Após um minuto, você pode clicar no ícone Refresh (Atualizar) para atualizar o status do crawler exibido na tabela.
2. Quando o crawler for concluído, será exibido um novo banner que descreve as alterações feitas por ele. Você pode escolher o link test-flights-db para exibir os objetos do Data Catalog.

Etapa 3: Exibir objetos do AWS Glue Data Catalog

O crawler lê dados no local de origem e cria tabelas no Data Catalog. A tabela é uma definição de metadados que representa seus dados, incluindo o esquema. As tabelas no Data Catalog não contêm dados. Em vez disso, você usa essas tabelas como uma origem ou destino em uma definição de trabalho.

Para exibir os objetos do Data Catalog criados pelo crawler

1. No painel de navegação do lado esquerdo, em Data Catalog, escolha Databases (Bancos de dados). Aqui você pode ver o banco de dados `flights-db` criado pelo crawler.

2. No painel de navegação do lado esquerdo, em Data Catalog e abaixo de Databases (Bancos de dados), escolha Tables (Tabelas). Aqui, você pode ver a tabela `flightscsv` criada pelo crawler. Se você escolher o nome da tabela, poderá exibir as configurações, os parâmetros e as propriedades dela. Ao rolar para baixo nessa exibição, você pode ver o esquema, que são informações sobre as colunas e os tipos de dados da tabela.
3. Se escolher View partitions (Exibir partições) na página de exibição da tabela, poderá ver as partições criadas para os dados. A primeira coluna é a chave de partição.

Definir metadados manualmente

O Catálogo de Dados do AWS Glue é um repositório central que armazena metadados sobre suas fontes de dados e conjuntos de dados. Embora um crawler possa obter e preencher automaticamente os metadados das fontes de dados compatíveis, há alguns cenários em que talvez seja necessário definir os metadados manualmente no Catálogo de Dados:

- Formatos de dados incompatíveis: se você tiver fontes de dados que não são compatíveis com o crawler, será necessário definir manualmente os metadados dessas fontes de dados no Catálogo de Dados.
- Requisitos de metadados personalizados: o Crawler do AWS Glue infere metadados com base em regras e convenções predefinidas. Se você tiver requisitos específicos de metadados que não são cobertos pelos metadados Crawler do AWS Glue inferidos, você poderá definir manualmente os metadados para atender às suas necessidades
- Governança e padronização de dados: em alguns casos, talvez você queira ter mais controle sobre as definições de metadados por motivos de governança, conformidade ou segurança de dados. A definição manual de metadados permite garantir que os metadados estejam de acordo com os padrões e políticas da sua organização.
- Espaço reservado para futura ingestão de dados: se houver fontes de dados que não estão imediatamente disponíveis ou acessíveis, você poderá criar tabelas de esquema vazias como espaços reservados. Quando as fontes de dados se tornarem disponíveis, você poderá preencher as tabelas com os dados reais, mantendo a estrutura predefinida.

Para definir metadados manualmente, você pode usar o console do AWS Glue, o console do Lake Formation, a API do AWS Glue ou o a AWS Command Line Interface (AWS CLI). É possível criar bancos de dados, tabelas e partições e especificar propriedades de metadados, como nomes de colunas, tipos de dados, descrições e outros atributos.

Criar bancos de dados

Os bancos de dados são usados para organizar tabelas de metadados no AWS Glue. Ao definir uma tabela no AWS Glue Data Catalog, você a adiciona a um banco de dados. Uma tabela pode estar somente em um banco de dados por vez.

Seu banco de dados pode conter tabelas que definem dados de diferentes armazenamentos de dados. Esses dados podem incluir objetos no Amazon Simple Storage Service (Amazon S3) e tabelas relacionais no Amazon Relational Database Service.

> **Note**
>
> Quando você exclui um banco de dados do AWS Glue Data Catalog, todas as tabelas contidas nele também são excluídas.

Para visualizar a lista de bancos de dados, faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/. Escolha Databases e, em seguida, selecione o nome do banco de dados na lista para ver os detalhes dele.

Na guia Databases no console do AWS Glue, você pode adicionar, editar e excluir bancos de dados:

- Para criar um novo banco de dados, escolha Add database e forneça um nome e uma descrição. Para compatibilidade com outros armazenamentos de metadados, como o Apache Hive, as letras do nome são transformadas em minúsculas.

  > **Note**
  >
  > Se você planeja acessar o banco de dados a partir do Amazon Athena, forneça um nome somente com caracteres alfanuméricos e sublinhados. Para obter mais informações, consulte Nomes de tabelas, bancos de dados e colunas.

- Para editar a descrição de um banco de dados, marque a caixa de seleção ao lado do nome do banco de dados e escolha Edit (Editar).
- Para excluir um banco de dados, marque a caixa de seleção ao lado do nome do banco de dados e escolha Remove.
- Para exibir a lista de tabelas contidas no banco de dados, escolha o nome do banco de dados e as propriedades do banco de dados exibirão todas as tabelas no banco de dados.

Para alterar o banco de dados em que o crawler escreve, você precisa alterar a definição desse crawler. Para ter mais informações, consulte Usar crawlers para preencher o catálogo de dados .

Links de recursos de bancos de dados

> O console do AWS Glue passou por uma atualização recente. A versão atual do console não é compatível com links de recursos de banco de dados.

O Data Catalog também pode conter links do recurso para bancos de dados. Um link de recurso de banco de dados é um link para um banco de dados local ou compartilhado. No momento, você pode criar links de recursos somente no AWS Lake Formation. Depois de criar um link de recurso para um banco de dados, você pode usar o nome do link de recurso onde quer que você use o nome do banco de dados. Junto com bancos de dados que você possui ou que são compartilhados com você, links de recursos de banco de dados são retornados por `glue:GetDatabases()` e aparecem como entradas na página Databases (Bancos de dados) do console do AWS Glue.

O Data Catalog também pode conter links do recurso para tabelas.

Para obter mais informações sobre links de recursos, consulte Criar links de recursos no Guia do desenvolvedor do AWS Lake Formation.

Criar tabelas

Embora a execução de um crawler seja o método recomendado para fazer o inventário dos dados em seus armazenamentos de dados, você pode adicionar tabelas de metadados ao AWS Glue Data Catalog manualmente. Essa abordagem permite que você tenha mais controle sobre as definições de metadados e as personalize de acordo com seus requisitos específicos.

Você também pode adicionar definições de tabela manualmente ao Catálogo de Dados das seguintes formas:

- Use o console do AWS Glue para criar manualmente uma tabela no AWS Glue Data Catalog. Para ter mais informações, consulte Criar tabelas usando o console.
- Use a operação `CreateTable` em API AWS Glue para criar uma tabela no AWS Glue Data Catalog. Para ter mais informações, consulte Ação CreateTable (Python: create_table).
- Use modelos do AWS CloudFormation. Para ter mais informações, consulte AWS CloudFormation para AWS Glue.

Ao definir uma tabela manualmente usando o console ou uma API, você especifica o esquema da tabela e o valor de um campo de classificação que indica o tipo e o formato dos dados na fonte de dados. Se um crawler criar a tabela, o esquema e o formato dos dados serão determinados por um classificador integrado ou um classificador personalizado. Para obter mais informações sobre como criar uma tabela usando o console do AWS Glue, consulte Criar tabelas usando o console.

Tópicos

- Partições de tabela
- Links de recursos de tabela
- Criar tabelas usando o console
- Criar índices de partição
- Atualizar tabelas do Data Catalog criadas manualmente usando crawlers
- Propriedades da tabela do Data Catalog

Partições de tabela

Uma definição de tabela do AWS Glue de uma pasta do Amazon Simple Storage Service (Amazon S3) pode descrever uma tabela particionada. Por exemplo, para melhorar a performance da consulta, uma tabela particionada pode separar dados mensais em diferentes arquivos usando o nome do mês como uma chave. No AWS Glue, as definições de tabela incluem a chave de particionamento de uma tabela. Quando o AWS Glue avalia os dados nas pastas do Amazon S3 para catalogar uma tabela, ele determina se foi adicionada uma tabela individual ou particionada.

Você pode criar índices de partição em uma tabela para buscar um subconjunto das partições em vez de carregar todas as partições na tabela. Para obter mais informações sobre como trabalhar com índices de partição, consulte Criar índices de partição .

Todas as condições a seguir precisam ser verdadeiras para que o AWS Glue crie uma tabela particionada para uma pasta do Amazon S3:

- Os esquemas dos arquivos são semelhantes, conforme determinado pelo AWS Glue.
- O formato de dados dos arquivos é o mesmo.
- A compressão de dados dos arquivos é a mesma.

Por exemplo, você pode possuir um bucket do Amazon S3 chamado `my-app-bucket`, onde armazena dados de vendas de aplicações iOS e Android. Os dados são particionados por ano,

mês e dia. Os arquivos de dados para vendas de aplicativos iOS e Android têm o mesmo esquema, formato de dados e formato de compactação. No AWS Glue Data Catalog, o crawler do AWS Glue cria uma definição de tabela com chaves de particionamento por ano, mês e dia.

A seguinte listagem do Amazon S3 de `my-app-bucket` mostra algumas das partições. O símbolo = é usado para atribuir valores de chave de partição.

```
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
```

Links de recursos de tabela

> O console do AWS Glue passou por uma atualização recente. A versão atual do console não é compatível com links de recursos de tabela.

O Data Catalog também pode conter links de recursos para tabelas. Um link de recurso de tabela é um link para uma tabela local ou compartilhada. No momento, você pode criar links de recursos somente no AWS Lake Formation. Depois de criar um link de recurso para uma tabela, você pode usar o nome do link de recurso onde quer que você use o nome da tabela. Junto com tabelas que você possui ou que são compartilhadas com você, links de recursos de tabelas são retornados por `glue:GetTables()` e aparecem como entradas na página Tables (Tabelas) do console do AWS Glue.

O Data Catalog também pode conter links de recursos de banco de dados.

Para obter mais informações sobre links de recursos, consulte Criar links de recursos no Guia do desenvolvedor do AWS Lake Formation.

Criar tabelas usando o console

Uma tabela no AWS Glue Data Catalog é a definição de metadados que representa os dados em um datastore. Você cria tabelas quando executa um crawler ou manualmente no console do AWS

Glue. A lista Tables (Tabelas) no console do AWS Glue exibe valores dos metadados da sua tabela. Você usa definições de tabela para especificar fontes e destino ao criar trabalhos de ETL (extração, transformação e carregamento).

> **Note**
>
> Com as mudanças recentes no console de gerenciamento da AWS, pode ser necessário modificar os perfis do IAM existentes para que tenham a permissão de `SearchTables`. Para a criação de um novo perfil, a permissão da API `SearchTables` já foi adicionada como padrão.

Para começar, faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/. Escolha a guia Tables e use o botão Add tables para criar tabelas com um crawler ou digitando atributos manualmente.

Adicionar tabelas ao console

Para usar um crawler para adicionar tabelas, escolha Add tables, Add tables using a crawler. Em seguida, siga as instruções no assistente Add crawler. Quando o crawler for executado, as tabelas serão adicionadas ao AWS Glue Data Catalog. Para ter mais informações, consulte Usar crawlers para preencher o catálogo de dados .

Se você conhecer os atributos necessários para criar uma definição de tabela do Amazon Simple Storage Service (Amazon S3) no Data Catalog, você poderá criá-la com o assistente de tabela. Escolha Add tables, Add table manually a siga as instruções no assistente Add table.

Ao adicionar uma tabela manualmente usando o console, considere o seguinte:

- Se você planeja acessar a tabela a partir do Amazon Athena, forneça um nome somente com caracteres alfanuméricos e sublinhados. Para obter mais informações, consulte Nomes do Athena.
- O local dos seus dados de origem deve ser um caminho do Amazon S3.
- O formato dos dados deve corresponder a um dos formatos listados no assistente. A classificação correspondente, SerDe e outras propriedades da tabela serão preenchidas automaticamente com base no formato escolhido. Você pode definir tabelas com os seguintes formatos:

  Avro

  Formato binário JSON do Apache Avro.

CSV

Valores separados por vírgula (CSV). Você também especifica o delimitador como vírgula, pipe, ponto e vírgula, tabulação ou Ctrl+A.

JSON

JavaScript Object Notation.

XML

Formato Extensible Markup Language. Especifique a tag XML que define uma linha nos dados. As colunas são definidas nas tags de linha.

Parquet

Armazenamento em colunas no Apache Parquet.

ORC

Formato Optimized Row Columnar (ORC). Um formato criado para armazenar dados do Hive com eficiência.

- Você pode definir uma chave de partição para a tabela.
- Atualmente, as tabelas particionadas que você cria com o console não podem ser usadas em trabalhos de ETL.

Atributos da tabela

Veja a seguir alguns atributos importantes da sua tabela:

Nome

O nome é determinado quando a tabela é criada, e você não pode alterá-la. Você faz referência a um nome de tabela em muitas operações do AWS Glue.

Banco de dados

O objeto do contêiner onde a sua tabela reside. Este objeto contém uma organização das suas tabelas que existe dentro do AWS Glue Data Catalog e pode diferir de uma organização no seu datastore. Quando você exclui um banco de dados, todas as tabelas contidas nele também são excluídas do Data Catalog.

Descrição

A descrição da tabela. Você pode escrever uma descrição para ajudá-lo a entender o conteúdo da tabela.

Formato da tabela

Especifique a criação de uma tabela padrão do AWS Glue ou de uma tabela no formato do Apache Iceberg.

O Data Catalog fornece as seguintes opções de otimização de tabelas para gerenciar o armazenamento de tabelas e melhorar o desempenho de consultas para tabelas Iceberg.

- Compactação: os arquivos de dados são mesclados e regravados para remover dados obsoletos e consolidar dados fragmentados em arquivos maiores e mais eficientes.
- Retenção de snapshots: os snapshots são versões com carimbo de data e hora de uma tabela do Iceberg. As configurações de retenção de snapshots permitem que os clientes determinem por quanto tempo reter e quantos snapshots devem ser retidos. A configuração de um otimizador de retenção de snapshots pode ajudar a gerenciar a sobrecarga de armazenamento removendo snapshots antigos e desnecessários e seus arquivos subjacentes.
- Exclusão de arquivos órfãos: arquivos órfãos são arquivos que não são mais referidos pelos metadados da tabela do Iceberg. Esses arquivos podem se acumular ao longo do tempo, especialmente após operações como exclusões de tabelas ou trabalhos de ETL com falha. Habilitar a exclusão de arquivos órfãos permite que o AWS Glue identifique e remova periodicamente esses arquivos desnecessários, liberando espaço de armazenamento.

Para ter mais informações, consulte Otimizar tabelas Iceberg.

Configuração de otimização

É possível usar as configurações padrão ou personalizar as configurações para ativar os otimizadores de tabela.

IAM role (Perfil do IAM)

Para executar a compactação, o serviço assume um perfil do IAM em seu nome. Você pode escolher um perfil do IAM usando o menu suspenso. Certifique-se de que o perfil tenha as permissões necessárias para habilitar a compactação.

Para saber mais sobre as permissões necessárias para o perfil do IAM, consulte Pré-requisitos de otimização de tabelas .

Local

O ponteiro para o local dos dados em um datastore que esta definição de tabela representa.

Classificação

Um valor de categorização fornecido quando a tabela foi criada. Normalmente, ele é escrito quando um crawler é executado e especifica o formato dos dados da fonte.

Última atualização

A hora e a data (UTC) em que esta tabela foi atualizada no Data Catalog.

Data adicionada

A hora e a data (UTC) em que esta tabela foi adicionada ao Data Catalog.

Preterido

Se o AWS Glue descobrir que uma tabela do Data Catalog não existe mais no seu datastore original, ele marcará essa tabela como defasada no catálogo de dados. Se você executar um trabalho que faz referência a uma tabela obsoleta, ele falhará. Edite trabalhos que fazem referência a tabelas obsoletas para removê-las como fontes e destinos. Recomendamos que você elimine tabelas obsoletas quando elas não forem mais necessárias.

Conexão

Se o AWS Glue exigir conexão com seu datastore, o nome da conexão será associado à tabela.

Exibir e gerenciar detalhes da tabela

Para ver os detalhes de uma tabela existente, escolha o nome dela na lista e, em seguida, Action, View details.

Esses detalhes incluem propriedades da sua tabela e do seu esquema. Essa exibição mostra o esquema da tabela, incluindo os nomes de colunas na ordem definida para a tabela, os tipos de dados e as colunas de chaves para partições. Se uma coluna for de um tipo complexo, você poderá escolher View properties para exibir detalhes da estrutura desse campo, como mostrado no exemplo a seguir:

```
{
"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"
    }
}
```

Para obter mais informações sobre as propriedades de uma tabela, como `StorageDescriptor`, consulte Estrutura StorageDescriptor.

Para alterar o esquema de uma tabela, escolha Edit schema para adicionar e remover colunas, alterar nomes de colunas e alterar tipos de dados.

Para comparar diferentes versões de uma tabela, incluindo seu esquema, escolha Compare versions para ver uma comparação lado-a-lado de duas versões do esquema para uma tabela. Para ter mais informações, consulte Comparar versões de esquema de tabelas .

Para exibir os arquivos que compõem uma partição do Amazon S3, escolha View partition (Visualizar partição). Para tabelas do Amazon S3, a coluna Key (Chave) exibe as teclas de partição usadas para particionar a tabela no datastore de origem. Particionar é uma maneira de separar uma tabela em partes relacionadas com base nos valores de uma coluna de chave, como data, local ou departamento. Para obter mais informações sobre partições, pesquise na Internet informações sobre "particionamento do Hive".

> **Note**
>
> Para obter orientação detalhada para visualizar os detalhes de uma tabela, consulte o tutorial Explore table no console.

Comparar versões de esquema de tabelas

Ao comparar duas versões de esquema de tabela, você pode comparar alterações de linhas aninhadas expandindo-as e contraindo-as, comparar esquemas de duas versões lado a lado e visualizar as propriedades da tabela lado a lado.

Para comparar versões

1. No console do AWS Glue, escolha Tabelas, depois Ações e Comparar versões.

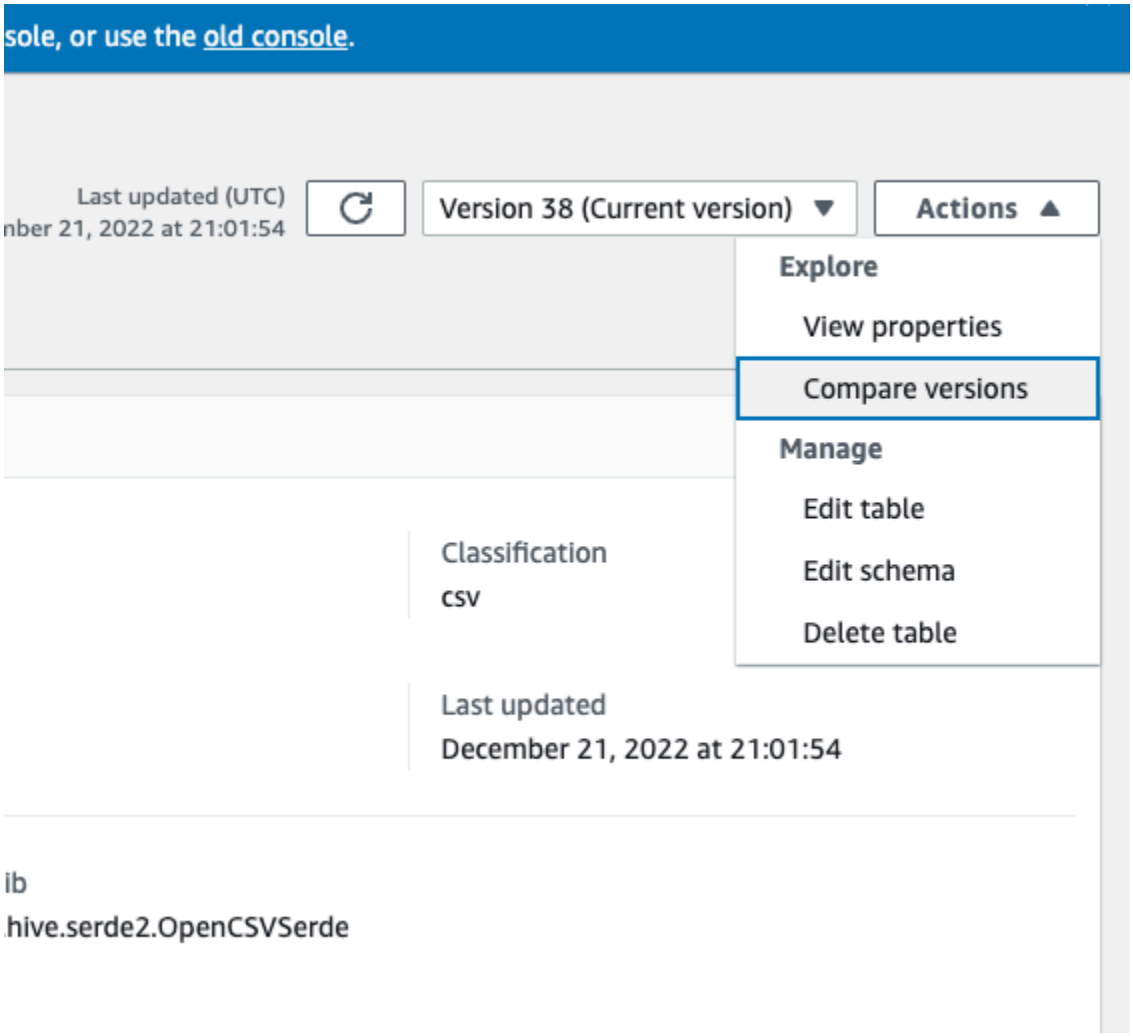

2. Escolha uma versão para comparar no menu suspenso de versões. Ao comparar esquemas, a guia Esquema fica realçada em laranja.
3. Quando você compara tabelas entre duas versões, os esquemas de tabela são apresentados a você no lado esquerdo e no lado direito da tela. Isso permite que você determine visualmente as alterações comparando os campos de nome da coluna, tipo de dados, chave e comentários lado a lado. Quando há uma alteração, um ícone colorido exibe o tipo de alteração que foi feita.
   - Excluído: exibido por um ícone vermelho indica onde a coluna foi removida de uma versão anterior do esquema da tabela.
   - Editado ou movido: exibido por um ícone azul indica onde a coluna foi modificada ou movida em uma versão mais recente do esquema da tabela.
   - Adicionado: exibido por um ícone verde indica onde a coluna foi adicionada a uma versão mais recente do esquema da tabela.

- Alterações aninhadas: exibido por um ícone amarelo indica onde a coluna aninhada contém as alterações. Escolha a coluna a ser expandida e visualize as colunas que foram excluídas, editadas, movidas ou adicionadas.

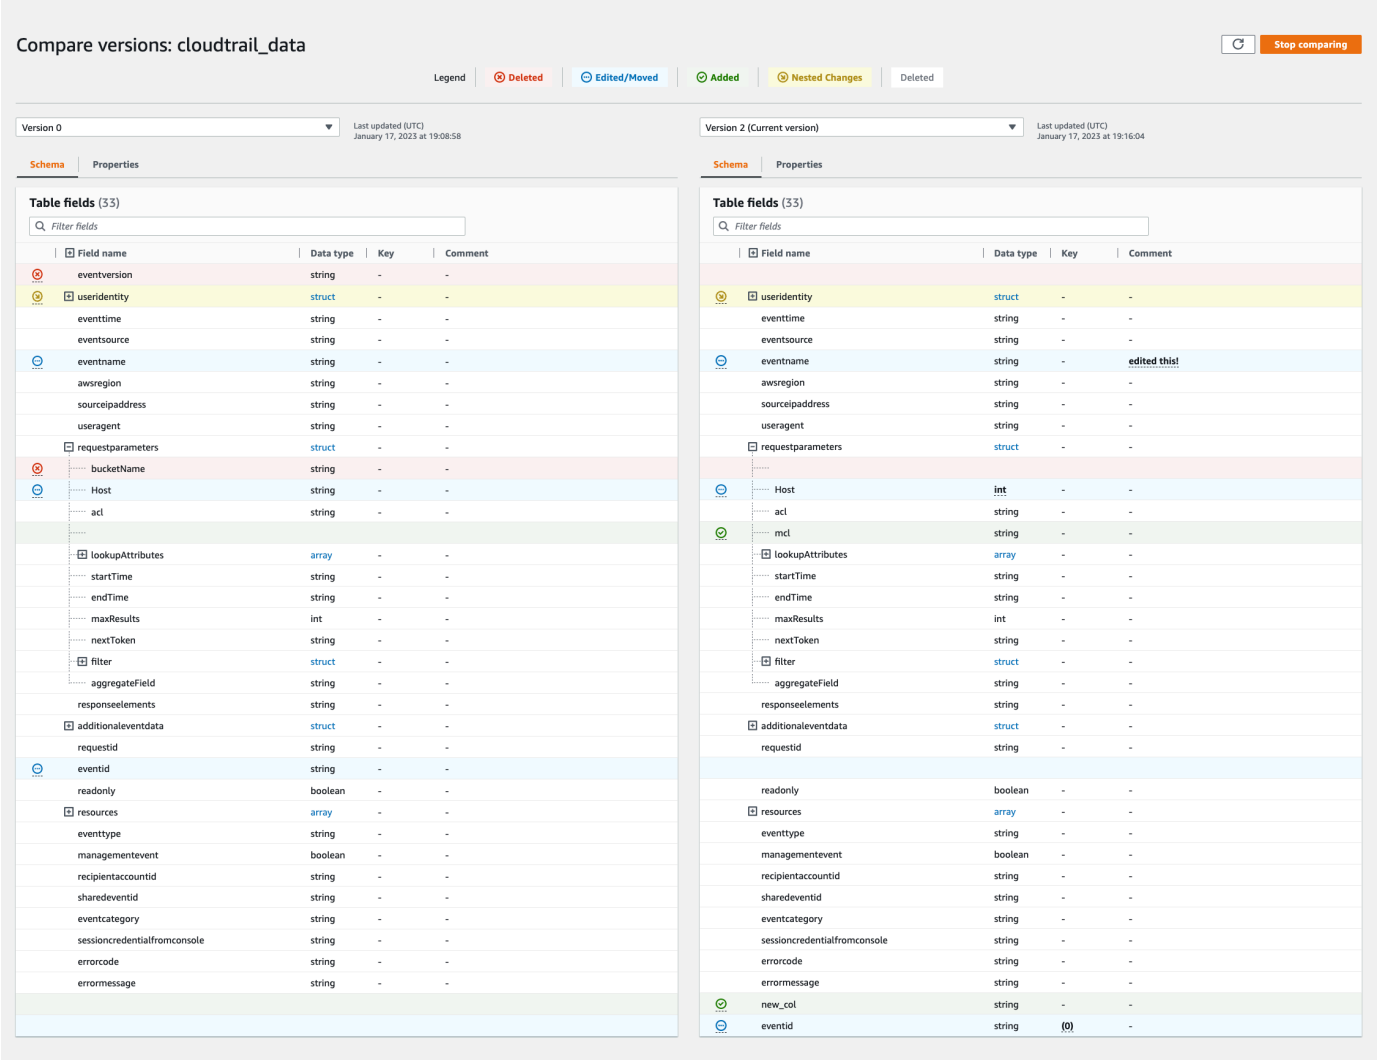

4. Use a barra de pesquisa de campos de filtro para exibir campos com base nos caracteres que você inserir aqui. Se você inserir um nome de coluna em qualquer uma das versões da tabela, os campos filtrados serão exibidos nas duas versões da tabela para mostrar onde as alterações ocorreram.
5. Para comparar propriedades, escolha a guia Propriedades.
6. Para parar de comparar versões, escolha Interromper comparação para retornar à lista de tabelas.

Criar índices de partição

Ao longo do tempo, centenas de milhares de partições são adicionadas a uma tabela. A API GetPartitions é usada para buscar as partições na tabela. A API retorna partições que correspondem à expressão fornecida na solicitação.

Vamos usar como exemplo uma tabela dados_vendas que é particionada pelas chaves País, Categoria, Ano, Mês e creationDate. Para obter os dados de vendas para todos os itens vendidos da categoria Livros no ano de 2020 após 15/8/2020, será necessário fazer uma solicitação `GetPartitions` com a expressão "Categoria = 'Livros' e creationDate > '2020-08-15'" ao Catálogo de Dados.

Se nenhum índice de partição estiver presente na tabela, o AWS Glue carrega todas as partições da tabela e, em seguida, filtra as partições carregadas usando a expressão de consulta fornecida pelo usuário na solicitação `GetPartitions`. A consulta leva mais tempo para ser executada à medida que o número de partições aumenta em uma tabela sem índices. Com um índice, a consulta `GetPartitions` tentará buscar um subconjunto das partições em vez de carregar todas as partições na tabela.

Tópicos

- Sobre índices de partição
- Criar uma tabela com índices de partição
- Adicionar um índice de partição a uma tabela existente
- Descrever índices de partição em uma tabela
- Limitações no uso de índices de partição
- Usar índices para uma chamada GetPartitions otimizada
- Integração com mecanismos

Sobre índices de partição

Ao criar um índice de partição, você especifica uma lista de chaves de partição que já existem em uma tabela específica. O índice de partição é uma sublista de chaves de partição definidas na tabela. Um índice de partição pode ser criado em qualquer permutação de chaves de partição definidas na tabela. Para a tabela dados_vendas acima os índices possíveis são (país, categoria, creationDate), (país, categoria, ano), (país, categoria), (país), (categoria, país, ano, mês), e assim por diante.

O Data Catalog concatenará os valores de partição na ordem fornecida no momento da criação do índice. O índice é criado consistentemente à medida que as partições são adicionadas à tabela. É possível criar índices para tipos de colunas string (string, char e varchar), numérico (int, bigint, long, tinyint e smallint) e data (aaaa-MM-dd).

Tipos de dados compatíveis

- Data: uma data no formato ISO, como `YYYY-MM-DD`. Por exemplo, data `2020-08-15`. O formato usa hífens (-) para separar o ano, o mês e o dia. O intervalo permitido para datas de indexação se estende de `0000-01-01` até `9999-12-31`.
- String: um literal de string entre aspas simples ou duplas.
- Char: dados de caractere de comprimento fixo, com um comprimento especificado entre 1 e 255, por exemplo, char(10).
- Varchar: dados de caracteres de comprimento variável com um tamanho especificado entre 1 e 65535, como varchar(10).
- Numérico: int, bigint, long, tinyint e smallint

Índices em dados dos tipos Numérico, String e Data são compatíveis com os operadores =, >, >=, <, <= e “between” (entre). Atualmente, a solução de indexação oferece suporte somente ao operador lógico `AND`. Subexpressões com os operadores “LIKE”, “IN”, “OR” e “NOT” são ignoradas na expressão para filtragem usando um índice. A filtragem da subexpressão ignorada é feita nas partições obtidas após a aplicação da filtragem de índice.

Para cada partição adicionada a uma tabela, há um item de índice correspondente criado. Para uma tabela com “n” partições , um índice de partição resultará em “n” itens de índice de partição. O índice de partição “m” na mesma tabela resultará em “m*n” itens de índice de partição. Cada item de índice de partição será cobrado de acordo com a política de preços AWS Glue para armazenamento no catálogo de dados. Para obter detalhes sobre o preço do objeto de armazenamento, consulte Preço do AWS Glue.

Criar uma tabela com índices de partição

Você pode criar um índice de partição durante a criação da tabela. O `CreateTable` solicita uma lista de objetos `PartitionIndex` como uma entrada. Um máximo de três índices de partição pode ser criado em uma determinada tabela. Cada índice de partição requer um nome e uma lista de `partitionKeys` definidos para a tabela. Os índices criados em uma tabela podem ser obtidos usando a API `GetPartitionIndexes`

Adicionar um índice de partição a uma tabela existente

Para adicionar um índice de partição a uma tabela existente, use a operação `CreatePartitionIndex`. Você só pode criar um `PartitionIndex` por operação `CreatePartitionIndex`. Adicionar um índice não afeta a disponibilidade de uma tabela, pois a tabela continua disponível enquanto os índices estão sendo criados.

O status do índice de uma partição adicionada é definido como CREATING (Criando) e a criação dos dados do índice é iniciada. Se o processo para criar os índices for bem-sucedido, indexStatus (status do índice) é atualizado para ACTIVE (Ativo) e, para um processo malsucedido, o status do índice é atualizado para FAILED (Falhou). A criação do índice pode falhar por vários motivos, e você pode usar a operação `GetPartitionIndexes` para recuperar os detalhes da falha. As possíveis falhas são:

- ENCRYPTED_PARTITION_ERROR (Erro de partição criptografada): a criação de índice em uma tabela com partições criptografadas não é suportada.
- INVALID_PARTITION_TYPE_DATA_ERROR (Erro de dados de tipo de partição inválidos): exibido quando o valor da `partitionKey` não é válido para o valor do tipo de dados da `partitionKey` correspondente. Por exemplo, uma `partitionKey` com o tipo de dados “int” tem um valor “foo”.
- MISSING_PARTITION_VALUE_ERROR (Erro de valor de partição ausente): exibido quando o `partitionValue` para uma `indexedKey` não está presente. Isso pode acontecer quando uma tabela não é particionada de forma consistente.
- UNSUPPORTED_PARTITION_CHARACTER_ERROR (Erro de caractere de partição não suportado): exibido quando o valor de uma chave de partição indexada contém os caracteres \u0000, \u0001 ou \u0002
- INTERNAL_ERROR (Erro interno): ocorreu um erro interno enquanto os índices eram criados.

Descrever índices de partição em uma tabela

Para buscar os índices de partição criados em uma tabela, use a operação `GetPartitionIndexes`. A resposta retorna todos os índices na tabela, juntamente com o status atual de cada índice (o `IndexStatus`).

O `IndexStatus` para um índice de partição será um dos seguintes:

- `CREATING`: o índice está sendo criado e ainda não está disponível para uso.
- `ACTIVE`: o índice está pronto para uso. As solicitações podem usar o índice para executar uma consulta otimizada.

- `DELETING`: o índice está sendo excluído e não pode mais ser usado. Um índice no estado ativo pode ser excluído usando a solicitação `DeletePartitionIndex`, que move o status de ACTIVE (Ativo) para DELETING (Excluindo).
- `FAILED`: falha na criação do índice em uma tabela existente. Cada tabela armazena os últimos dez índices com falha.

As possíveis transições de estado para índices criados em uma tabela existente são:

- CREATING → ACTIVE → DELETING
- CREATING → FAILED

Limitações no uso de índices de partição

Depois de criar um índice de partição, observe estas alterações na funcionalidade da tabela e da partição:

Criação de uma nova partição (após a adição do índice)

Depois que um índice de partição é criado em uma tabela, todas as novas partições adicionadas à tabela serão validadas para as verificações de tipo de dados para chaves indexadas. O valor da partição das chaves indexadas será validado para o formato do tipo de dados. Se a verificação do tipo de dados falhar, a operação de criação de partição falhará. Para a tabela dados_de_venda, se um índice for criado para chaves (categoria, ano) em que a categoria é do tipo `string` e ano do tipo `int`, a criação da nova partição com um valor de ANO como “foo” falhará.

Depois que os índices estiverem habilitados, a adição de partições com valores de chave indexados com os caracteres U+0000, U+00001 e U+0002 passará a falhar.

Atualizações de tabelas

Depois que um índice de partição é criado em uma tabela, você não pode modificar os nomes de chave de partição para chaves de partição existentes e não pode alterar o tipo, ou ordem, das chaves registradas com o índice.

Usar índices para uma chamada GetPartitions otimizada

Quando você chama `GetPartitions` em uma tabela com um índice, pode incluir uma expressão e, se aplicável, o Data Catalog usará um índice, se possível. A primeira chave do índice deve ser

inserida na expressão para os índices a serem usados na filtragem. A otimização de índice na filtragem é aplicada como um melhor esforço. O Data Catalog tenta usar a otimização de índice tanto quanto possível, mas no caso de um índice ausente, ou operador não suportado, ele volta para a implantação existente de carregamento de todas as partições.

Para a tabela dados_de_venda anterior, vamos adicionar o índice [País, Categoria, Ano]. Se “País” não for inserido na expressão, o índice registrado não poderá filtrar partições usando índices. Você pode adicionar até três índices para suportar vários padrões de consulta.

Vamos pegar algumas expressões de exemplo e ver como os índices funcionam nelas:

Expressões	Como o índice será usado
País = 'EUA'	O índice será usado para filtrar partições.
País = 'EUA' and Categoria = 'Sapatos'	O índice será usado para filtrar partições.
Categoria = 'Sapatos'	Os índices não serão usados, pois “país” não foi fornecido na expressão. Todas as partições serão carregadas para retornar uma resposta.
País = 'EUA' and Categoria = 'Sapatos' and Ano > '2018'	O índice será usado para filtrar partições.
País = 'EUA' and Categoria = 'Sapatos' and Ano > '2018' and mês = 2	O índice será usado para buscar todas as partições com país = “EUA” e categoria = “sapatos” e ano > 2018. Em seguida, a filtragem com a expressão mês será realizada.
País = 'EUA' AND Categoria = 'Sapatos' OR Ano > '2018'	Os índices não serão usados, pois há um operador `OR` na expressão.
País = 'EUA' AND Categoria = 'Sapatos' AND (Ano = '2017' OR Ano = '2018')	O índice será usado para buscar todas as partições com país = “US” e categoria = “sapatos” e, em seguida, a filtragem com a expressão ano será realizada.
País in ('EUA', 'Reino Unido') AND Categoria = 'Sapatos'	Os índices não serão usados para filtrar, pois o operador `IN` não é suportado no momento.

Expressões	Como o índice será usado
País = 'EUA' AND Categoria in ('Sapatos', 'Livros')	O índice será usado para buscar todas as partições com país = “EUA”. A filtragem com a expressão Categoria será realizada em seguida.
País = 'EUA' AND Categoria in ('Sapatos', 'Livros') AND (creationDate > '2023-9-01')	O índice será usado para buscar todas as partições com país = "EUA" e creationDate > "2023-9-01". A filtragem com a expressão Categoria será realizada em seguida.

Integração com mecanismos

Redshift Spectrum, Amazon EMR e AWS Glue ETL Spark DataFrames são capazes de utilizar índices para buscar partições depois que os índices estiverem em um estado ACTIVE (Ativo) no AWS Glue. Athena e AWS Glue ETL Dynamic frames exigem que você siga etapas adicionais a fim de utilizar índices para melhorar consultas.

Habilitar filtragem de partições

Para ativar a filtragem de partições no Athena, é necessário atualizar as propriedades da tabela da seguinte forma:

1. No console do AWS Glue, escolha Tabelas em Catálogo de Dados.
2. Escolha uma tabela.
3. Em Ações, escolha Editar tabela.
4. Em Propriedades da tabela, adicione o seguinte:
   - Chave: `partition_filtering.enabled`
   - Valor: `true`
5. Selecione Apply (Aplicar).

Como alternativa, é possível definir esse parâmetro executando uma consulta ALTER TABLE SET PROPERTIES no Athena.

```
ALTER TABLE partition_index.table_with_index
```

```
SET TBLPROPERTIES ('partition_filtering.enabled' = 'true')
```

Atualizar tabelas do Data Catalog criadas manualmente usando crawlers

Você pode querer criar tabelas do AWS Glue Data Catalog manualmente e mantê-las atualizadas com crawlers do AWS Glue. Os crawlers em execução em uma programação podem adicionar novas partições e atualizar as tabelas com qualquer alteração de esquema. Isso também se aplica a tabelas migradas de um metastore do Apache Hive.

Para fazer isso, ao definir um crawler, em vez de especificar um ou mais armazenamentos de dados como a fonte de um crawl, você especifica uma ou mais tabelas do Data Catalog existentes. Em seguida, o crawler rastreia os armazenamentos de dados especificados pelas tabelas de catálogo. Nesse caso, nenhuma tabela nova é criada; em vez disso, suas tabelas criadas manualmente são atualizadas.

Veja a seguir os outros motivos pelos quais você pode querer criar manualmente tabelas de catálogo e especificar tabelas de catálogo como a origem do crawler:

- Você deseja escolher o nome da tabela de catálogo e não depender do algoritmo de nomenclatura da tabela de catálogo.
- Você deseja impedir que novas tabelas sejam criadas caso arquivos com um formato que possa interromper a detecção de partição sejam salvos por engano no caminho da fonte de dados.

Para ter mais informações, consulte Etapa 2: escolher as fontes de dados e os classificadores.

Propriedades da tabela do Data Catalog

As propriedades ou parâmetros da tabela, como são conhecidos na AWS CLI, são strings de chave e valor não validadas. Você pode definir suas próprias propriedades na tabela para permitir o uso do Data Catalog fora do AWS Glue. Outros serviços que usam o Data Catalog também podem fazer isso. AWS Glue define algumas propriedades da tabela ao executar trabalhos ou rastreadores. Salvo indicação em contrário, essas propriedades são para uso interno. Não podemos garantir que elas continuarão existindo em sua forma atual nem que o produto se comportará conforme esperado se essas propriedades forem alteradas manualmente.

Para obter mais informações sobre as propriedades da tabela definidas pelos crawlers do AWS Glue, consulte the section called “Parâmetros definidos nas tabelas do Data Catalog pelo crawler”.

Integração a outros serviços da AWS

Embora você possa usar Crawler do AWS Glues para preencher o AWS Glue Data Catalog, há vários serviços da AWS que podem se integrar e preencher automaticamente o catálogo para você. As seções a seguir fornecem mais informações sobre os casos de uso específicos aceitos por serviços da AWS que podem preencher o Catálogo de dados.

Tópicos

- AWS Lake Formation
- Amazon Athena

AWS Lake Formation

O AWS Lake Formation é um serviço que facilita configurar um data lake seguro na AWS. O Lake Formation é construído sobre a plataforma AWS Glue, e tanto ele quanto o AWS Glue compartilham o mesmo AWS Glue Data Catalog. Você pode registrar sua localização de dados do Amazon S3 com o Lake Formation e usar o console do Lake Formation para criar bancos de dados e tabelas no Catálogo de Dados do AWS Glue, definir políticas de acesso aos dados e auditar o acesso aos dados em seu data lake desde um local central. Você pode usar o controle de acesso refinado do Lake Formation para gerenciar seus recursos existentes do catálogo de dados e os locais de dados do Amazon S3.

Com os dados registrados no Lake Formation, você pode compartilhar com segurança os recursos do Catálogo de Dados entre as entidades principais do IAM, contas da AWS, organizações da AWS e unidades organizacionais.

Para obter mais informações sobre a criação de recursos do Catálogo de Dados usando o Lake Formation, consulte Criar tabelas e bancos de dados do Catálogo de Dados no Guia do desenvolvedor do AWS Lake Formation.

Amazon Athena

O Amazon Athena usa o Catálogo de Dados para armazenar e recuperar metadados de tabela para os dados do Amazon S3 em sua conta da AWS. Os metadados da tabela permitem que o mecanismo de consulta do Athena saiba como localizar, ler e processar os dados que você deseja consultar.

Você pode preencher o AWS Glue Data Catalog usando diretamente as instruções `CREATE TABLE` do Athena. É possível definir e preencher manualmente os metadados do esquema e de partição no Catálogo de Dados sem precisar executar um crawler.

1. No console do Athena, crie um banco de dados que armazenará os metadados da tabela no Catálogo de Dados.
2. Use a instrução `CREATE EXTERNAL TABLE` para definir o esquema da sua fonte de dados.
3. Use a cláusula `PARTITIONED BY` para definir quaisquer chaves de partição se seus dados estiverem particionados.
4. Use a cláusula `LOCATION` para especificar o caminho do Amazon S3 em que seus arquivos de dados reais são armazenados.
5. Execute a instrução `CREATE TABLE`.

   Essa consulta cria os metadados da tabela no Catálogo de Dados com base no esquema e nas partições definidos, sem realmente fazer o crawling dos dados.

Você pode consultar a tabela no Athena e ela usará os metadados do Catálogo de Dados para acessar e consultar seus arquivos de dados no Amazon S3.

Para obter mais informações, consulte Criar bancos de dados e tabelas no Guia do usuário do Amazon Athena.

Configurações do Catálogo de Dados

A página de configurações do Data Catalog contém opções para definir opções de criptografia e permissões do Catálogo de Dados em sua conta.

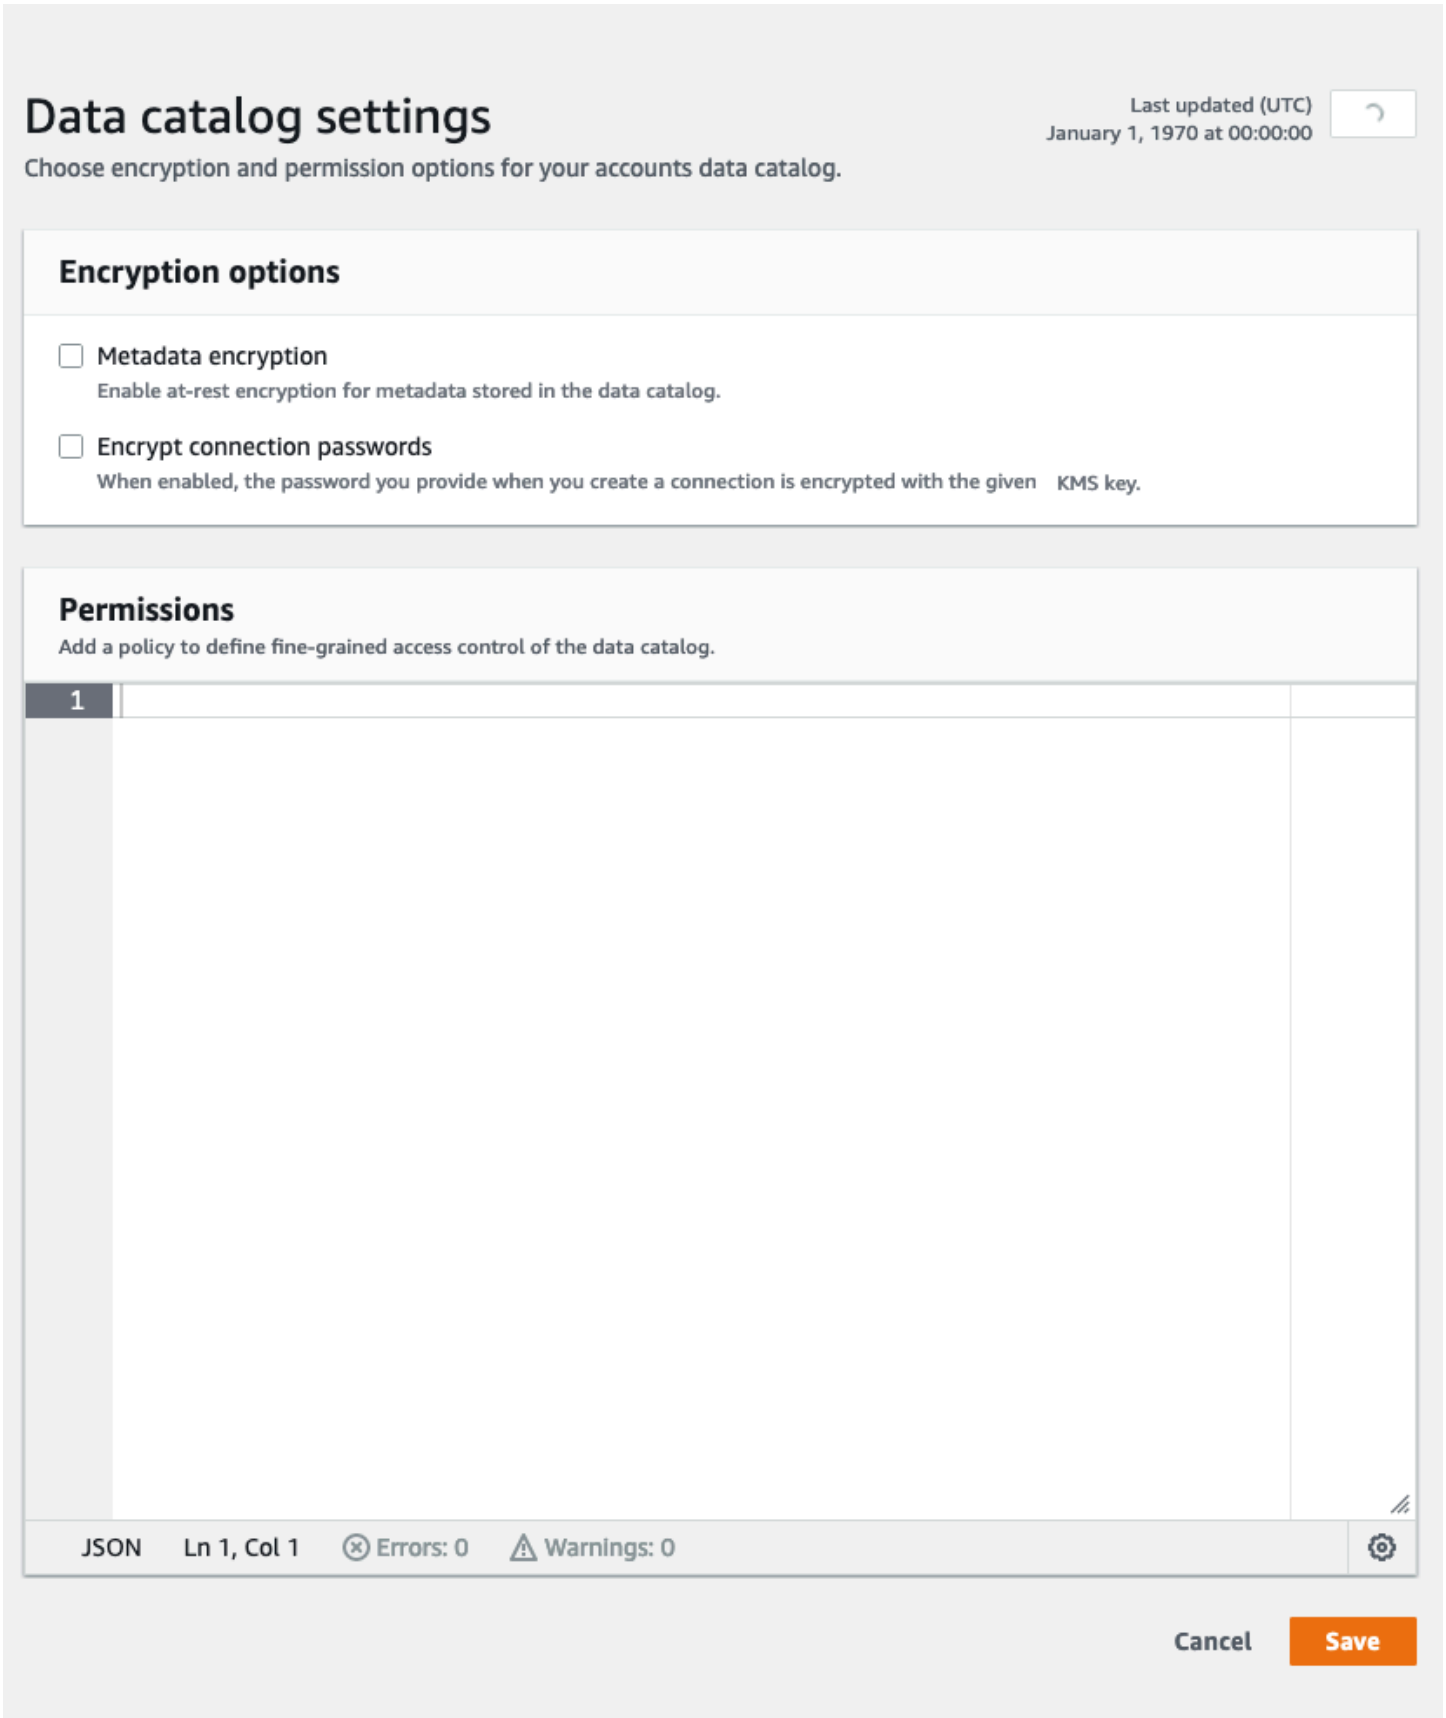
Data catalog settings
Choose encryption and permission options for your accounts data catalog.
Last updated (UTC)
January 1, 1970 at 00:00:00
Encryption options
Metadata encryption
Enable at-rest encryption for metadata stored in the data catalog.
Encrypt connection passwords
When enabled, the password you provide when you create a connection is encrypted with the given KMS key.
Permissions
Add a policy to define fine-grained access control of the data catalog.
1
JSON
Ln 1, Col 1
Errors: 0
Warnings: 0
Cancel
Save

Para alterar o controle de acesso granular do Data Catalog

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha uma opção de criptografia.

   - Criptografia de metadados: marque essa caixa de seleção para criptografar os metadados no Data Catalog. Os metadados são criptografados em repouso usando a chave AWS Key Management Service (AWS KMS) que você especifica. Para ter mais informações, consulte Como criptografar seu Data Catalog.
   - Criptografar senhas de conexão: marque essa caixa de seleção para criptografar senhas no objeto de conexão do AWS Glue quando a conexão for criada ou atualizada. As senhas são criptografadas usando a AWS KMS chave que você especificar. Quando as senhas forem retornadas, elas são criptografadas. Esta opção é uma configuração global para todas as conexões do AWS Glue no Data Catalog. Se você desmarcar esta caixa de seleção, as senhas criptografadas anteriormente permanecerão criptografadas usando a chave que foi usada quando foram criadas ou atualizadas. Para obter mais informações sobre conexões do AWS Glue, consulte Conectar a dados.

     Ao habilitar essa opção, escolha uma AWS KMS chave ou escolha Insira uma chave ARN e forneça o nome de recurso da Amazon (ARN) para a chave. Insira o ARN no formato `arn:aws:kms:`*`region`*`:`*`account-id`*`:key/`*`key-id`* . Você também pode fornecer o ARN como um alias da chave, como `arn:aws:kms:`*`region`*`:`*`account-id`*`:alias/`*`alias-name`* .

     > **Important**
     >
     > Se esta opção estiver selecionada, qualquer usuário ou função que crie ou atualize uma conexão deve ter `kms:Encrypt` permissão na chave KMS especificada.

     Para ter mais informações, consulte Criptografar senhas de conexão.
3. Escolha Settings (Configurações) e, em seguida, no editor Permissions (Permissões), adicione a declaração de política para alterar o controle de acesso granular do Data Catalog de sua conta. Apenas uma política pode ser anexada a um Data Catalog de cada vez. Você pode colar uma política de recurso JSON nesse controle. Para ter mais informações, consulte Políticas baseadas em recursos no Glue AWS.

4. Escolha Save (Salvar) para atualizar o Data Catalog com as alterações feitas.

Você também pode usar AWS Glue operações da API para colocar, obter e excluir políticas de recursos.. Para ter mais informações, consulte APIs de segurança no AWS Glue.

Preencher e gerenciar tabelas transacionais

O Apache Iceberg, o Apache Hudi e o Linux Foundation Delta Lake são formatos de tabela de código aberto projetados para lidar com análises de dados em grande escala e workloads de data lake no Apache Spark.

Você pode preencher as tabelas do Iceberg, Hudi e Delta Lake no AWS Glue Data Catalog usando os seguintes métodos:

- Crawler do AWS Glue: os Crawler do AWS Glues podem descobrir e preencher automaticamente os metadados das tabelas do Iceberg, Hudi e Delta Lake no Catálogo de Dados. Para ter mais informações, consulte Usar crawlers para preencher o catálogo de dados .
- Trabalhos do AWS Glue ETL: é possível criar trabalhos de ETL para gravar dados nas tabelas do Iceberg, Hudi e Delta Lake e preencher seus metadados no Catálogo de Dados. Para obter mais informações, consulte Usar estruturas de data lake com trabalhos do AWS Glue ETL.
- Console do AWS Glue, console do AWS Lake Formation, AWS CLI ou API: você pode usar o console do AWS Glue, o console do Lake Formation ou a API da para criar e gerenciar definições de tabelas do Iceberg no Catálogo de Dados.

Tópicos

- Criar tabelas no Apache Iceberg
- Otimizar tabelas Iceberg
- Otimizar a performance da consulta para tabelas Iceberg

Criar tabelas no Apache Iceberg

Agora você pode criar tabelas do Apache Iceberg que usam o formato de dados do Apache Parquet no AWS Glue Data Catalog com dados residentes no Amazon S3. Uma tabela no catálogo de dados é a definição de metadados que representa os dados em um armazenamento de dados. Por padrão, o AWS Glue cria tabelas do Iceberg v2. Para saber a diferença entre as tabelas da v1 e v2, consulte Alterações de versão do formato na documentação do Apache Iceberg.

Apache Iceberg é um formato de tabela aberta para conjuntos de dados analíticos muito grandes. O Iceberg permite mudanças fáceis em seu esquema, também conhecido como evolução do esquema, o que significa que os usuários podem adicionar, renomear ou remover colunas de uma tabela de dados sem interromper os dados subjacentes. O Iceberg também fornece suporte para controle de versão de dados, o que permite que os usuários acompanhem as alterações nos dados ao longo do tempo. Isso ativa o atributo de viagem no tempo, que permite que os usuários acessem e consultem versões históricas dos dados e analisem as alterações nos dados entre atualizações e exclusões.

Você pode usar o AWS Glue, o console do Lake Formation ou a operação `CreateTable` na API do AWS Glue para criar uma tabela do Iceberg no Catálogo de Dados. Para obter mais informações, consulte a ação CreateTable (Python: create_table).

Ao criar uma tabela do Iceberg no catálogo de dados, você deve especificar o formato da tabela e o caminho do arquivo de metadados no Amazon S3 para poder realizar leituras e gravações.

Você pode usar o Lake Formation para proteger sua tabela do Iceberg usando permissões de controle de acesso refinadas ao registrar a localização de dados do Amazon S3 com o AWS Lake Formation. Para dados de origem no Amazon S3 e metadados que não estão registrados no Lake Formation, o acesso é determinado pelas políticas de permissões do IAM para ações do Amazon S3 e do AWS Glue. Para obter mais informações, consulte Gerenciar permissões.

> **Note**
>
> O catálogo de dados não oferece suporte à criação de partições e à adição de propriedades da tabela do Iceberg.

Pré-requisitos

Para criar tabelas Iceberg no catálogo de dados e configurar as permissões de acesso aos dados do Lake Formation, você precisa preencher os seguintes requisitos:

1. Permissões necessárias para criar tabelas do Iceberg sem os dados registrados no Lake Formation.

   Além das permissões necessárias para criar uma tabela no catálogo de dados, o criador da tabela precisa as seguintes permissões:

   - `s3:PutObject` no recurso arn:aws:s3:::{bucketName}
   - `s3:GetObject` no recurso arn:aws:s3:::{bucketName}

- `s3:DeleteObject` no recurso arn:aws:s3:::{bucketName}

2. Permissões necessárias para criar tabelas do Iceberg com dados registrados no Lake Formation:

   Para usar o Lake Formation para gerenciar e proteger os dados em seu data lake, registre sua localização no Amazon S3 que tenha os dados para tabelas com o Lake Formation. Isso é para que a Lake Formation possa fornecer credenciais para serviços analíticos AWS como Athena, Redshift Spectrum e Amazon EMR para acessar dados. Para obter mais informações sobre o registro de um local do Amazon S3, consulte Adicionar um local do Amazon S3 ao seu data lake.

   Uma entidade principal que lê e grava os dados subjacentes registrados no Lake Formation exige as seguintes permissões:

   - `lakeformation:GetDataAccess`
   - `DATA_LOCATION_ACCESS`

     Uma entidade principal que tem permissões de localização de dados em um local também tem permissões de localização em todos os locais secundários.

     Para obter mais informações sobre permissões de localização de dados, consulte Controle de acesso a dados subjacente.

Para permitir a compactação, o serviço precisa assumir um perfil do IAM que tenha permissões para atualizar tabelas no catálogo de dados. Para obter detalhes, consulte Pré-requisitos de otimização de tabelas

Criar uma tabela no Iceberg

Você pode criar tabelas do Iceberg v1 e v2 usando o AWS Glue, o console do Lake Formation ou a AWS Command Line Interface conforme documentado nesta página. Você também pode criar tabelas do Iceberg usando o Crawler do AWS Glue. Para obter mais informações, consulte Catálogo de dados e crawlers no Guia do desenvolvedor do AWS Glue.

Para criar uma tabela no Iceberg

Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

2. Em catálogo de dados, escolha Tabelas e use o botão Criar tabela para especificar os seguintes atributos:
   - Nome da tabela: insira um nome para a tabela. Se você estiver usando o Athena para acessar tabelas, use essas dicas de nomenclatura no Guia do usuário do Amazon Athena.
   - Banco de dados: escolha um banco de dados existente ou crie um novo.
   - Descrição: a descrição da tabela. Você pode escrever uma descrição para ajudá-lo a entender o conteúdo da tabela.
   - Formato da tabela: para Formato da tabela, escolha Apache Iceberg.
   - Ativar compactação: escolha Ativar compactação para compactar objetos pequenos do Amazon S3 na tabela em objetos maiores.
   - Perfil do IAM: para executar a compactação, o serviço assume um perfil do IAM em seu nome. Você pode escolher um perfil do IAM usando o menu suspenso. Certifique-se de que a função tenha as permissões necessárias para habilitar a compactação.

     Para saber mais sobre as permissões necessárias, consulte Pré-requisitos de otimização de tabelas .
   - Localização: especifique o caminho para a pasta no Amazon S3 que armazena a tabela de metadados. O Iceberg precisa de um arquivo de metadados e de um local no catálogo de dados para poder realizar leituras e gravações.
   - Esquema: escolha Adicionar colunas para adicionar colunas e tipos de dados das colunas. Você tem a opção de criar uma tabela vazia e atualizar o esquema posteriormente.
     O catálogo de dados oferece suporte aos tipos de dados do Hive. Para obter mais informações, consulte Tipos de dados do Hive.

     O Iceberg permite que você evolua o esquema e a partição depois de criar a tabela. Você pode usar as consultas do Athena para atualizar o esquema da tabela e as consultas do Spark para atualizar as partições.

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/"
            }
        }'
```

Otimizar tabelas Iceberg

O AWS Glue é compatível com várias opções de otimização de tabela para aprimorar o gerenciamento e a performance das tabelas do Apache Iceberg usadas pelos mecanismos analíticos da AWS e pelos trabalhos de ETL. Esses otimizadores fornecem utilização eficiente do espaço em disco, melhor performance de consultas e gerenciamento de dados. Existem três tipos de otimizadores de tabela disponíveis no AWS Glue:

- Compactação: a compactação de dados compacta pequenos arquivos de dados para reduzir o uso de armazenamento e melhorar a performance de leitura. Os arquivos de dados são mesclados e regravados para remover dados obsoletos e consolidar dados fragmentados em arquivos maiores e mais eficientes. Você pode configurar a compactação para execução automática.

  O binpack é a estratégia de compactação padrão no Apache Iceberg. Ela combina arquivos de dados menores em arquivos maiores para um desempenho ideal. A compactação também é compatível com estratégias de classificação e ordem Z que agrupam em cluster dados semelhantes. A classificação organiza os dados com base em colunas especificadas, melhorando o desempenho da consulta para operações filtradas. A ordem Z cria conjuntos de dados ordenados que melhoram o desempenho da consulta quando várias colunas são consultadas simultaneamente. Todas as três estratégias de compactação (binpack, classificação e ordem Z) reduzem a quantidade de dados varridos pelos mecanismos de consulta, reduzindo os custos de processamento de consultas.

- Retenção de snapshots: os snapshots são versões com carimbo de data e hora de uma tabela do Iceberg. As configurações de retenção de snapshots permitem que os clientes determinem por quanto tempo reter e quantos snapshots devem ser retidos. A configuração de um otimizador de retenção de snapshots pode ajudar a gerenciar a sobrecarga de armazenamento removendo snapshots antigos e desnecessários e seus arquivos subjacentes.
- Exclusão de arquivos órfãos: arquivos órfãos são arquivos que não são mais referidos pelos metadados da tabela do Iceberg. Esses arquivos podem se acumular ao longo do tempo, especialmente após operações como exclusões de tabelas ou trabalhos de ETL com falha. Habilitar a exclusão de arquivos órfãos permite que o AWS Glue identifique e remova periodicamente esses arquivos desnecessários, liberando espaço de armazenamento.

É possível habilitar ou desabilitar a compactação, a retenção de snapshots e os otimizadores de exclusão de arquivos órfãos para tabelas Iceberg individuais usando o console do AWS Glue, a AWS CLI ou as operações de API do AWS Glue.

Tópicos

- Pré-requisitos de otimização de tabelas
- Otimização de compactação
- Otimização de retenção de snapshots
- Excluir arquivos órfãos
- Visualizar detalhes da otimização
- Visualizar métricas do Amazon CloudWatch
- Excluindo um otimizador
- Considerações e limitações
- Regiões compatíveis para otimizadores de tabela

Pré-requisitos de otimização de tabelas

O otimizador de tabela assume as permissões do perfil do AWS Identity and Access Management (IAM) que você especificou ao habilitar as opções de otimização (compactação, retenção de snapshot e exclusão de arquivos órfãos) para uma tabela. Você pode criar um único perfil para todos os otimizadores ou criar perfis separados para cada otimizador.

> **Note**
>
> O otimizador de exclusão de arquivos órfãos não exige as permissões `glue:updateTable` ou `s3:putObject`. Os otimizadores de expiração e compactação de snapshots exigem o mesmo conjunto de permissões.

O perfil do IAM deve ter as permissões para ler dados e atualizar metadados no catálogo de dados. Você pode criar um perfil do IAM e anexar as políticas em linha a seguir:

- Adicione a seguinte política em linha que concede ao Amazon S3 permissões de leitura/gravação no local para dados que não estão registrados no AWS Lake Formation. Essa política também inclui permissões para atualizar a tabela no catálogo de dados e permitir que o AWS Glue adicione logs em logs do Amazon CloudWatch e a publicação de métricas. Para dados de origem no Amazon S3 que não estão registrados no Lake Formation, o acesso é determinado pelas políticas de permissões do IAM para o Amazon S3 e ações AWS Glue.

  Nas políticas em linha a seguir, substitua `bucket-name` pelo nome do bucket do Amazon S3, `aws-account-id` e `region` por um número de conta da AWS e por uma região do catálogo de dados válidos, `database_name` pelo nome do seu banco de dados e `table_name` pelo nome da tabela.

```
{
    "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:*"
        }
    ]
}
```

- Use a política a seguir para habilitar a compactação de dados registrados no Lake Formation.

  Se o perfil de otimização não tiver permissões do grupo `IAM_ALLOWED_PRINCIPALS` concedidas na tabela, ele exigirá as permissões `ALTER`, `DESCRIBE`, `INSERT` e `DELETE` do Lake Formation na tabela.

Para obter mais informações sobre o registro de um bucket do Amazon S3 com o Lake Formation, consulte Adicionar um local do Amazon S3 ao seu data lake.

```
{
 "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:*"
        }
```

```
    ]
}
```

- (Opcional) Para otimizar tabelas Iceberg com dados em buckets criptografados do Amazon S3 usando criptografia no lado do servidor, o perfil de compactação exigirá permissões para descriptografar objetos do Amazon S3 e gerar uma nova chave de dados para gravar objetos nos buckets criptografados. Adicione a seguinte política à chave do AWS KMS desejada. Oferecemos suporte somente à criptografia em nível de bucket.

```
{
    "Effect": "Allow",
    "Principal": {
        "AWS": "arn:aws:iam::<aws-account-id>:role/<optimizer-role-name>"
    },
    "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey"
    ],
    "Resource": "*"
}
```

- (Opcional) Para locais de dados registrados no Lake Formation, o perfil usado para registrar a localização exige permissões para descriptografar objetos do Amazon S3 e gerar uma nova chave de dados para gravar objetos nos buckets criptografados. Para obter mais informações, consulte Registrar um local do Amazon S3.
- (Opcional) Se a chave do AWS KMS estiver armazenada em uma conta da AWS diferente, você precisará incluir as permissões a seguir no perfil de compactação.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "kms:Decrypt",
                "kms:GenerateDataKey"
            ],
            "Resource": ["arn:aws:kms:<REGION>:<KEY_OWNER_ACCOUNT_ID>:key/<KEY_ID>" ]
        }
    ]
```

```
}
```

- A função que você usa para executar a compactação deve ter a permissão `iam:PassRole` da função.

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

- Adicione a política de confiança a seguir à função para que o serviço AWS Glue assuma o perfil do IAM para executar o processo de compactação.

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

Otimização de compactação

Os data lakes do Amazon S3 usando formatos de tabela aberta, como o Apache Iceberg, armazenam dados como objetos do S3. Ter milhares de pequenos objetos do Amazon S3 em uma tabela de data lake aumenta a sobrecarga de metadados e afeta a performance de leitura. O AWS Glue Data Catalog fornece compactação gerenciada para tabelas Iceberg, compactando objetos pequenos em objetos maiores para melhor performance de leitura por meio de serviços de analytics da AWS, como o Amazon Athena e o Amazon EMR, e trabalhos de ETL do AWS Glue. O Catálogo de Dados executa compactação sem interferir nas consultas simultâneas e é compatível com compactação somente para tabelas no formato Parquet.

O otimizador de tabelas monitora constantemente as partições da tabela e inicia o processo de compactação quando o limite é excedido para o número de arquivos e tamanhos de arquivo.

No Catálogo de Dados, o processo de compactação começa quando uma tabela ou qualquer uma de suas partições tem mais de 100 arquivos. Cada arquivo deve ser menor que 75% do tamanho do arquivo de destino. O tamanho do arquivo de destino é definido pela propriedade `write.target-file-size-bytes` da tabela, cujo padrão é 512 MB caso não tenha sido definido explicitamente.

Para conhecer as limitações, consulte Formatos e limitações compatíveis para compactação gerenciada de dados .

Tópicos

- Habilitar o otimizador de compactação
- Desabilitar o otimizador de compactação

Habilitar o otimizador de compactação

Você pode usar o console do AWS Glue, a AWS CLI, ou a API da AWS para habilitar a compactação de tabelas Apache Iceberg no Catálogo de Dados do AWS Glue. Para novas tabelas, você pode escolher o Apache Iceberg como formato de tabela e ativar a compactação ao criar a tabela. A compactação está desabilitada por padrão para novas tabelas.

Console

Para habilitar compactação

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/ e faça login como administrador do data lake, criador da tabela ou um usuário que tenha recebido as permissões `glue:UpdateTable` e `lakeformation:GetDataAccess` na tabela.
2. No painel de navegação, em Catálogo de dados, escolha Tabelas.
3. Na página Tabelas, escolha uma tabela em formato de tabela aberta para a qual você deseja habilitar a compactação e, em seguida, no menu Ações, escolha Optimização e Habilitar.

   Você também pode habilitar a compactação selecionando a tabela Otimização de tabela e abrindo a página Detalhes da tabela. Escolha a guia Otimização de tabela na seção inferior da página e escolha Ativar compactação.

   A opção Ativar otimização também está disponível ao criar uma nova tabela Iceberg no Catálogo de Dados.
4. Na página Habilitar otimização, escolha Compactação em Opções de otimização.

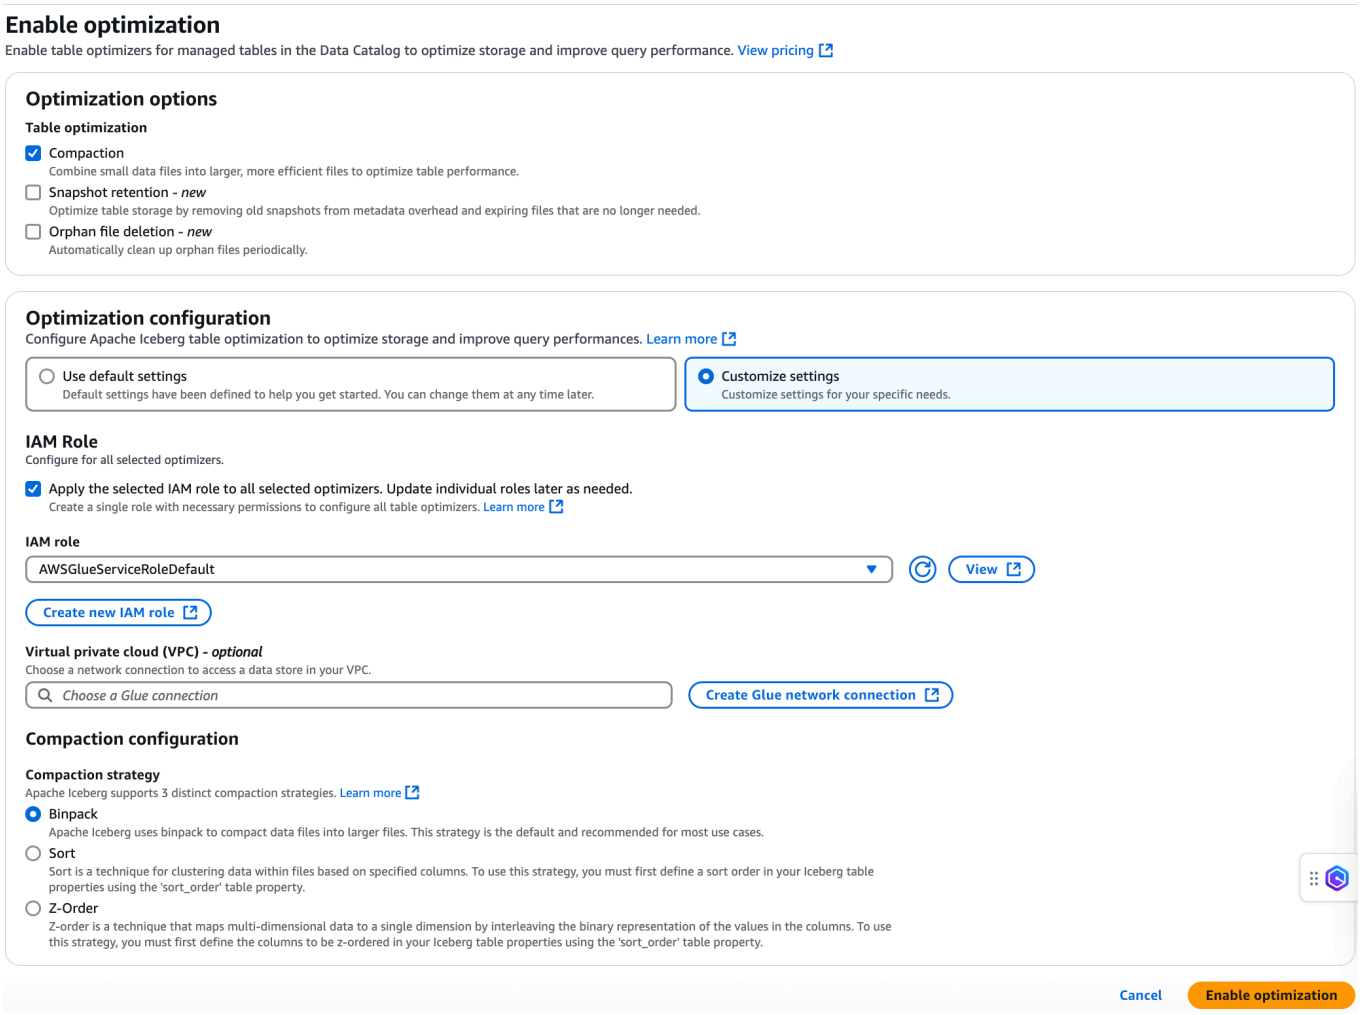

5. Em seguida, selecione um perfil do IAM na lista suspensa com as permissões mostradas na seção Pré-requisitos de otimização de tabelas .

   Você também pode escolher a opção Criar um novo perfil do IAM para criar um perfil personalizado com as permissões necessárias para executar a compactação.

   Siga as etapas abaixo para atualizar um perfil do IAM existente:

   a. Para atualizar a política de permissões para o perfil do IAM, no console do IAM, acesse a função do IAM que está sendo usada para executar a compactação.

   b. Na seção Adicionar permissões, escolha Criar política. Na janela recém-aberta do navegador, crie uma nova política para usar com sua função.

   c. Na página Criar política, escolha a guia `JSON`. Copie o código JSON mostrado nos Pré-requisitos no campo do editor de políticas.

6. Se você tiver configurações de política de segurança em que o otimizador de tabelas do Iceberg precise acessar buckets do Amazon S3 de uma Nuvem Privada Virtual (VPC) específica, crie uma conexão de rede do AWS Glue ou use uma existente.

   Se você ainda não tiver uma conexão VPC do AWS Glue configurada, crie uma seguindo as etapas na seção Creating connections for connectors usando o console do AWS Glue ou a AWS CLI/o SDK.

7. Escolha uma estratégia de compactação. As opções disponíveis são:

   - Binpack: binpack é a estratégia de compactação padrão no Apache Iceberg. Ela combina arquivos de dados menores em arquivos maiores para um desempenho ideal.
   - Sort: a classificação no Apache Iceberg é uma técnica de organização de dados que agrupa em cluster informações em arquivos com base em colunas especificadas, melhorando significativamente o desempenho da consulta ao reduzir o número de arquivos que precisam ser processados. Você define a ordem de classificação nos metadados do Iceberg usando o campo sort-order e, quando houver a especificação de várias colunas, os dados são classificados na sequência em que as colunas aparecem na ordem de classificação, garantindo que registros com valores semelhantes sejam armazenados juntos nos arquivos. A estratégia de compactação de classificação promove ainda mais otimização ao classificar os dados em todos os arquivos dentro de uma partição.
   - Z-order: a ordenação Z é uma forma de organizar dados quando você precisa classificar por várias colunas com importância igual. Diferentemente da classificação tradicional que prioriza uma coluna em detrimento de outras, a ordenação Z dá um peso equilibrado a cada coluna, ajudando seu mecanismo de consulta a ler menos arquivos ao pesquisar dados.

     A técnica funciona entrelaçando os dígitos binários dos valores de diferentes colunas. Por exemplo, se você tiver os números 3 e 4 de duas colunas, primeiro a ordenação Z os converte em binário (3 vira 011 e 4 vira 100) e, em seguida, intercala esses dígitos para criar um novo valor: 011010. Essa intercalação cria um padrão que mantém os dados relacionados fisicamente próximos uns dos outros.

     A ordenação Z é particularmente eficaz para consultas multidimensionais. Por exemplo, uma tabela de clientes com ordenação em Z por renda, estado e código postal pode oferecer desempenho superior em comparação à classificação hierárquica ao fazer consultas em várias dimensões. Essa organização permite que consultas direcionadas a combinações específicas de renda e localização geográfica localizem rapidamente dados relevantes e, ao mesmo tempo, minimizem varreduras desnecessárias de arquivos.

8. Escolha Habilitar otimização.

AWS CLI

O exemplo a seguir mostra como habilitar a compactação. Substitua o ID da conta por um ID de conta da AWS válido. Substitua o nome do banco de dados e o nome da tabela pelo nome real da tabela do Iceberg e pelo nome do banco de dados. Substitua o `roleArn` pelo nome do recurso (ARN) AWS do perfil do IAM e o nome do perfil do IAM que tem as permissões necessárias para executar a compactação. Você pode substituir a estratégia de compactação `sort` por outras estratégias compatíveis, como `z-order` ou `binpack`.

order" dependendo dos seus requisitos.

```
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

Chame a operação CreateTableOptimizer para ativar a compactação de uma tabela.

Após habilitar a compactação, a guia Otimização da tabela mostrará os seguintes detalhes da compactação após a conclusão da execução da compactação:

Horário de início

A hora em que o processo de compactação iniciou no Catálogo de Dados. O valor é um timestamp no horário UTC.

Horário de término

A hora em que o processo de compactação terminou no catálogo de dados. O valor é um timestamp no horário UTC.

Status

O status de execução da compactação. Os valores são sucesso ou falha.

Arquivos compactados

Número total de arquivos compactados.

Bytes compactados

Número total de bytes compactados.

Desabilitar o otimizador de compactação

Você pode desativar a compactação automática para uma tabela específica do Apache Iceberg usando o console do AWS Glue ou a AWS CLI.

Console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Catálogo de dados, escolha Tabelas.
3. Na lista de tabelas, escolha a tabela Iceberg da qual você deseja desabilitar a compactação.
4. Selecione a guia Otimização de tabela na seção inferior da página Detalhes da tabela.
5. Em Ações, escolha Desativar e, em seguida, escolha Compactação.
6. Escolha Desativar compactação na mensagem de confirmação. Você poderá reabilitar a compactação mais tarde.

   Após a confirmação, a compactação é desativada e o status de compactação da tabela volta para `Disabled`.

AWS CLI

No exemplo a seguir, substitua o ID da conta por um ID de conta da AWS válido. Substitua o nome do banco de dados e o nome da tabela pelo nome real da tabela do Iceberg e pelo nome

do banco de dados. Substitua o `roleArn` pelo nome do recurso (ARN) AWS do perfil do IAM e o nome real do perfil do IAM que tem as permissões necessárias para executar a compactação.

```
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

Chame a operação UpdateTableOptimizer para desabilitar a compactação para uma tabela específica.

Otimização de retenção de snapshots

O recurso de retenção de snapshots do Apache Iceberg permite que os usuários consultem dados históricos em momentos específicos e revertam modificações indesejadas em suas tabelas. No Catálogo de Dados do AWS Glue, a configuração de retenção de snapshots controla por quanto tempo esses snapshots (versões dos dados da tabela) são mantidos antes de expirarem e serem removidos. Isso ajuda a gerenciar os custos de armazenamento e a sobrecarga de metadados removendo automaticamente os snapshots antigos com base em um período de retenção configurado ou no número máximo de snapshots a serem mantidos.

Você pode configurar o período de retenção em dias e o número máximo de snapshots a serem retidos em uma tabela. O AWS Glue remove os snapshots mais antigos do que o período de retenção especificado dos metadados da tabela, enquanto mantém os snapshots mais recentes até o limite configurado. Depois de remover os snapshots antigos dos metadados, o AWS Glue exclui os dados e os arquivos de metadados correspondentes que não são mais relacionados e que são exclusivos dos snapshots expirados. Isso permite consultas de viagem no tempo somente até os snapshots retidos restantes, enquanto recupera o espaço de armazenamento usado pelos dados de snapshots expirados.

Tópicos

- Habilitar o otimizador de retenção de snapshots
- Atualizar o otimizador de retenção de snapshots

- Desabilitar o otimizador de retenção de snapshots

Habilitar o otimizador de retenção de snapshots

Você pode usar o console do AWS Glue, a AWS CLI ou a API da AWS para habilitar os otimizadores de retenção de snapshots nas suas tabelas Apache Iceberg no Catálogo de Dados. Para novas tabelas, você pode escolher Apache Iceberg como o formato de tabela e habilitar o otimizador de retenção de snapshots ao criar a tabela. A retenção de snapshots está desabilitada por padrão para novas tabelas.

Console

Para habilitar o otimizador de retenção de snapshots

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/ e faça login como administrador do data lake, criador da tabela ou um usuário que tenha recebido as permissões `glue:UpdateTable` e `lakeformation:GetDataAccess` na tabela.
2. No painel de navegação, em Catálogo de dados, escolha Tabelas.
3. Na página Tabelas, escolha uma tabela Iceberg para a qual você deseja habilitar o otimizador de retenção de snapshots e, no menu Ações, escolha Habilitar em Otimização.

   Você também pode habilitar a otimização selecionando a tabela e abrindo a página Detalhes da tabela. Escolha a guia Otimização de tabela na seção inferior da página e depois Habilitar a retenção de snapshots.
4. Na página Habilitar otimização, em Configuração da otimização, você tem duas opções: Usar configuração padrão ou Personalizar configurações. Se você optar por usar as configurações padrão, o AWS Glue utiliza as propriedades definidas na configuração da tabela Iceberg para determinar o período de retenção de snapshots e o número de snapshots a serem retidos. Na ausência dessa configuração, o AWS Glue retém um snapshot por cinco dias e exclui os arquivos associados aos snapshots expirados.
5. Em seguida, escolha um perfil do IAM que o AWS Glue possa assumir em seu nome para executar o otimizador. Para obter detalhes sobre as permissões necessárias para o perfil do IAM, consulte a seção Pré-requisitos de otimização de tabelas .

   Siga as etapas abaixo para atualizar um perfil do IAM existente:

   a. Para atualizar a política de permissões para o perfil do IAM, no console do IAM, acesse a função do IAM que está sendo usada para executar a compactação.

b. Na seção Adicionar permissões, escolha Criar política. Na janela recém-aberta do navegador, crie uma nova política para usar com sua função.

c. Na página Criar política, escolha a guia JSON. Copie o código JSON mostrado nos Pré-requisitos no campo do editor de políticas.

6. Se você preferir definir os valores da Configuração de retenção de snapshots manualmente, escolha Personalizar configurações.

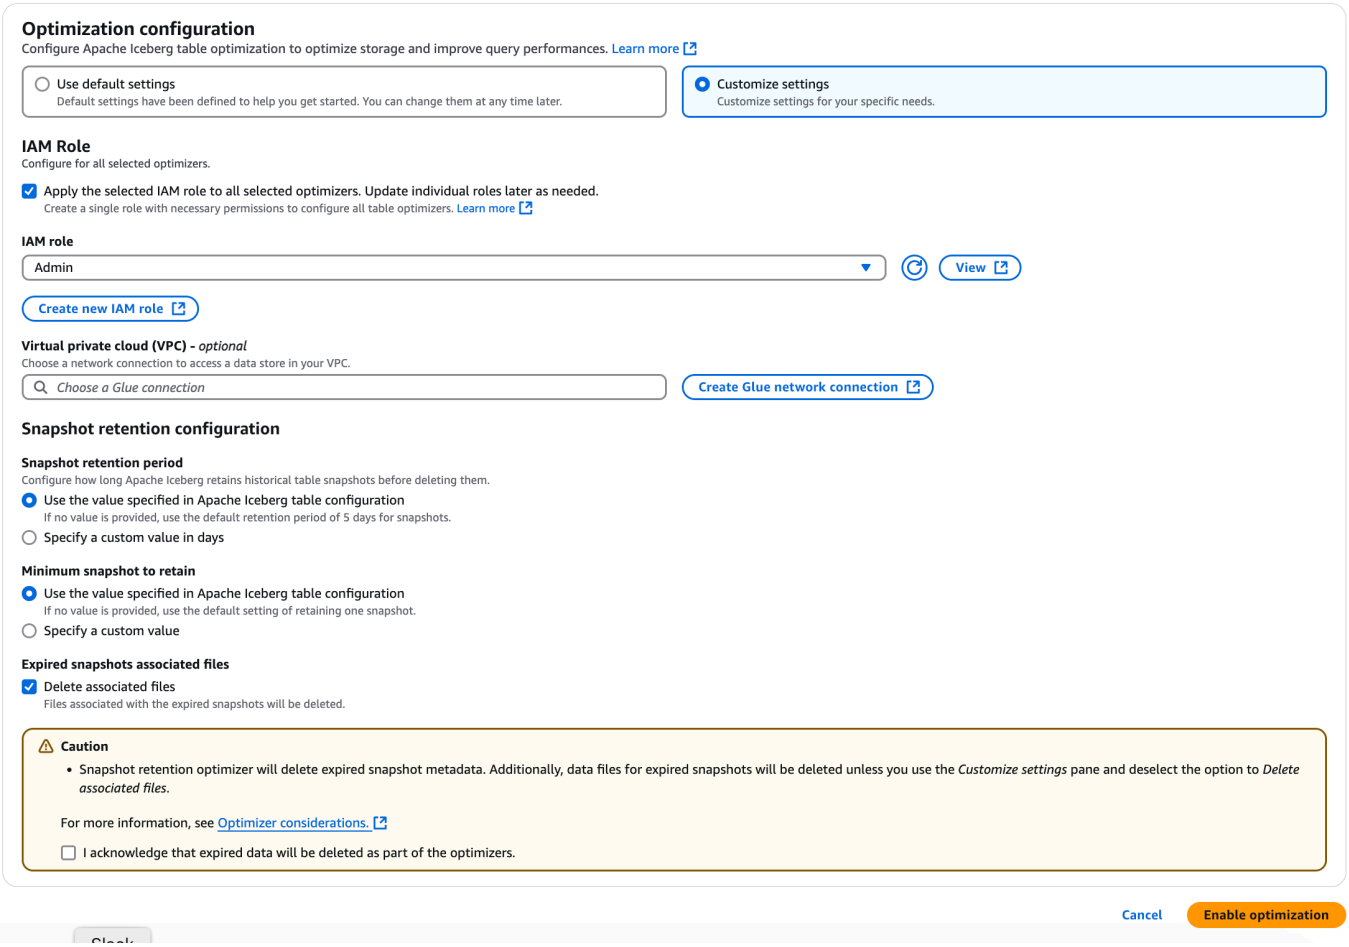

7. Escolha a opção Aplicar o perfil do IAM selecionado aos otimizadores selecionados para usar um único perfil do IAM para habilitar todos os otimizadores.

8. Se você tiver configurações de política de segurança em que o otimizador de tabelas do Iceberg precise acessar buckets do Amazon S3 de uma Nuvem Privada Virtual (VPC) específica, crie uma conexão de rede do AWS Glue ou use uma existente.

   Se você ainda não tiver uma conexão VPC do AWS Glue configurada, crie uma seguindo as etapas na seção Creating connections for connectors usando o console do AWS Glue ou a AWS CLI/o SDK.

9. Em seguida, em Configuração de retenção de snapshots, escolha usar os valores especificados na configuração da tabela Iceberg, ou especifique valores personalizados para o período de retenção de snapshots (history.expire.max-snapshot-age-ms) e o número mínimo de snapshots (history.expire.min-snapshots-to-keep) a serem retidos.
10. Escolha Excluir arquivos associados para excluir arquivos subjacentes quando o otimizador de tabela excluir snapshots antigos dos metadados da tabela.

    Se você não escolher essa opção, quando os snapshots mais antigos forem removidos dos metadados da tabela, seus arquivos associados permanecerão no armazenamento como arquivos órfãos.
11. Em seguida, leia a declaração de atenção e escolha Eu confirmo para continuar.

    > **Note**
    >
    > No Catálogo de Dados, o otimizador de retenção de snapshots respeita o ciclo de vida controlado pelas políticas de retenção no nível de ramificação e tag. Para obter mais informações, consulte a seção Branching and tagging na documentação do Iceberg.
12. Revise a configuração e escolha Habilitar otimização.

    Aguarde alguns minutos até que o otimizador de retenção seja executado e expire os snapshots antigos com base na configuração.

AWS CLI

Para habilitar a retenção de snapshots para novas tabelas Iceberg no AWS Glue, você precisa criar um otimizador de tabela do tipo `retention` e definir o campo `enabled` como `true` na `table-optimizer-configuration`. Você pode executar essa ação usando o comando `create-table-optimizer` ou `update-table-optimizer` da AWS CLI. Além disso, você precisa especificar os campos de configuração de retenção, como `snapshotRetentionPeriodInDays` e `numberOfSnapshotsToRetain`, com base em seus requisitos.

O exemplo a seguir mostra como habilitar o otimizador de retenção de snapshots. Substitua o ID da conta por um ID de conta da AWS válido. Substitua o nome do banco de dados e o nome da tabela pelo nome real da tabela do Iceberg e pelo nome do banco de dados. Substitua `roleArn` pelo nome do recurso da AWS (ARN) do perfil do IAM e o nome atual do perfil do IAM que tem as permissões necessárias para executar o otimizador de retenção de snapshots.

```
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
```

Esse comando cria um otimizador de retenção para a tabela Iceberg especificada no catálogo, no banco de dados e na região especificados. A configuração do otimizador de tabela especifica o ARN do perfil do IAM a ser usado, habilita o otimizador e define a configuração de retenção. Neste exemplo, ele retém os snapshots por sete dias, mantém um mínimo três snapshots e limpa os arquivos expirados.

- snapshotRetentionPeriodInDays: o número de dias para reter os snapshots antes de expirá-los. O valor padrão é 5.
- numberOfSnapshotsToRetain: o número mínimo de snapshots a serem mantidos, mesmo que sejam mais antigos que o período de retenção. O valor padrão é 1.
- cleanExpiredFiles: um booleano que indica se os arquivos de dados expirados devem ser excluídos após a expiração dos snapshots. O valor padrão é `true`.

  Quando definido como true, os snapshots mais antigos são removidos dos metadados da tabela e seus arquivos subjacentes são excluídos. Se esse parâmetro for definido como false, os snapshots mais antigos serão removidos dos metadados da tabela, mas seus arquivos subjacentes permanecerão no armazenamento como arquivos órfãos.

AWS API

Chame a operação CreateTableOptimizer para habilitar o otimizador de retenção de snapshots de uma tabela.

Depois de ativar a compactação, a guia Otimização de tabela mostra os seguintes detalhes da compactação (após aproximadamente 15 a 20 minutos):

Horário de início

A hora em que o otimizador de retenção de snapshots foi iniciado. O valor é um timestamp no horário UTC.

Run time (runtime)

A hora mostra quanto tempo o otimizador leva para concluir a tarefa. O valor é um timestamp no horário UTC.

Status

O status da execução do otimizador. Os valores são sucesso ou falha.

Arquivos de dados excluídos

Número total de arquivos excluídos.

Arquivos de manifesto excluídos

Número total de arquivos de manifesto excluídos.

Listas de manifestos excluídas

Número total de listas de manifestos excluídas.

Atualizar o otimizador de retenção de snapshots

Você pode atualizar a configuração atual de um otimizador de retenção de snapshots para uma tabela Apache Iceberg específica usando o console do AWS Glue, a AWS CLI ou a API UpdateTableOptimizer.

Console

Para atualizar a configuração de retenção de snapshots

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha catálogo de dados e escolha Tabelas. Na lista de tabelas, escolha a tabela do Iceberg para a qual deseja atualizar a configuração do otimizador de retenção de snapshots.
3. Na seção inferior da página de Detalhes das tabelas, selecione a guia Otimização da tabela e Editar. Você também pode escolher Editar em Otimização no menu Ações localizado no canto superior direito da página.

4. Na página Editar otimização, faça as alterações necessárias.
5. Escolha Salvar.

AWS CLI

Para atualizar um otimizador de retenção de snapshots usando aAWS CLI, você pode usar o seguinte comando:

```
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
```

Esse comando atualiza a configuração de retenção para a tabela especificada em determinado catálogo, banco de dados e região. Os principais parâmetros são:

- snapshotRetentionPeriodInDays: o número de dias para reter os snapshots antes de expirá-los. O valor padrão é 1.
- numberOfSnapshotsToRetain: o número mínimo de snapshots a serem mantidos, mesmo que sejam mais antigos que o período de retenção. O valor padrão é 5.
- cleanExpiredFiles: um booleano que indica se os arquivos de dados expirados devem ser excluídos após a expiração dos snapshots. O valor padrão é `true`.

  Quando definido como true, os snapshots mais antigos são removidos dos metadados da tabela e seus arquivos subjacentes são excluídos. Se esse parâmetro for definido como false, os snapshots mais antigos serão removidos dos metadados da tabela, mas seus arquivos subjacentes permanecerão no armazenamento como arquivos órfãos.

API

Para atualizar um otimizador de tabela, você pode usar a API `UpdateTableOptimizer`. Essa API permite que você atualize a configuração de um otimizador de tabela existente para compactação, retenção ou remoção de arquivos órfãos. Os parâmetros de solicitação incluem:

- catalogId (obrigatório): o ID do catálogo que contém a tabela
- databaseName (opcional): o nome do banco de dados que contém a tabela
- tableName (opcional): o nome da tabela
- type (obrigatório): o tipo de otimizador de tabela (compactação, retenção ou orphan_file_deletion)
- retentionConfiguration (obrigatório): a configuração atualizada do otimizador de tabela, incluindo o ARN do perfil, o status habilitado, a configuração de retenção e a configuração de remoção de arquivos órfãos.

Desabilitar o otimizador de retenção de snapshots

Você pode desabilitar o otimizador de retenção de snapshots para uma tabela Apache Iceberg específica usando o console do AWS Glue ou a AWS CLI.

Console

Para desabilitar a retenção de snapshots

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha catálogo de dados e escolha Tabelas. Na lista de tabelas, escolha a tabela Iceberg da qual você deseja desabilitar o otimizador para a retenção de snapshots.
3. Na seção inferior da página Detalhes da tabela, escolha Otimização de tabela e Desabilitar, Retenção de snapshots, em Ações.

   Também é possíveç escolher Desativar em Otimização no menu Ações, localizado no canto superior direito da página.
4. Escolha Desabilitar na mensagem de confirmação. Você poderá habilitar novamente o otimizador de retenção de snapshots mais tarde.

   Após a confirmação, o otimizador de retenção de snapshots é desabilitado e o status de retenção de snapshots volta a ser `Not enabled`.

AWS CLI

No exemplo a seguir, substitua o ID da conta por um ID de conta da AWS válido. Substitua o nome do banco de dados e o nome da tabela pelo nome real da tabela do Iceberg e pelo nome do banco de dados. Substitua `roleArn` pelo nome do recurso da AWS (ARN) do perfil do IAM e o nome atual do perfil do IAM que tem as permissões necessárias para executar o otimizador de retenção.

```
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

Chame a operação UpdateTableOptimizer para desabilitar o otimizador de retenção de snapshots para uma tabela específica.

Excluir arquivos órfãos

O AWS Glue Data Catalog permite que você remova arquivos órfãos de suas tabelas Iceberg. Arquivos órfãos são arquivos que existem na sua fonte de dados do Amazon S3 na localização da tabela especificada, não são rastreados pelos metadados da tabela Iceberg e são mais antigos do que o limite de idade configurado. Esses arquivos órfãos podem se acumular com o tempo devido a operações como compactação, descarte de partições ou regravações de tabelas, além de ocupar espaço de armazenamento desnecessário.

O otimizador de exclusão de arquivos órfãos no AWS Glue verifica os metadados da tabela e os arquivos de dados reais, identifica os arquivos órfãos e os exclui para recuperar espaço de armazenamento.

Você pode iniciar a exclusão de arquivos órfãos criando um otimizador de tabela de exclusão de arquivos órfãos no Catálogo de Dados.

> **Important**
>
> Por padrão, a exclusão de arquivos órfãos avalia os arquivos em toda a localização da sua tabela do AWS Glue. Embora você possa configurar um subprefixo para limitar o escopo da avaliação, você deve garantir que a localização da sua tabela não contenha arquivos de outras fontes de dados ou tabelas. Se a localização da sua tabela se sobrepuser a outras fontes de dados, o serviço poderá identificar e excluir arquivos não relacionados como órfãos.

Tópicos

- Habilitar a exclusão de arquivos órfãos
- Atualizar o otimizador de exclusão de arquivos órfãos
- Desabilitar a exclusão de arquivos órfãos

Habilitar a exclusão de arquivos órfãos

Você pode usar o console do AWS Glue, a AWS CLI ou a API da AWS para habilitar a exclusão de arquivos órfãos das suas tabelas Apache Iceberg que estão no Catálogo de Dados. Para novas tabelas, você pode escolher Apache Iceberg como o formato de tabela e habilitar o otimizador de exclusão de arquivos órfãos ao criar a tabela. A retenção de snapshots está desabilitada por padrão para novas tabelas.

Console

Para habilitar a exclusão de arquivos órfãos

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/ e faça login como administrador do data lake, criador da tabela ou um usuário que tenha recebido as permissões `glue:UpdateTable` e `lakeformation:GetDataAccess` na tabela.
2. No painel de navegação, em Catálogo de dados, escolha Tabelas.
3. Na página Tabelas, escolha uma tabela Iceberg na qual você deseja habilitar a exclusão de arquivos órfãos.

   Escolha a guia Otimização de tabela na seção inferior da página e depois Habilitar, Exclusão de arquivos órfãos, em Ações.

Você também pode escolher Habilitar em Otimização no menu Ações localizado no canto superior direito da página.

4. Na página Habilitar otimização, escolha Exclusão de arquivos órfãos em Opções de otimização.
5. Se você optar por usar as Configurações padrão, todos os arquivos órfãos serão excluídos após 3 dias. Se quiser manter os arquivos órfãos por um número específico de dias, escolha Personalizar configurações.
6. Depois, escolha uma perfil do IAM com as permissões necessárias para excluir arquivos órfãos.
7. Se você tiver configurações de política de segurança em que o otimizador de tabelas do Iceberg precise acessar buckets do Amazon S3 de uma Nuvem Privada Virtual (VPC) específica, crie uma conexão de rede do AWS Glue ou use uma existente.

   Se você ainda não tiver uma conexão VPC do AWS Glue configurada, crie uma seguindo as etapas na seção Creating connections for connectors usando o console do AWS Glue ou a AWS CLI/o SDK.
8. Em Personalizar configurações, insira o número de dias para reter os arquivos antes da exclusão em Configuração de exclusão de arquivos órfãos.
9. Escolha Habilitar otimização.

AWS CLI

Para habilitar a exclusão de arquivos órfãos para uma tabela Iceberg no AWS Glue, você precisa criar um otimizador de tabela do tipo `orphan_file_deletion` e definir o campo `enabled` como true. Para criar um otimizador de exclusão de arquivos órfãos para uma tabela Iceberg usando a AWS CLI, você pode usar o seguinte comando:

```
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
```

Esse comando cria um otimizador de exclusão de arquivos órfãos para a tabela Iceberg especificada. Os principais parâmetros são:

- roleArn: o ARN do perfil do IAM com permissões para acessar o bucket do S3 e os recursos do Glue.
- enabled: defina como true para habilitar o otimizador.
- orphanFileRetentionPeriodInDays: o número de dias para reter arquivos órfãos antes de excluí-los (o mínimo é um dia).
- type: defina como orphan_file_deletion para criar um otimizador de exclusão de arquivos órfãos.

Depois de criar o otimizador de tabela, ele executará a exclusão de arquivos órfãos periodicamente (uma vez por dia, se estiver habilitado). Você pode verificar as execuções usando a API `list-table-optimizer-runs`. O trabalho de exclusão de arquivos órfãos identificará e excluirá arquivos que não são rastreados nos metadados Iceberg da tabela.

API

Chame a operação CreateTableOptimizer para criar o otimizador de exclusão de arquivos órfãos de uma tabela específica.

Atualizar o otimizador de exclusão de arquivos órfãos

Você pode modificar a configuração do otimizador de exclusão de arquivos órfãos, como alterar o período de retenção de arquivos órfãos ou o perfil do IAM usado pelo otimizador usando o console do AWS Glue, a AWS CLI ou a operação `UpdateTableOptimizer`.

AWS Management Console

Para atualizar o otimizador de exclusão de arquivos órfãos

1. Escolha catálogo de dados e escolha Tabelas. Na lista de tabelas, escolha a tabela da qual você deseja atualizar a configuração do otimizador de exclusão de arquivos órfãos.
2. Na seção inferior da página de Detalhes das tabelas, escolha Otimização de tabela e, em seguida, Editar.
3. Na página Editar otimização, faça as alterações necessárias.
4. Escolha Salvar.

AWS CLI

Você pode usar a chamada `update-table-optimizer` para atualizar o otimizador de exclusão de arquivos órfãos no AWS Glue, você pode usar a chamada. Isso permite que você modifique a `OrphanFileDeletionConfiguration` no campo `icebergConfiguration` em que você pode especificar a atualização de `OrphanFileRetentionPeriodInDays` para definir o número de dias para reter arquivos órfãos, para especificar a localização da tabela Iceberg da qual excluir arquivos órfãos.

```
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

Chame a operação UpdateTableOptimizer para atualizar o otimizador de exclusão de arquivos órfãos de uma tabela.

Desabilitar a exclusão de arquivos órfãos

Você pode desabilitar o otimizador de exclusão de arquivos órfãos para uma tabela Apache Iceberg específica usando o console do AWS Glue ou a AWS CLI.

Console

Para desabilitar a exclusão de arquivos órfãos

1. Escolha catálogo de dados e escolha Tabelas. Na lista de tabelas, escolha a tabela Iceberg da qual você deseja desabilitar o otimizador para a exclusão de arquivos órfãos.
2. Na seção inferior da página Detalhes da tabela, escolha a guia Otimização de tabela.
3. Escolha Ações e, em seguida, escolha Desativar, Exclusão de arquivo órfão.

   Você também pode escolher Desabilitar em Otimização no menu Ações.

4. Escolha Desabilitar na mensagem de confirmação. Você poderá habilitar novamente o otimizador de exclusão de arquivos órfãos mais tarde.

   Após a confirmação, o otimizador de exclusão de arquivos órfãos é desabilitado e o status da exclusão de arquivos órfãos volta a ser `Not enabled`.

AWS CLI

No exemplo a seguir, substitua o ID da conta por um ID de conta da AWS válido. Substitua o nome do banco de dados e o nome da tabela pelo nome real da tabela do Iceberg e pelo nome do banco de dados. Substitua `roleArn` pelo nome do recurso da AWS (ARN) do perfil do IAM e o nome atual do perfil do IAM que tem as permissões necessárias para desabilitar o otimizador.

```
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'}'\
  --type orphan_file_deletion
```

API

Chame a operação UpdateTableOptimizer para desabilitar o otimizador de retenção de snapshots para uma tabela específica.

Visualizar detalhes da otimização

Você pode visualizar o status de otimização das tabelas Apache Iceberg no console do AWS Glue, na AWS CLI ou usando as operações de API da AWS.

Console

Para visualizar o status de otimização das tabelas Iceberg (console)

- Você pode visualizar o status de otimização das tabelas Iceberg no console do AWS Glue escolhendo uma tabela Iceberg na lista Tabelas em Catálogo de Dados. Em Otimização da tabela. Escolha a opção Exibir tudo

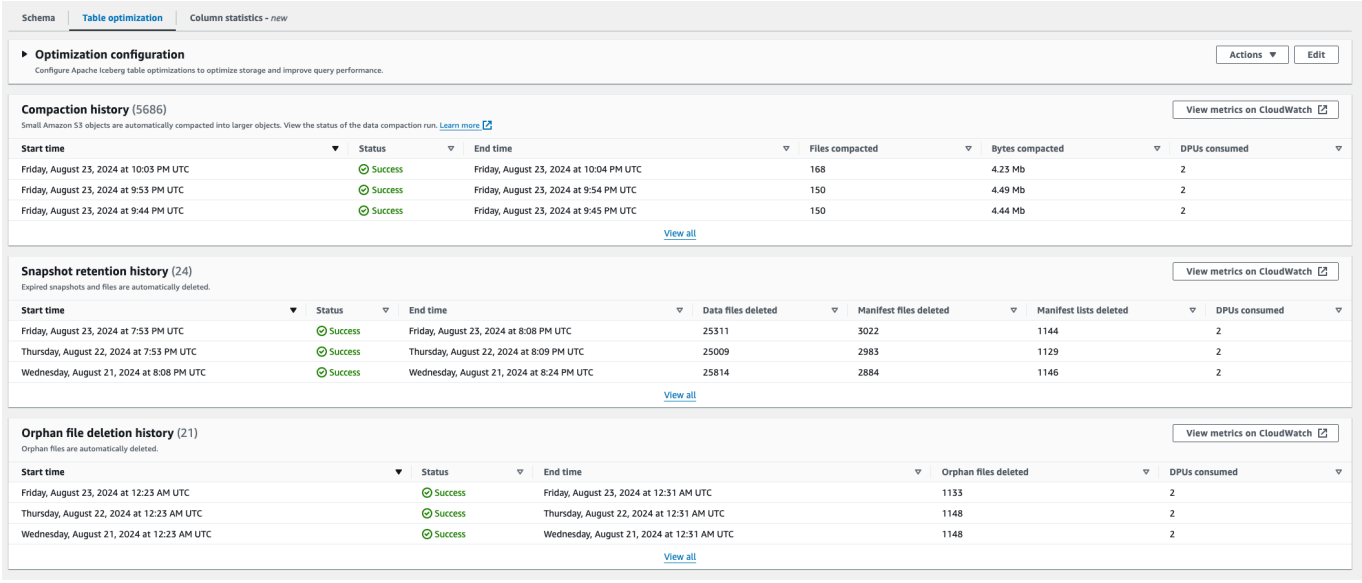

AWS CLI

Você pode visualizar os detalhes da otimização usando a AWS CLI.

Nos exemplos a seguir, substitua o ID da conta por um ID de conta da AWS válido, o nome do banco de dados e o nome da tabela pelo nome real da tabela Iceberg. Para `type`, forneça um tipo de otimização. Os valores aceitáveis são `compaction`, `retention` e `orphan-file-deletion`.

- Para obter os detalhes da última execução de compactação para uma tabela

```
aws get-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --type compaction
```

- Use o exemplo a seguir para recuperar o histórico de um otimizador para uma tabela específica.

```
aws list-table-optimizer-runs \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --type compaction
```

- O exemplo a seguir mostra como recuperar a execução de otimização e os detalhes de configuração de vários otimizadores. Você pode especificar no máximo 20 otimizadores.

```
aws glue batch-get-table-optimizer \
--entries '[{"catalogId":"123456789012", "databaseName":"iceberg_db",
 "tableName":"iceberg_table", "type":"compaction"}]'
```

API

- Use a operação `GetTableOptimizer` para recuperar os detalhes da última execução de um otimizador.
- Use a operação `ListTableOptimizerRuns` para recuperar o histórico de um determinado otimizador em uma tabela específica. Você pode especificar 20 otimizadores em uma única chamada de API.
- Use a operação BatchGetTableOptimizer para recuperar detalhes de configuração de vários otimizadores na conta.

Visualizar métricas do Amazon CloudWatch

Depois de executar os otimizadores de tabela com êxito, o serviço cria métricas do Amazon CloudWatch sobre a performance do trabalho de otimização. Você pode acessar as Métricas do CloudWatch e escolher Métricas, Todas as métricas. Você pode filtrar métricas pelo namespace específico (por exemplo, do AWS Glue), nome da tabela ou nome do banco de dados.

Para obter mais informações, consulte Visualizar métricas disponíveis no Guia do usuário do Amazon CloudWatch.

Compactação

- Número de bytes compactados
- Número de arquivos compactados
- Número de DPU alocado para o trabalho
- Duração do trabalho (horas)

Retenção de snapshots

- Número de arquivos de dados excluídos
- Número de arquivos de manifesto excluídos
- Número de listas de manifestos excluídas
- Duração do trabalho (horas)

Exclusão de arquivos órfãos

- Número de arquivos órfãos excluídos
- Duração do trabalho (horas)

Excluindo um otimizador

Você pode excluir um otimizador e os metadados associados à tabela usando a AWS CLI ou a operação de API da AWS.

Execute o comando AWS CLI a seguir para excluir o histórico de otimização de uma tabela. Você precisa especificar o otimizador `type` junto com o ID do catálogo, o nome do banco de dados e o nome da tabela. Os valores aceitáveis são: `compaction`, `retention` e `orphan_file_deletion`.

```
aws glue delete-table-optimizer \
  --catalog-id 123456789012 \
  --database-name iceberg_db \
  --table-name iceberg_table \
  --type compaction
```

Use a operação `DeleteTableOptimizer` para excluir um otimizador para uma tabela.

Considerações e limitações

Esta seção inclui considerações a serem feitas quando forem usados otimizadores de tabela no AWS Glue Data Catalog.

Formatos e limitações compatíveis para compactação gerenciada de dados

A compactação de dados aceita uma variedade de tipos de dados e formatos de compactação para leitura e gravação de dados, incluindo a leitura de dados de tabelas criptografadas.

A compactação de dados suporta:

- Criptografia: a compactação de dados oferece suporte somente à criptografia padrão do Amazon S3 (SSE-S3) e a criptografia do KMS no lado do servidor (SSE-KMS).
- Estratégias de compactação: binpack, classificação e classificação em ordem Z.
- Você pode executar a compactação a partir da conta em que o catálogo de dados reside quando o bucket do Amazon S3 que armazena os dados subjacentes estiver em outra conta. Para fazer isso, a função de compactação exige acesso ao bucket do Amazon S3.

Atualmente, a compactação de dados não oferece suporte a:

- Compactação em tabelas de contas cruzadas: não é possível executar a compactação em tabelas de contas cruzadas.
- Compactação de tabelas entre regiões: não é possível executar a compactação de tabelas entre regiões.
- Habilitando a compactação em links de recursos
- Tabelas na classe de armazenamento Amazon S3 Express One Zone: você não pode executar compactação nas tabelas do iceberg do S3 Express One Zone.
- A estratégia de compactação em ordem Z não é compatível com os seguintes tipos de dados:
  - Decimal
  - TimestampWithoutZone

Considerações sobre otimizadores de retenção de snapshots e exclusão de arquivos órfãos

A consideração a seguir se aplica ao otimizador de retenção de snapshots e exclusão de arquivos órfãos.

- Os processos de retenção de snapshots e exclusão de arquivos órfãos têm um limite máximo de exclusão de 1 milhão de arquivos por execução. Ao excluir snapshots expirados, se o número de arquivos elegíveis para exclusão ultrapassar 1 milhão, todos os arquivos restantes além desse limite continuarão existindo no armazenamento da tabela como arquivos órfãos.
- Os snapshots serão preservados pelo otimizador de retenção de snapshots somente quando ambos os critérios forem satisfeitos: o número mínimo de snapshots a serem mantidos e o período de retenção especificado.
- O otimizador de retenção de snapshots exclui metadados de snapshots expirados do Apache Iceberg, evitando consultas de viagem no tempo para snapshots expirados e, opcionalmente, excluindo arquivos de dados associados.

- O otimizador de exclusão de arquivos órfãos exclui dados órfãos e arquivos de metadados que não são mais referenciados pelos metadados do Iceberg se a hora de criação for anterior ao período de retenção da exclusão de arquivos órfãos a partir do momento da execução do otimizador.
- O Apache Iceberg facilita o controle de versão por meio de ramificações e tags, que são denominadas ponteiros para estados específicos de snapshots. Cada ramificação e tag segue seu próprio ciclo de vida independente, regido por políticas de retenção definidas em seus respectivos níveis. Os otimizadores do AWS Glue Data Catalog levam em consideração essas políticas de ciclo de vida, garantindo a adesão às regras de retenção especificadas. As políticas de retenção em nível de ramificação e tag têm precedência sobre as configurações do otimizador.

  Para obter mais informações, consulte a seção Ramificações e marcações na documentação do Iceberg.
- Os otimizadores de retenção de snapshots e exclusão de arquivos órfãos excluirão os arquivos elegíveis para limpeza de acordo com os parâmetros configurados. Melhore seu controle sobre a exclusão de arquivos implementando políticas de controle de versão e ciclo de vida do S3 nos buckets apropriados.

  Para obter instruções detalhadas sobre como configurar o controle de versão e criar regras de ciclo de vida, consulte https://docs.aws.amazon.com/AmazonS3/latest/userguide/Versioning.html.
- Para a determinação correta dos arquivos órfãos, certifique-se de que o local da tabela fornecido e quaisquer caminhos secundários não se sobreponham ou contenham dados de outras tabelas ou fontes de dados. Caso haja sobreposição de caminhos, você corre o risco de perda de dados irrecuperáveis devido à exclusão não intencional de arquivos.

Regiões compatíveis para otimizadores de tabela

Os recursos de otimização de tabelas (compactação, retenção de instantâneos e exclusão de arquivos órfãos) do AWS Glue Data Catalog estão disponíveis nas seguintes Regiões da AWS:

- Ásia-Pacífico (Tóquio)
- Ásia-Pacífico (Seul)
- Ásia-Pacífico (Mumbai)
- Ásia-Pacífico (Singapura)
- Ásia-Pacífico (Sydney)
- Ásia-Pacífico (Jacarta)

- Canadá (Central)
- Europa (Irlanda)
- Europa (Londres)
- Europa (Frankfurt)
- Europa (Estocolmo)
- Leste dos EUA (Norte da Virgínia)
- Leste dos EUA (Ohio)
- Oeste dos EUA (Oregon)
- América do Sul (São Paulo)

Otimizar a performance da consulta para tabelas Iceberg

Apache Iceberg é um formato de tabela aberta de alta performance para grandes conjuntos de dados analíticos. O AWS Glue é compatível com o cálculo e a atualização do número de valores distintos (NDVs) para cada coluna nas tabelas Iceberg. Essas estatísticas podem facilitar uma melhor otimização de consultas, gerenciamento de dados e eficiência de performance para cientistas e engenheiros de dados que trabalham com conjuntos de dados em grande escala.

O AWS Glue estima o número de valores distintos em cada coluna da tabela Iceberg e os armazena em arquivos Puffin no Amazon S3 associados aos snapshots da tabela Iceberg. Puffin é um formato de arquivo Iceberg projetado para armazenar metadados como índices, estatísticas e esboços. Armazenar esboços em arquivos Puffin vinculados a snapshots garante a consistência transacional e a atualização das estatísticas do NDV.

Você pode configurar para executar a tarefa de geração de estatísticas de coluna usando o console do AWS Glue ou a AWS CLI. Quando você inicia o processo, o AWS Glue inicia um trabalho do Spark em segundo plano e atualiza os metadados da tabela AWS Glue no Catálogo de Dados. Você pode visualizar as estatísticas da coluna usando o console do AWS Glue ou a AWS CLI ou chamando a operação da API GetColumnStatisticsForTable.

> **Note**
>
> Se você estiver usando as permissões do AWS Lake Formation para controlar o acesso à tabela, o perfil assumido pela tarefa de estatísticas da coluna exigirá acesso total à tabela para gerar estatísticas.

Tópicos

- Pré-requisitos para gerar estatísticas de colunas
- Gerar estatísticas de colunas para tabelas Iceberg
- Consulte também

Pré-requisitos para gerar estatísticas de colunas

Para gerar ou atualizar as estatísticas de colunas para tabelas Iceberg, a tarefa de geração de estatísticas assume um perfil do AWS Identity and Access Management (IAM) em seu nome. Com base nas permissões concedidas ao perfil, a tarefa de geração de estatísticas da coluna pode ler os dados do datastore do Amazon S3.

Ao configurar a tarefa de geração de estatísticas de colunas, o AWS Glue permite que você crie um perfil que inclua a política `AWSGlueServiceRole` gerenciada pela AWS, além da política em linha necessária para a fonte de dados especificada.

Se você especificar um perfil existente para a geração de estatísticas de colunas, certifique-se de que ele inclua a política `AWSGlueServiceRole` ou equivalente (ou uma versão dessa política com um escopo reduzido), além das políticas em linha necessárias.

Para mais informações sobre as permissões necessárias, consulte Pré-requisitos para gerar estatísticas de colunas.

Gerar estatísticas de colunas para tabelas Iceberg

Siga estas etapas para configurar um cronograma para gerar estatísticas no Catálogo de Dados usando o AWS Glue console AWS CLI ou ou execute a StartColumnStatisticsTaskRunoperação.

Para gerar estatísticas de colunas

1. Faça login no AWS Glue console em https://console.aws.amazon.com/glue/.
2. Escolha Tabelas em Catálogo de Dados.
3. Escolha uma tabela Iceberg na lista.
4. Escolha Estatísticas de colunas, Gerar sob demanda no menu Ações.

   Você também pode escolher o botão Gerar estatísticas na guia Estatísticas da coluna na seção inferior da página Tabelas.

5. Na página Gerar estatísticas, forneça os detalhes da geração de estatísticas. Siga as etapas 6 a 11 na Gerando estatísticas de colunas em um cronograma seção para configurar um cronograma para geração de estatísticas para tabelas Iceberg.

   Você também pode optar por gerar estatísticas de coluna sob demanda seguindo as instruções na Geração de estatísticas de colunas sob demanda

   > **Note**
   >
   > A opção de amostragem não está disponível para tabelas Iceberg.

   AWS Glue calcula o número de valores distintos de cada coluna da tabela Iceberg para um novo arquivo Puffin comprometido com o ID de snapshot especificado em sua localização no Amazon S3.

Consulte também

- Visualizar estatísticas de colunas
- Visualizar as execuções de tarefas de estatísticas de colunas
- Interromper a execução da tarefa de estatísticas de coluna
- Excluir estatísticas de colunas

Gerenciar o Catálogo de Dados

O AWS Glue Data Catalog é um repositório central de metadados que armazena metadados estruturais e operacionais para seus conjuntos de dados do Amazon S3. Gerenciar o Catálogo de Dados de forma eficaz é crucial para manter a qualidade, o desempenho, a segurança e a governança dos dados.

Ao entender e aplicar essas práticas de gerenciamento de Catálogos de Dados, é possível garantir que seus metadados permaneçam precisos, eficientes, seguros e bem governados à medida que seu cenário de dados evolui.

Esta seção aborda os seguintes aspectos do gerenciamento do Catálogo de Dados:

- Atualização do esquema e das partições da tabela Conforme seus dados evoluírem, talvez seja necessário atualizar o esquema da tabela ou a estrutura de partições definida no Catálogo de Dados. Para obter mais informações sobre como fazer essas atualizações programaticamente usando o AWS Glue ETL, consulte Atualizar esquemas e adicionar novas partições ao Catálogo de Dados em trabalhos do AWS Glue ETL.
- Gerenciar estatísticas de colunas: estatísticas de colunas precisas ajudam a otimizar os planos de consulta e melhorar a performance. Para obter mais informações sobre como gerar, atualizar e gerenciar estatísticas de colunas, consulte Otimizar a performance da consulta usando estatísticas de coluna.
- Criptografar o Catálogo de Dados Para proteger metadados confidenciais, é possível criptografar seu Catálogo de Dados usando o AWS Key Management Service (AWS KMS). Esta seção explica como habilitar e gerenciar a criptografia em seu Catálogo de Dados.
- Proteger o Catálogo de Dados com o AWS Lake Formation O Lake Formation fornece uma abordagem abrangente para a segurança e o controle de acesso do data lake. É possível usar o Lake Formation para proteger e controlar o acesso ao seu catálogo de dados e aos dados subjacentes.

Tópicos

- Atualizar esquemas e adicionar novas partições ao Catálogo de Dados em trabalhos do AWS Glue ETL
- Otimizar a performance da consulta usando estatísticas de coluna
- Como criptografar seu Data Catalog
- Proteger seu catálogo de dados usando o Lake Formation
- Trabalho com as visualizações do AWS Glue Data Catalog no AWS Glue

Atualizar esquemas e adicionar novas partições ao Catálogo de Dados em trabalhos do AWS Glue ETL

O trabalho de extração, transformação e carregamento (ETL) pode criar partições de tabelas no armazenamento de dados de destino. Os esquemas do conjunto de dados podem evoluir e divergir do esquema do esquema do AWS Glue Data Catalog ao longo do tempo. Os trabalhos de ETL do AWS Glue agora oferecem vários recursos que podem ser usados no script de ETL para atualizar os esquemas e as partições no Data Catalog. Esses recursos permitem visualizar os resultados do trabalho de ETL no Data Catalog sem precisar executar o crawler novamente.

Novas partições

Se quiser visualizar as novas partições no AWS Glue Data Catalog, é possível realizar um dos seguintes procedimentos:

- Quando o trabalho terminar, execute novamente o crawler e exiba as novas partições no console quando o crawler terminar.
- Quando o trabalho terminar, exiba as novas partições no console imediatamente, sem precisar executar novamente o crawler. Você pode habilitar esse recurso adicionando algumas linhas de código ao seu script de ETL, como exibido nos exemplos a seguir. O código usa o argumento `enableUpdateCatalog` para indicar que o Data Catalog deve ser atualizado durante a execução do trabalho à medida que as novas partições são criadas.

Método 1

Passe `enableUpdateCatalog` e `partitionKeys` em um argumento de opções.

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)
```

Método 2

Passe `enableUpdateCatalog` e `partitionKeys` em `getSink()` e chame o objeto `setCatalogInfo()` no `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)
```

Agora, é possível criar novas tabelas de catálogo, atualizar tabelas existentes com esquema modificado e adicionar novas partições de tabelas no Data Catalog usando um trabalho de ETL do AWS Glue, sem a necessidade de executar crawlers novamente.

Atualizar esquema da tabela

Se você quiser substituir o esquema da tabela do Data Catalog, é possível realizar um dos seguintes procedimentos:

- Quando o trabalho for concluído, execute o crawler novamente e verifique se está configurado para atualizar a definição da tabela também. Visualize as partições no console junto com atualizações do esquema, quando o crawler finalizar. Para obter mais informações, consulte Configurar um crawler com a API.

- Quando o trabalho for concluído, visualize o esquema modificado no console imediatamente, sem precisar executar o crawler novamente. Você pode habilitar esse recurso adicionando algumas linhas de código ao seu script de ETL, como exibido nos exemplos a seguir. O código usa `enableUpdateCatalog` definido como true e `updateBehavior` definido como `UPDATE_IN_DATABASE`, o que indica substituir o esquema e adicionar novas partições no Data Catalog durante a execução do trabalho.

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)
```

Também é possível definir o valor de `updateBehavior` como `LOG` se quiser impedir que o esquema da tabela seja substituído, mas ainda quiser adicionar novas partições. O valor padrão de `updateBehavior` é `UPDATE_IN_DATABASE`, portanto, se você não defini-lo explicitamente, o esquema da tabela será substituído.

Se `enableUpdateCatalog` não estiver definido como true, independentemente da opção selecionada para `updateBehavior`, o trabalho de ETL não atualizará a tabela no Data Catalog.

Criar novas tabelas

Também é possível usar as mesmas opções para criar uma tabela no Data Catalog. Também é possível especificar o banco de dados e o nome da nova tabela usando `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)
```

Restrições

Observe as seguintes restrições:

- Somente os destinos do Amazon Simple Storage Service (Amazon S3) são suportados.
- O atributo `enableUpdateCatalog` é suportado para tabelas governadas.
- Somente os seguintes formatos são compatíveis: `json`, `csv`, `avro` e `parquet`.
- Para criar ou atualizar tabelas com a classificação `parquet`, você deve utilizar o gravador de parquet do AWS Glue otimizado para DynamicFrames. Isso pode ser feito de uma das seguintes maneiras:
  - se você estiver atualizando uma tabela existente no catálogo com classificação `parquet`, a tabela deve ter a propriedade de tabela `"useGlueParquetWriter"` definida como `true` antes

de você atualizá-la. Você pode definir essa propriedade por meio de APIs/SDK do AWS Glue, por meio do console ou por meio de uma instrução DDL do Athena.

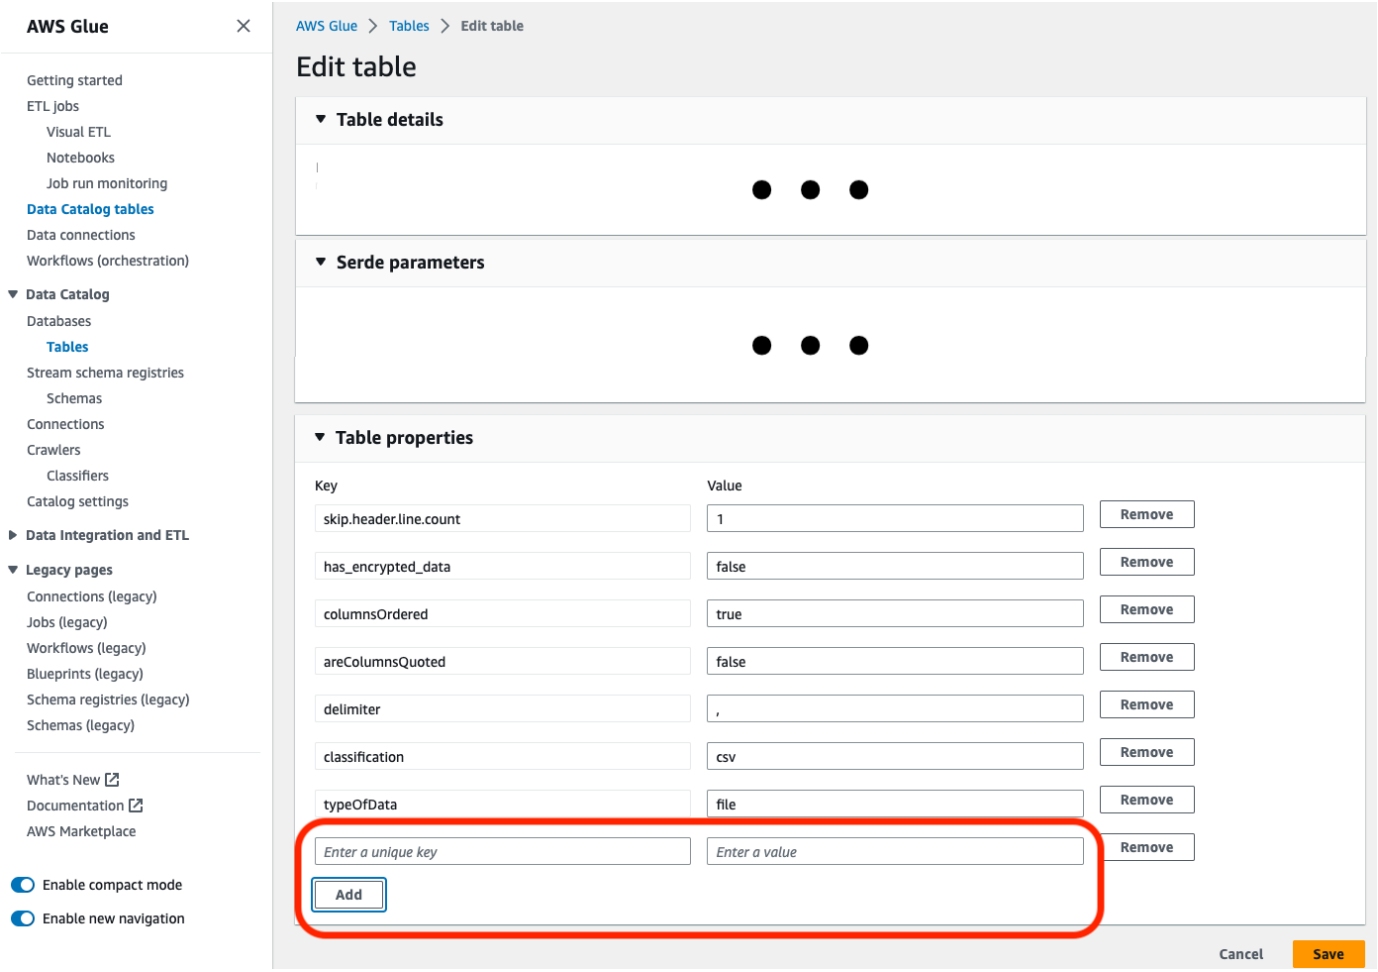

Depois que a propriedade da tabela do catálogo estiver definida, você poderá usar o seguinte trecho de código para atualizar a tabela do catálogo com os novos dados:

```
glueContext.write_dynamic_frame.from_catalog(
    frame=frameToWrite,
    database="dbName",
    table_name="tableName",
    additional_options={
        "enableUpdateCatalog": True,
        "updateBehavior": "UPDATE_IN_DATABASE"
    }
)
```

- Se a tabela ainda não existir no catálogo, você pode utilizar o método `getSink()` em seu script com `connection_type="s3"` para adicionar a tabela e suas partições ao catálogo, além de

gravar os dados no Amazon S3. Forneça as `partitionKeys` e a `compression` para seu fluxo de trabalho.

```
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)
```

  - O valor de formato `glueparquet` é um método herdado para habilitar o gravador parquet AWS Glue.
- Quando `updateBehavior` for definido como `LOG`, as novas partições serão adicionadas somente se o esquema `DynamicFrame` for equivalente a, ou contiver, um subconjunto das colunas definidas no esquema da tabela do Data Catalog.
- As atualizações de esquema não são aceitas para tabelas não particionadas (que não usam a opção “partitionKeys”).
- As partitionKeys devem ser equivalentes e estar na mesma ordem, entre o parâmetro informado no script de ETL e as partitionKeys no esquema da tabela do Data Catalog.
- Atualmente, esse recurso ainda não suporta atualização/criação de tabelas nas quais os esquemas de atualização são aninhados (por exemplo, matrizes dentro de estruturas).

Para ter mais informações, consulte the section called “AWS Glue para Spark”.

Trabalhar com conexões MongoDB em trabalhos de ETL

Você pode criar uma conexão para MongoDB e, em seguida, usar essa conexão em seu trabalho do AWS Glue. Para obter mais informações, consulte the section called “Conexões do MongoDB” no guia de programação do AWS Glue. O `url`, `username` e `password` da conexão são armazenados na conexão do MongoDB. Outras opções podem ser especificadas em seu script de trabalho de ETL

usando o parâmetro `additionalOptions` do `glueContext.getCatalogSource`. As outras opções podem incluir:

- `database`: (obrigatório) o banco de dados MongoDB do qual fazer a leitura.
- `collection`: (obrigatório) a coleção do MongoDB da qual fazer a leitura.

Ao colocar as informações de `database` e `collection` dentro do script de trabalho de ETL, você pode usar a mesma conexão em vários trabalhos.

1. Criar uma conexão do AWS Glue Data Catalog para a fonte de dados do MongoDB. Consulte "connectionType": "mongodb" para uma descrição dos parâmetros de conexão. É possível criar a conexão ao utilizar o console, as APIs ou a CLI.
2. Crie um banco de dados no AWS Glue Data Catalog para armazenar as definições de tabela para seus dados do MongoDB. Consulte Criar bancos de dados Para mais informações.
3. Crie um crawler que rastreie os dados no MongoDB usando as informações na conexão para se conectar ao MongoDB. O crawler cria as tabelas no AWS Glue Data Catalog que descrevem as tabelas no banco de dados MongoDB que você usa em seu trabalho. Consulte Usar crawlers para preencher o catálogo de dados Para mais informações.
4. Crie um trabalho com um script personalizado. É possível criar o trabalho usando o console, as APIs ou a CLI. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.
5. Escolha os destinos de dados para o seu trabalho. As tabelas que representam o destino dos dados podem ser definidas no Data Catalog, ou seu trabalho pode criar as tabelas de destino quando for executado. Você escolhe um local de destino ao criar o trabalho. Se o destino exigir uma conexão, ela também será referenciada no seu trabalho. Se o trabalho precisar de vários destinos de dados, você poderá adicioná-los posteriormente editando o script.
6. Personalize o ambiente de processamento de trabalhos informando os argumentos para seu trabalho e o script gerado.

   A seguir, encontra-se um exemplo de como criar um `DynamicFrame` do banco de dados MongoDB com base na estrutura da tabela definida no Data Catalog. O código usa `additionalOptions` para fornecer as informações adicionais sobre a origem dos dados:

   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. Execute o trabalho, sob demanda ou por meio de um acionador.

Otimizar a performance da consulta usando estatísticas de coluna

Você pode calcular estatísticas em nível de coluna para tabelas do AWS Glue Data Catalog em formatos de dados como Parquet, ORC, JSON, ION, CSV e XML sem precisar configurar pipelines de dados adicionais. As estatísticas de colunas ajudam você a entender os perfis de dados obtendo insights sobre os valores em uma coluna.

O Catálogo de Dados possibilita a geração de estatísticas para valores de colunas, como valor mínimo, valor máximo, total de valores nulos, total de valores distintos, comprimento médio dos valores e ocorrências totais de valores reais. Os serviços analíticos da AWS, como o Amazon Redshift e o Amazon Athena, podem usar essas estatísticas de colunas para gerar planos de execução de consultas e escolher o plano ideal para melhorar a performance da consulta.

Há três cenários para a geração de estatísticas de colunas:

Auto

O AWS Glue oferece suporte à geração automática de estatísticas de colunas no nível do catálogo para que ele possa gerar automaticamente estatísticas para novas tabelas no AWS Glue Data Catalog.

Programado

O AWS Glue oferece suporte à programação da geração de estatísticas de coluna para que ela possa ser executada automaticamente em uma programação recorrente.

Com o cálculo de estatísticas programado, a tarefa de estatísticas de coluna atualiza as estatísticas gerais em nível de tabela, como mínimos, máximos e média, com as novas estatísticas, fornecendo aos mecanismos de consulta estatísticas precisas e atualizadas para otimizar a execução de consultas.

Sob demanda

Use essa opção para gerar estatísticas de coluna sob demanda sempre que necessário. Isso é útil para análises ad hoc ou quando as estatísticas precisam ser calculadas imediatamente.

É possível configurar para executar a tarefa de geração de estatísticas de coluna usando o console do AWS Glue, a AWS CLI ou a API do AWS Glue. Quando você inicia o processo, o AWS Glue inicia um trabalho do Spark em segundo plano e atualiza os metadados da tabela AWS Glue no Catálogo de Dados. Você pode visualizar as estatísticas da coluna usando o console do AWS Glue ou a AWS CLI ou chamando a operação da API GetColumnStatisticsForTable.

> **Note**
>
> Se você estiver usando as permissões do Lake Formation para controlar o acesso à tabela, o perfil assumido pela tarefa de estatísticas da coluna exigirá acesso total à tabela para gerar estatísticas.

Tópicos

- Pré-requisitos para gerar estatísticas de colunas
- Geração automática de estatísticas de colunas
- Gerando estatísticas de colunas em um cronograma
- Geração de estatísticas de colunas sob demanda
- Visualizar estatísticas de colunas
- Visualizar as execuções de tarefas de estatísticas de colunas
- Interromper a execução da tarefa de estatísticas de coluna
- Excluir estatísticas de colunas
- Considerações e limitações

Pré-requisitos para gerar estatísticas de colunas

Para gerar ou atualizar as estatísticas de colunas, a tarefa de geração de estatísticas assume um perfil do AWS Identity and Access Management (IAM) em seu nome. Com base nas permissões concedidas ao perfil, a tarefa de geração de estatísticas da coluna pode ler os dados do datastore do Amazon S3.

Ao configurar a tarefa de geração de estatísticas de colunas, o AWS Glue permite que você crie um perfil que inclua a política `AWSGlueServiceRole` gerenciada pela AWS, além da política em linha necessária para a fonte de dados especificada.

Se você especificar um perfil existente para a geração de estatísticas de colunas, certifique-se de que ele inclua a política `AWSGlueServiceRole` ou equivalente (ou uma versão dessa política com um escopo reduzido), além das políticas em linha necessárias. Siga estas etapas para criar um novo perfil do IAM:

> **Note**
>
> Para gerar estatísticas para tabelas gerenciadas pelo Lake Formation, o perfil do IAM usado para gerar estatísticas exige acesso total à tabela.

Ao configurar a tarefa de geração de estatísticas de colunas, o AWS Glue permite que você crie um perfil que inclua a política `AWSGlueServiceRole` gerenciada pela AWS, além da política em linha necessária para a fonte de dados especificada. Você também pode criar um perfil e anexar as permissões listadas na política abaixo, e adicionar esse perfil à tarefa de geração de estatísticas da coluna.

Para criar um perfil do IAM para gerar estatísticas de coluna

1. Para criar um perfil do IAM, consulte Criar um perfil do IAM para o AWS Glue.
2. Para atualizar um perfil existente, no console do IAM, acesse o perfil do IAM que está sendo usado pelo processo de geração de estatísticas de colunas.
3. Na guia Adicionar permissões, escolha Anexar políticas. Na janela recém-aberta do navegador, escolha política gerenciada pela AWS `AWSGlueServiceRole`.
4. Você também precisa incluir permissão para ler dados da localização de dados do Amazon S3.

   Na seção Adicionar permissões, escolha Criar política. Na janela recém-aberta do navegador, crie uma nova política para usar com seu perfil.

5. Na página Criar política, escolha a guia JSON. Copie o seguinte código `JSON` no editor.

> **Note**
>
> Nas políticas a seguir, substitua o ID da conta por uma Conta da AWS válida e substitua `region` pela região da tabela e `bucket-name` pelo nome do bucket do 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. (Opcional) Se você estiver usando as permissões do Lake Formation para fornecer acesso aos seus dados, o perfil do IAM exigirá permissões de `lakeformation:GetDataAccess`.

```
{
    "Version": "2012-10-17",
    "Statement": [
       {
            "Sid": "LakeFormationDataAccess",
            "Effect": "Allow",
            "Action": "lakeformation:GetDataAccess",
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Se a localização dos dados do Amazon S3 estiver registrada no Lake Formation e o perfil do IAM assumido pela tarefa de geração de estatísticas de colunas não tiver permissões de grupo `IAM_ALLOWED_PRINCIPALS` concedidas na tabela, o perfil exigirá as permissões `ALTER` e `DESCRIBE` do Lake Formation na tabela. O perfil usado para registrar o bucket do Amazon S3 requer as permissões `INSERT` e `DELETE` do Lake Formation na tabela.

Se a localização dos dados do Amazon S3 não estiver registrada no Lake Formation e o perfil do IAM não tiver permissões de grupo `IAM_ALLOWED_PRINCIPALS` concedidas na tabela, o perfil exigirá as permissões `ALTER`, `DESCRIBE`, `INSERT` e `DELETE` do Lake Formation na tabela.

7. Se você ativou a opção `Automatic statistics generation` em nível de catálogo, o perfil do IAM deve ter a permissão `glue:UpdateCatalog` ou a permissão `ALTER CATALOG` do Lake Formation no Catálogo de Dados padrão. Você pode usar a operação `GetCatalog` para verificar as propriedades do catálogo.
8. (Opcional) A tarefa de geração de estatísticas de colunas que grava Amazon CloudWatch Logs criptografados requer as permissões a seguir na política de chave.

```
{
    "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. O perfil que você usa para executar as estatísticas de colunas deve ter a permissão `iam:PassRole`.

```
{
    "Version": "2012-10-17",
    "Statement": [{
        "Effect": "Allow",
        "Action": [
            "iam:PassRole"
        ],
        "Resource": [
            "arn:aws:iam::111122223333:role/<columnstats-role-name>"
        ]
    }]
}
```

10. Ao criar um perfil do IAM para gerar estatísticas de coluna, esse perfil também deve ter a política de confiança a seguir que permite que o serviço assuma o perfil.

```
{
    "Version": "2012-10-17",
    "Statement": [
      {
        "Sid": "TrustPolicy",
        "Effect": "Allow",
        "Principal": {
          "Service": "glue.amazonaws.com"
```

```
        },
        "Action": "sts:AssumeRole",
      }
   ]
}
```

Geração automática de estatísticas de colunas

A geração automática de estatísticas de colunas permite a você agendar e calcular automaticamente estatísticas em novas tabelas no AWS Glue Data Catalog. Quando a geração automática de estatísticas é habilitada, o Catálogo de Dados descobre novas tabelas com formatos de dados específicos, como Parquet, JSON, CSV, XML, ORC, ION e Apache Iceberg, junto com seus caminhos de bucket individuais. Com uma configuração única de catálogo, o Catálogo de Dados gera estatísticas para essas tabelas.

Os administradores do Data Lake podem configurar a geração de estatísticas selecionando o catálogo padrão no console do Lake Formation e habilitando as estatísticas da tabela usando a opção `Optimization configuration`. Quando você cria novas tabelas ou atualiza tabelas existentes no Catálogo de Dados, o Catálogo de Dados coleta semanalmente o número de valores distintos (NDVs) das tabelas do Apache Iceberg e estatísticas adicionais, como o número de nulos, tamanho máximo, mínimo e médio de outros formatos de arquivo compatíveis.

Se você configurou a geração de estatísticas no nível da tabela ou se já excluiu as configurações de geração de estatísticas de uma tabela, essas configurações específicas da tabela têm precedência sobre as configurações padrão do catálogo para a geração automática de estatísticas de coluna.

A tarefa de geração automática de estatísticas analisa 50% dos registros nas tabelas para calcular estatísticas. A geração automática de estatísticas de colunas garante que o Catálogo de dados mantenha as métricas semanais que podem ser usadas por mecanismos de consulta como Amazon Athena e Amazon Redshift Spectrum para melhorar a performance das consultas e reduzir custos potenciais. Isso permite programar a geração de estatísticas usando APIs ou o console do AWS Glue, fornecendo um processo automatizado sem intervenção manual.

Tópicos

- Habilitar a geração automática de estatísticas em nível de catálogo
- Visualizar configurações em nível de tabela automatizadas
- Desabilitar a geração de estatísticas de colunas em nível de catálogo

Habilitar a geração automática de estatísticas em nível de catálogo

É possível habilitar a geração automática de estatísticas de colunas para todas as novas tabelas do Apache Iceberg e tabelas em formatos não OTF (Parquet, JSON, CSV, XML, ORC, ION) no Catálogo de Dados. Depois de criar a tabela, você também poderá atualizar explicitamente as configurações de estatísticas de coluna manualmente.

Para atualizar as configurações do Catálogo de Dados para habilitar o nível do catálogo, o perfil do IAM usado deve ter a permissão `glue:UpdateCatalog` ou a permissão `ALTER CATALOG` do AWS Lake Formation no catálogo raiz. É possível usar a API `GetCatalog` para verificar as propriedades do catálogo.

AWS Management Console

Para habilitar a geração automática de estatísticas de colunas no nível da conta

1. Abra o console do Lake Formation em https://console.aws.amazon.com/lakeformation/.
2. No painel de navegação à esquerda, escolha Catálogos).
3. Na página Resumo do catálogo, escolha Editar em Configuração da otimização.

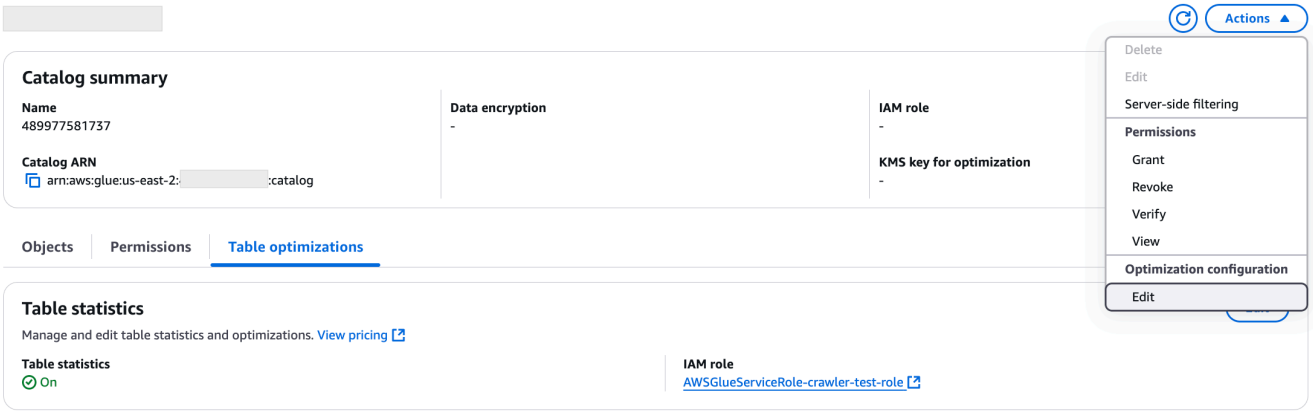

4. Na página Configuração da otimização de tabelas, escolha a opção Habilitar geração automática de estatísticas para as tabelas do catálogo.

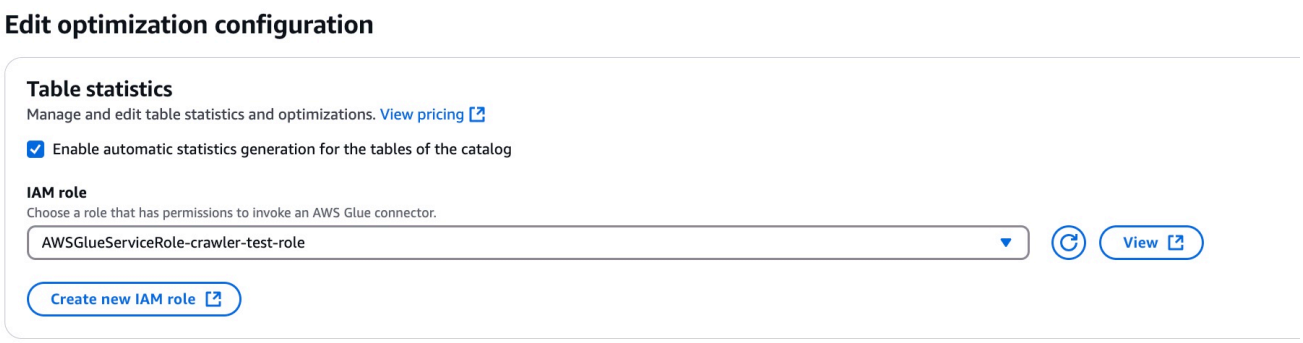

5. Escolha um perfil do IAM existente ou crie um novo com as permissões necessárias para executar a tarefa de estatísticas de coluna.
6. Selecione Enviar.

AWS CLI

Você também pode habilitar a coleta de estatísticas em nível de catálogo via AWS CLI. Para configurar a coleta de estatísticas em nível de tabela usando a AWS CLI, execute o seguinte comando:

```
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"
            }
        }
    }
}'
```

O comando acima chama a operação `UpdateCatalog` do AWS Glue, que usa uma estrutura `CatalogProperties` com os seguintes pares de chave-valor para geração de estatísticas em nível de catálogo:

- ColumnStatistics.RoleArn: ARN do perfil do IAM a ser usado para todas as tarefas acionadas para geração de estatísticas em nível de catálogo
- ColumnStatistics.Enabled: booleano que indica se as configurações em nível de catálogo estão habilitadas ou desabilitadas

Visualizar configurações em nível de tabela automatizadas

Quando a coleta de estatísticas em nível de catálogo está habilitada, sempre que uma tabela do Apache Hive ou uma tabela do Apache Iceberg é criada ou atualizada por meio das APIs `CreateTable` ou `UpdateTable` via AWS Management Console, SDK ou Crawler do AWS Glue, uma configuração em nível de tabela equivalente é criada para essa tabela.

As tabelas com a geração automática de estatísticas habilitada devem seguir uma das seguintes propriedades:

- Usar um `InputSerdeLibrary` que comece com org.apache.hadoop e em que `TableType` seja igual a `EXTERNAL_TABLE`
- Usar um `InputSerdeLibrary` que comece com `com.amazon.ion` e em que `TableType` seja igual a `EXTERNAL_TABLE`
- Conter table_type: "ICEBERG" em sua estrutura de parâmetros.

Após criar ou atualizar uma tabela, você poderá verificar os detalhes da tabela para confirmar a geração de estatísticas. `Statistics generation summary` mostra a propriedade `Schedule` definida como `AUTO` e o valor de `Statistics configuration` é `Inherited from catalog`. Qualquer configuração de tabela com a configuração a seguir seria acionada automaticamente pelo Glue internamente.

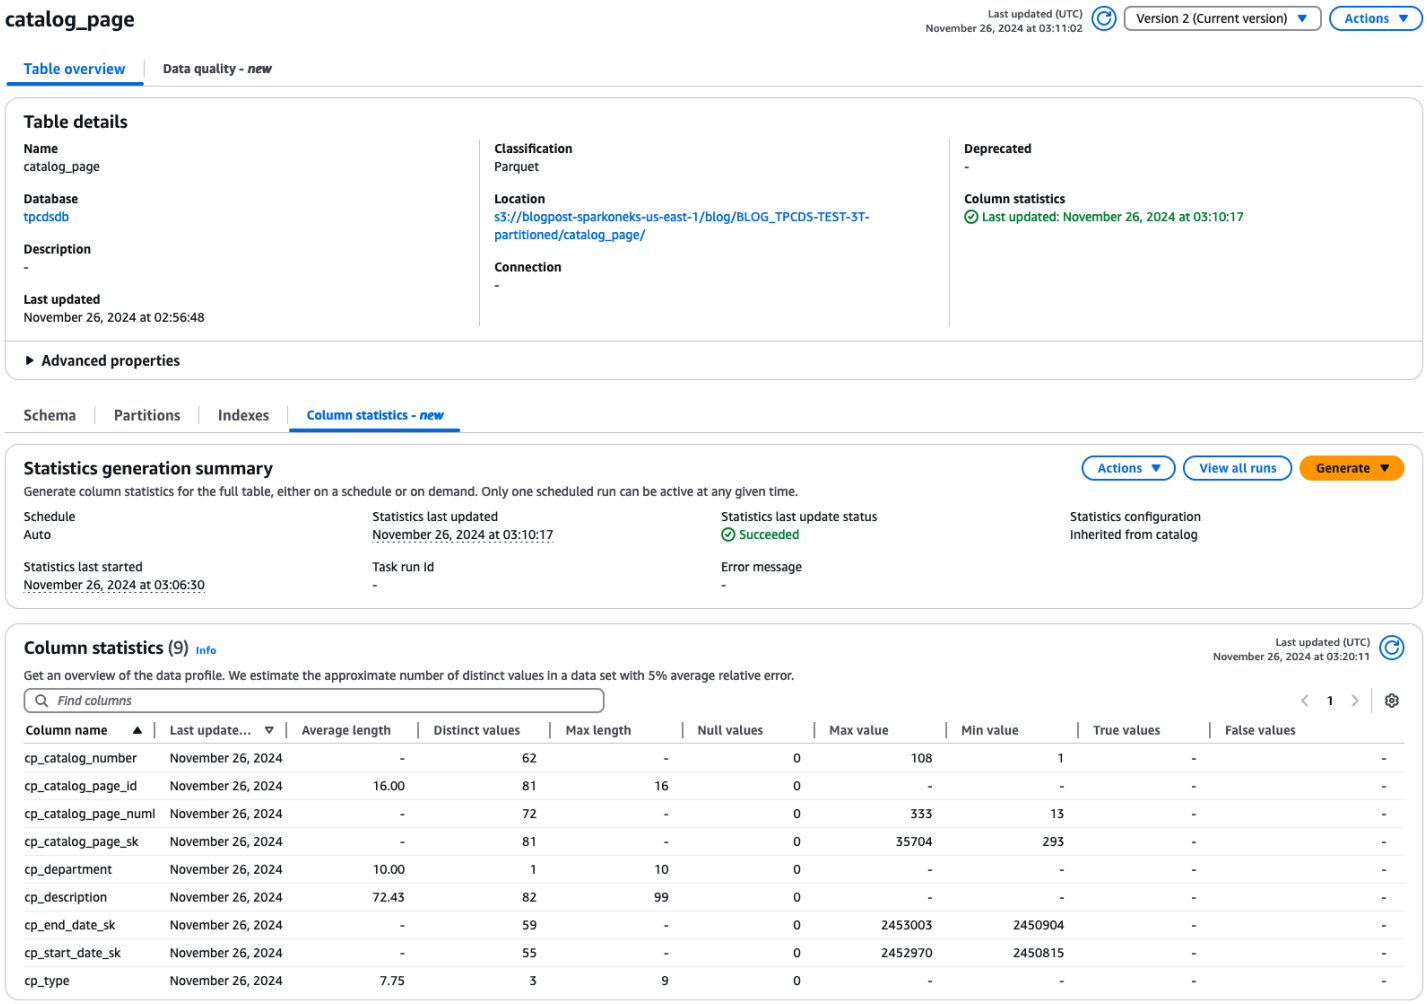

Desabilitar a geração de estatísticas de colunas em nível de catálogo

É possível desabilitar a geração automática de estatísticas de colunas para novas tabelas usando o console do AWS Lake Formation, a API `glue:UpdateCatalogSettings` ou a API `glue:DeleteColumnStatisticsTaskSettings`.

Para desabilitar a geração automática de estatísticas de colunas no nível da conta

1. Abra o console do Lake Formation em https://console.aws.amazon.com/lakeformation/.
2. No painel de navegação à esquerda, escolha Catálogos).
3. Na página Resumo do catálogo, escolha Editar em Configuração da otimização.
4. Na página Configuração da otimização de tabelas, desmarque a opção Habilitar geração automática de estatísticas para as tabelas do catálogo.
5. Selecione Enviar.

Gerando estatísticas de colunas em um cronograma

Siga estas etapas para configurar um cronograma para gerar estatísticas de coluna no AWS Glue Data Catalog uso do AWS Glue console AWS CLI, do ou da CreateColumnStatisticsTaskSettingsoperação.

Console

Para gerar estatísticas de colunas usando o console

1. Faça login no AWS Glue console em https://console.aws.amazon.com/glue/.
2. Escolha uma tabela do Catálogo de Dados.
3. Escolha uma tabela na lista.
4. Escolha a guia Estatísticas da coluna na seção inferior da página Tabelas.
5. Você também pode escolher Gerar de acordo com o cronograma em Estatísticas da coluna em Ações.
6. Na página Gerar estatísticas na agenda, configure uma agenda recorrente para executar a tarefa de estatísticas da coluna escolhendo a frequência e a hora de início. Você pode escolher a frequência para ser horária, diária, semanal ou definir uma expressão cron para especificar a programação.

   Uma expressão cron é uma string que representa um padrão de agendamento, consistindo em 6 campos separados por espaços: * * * * * <minute><hour><day of month><month><day of week><year>Por exemplo, para executar uma tarefa todos os dias à meia-noite, a expressão cron seria: 0 0 * *? *

   Para obter mais informações, consulte Expressões cron.

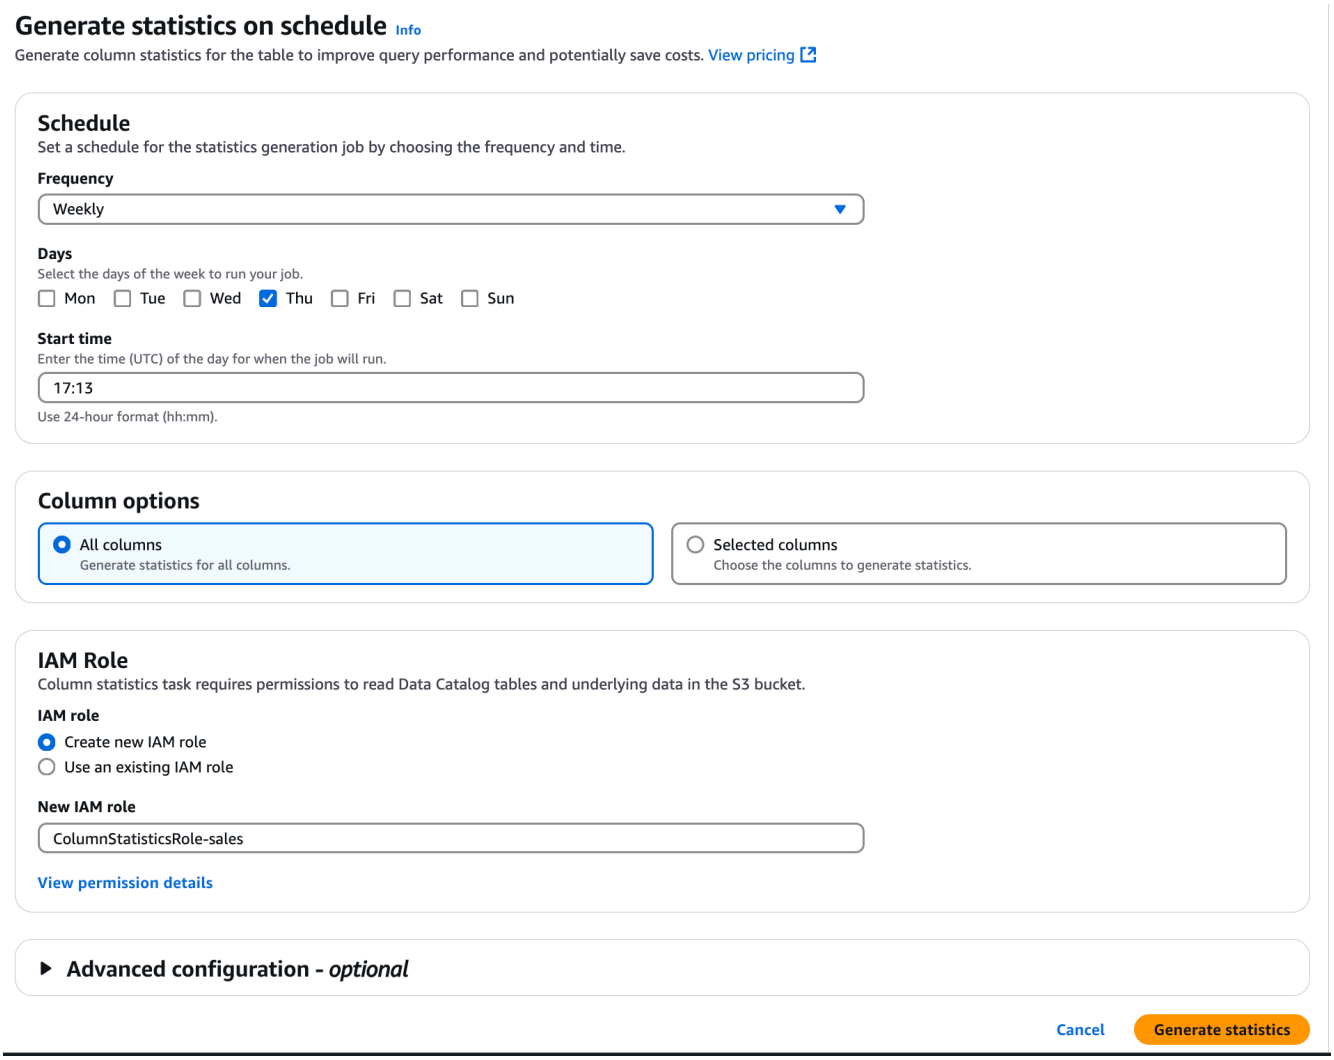

7. Em seguida, escolha a opção de coluna para gerar estatísticas.

   - Todas as colunas: escolha essa opção para gerar estatísticas para todas as colunas na tabela.
   - Colunas selecionadas: escolha essa opção para gerar estatísticas para colunas específicas. É possível selecionar as colunas na lista suspensa.

8. Escolha uma IAM função ou crie uma função existente que tenha permissões para gerar estatísticas. AWS Glue assume essa função para gerar estatísticas de colunas.

   Uma abordagem mais rápida é deixar o AWS Glue console criar uma função para você. A função que ele cria é especificamente para gerar estatísticas de colunas e inclui a política `AWSGlueServiceRole` AWS gerenciada mais a política embutida necessária para a fonte de dados especificada.

Se você especificar uma função existente para gerar estatísticas de coluna, certifique-se de que ela inclua a `AWSGlueServiceRole` política ou equivalente (ou uma versão com escopo reduzido dessa política), além das políticas embutidas necessárias.

9. (Opcional) Em seguida, escolha uma configuração de segurança para ativar a criptografia em repouso para logs.
10. (Opcional) Você pode escolher um tamanho de amostra indicando somente uma porcentagem específica de linhas da tabela para gerar estatísticas. O padrão é todas as linhas. Use as setas para cima e para baixo para aumentar ou diminuir o valor percentual.

    Recomendamos incluir todas as linhas na tabela para calcular estatísticas precisas. Use as linhas de exemplo para gerar estatísticas de coluna somente quando valores aproximados forem aceitáveis.
11. Escolha Gerar estatísticas para executar a tarefa de geração de estatísticas da coluna.

AWS CLI

Você pode usar o AWS CLI exemplo a seguir para criar um cronograma de geração de estatísticas de coluna. O nome do banco de dados, o nome da tabela e a função são parâmetros obrigatórios, e os parâmetros opcionais são agenda, id do catálogo column-name-list, tamanho da amostra e configuração de segurança.

```
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'
```

Você também pode gerar estatísticas de coluna chamando a StartColumnStatisticsTaskRunoperação.

Gerenciando o cronograma para geração de estatísticas de colunas

Você pode gerenciar as operações de agendamento, como atualizar, iniciar, interromper e excluir agendas para a geração de estatísticas da coluna em. AWS Glue Você pode usar APIoperações de AWS CLI estatísticas de AWS Glue console ou AWS Glue coluna para realizar essas tarefas.

Tópicos

- Atualizando o cronograma de geração de estatísticas da coluna
- Interrompendo o cronograma para geração de estatísticas de colunas
- Retomando o cronograma para geração de estatísticas de colunas
- Excluindo o cronograma de geração de estatísticas da coluna

Atualizando o cronograma de geração de estatísticas da coluna

Você pode atualizar a agenda para acionar a tarefa de geração de estatísticas da coluna após sua criação. Você pode usar o AWS Glue console ou executar a UpdateColumnStatisticsTaskSettingsoperação para atualizar a agenda de uma tabela. AWS CLI Você pode modificar os parâmetros de uma agenda existente, como o tipo de programação (sob demanda ou programada) e outros parâmetros opcionais.

AWS Management Console

Para atualizar as configurações de uma tarefa de geração de estatísticas de coluna

1. Faça login no AWS Glue console em https://console.aws.amazon.com/glue/.
2. Escolha a tabela que você deseja atualizar na lista de tabelas.
3. Na seção inferior da página de detalhes da tabela, escolha Estatísticas da coluna.
4. Em Ações, escolha Editar para atualizar o cronograma.
5. Faça as alterações desejadas na agenda e escolha Salvar.

AWS CLI

Se você não estiver usando AWS Glue o recurso de geração de estatísticas do console, poderá atualizar manualmente a programação usando o `update-column-statistics-task-settings` comando. O exemplo a seguir mostra como excluir estatísticas de colunas usando a 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'
```

Interrompendo o cronograma para geração de estatísticas de colunas

Se você não precisar mais das estatísticas incrementais, poderá interromper a geração programada para economizar recursos e custos. Pausar o cronograma não afeta as estatísticas geradas anteriormente. Você pode retomar a programação conforme sua conveniência.

AWS Management Console

Para interromper o agendamento de uma tarefa de geração de estatísticas de coluna

1. No AWS Glue console, escolha Tabelas em Catálogo de dados.
2. Selecione uma tabela com estatísticas de colunas.
3. Na página Detalhes da tabela, escolha Estatísticas da coluna.
4. Em Ações, escolha Geração agendada, Pausa.
5. Escolha Pausar para confirmar.

AWS CLI

Para interromper o cronograma de execução de uma tarefa de estatísticas de coluna usando o AWS CLI, você pode usar o seguinte comando:

```
aws glue stop-column-statistics-task-run-schedule \
 --database-name ''database_name' \
 --table-name 'table_name'
```

Substitua o `database_name` e o `table_name` pelos nomes reais do banco de dados e da tabela para os quais você deseja interromper o cronograma de execução da tarefa de estatísticas da coluna.

Retomando o cronograma para geração de estatísticas de colunas

Se você pausou o cronograma de geração de estatísticas, AWS Glue permite que você retome o cronograma conforme sua conveniência. Você pode retomar o agendamento usando o AWS Glue AWS CLI console ou a StartColumnStatisticsTaskRunScheduleoperação.

AWS Management Console

Para retomar o cronograma para geração de estatísticas de colunas

1. No AWS Glue console, escolha Tabelas em Catálogo de dados.
2. Selecione uma tabela com estatísticas de colunas.
3. Na página Detalhes da tabela, escolha Estatísticas da coluna.
4. Em Ações, escolha Geração agendada e escolha Continuar.
5. Escolha Retomar para confirmar.

AWS CLI

Substitua o `database_name` e o `table_name` pelos nomes reais do banco de dados e da tabela para os quais você deseja interromper o cronograma de execução da tarefa de estatísticas da coluna.

```
aws glue start-column-statistics-task-run-schedule \
 --database-name 'database_name' \
 --table-name 'table_name'
```

Excluindo o cronograma de geração de estatísticas da coluna

Embora a manutenção de up-to-date estatísticas seja geralmente recomendada para otimizar o desempenho da consulta, há casos de uso específicos em que a remoção do cronograma de geração automática pode ser benéfica.

- Se os dados permanecerem relativamente estáticos, as estatísticas das colunas existentes poderão permanecer precisas por um longo período, reduzindo a necessidade de atualizações

frequentes. A exclusão da agenda pode evitar o consumo desnecessário de recursos e a sobrecarga associada à regeneração de estatísticas em dados inalterados.

- Quando o controle manual sobre a geração de estatísticas é preferido. Ao excluir a programação automática, os administradores podem atualizar seletivamente as estatísticas das colunas em intervalos específicos ou após alterações significativas nos dados, alinhando o processo com suas estratégias de manutenção e necessidades de alocação de recursos.

AWS Management Console

Para excluir a programação para geração de estatísticas de coluna

1. No AWS Glue console, escolha Tabelas em Catálogo de dados.
2. Selecione uma tabela com estatísticas de colunas.
3. Na página Detalhes da tabela, escolha Estatísticas da coluna.
4. Em Ações, escolha Geração agendada, Excluir.
5. Escolha Excluir para confirmar.

AWS CLI

Substitua o `database_name` e o `table_name` pelos nomes reais do banco de dados e da tabela para os quais você deseja interromper o cronograma de execução da tarefa de estatísticas da coluna.

Você pode excluir o cronograma de estatísticas da coluna usando a DeleteColumnStatisticsTaskSettingsAPIoperação ou AWS CLI. O exemplo a seguir mostra como excluir a programação para gerar estatísticas de coluna usando AWS Command Line Interface (AWS CLI).

```
aws glue delete-column-statistics-task-settings \
    --database-name 'database_name' \
    --table-name 'table_name'
```

Geração de estatísticas de colunas sob demanda

Você pode executar a tarefa de estatísticas de coluna para a tarefa de AWS Glue Data Catalog tabelas sob demanda sem um cronograma definido. Essa opção é útil para análises ad hoc ou quando as estatísticas precisam ser calculadas imediatamente.

Siga estas etapas para gerar estatísticas de coluna sob demanda para as tabelas do Catálogo de Dados usando o AWS Glue console ou AWS CLI.

AWS Management Console

Para gerar estatísticas de colunas usando o console

1. Faça login no AWS Glue console em https://console.aws.amazon.com/glue/.
2. Escolha uma tabela do Catálogo de Dados.
3. Escolha uma tabela na lista.
4. Escolha Gerar estatísticas no menu Ações.

   Você também pode escolher a opção Gerar, Gerar sob demanda na guia Estatísticas da coluna na seção inferior da página Tabela.
5. Siga as etapas 7 a 11 em Gerando estatísticas de colunas em um cronograma para gerar estatísticas de coluna para a tabela.
6. Na página Gerar estatísticas, especifique as seguintes opções:

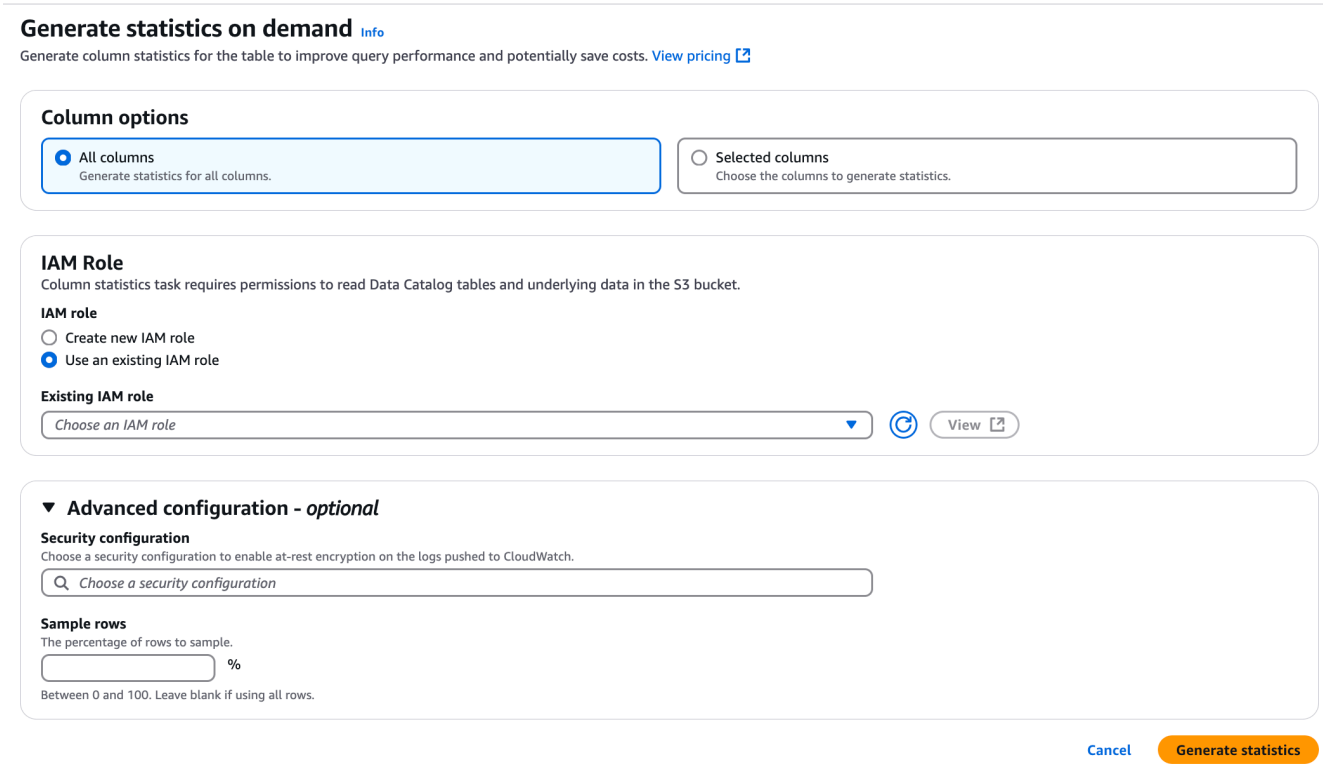

- Todas as colunas: escolha essa opção para gerar estatísticas para todas as colunas na tabela.
- Colunas selecionadas: escolha essa opção para gerar estatísticas para colunas específicas. É possível selecionar as colunas na lista suspensa.
- IAMfunção — Escolha Criar uma nova IAM função que tenha as políticas de permissão necessárias para executar a tarefa de geração de estatísticas da coluna. Escolha Exibir detalhes da permissão para revisar a declaração de política. Você também pode selecionar uma IAM função na lista. Para mais informações sobre as permissões necessárias, consulte Pré-requisitos para gerar estatísticas de colunas.

  AWS Glue assume as permissões da função que você especifica para gerar estatísticas.

  Para obter mais informações sobre o fornecimento de funções para AWS Glue, consulte Políticas baseadas em identidade para. AWS Glue.
- (Opcional) Em seguida, escolha uma configuração de segurança para ativar a criptografia em repouso para logs.
- Linhas de exemplo: escolha somente uma porcentagem específica de linhas da tabela para gerar estatísticas. O padrão é todas as linhas. Use as setas para cima e para baixo para aumentar ou diminuir o valor percentual.

> **Note**
>
> Recomendamos incluir todas as linhas na tabela para calcular estatísticas precisas. Use as linhas de exemplo para gerar estatísticas de coluna somente quando valores aproximados forem aceitáveis.

Escolha Gerar estatísticas para executar a tarefa.

AWS CLI

Esse comando acionará a execução de uma tarefa de estatísticas de coluna para a tabela especificada. Você precisa fornecer o nome do banco de dados, o nome da tabela, uma IAM função com permissões para gerar estatísticas e, opcionalmente, fornecer os nomes das colunas e uma porcentagem do tamanho da amostra para o cálculo das estatísticas.

```
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
```

Esse comando iniciará uma tarefa para gerar estatísticas de coluna para a tabela especificada.

Atualizando estatísticas de colunas sob demanda

Manter as estatísticas das up-to-date colunas é crucial para que o otimizador de consultas gere planos de execução eficientes, garantindo melhor desempenho da consulta, menor consumo de recursos e melhor desempenho geral do sistema. Esse processo é particularmente importante após alterações significativas nos dados, como cargas em massa ou modificações extensivas, que podem tornar obsoletas as estatísticas existentes.

Você precisa executar explicitamente a tarefa Gerar estatísticas no AWS Glue console para atualizar as estatísticas da coluna. O Catálogo de Dados não atualiza as estatísticas automaticamente.

Se você não estiver usando o recurso AWS Glue de geração de estatísticas do console, poderá atualizar manualmente as estatísticas da coluna usando a UpdateColumnStatisticsForTableAPIoperação ou AWS CLI. O exemplo a seguir mostra como excluir estatísticas de colunas usando a 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
                }
            }
        }
    ]
}
```

Visualizar estatísticas de colunas

Depois de gerar as estatísticas com sucesso, o Data Catalog armazena essas informações para que os otimizadores baseados em custos do Amazon Amazon Athena Redshift façam as melhores escolhas ao executar consultas. As estatísticas variam de acordo com o tipo de coluna.

AWS Management Console

Para visualizar estatísticas de colunas para uma tabela

- Após a execução da tarefa de estatísticas da coluna, a guia Estatísticas da coluna na página Detalhes da tabela mostra as estatísticas da tabela.

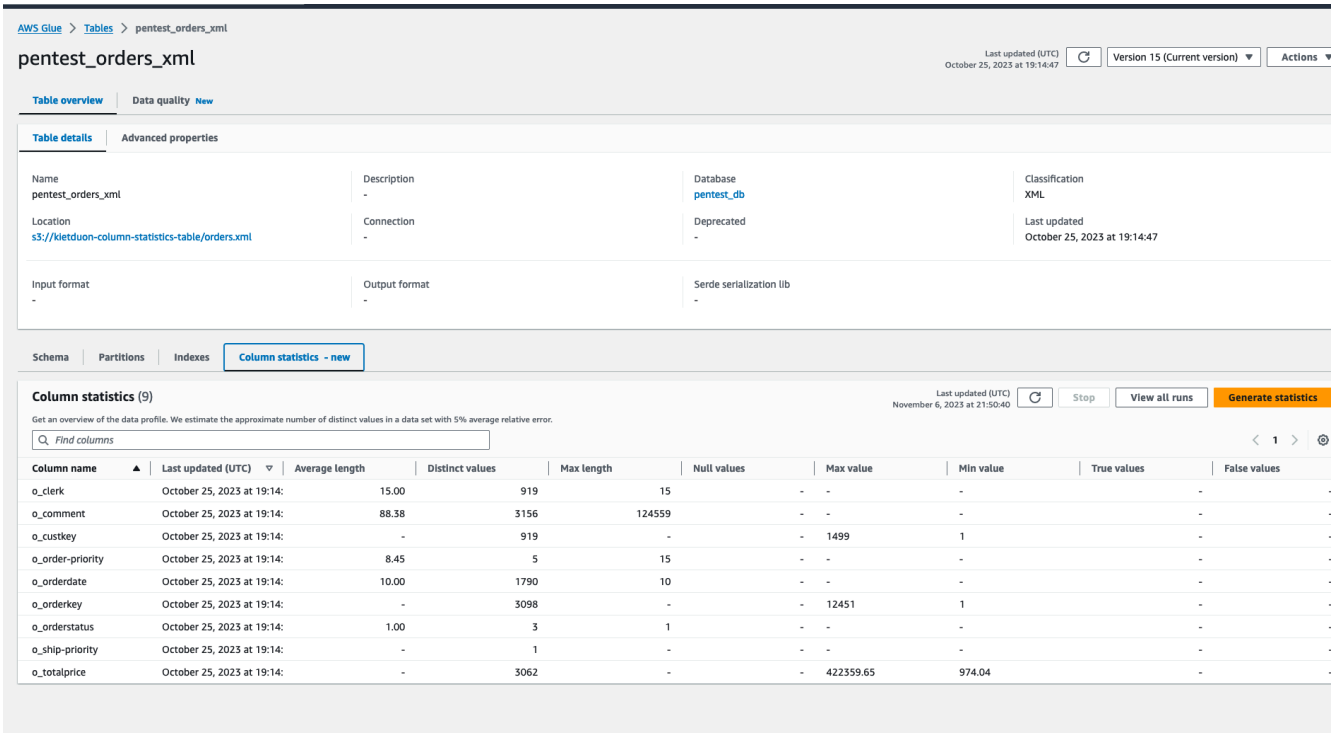

As seguintes estatísticas estão disponíveis:

- Nome da coluna: o nome da coluna usada para gerar as estatísticas
- Última atualização: a data e a hora em que as estatísticas foram geradas
- Comprimento médio: o comprimento médio dos valores na coluna
- Valores distintos: o número total de valores distintos na coluna. Estimamos o número de valores distintos em uma coluna com erro relativo de 5%.
- Valor máximo: o maior valor na coluna.
- Valor mínimo: o menor valor na coluna.
- Comprimento máximo: o comprimento do valor mais alto na coluna.
- Valores nulos: o número de valores nulos na coluna.
- Valores verdadeiros: o número de valores verdadeiros na coluna.
- Valores falsos: o número de valores falsos na coluna.
- numFiles: o número total de arquivos na tabela. Esse valor está disponível na guia Propriedades avançadas.

AWS CLI

O exemplo a seguir mostra como recuperar estatísticas de colunas usando a AWS CLI.

```
aws glue get-column-statistics-for-table \
    --database-name database_name \
    --table-name table_name \
    --column-names <column_name>
```

Você também pode visualizar as estatísticas da coluna usando a GetColumnStatisticsForTableAPIoperação.

Visualizar as execuções de tarefas de estatísticas de colunas

Depois de executar uma tarefa de estatísticas de coluna, você pode explorar os detalhes de execução de uma tabela usando o AWS Glue console AWS CLI ou usando a GetColumnStatisticsTaskRunsoperação.

Console

Para visualizar detalhes da execução da tarefa de estatísticas da coluna

1. No AWS Glue console, escolha Tabelas em Catálogo de dados.
2. Selecione uma tabela com estatísticas de colunas.
3. Na página Detalhes da tabela, escolha Estatísticas da coluna.
4. Escolha Visualizar execuções.

   É possível ver informações sobre todas as execuções associadas à tabela especificada.

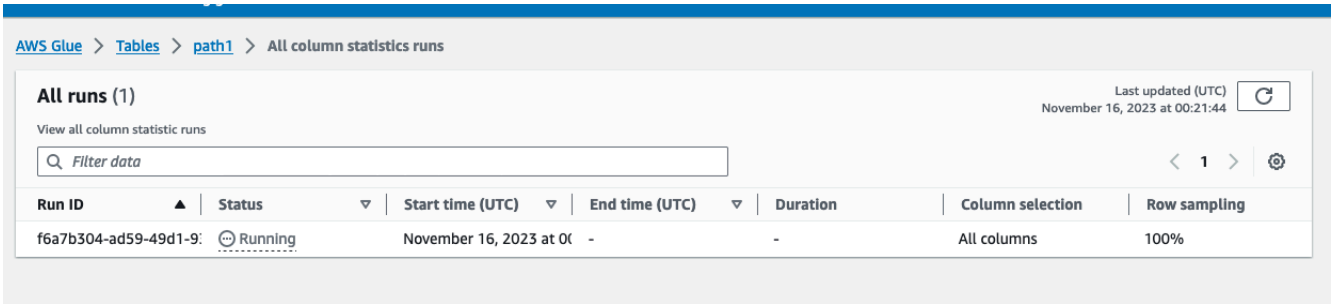

AWS CLI

No exemplo a seguir, substitua os valores de `DatabaseName` e `TableName` pelos nomes reais do banco de dados e da tabela.

```
aws glue get-column-statistics-task-runs --input-cli-json file://input.json
```

```
{
    "DatabaseName": "database_name",
    "TableName": "table_name"
}
```

Interromper a execução da tarefa de estatísticas de coluna

Você pode interromper a execução de uma tarefa de estatísticas de coluna para uma tabela usando o AWS Glue console AWS CLI ou usando StopColumnStatisticsTaskRuna operação.

Console

Para interromper a execução de uma tarefa de estatísticas de coluna

1. No AWS Glue console, escolha Tabelas em Catálogo de dados.
2. Selecione a tabela com a execução da tarefa de estatísticas da coluna em andamento.
3. Na página Detalhes da tabela, escolha Estatísticas da coluna.
4. Escolha Parar.

   Se você interromper a tarefa antes que a execução seja concluída, as estatísticas da coluna não serão geradas para a tabela.

AWS CLI

No exemplo a seguir, substitua os valores de `DatabaseName` e `TableName` pelos nomes reais do banco de dados e da tabela.

```
aws glue stop-column-statistics-task-run --input-cli-json file://input.json
{
    "DatabaseName": "database_name",
    "TableName": "table_name"
}
```

Excluir estatísticas de colunas

Você pode excluir as estatísticas da coluna usando a DeleteColumnStatisticsForTableAPIoperação ou AWS CLI. O exemplo a seguir mostra como excluir estatísticas de colunas usando 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'
```

Considerações e limitações

As considerações e limitações a seguir se aplicam à geração de estatísticas de colunas.

Considerações

- Usar amostragem para gerar estatísticas reduz o tempo de execução, mas pode gerar estatísticas imprecisas.
- O Catálogo de Dados não armazena versões diferentes das estatísticas.
- Só é possível executar uma tarefa de geração de estatísticas de cada vez por tabela.
- Se uma tabela for criptografada usando a AWS KMS chave do cliente registrada no Catálogo de Dados, AWS Glue usa a mesma chave para criptografar as estatísticas.

A tarefa de estatísticas de colunas oferece suporte à geração de estatísticas:

- Quando a IAM função tem permissões completas de tabela (IAMou Lake Formation).
- Quando a IAM função tem permissões na tabela usando o modo de acesso híbrido Lake Formation.

A tarefa de estatísticas de colunas não oferece suporte à geração de estatísticas para:

- Tabelas com controle de acesso baseado em células Lake Formation
- Lagos de dados transacionais - fundação Linux Delta Lake, Apache Hudi
- Tabelas em bancos de dados federados: metastore do Hive, compartilhamentos de dados do Amazon Redshift

- Colunas aninhadas, matrizes e tipos de dados struct.
- Tabela que é compartilhada com você de outra conta

Como criptografar seu Data Catalog

Você pode proteger seus metadados armazenados no AWS Glue Data Catalog em repouso usando chaves de criptografia gerenciadas pelo AWS Key Management Service (AWS KMS). É possível habilitar a criptografia do Catálogo de Dados para o novo Catálogo de Dados usando as Configurações do Catálogo de Dados. Você pode habilitar ou desabilitar a criptografia para o Catálogo de Dados existente conforme necessário. Quando habilitada, o AWS Glue criptografa todos os novos metadados gravados no catálogo, enquanto os metadados existentes permanecem sem criptografia.

Para obter informações detalhadas sobre como criptografar seu Catálogo de Dados, consulte Como criptografar seu Data Catalog.

Proteger seu catálogo de dados usando o Lake Formation

O AWS Lake Formation é um serviço que facilita configurar um data lake seguro na AWS. Ele fornece um local central para criar e gerenciar com segurança seus data lakes com a definição de permissões de controle de acesso refinadas. O Lake Formation usa o Catálogo de Dados para armazenar e recuperar metadados sobre seu data lake, como definições de tabelas, informações de esquema e configurações de controle de acesso a dados.

Você pode registrar a localização da tabela de metadados ou do banco de dados no Amazon S3 com o Lake Formation e usá-la para definir permissões em nível de metadados nos recursos do Catálogo de Dados. Também é possível usar o Lake Formation para gerenciar permissões de acesso ao armazenamento nos dados subjacentes armazenados no Amazon S3 em nome de mecanismos analíticos integrados.

Para obter mais informações, consulte O que é o AWS Lake Formation?.

Trabalho com as visualizações do AWS Glue Data Catalog no AWS Glue

É possível criar e gerenciar as visualizações no AWS Glue Data Catalog, comumente conhecidas como visualizações do AWS Glue Data Catalog. Essas visualizações são úteis por serem compatíveis com diversos mecanismos de consulta SQL, permitindo o acesso à mesma visualização por diferentes serviços da AWS, como o Amazon Athena, o Amazon Redshift e o AWS Glue. É possível usar visualizações baseadas em Apache Iceberg, Apache Hudi e Delta Lake.

Ao criar uma visualização no Catálogo de Dados, você pode usar concessões de recursos e controles de acesso baseados em etiquetas no AWS Lake Formation para conceder acesso à visualização. Com esse método de controle de acesso, não é necessário configurar permissões de acesso adicionais para as tabelas referenciadas na criação da visualização. Esse método de concessão de permissões é chamado de semântica definidora, e essas exibições são chamadas de vizualizações definidoras. Para obter mais informações sobre controle de acesso no AWS Lake Formation, consulte a página Granting and revoking permissions on Data Catalog resources no Guia do desenvolvedor do AWS Lake Formation.

As vizualizações do Data Catalog são úteis para os seguintes casos de uso:

- Controle de acesso granular: é possível criar uma visualização que restringe o acesso aos dados com base nas permissões necessárias ao usuário. Por exemplo, você pode usar visualizações no Catálogo de Dados para impedir que colaboradores externos ao departamento de Recursos Humanos acessem informações de identificação pessoal (PII).
- Definição completa da visualização: ao aplicar filtros em sua visualização no Catálogo de Dados, você garante que os registros de dados disponíveis estejam sempre completos.
- Segurança aprimorada: a obrigatoriedade de uma definição de consulta completa durante a criação da visualização contribui para reduzir a suscetibilidade das visualizações do Catálogo de Dados a comandos SQL de agentes mal-intencionados.
- Compartilhamento de dados simplificado: compartilhe dados com outras contas da AWS sem a necessidade de movimentação dos dados, usando o compartilhamento de dados entre contas no AWS Lake Formation.

Criação de uma visualização do Catálogo de Dados

Você pode criar visualizações do Catálogo de Dados usando a AWS CLI ou scripts de ETL do AWS Glue desenvolvidos com Spark SQL. A criação de visualizações do Catálogo de Dados segue uma sintaxe que inclui a especificação do tipo de visualização como `MULTI DIALECT` e do predicado `SECURITY` como `DEFINER`, o que configura uma visualização do tipo “definer”.

Exemplo de instrução SQL para a criação de uma visualização do Catálogo de Dados:

```
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;
```

Após criar uma visualização do Catálogo de Dados, é possível usar um perfil do IAM com a permissão “SELECT” do AWS Lake Formation sobre a visualização para consultá-la, usando serviços como o Amazon Athena, o Amazon Redshift ou trabalhos de ETL do AWS Glue. Não é necessário conceder acesso às tabelas subjacentes referenciadas na visualização.

Para obter mais informações sobre a criação e a configuração de visualizações do Catálogo de Dados, consulte a página Building AWS Glue Data Catalog views no Guia do desenvolvedor do AWS Lake Formation.

Operações compatíveis para visualizações

Os fragmentos de comandos apresentados a seguir mostram como é possível trabalhar com as visualizações do Catálogo de Dados de diferentes formas:

CREATE VIEW

Cria uma visualização do Catálogo de Dados. A seguir, um exemplo que demonstra a criação da visualização usando uma tabela existente:

```
CREATE PROTECTED MULTI DIALECT VIEW catalog_view
SECURITY DEFINER AS SELECT * FROM my_catalog.my_database.source_table
```

ALTER VIEW

Sintaxe disponível:

```
ALTER VIEW view_name [FORCE] ADD DIALECT AS query
ALTER VIEW view_name [FORCE] UPDATE DIALECT AS query
ALTER VIEW view_name DROP DIALECT
```

É possível usar a opção `FORCE ADD DIALECT` para aplicar a atualização do esquema e dos objetos secundários de acordo com o novo dialeto do mecanismo. Lembre-se de que essa ação pode resultar em erros de consulta, caso a opção `FORCE` não seja usada para atualizar os demais dialetos do mecanismo. A seguir, um exemplo que demonstra a aplicação:

```
ALTER VIEW catalog_view FORCE ADD DIALECTAS
SELECT order_date, sum(totalprice) AS priceFROM source_tableGROUP BY orderdate;
```

A seguir, um exemplo que demonstra a alteração de uma visualização para a atualização do dialeto:

```
ALTER VIEW catalog_view UPDATE DIALECT AS
SELECT count(*) FROM my_catalog.my_database.source_table;
```

DESCRIBE VIEW

Sintaxe disponível para descrever uma visualização:

`SHOW COLUMNS {FROM|IN} view_name [{FROM|IN} database_name]`: se o usuário tiver as permissões necessárias no AWS Glue e no AWS Lake Formation para descrever a visualização, será possível listar as colunas. A seguir, alguns exemplos de comandos que demonstram como visualizar colunas:

```
SHOW COLUMNS FROM my_database.source_table;
SHOW COLUMNS IN my_database.source_table;
```

`DESCRIBE view_name`: se o usuário tiver as permissões necessárias no AWS Glue e no AWS Lake Formation para descrever a visualização, será possível listar as colunas na visualização, incluindo os respectivos metadados.

DROP VIEW

Sintaxe disponível:

```
DROP VIEW [ IF EXISTS ] view_name
```

A seguir, um exemplo de instrução DROP que demonstra como realizar um teste para verificar a existência da visualização antes de sua remoção:

```
DROP VIEW IF EXISTS catalog_view;
```

`SHOW CREATE VIEW view_name`: mostra a instrução SQL responsável pela criação da visualização especificada. A seguir, um exemplo que demonstra o processo de criação de uma visualização no Catálogo de Dados:

```
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_lf WHERE customer_id IN (SELECT customer_id from
 source_table limit 10)
```

SHOW VIEWS

Lista todas as visualizações existentes no catálogo, incluindo as visualizações regulares, as visualizações com múltiplos dialetos (MDV, na sigla em inglês) e as MDVs sem suporte ao dialeto Spark. A sintaxe disponível é a seguinte:

```
SHOW VIEWS [{ FROM | IN } database_name] [LIKE regex_pattern]:
```

A seguir, um exemplo que demonstra um comando para mostrar as visualizações:

```
SHOW VIEWS IN marketing_analytics LIKE 'catalog_view*';
```

Para obter mais informações sobre a criação e a configuração de visualizações do Catálogo de Dados, consulte a página Building AWS Glue Data Catalog views no Guia do desenvolvedor do AWS Lake Formation.

Consulta de uma visualização do Catálogo de Dados

Após criar uma visualização do Catálogo de Dados, é possível consultá-la normalmente. O perfil do IAM configurado em seus trabalhos do AWS Glue deve ter a permissão SELECT do Lake Formation na visualização do Catálogo de Dados. Não é necessário conceder acesso às tabelas subjacentes referenciadas na visualização.

Depois de configurar tudo, você pode consultar sua exibição. Por exemplo, você pode executar a consulta apresentada a seguir para acessar uma visualização.

```
SELECT * from my_database.catalog_view LIMIT 10;
```

Limitações

Considere as limitações a seguir ao usar as vizualizações do Data Catalog.

- É possível criar visualizações do Catálogo de Dados apenas com a versão 5.0 ou superior do AWS Glue.
- O responsável pela definição da visualização do Catálogo de Dados deve ter permissão de acesso `SELECT` nas tabelas de base subjacentes acessadas pela visualização. A operação de criação da visualização do Catálogo de Dados não será bem-sucedida caso uma das tabelas de base tenha filtros do Lake Formation atribuídos ao perfil “definer”.
- As tabelas de base devem estar configuradas sem a permissão `IAMAllowedPrincipals` no data lake do AWS Lake Formation. Se presente, o erro Visualizações de vários dialetos só podem fazer referência a tabelas sem permissões de IAMAllowedPrincipals permissions ocorrerá.
- A localização da tabela no Amazon S3 deve estar registrada como um local de data lake no AWS Lake Formation. Caso a tabela não esteja registrada, será gerado o erro: `Multi Dialect views may only reference AWS Lake Formation managed tables`. Para obter informações sobre como registrar localizações do Amazon S3 no AWS Lake Formation, consulte Registering an Amazon S3 location no Guia do desenvolvedor do AWS Lake Formation.
- Você só pode criar vizualizações `PROTECTED` do Data Catalog. Não há suporte para exibições `UNPROTECTED`.
- Você não pode referenciar tabelas de outra conta da AWS na definição de uma visualização do Catálogo de Dados. Além disso, não é possível referenciar uma tabela da mesma conta que esteja em uma região diferente.
- Para compartilhar dados entre contas ou regiões, a visualização inteira deve ser compartilhada entre contas e entre regiões, usando links de recurso do AWS Lake Formation.
- As funções definidas pelo usuário (UDFs) não são compatíveis.
- Não é possível fazer referência a outras vizualizações nas exibições do Data Catalog.

Acessar o Catálogo de Dados

É possível usar o AWS Glue Data Catalog (Catálogo de Dados) para descobrir e entender seus dados. O Catálogo de Dados fornece uma maneira consistente de manter definições de esquema, tipos de dados, localizações e outros metadados. É possível acessar o Catálogo de Dados usando qualquer um dos seguintes métodos:

- Console do AWS Glue: é possível acessar e gerenciar o Catálogo de Dados via console do AWS Glue, uma interface do usuário baseada na Web. O console permite que você navegue por e pesquise bancos de dados, tabelas e seus metadados associados, além de criar, atualizar e excluir definições de metadados.

- Crawler do AWS Glue: os crawlers são programas que examinam automaticamente suas fontes de dados e preenchem o Catálogo de Dados com metadados. É possível criar e executar crawlers para descobrir e catalogar dados de várias fontes, como Amazon S3, Amazon RDS, Amazon DynamoDB, Amazon CloudWatch e bancos de dados relacionais compatíveis com JDBC, como MySQL e PostgreSQL, além de várias fontes não relacionadas à AWS, como Snowflake e Google BigQuery.
- APIs do AWS Glue: é possível acessar o catálogo de dados programaticamente usando as APIs do AWS Glue. Essas APIs permitem que você interaja com o Catálogo de Dados de forma programática, possibilitando a automação e a integração com outros serviços e aplicações.
- AWS Command Line Interface (AWS CLI): é possível usar a AWS CLI para acessar e gerenciar o Catálogo de Dados a partir da linha de comando. A CLI fornece comandos para criar, atualizar e excluir definições de metadados, bem como consultar e recuperar informações de metadados.
- Integração com outros serviços da AWS: o Catálogo de Dados se integra a vários outros serviços da AWS, permitindo que você acesse e utilize os metadados armazenados no catálogo. Por exemplo, é possível usar o Amazon Athena para consultar fontes de dados usando os metadados no catálogo de dados e usar o AWS Lake Formation para gerenciar o acesso aos dados e a governança dos recursos do Catálogo de Dados.

Tópicos

- Conectar ao Catálogo de Dados usando o endpoint REST do Iceberg do AWS Glue
- Conectar ao Catálogo de Dados usando o endpoint da extensão REST do Iceberg do AWS Glue
- APIs REST do AWS Glue para especificações do Apache Iceberg
- Conectar ao Catálogo de Dados via aplicação Spark autônoma
- Mapeamento de dados entre o Amazon Redshift e o Amazon Iceberg
- Considerações e limitações ao usar APIs do catálogo REST do Iceberg do AWS Glue

Conectar ao Catálogo de Dados usando o endpoint REST do Iceberg do AWS Glue

O endpoint REST do Iceberg do AWS Glue oferece suporte a operações de API definidas na especificação REST do Apache Iceberg. Usando um cliente REST do Iceberg, é possível conectar sua aplicação em execução em um mecanismo de análise ao catálogo REST hospedado no Catálogo de Dados.

O endpoint oferece suporte às especificações v1 e v2 das tabelas do Apache Iceberg, sendo v2 a padrão. Ao usar a especificação v1 das tabelas do Iceberg, será necessário especificar v1 na chamada da API. Usando a operação da API, você é possível acessar tabelas do Iceberg residentes no armazenamento de objetos do Amazon S3 e no armazenamento de tabelas do Amazon S3.

Configuração do endpoint

É possível acessar o catálogo REST do AWS Glue Iceberg usando o endpoint do serviço. Consulte o Guia de referência dos endpoints de serviço do AWS Glue para o endpoint específico da região. Por exemplo, ao se conectar ao AWS Glue na região us-east-1, você precisará configurar a propriedade URI do endpoint da seguinte forma:

```
Endpoint : https://glue.us-east-1.amazonaws.com/iceberg
```

Propriedades de configuração adicionais: ao usar o cliente do Iceberg para conectar um mecanismo de análise como o Spark ao endpoint de serviço, é necessário especificar as seguintes propriedades de configuração da aplicação:

```
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.IcebergSparkSessionExtensi
 \
    .getOrCreate()
```

O endpoint do Iceberg `https://glue.us-east-1.amazonaws.com/iceberg` do AWS Glue é compatível com as seguintes APIs REST do Iceberg:

- GetConfig
- ListNamespaces
- CreateNamespace
- LoadNamespaceMetadata
- UpdateNamespaceProperties
- DeleteNamespace
- ListTables
- CreateTable
- LoadTable
- TableExists
- UpdateTable
- DeleteTable

Parâmetros de prefixo e caminho do catálogo

As APIs do catálogo REST do Iceberg têm um prefixo de formato livre em seus URLs de solicitação. Por exemplo, a chamada de API `ListNamespaces` usa o formato de URL `GET/v1/{prefix}/namespaces`. O prefixo AWS Glue sempre segue a estrutura `/catalogs/{catalog}` para garantir que o caminho REST alinhe a hierarquia de múltiplos catálogos do AWS Glue. O parâmetro de caminho `{catalog}` pode ser derivado com base nas seguintes regras:

Padrão de acesso	Estilo de ID do catálogo do Glue	Estilo de prefixo	Exemplo de ID de catálogo padrão	Exemplo de rota REST
Acesar o catálogo padrão na conta atual	não obrigatório	:	não aplicável	GET /v1/catalogs/:/namespaces
Acessar o catálogo padrão em uma conta específica	accountID	accountID	111122223333	GET /v1/catalogs/111122223333/namespaces

Padrão de acesso	Estilo de ID do catálogo do Glue	Estilo de prefixo	Exemplo de ID de catálogo padrão	Exemplo de rota REST
Acesar um catálogo aninhado na conta atual	catalog1/catalog2	catalog1/catalog2	rmscatalog1:db1	GET /v1/catalogs/rmscatalog1:db1/namespaces
Acessar um catálogo aninhado em uma conta específica	accountId:catalog1/catalog2	accountId:catalog1/catalog2	123456789012/rmscatalog1:db1	GET /v1/catalogs/123456789012:rmscatalog1:db1/namespaces

Esse mapeamento de ID de catálogo em prefixo é necessário somente quando você chama diretamente as APIs REST. Ao trabalhar com as APIs do catálogo REST do Iceberg do AWS Glue por meio de um mecanismo, é necessário especificar o ID do catálogo do AWS Glue no parâmetro `warehouse` da configuração da API do catálogo REST do Iceberg ou no parâmetro `glue.id` da configuração da API de extensões do AWS Glue. Por exemplo, veja como você pode usá-lo com o EMR Spark em Usar um cluster do Iceberg com o Spark.

Parâmetro do caminho do namespace

Os namespaces no caminho das APIs do catálogo REST do Iceberg podem ter vários níveis. No entanto, o AWS Glue só oferece suporte a namespaces de nível único. Para acessar um namespace em uma hierarquia de catálogos de vários níveis, é possível se conectar a um catálogo de vários níveis acima do namespace para fazer referência ao namespace. Isso permite que qualquer mecanismo de consulta que suporte a notação em três partes de `catalog.namespace.table` acesse objetos na hierarquia de catálogos de vários níveis do AWS Glue sem problemas de compatibilidade em comparação com o uso do namespace de vários níveis.

Conectar ao Catálogo de Dados usando o endpoint da extensão REST do Iceberg do AWS Glue

O endpoint da extensão REST do Iceberg do AWS Glue fornece APIs adicionais que não estão presentes na especificação REST do Apache Iceberg, além de recursos de planejamento verificação

no lado do servidor. Essas APIs adicionais são usadas quando você acessa tabelas residentes no armazenamento gerenciado do Amazon Redshift. O endpoint pode ser acessado a partir de uma aplicação por meio de extensões do AWS Glue Data Catalog para Apache Iceberg.

Configuração do endpoint: um catálogo com tabelas no armazenamento gerenciado do Redshift é acessível usando o endpoint de serviço. Consulte o Guia de referência dos endpoints de serviço do AWS Glue para o endpoint específico da região. Por exemplo, ao se conectar ao AWS Glue na região us-east-1, você precisará configurar a propriedade URI do endpoint da seguinte forma:

```
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.IcebergSparkSessionExtensi
 \
    .getOrCreate()
```

APIs REST do AWS Glue para especificações do Apache Iceberg

Esta seção contém especificações sobre o catálogo REST do AWS Glue para Iceberg e as APIs de extensão do AWS Glue, além de considerações sobre o uso dessas APIs.

As solicitações de API aos endpoints do AWS Glue Data Catalog são autenticadas por meio do AWS Signature Version 4 (SigV4). Consulte a seção AWS Signature Version 4 para solicitações de API para saber mais sobre o AWS SigV4.

Ao acessar o endpoint de serviço do AWS Glue e os metadados do AWS Glue, a aplicação assume um perfil do IAM que exige uma ação `glue:getCatalog` do IAM.

O acesso ao Catálogo de Dados e seus objetos pode ser gerenciado usando permissões do IAM, Lake Formation ou modo híbrido do Lake Formation.

Os catálogos federados no Catálogo de Dados têm locais de dados registrados no Lake Formation. O Lake Formation trabalha com o Catálogo de Dados para fornecer permissões no estilo de banco de dados para gerenciar o acesso de usuários a objetos do Catálogo de Dados.

É possível usar as permissões do IAM, do AWS Lake Formation ou do modo híbrido do Lake Formation para gerenciar o acesso ao Catálogo de Dados padrão e seus objetos.

Para criar, inserir ou excluir dados em objetos gerenciados do Lake Formation, é necessário configurar permissões específicas para o usuário ou perfil do IAM.

- CREATE_CATALOG: necessária para criar catálogos
- CREATE_DATABASE: necessária para criar bancos de dados
- CREATE_TABLE: necessária para criar tabelas
- DELETE: necessária para excluir dados de uma tabela
- DESCRIBE: necessária para ler metadados
- DROP: necessária para descartar/excluir uma tabela ou banco de dados
- INSERT: necessária quando a entidade principal precisa inserir dados em uma tabela
- SELECT: necessária quando a entidade principal precisa selecionar dados de uma tabela

Para obter mais informações, consulte Referência de permissões do Lake Formation no Guia do desenvolvedor do AWS Lake Formation.

GetConfig

Informações gerais

Nome da operação	GetConfig
Tipo	API do catálogo REST do Iceberg
Caminho REST	GET /iceberg/v1/config
Ação do IAM	glue:GetCatalog
Permissões do Lake Formation	Não aplicável
Evento do CloudTrail	glue:GetCatalog

Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L67

Considerações e limitações

- O parâmetro da consulta `warehouse` deve ser definido como o ID do catálogo do AWS Glue. Caso não tenha sido definido, o catálogo raiz na conta atual será usado para retornar a resposta. Para ter mais informações, consulte the section called “Parâmetros de prefixo e caminho do catálogo”.

GetCatalog

Informações gerais

Nome da operação	GetCatalog
Tipo	API de extensão do AWS Glue
Caminho REST	GET/extensions/v1/catalogs/{catalog}
Ação do IAM	glue:GetCatalog
Permissões do Lake Formation	DESCRIBE
Evento do CloudTrail	glue:GetCatalog
Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L40

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.

ListNamespaces

Informações gerais

Nome da operação	ListNamespaces
Tipo	API do catálogo REST do Iceberg
Caminho REST	GET/iceberg/v1/catalogs/{catalog}/namespaces
Ação do IAM	glue:GetDatabase
Permissões do Lake Formation	ALL, DESCRIBE, SELECT
Evento do CloudTrail	glue:GetDatabase
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L205

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".
- Somente os namespaces do próximo nível são exibidos. Para listar namespaces em níveis mais profundos, especifique o ID do catálogo aninhado no parâmetro do caminho do catálogo.

CreateNamespace

Informações gerais

Nome da operação	CreateNamespace
Tipo	API do catálogo REST do Iceberg
Caminho REST	POST/iceberg/v1/catalogs/{catalog}/namespaces
Ação do IAM	glue:CreateDatabase
Permissões do Lake Formation	ALL, DESCRIBE, SELECT

Evento do CloudTrail	glue:CreateDatabase
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L256

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".
- Somente um namespace de nível único pode ser criado. Para criar um namespace de vários níveis, é necessário criar iterativamente cada nível e se conectarao nível usando o parâmetro de caminho do catálogo.

StartCreateNamespaceTransaction

Informações gerais

Nome da operação	StartCreateNamespaceTransaction
Tipo	API de extensões do AWS Glue
Caminho REST	POST/extensions/v1/catalogs/{catalog}/namespaces
Ação do IAM	glue:CreateDatabase
Permissões do Lake Formation	ALL, DESCRIBE, SELECT
Evento do CloudTrail	glue:CreateDatabase
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L256

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".

- É possível criar somente um namespace de nível único. Para criar namespaces de vários níveis, é necessário criar cada nível de forma iterativa e conectar-se ao nível usando o parâmetro de caminho do catálogo.
- A API é assíncrona e retorna um ID de transação que você pode usar para rastreamento usando a chamada de API `CheckTransactionStatus`.
- Você poderá chamar essa API somente se a chamada de API `GetCatalog` contiver o parâmetro `use-extensions=true` na resposta.

LoadNamespaceMetadata

Informações gerais

Nome da operação	LoadNamespaceMetadata
Tipo	API do catálogo REST do Iceberg
Caminho REST	GET/iceberg/v1/catalogs/{catalog}/namespaces/{ns}
Ação do IAM	glue:GetDatabase
Permissões do Lake Formation	ALL, DESCRIBE, SELECT
Evento do CloudTrail	glue:GetDatabase
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L302

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.

UpdateNamespaceProperties

Informações gerais

Nome da operação	UpdateNamespaceProperties
Tipo	API do catálogo REST do Iceberg
Caminho REST	POST /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/properties
Ação do IAM	glue:UpdateDatabase
Permissões do Lake Formation	ALL, ALTER
Evento do CloudTrail	glue:UpdateDatabase
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L400

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.

DeleteNamespace

Informações gerais

Nome da operação	DeleteNamespace
Tipo	API do catálogo REST do Iceberg
Caminho REST	DELETE/iceberg/v1/catalogs/{catalog}/namespces/{ns}
Ação do IAM	glue:DeleteDatabase

Permissões do Lake Formation	ALL, DROP
Evento do CloudTrail	glue:DeleteDatabase
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L365

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called "Parâmetro do caminho do namespace".
- Se houver objetos no banco de dados, a operação falhará.
- A API é assíncrona e retorna um ID de transação que você pode usar para rastreamento usando a chamada de API `CheckTransactionStatus`.
- A API só poderá ser usada se a chamada de API `GetCatalog` indicar `use-extensions=true` na resposta.

StartDeleteNamespaceTransaction

Informações gerais

Nome da operação	StartDeleteNamespaceTransaction
Tipo	API de extensões do AWS Glue
Caminho REST	DELETE /extensions/v1/catalogs/{catalog}/namespces/{ns}
Ação do IAM	glue:DeleteDatabase
Permissões do Lake Formation	ALL, DROP
Evento do CloudTrail	glue:DeleteDatabase

Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L85

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- Se houver objetos no banco de dados, a operação falhará.
- A API é assíncrona e retorna um ID de transação que você pode usar para rastreamento usando a chamada de API `CheckTransactionStatus`.
- A API só poderá ser usada se a chamada de API `GetCatalog` indicar `use-extensions=true` na resposta.

ListTables

Informações gerais

Nome da operação	ListTables
Tipo	API do catálogo REST do Iceberg
Caminho REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables
Ação do IAM	glue:GetTables
Permissões do Lake Formation	ALL, SELECT, DESCRIBE
Evento do CloudTrail	glue:GetTables
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L463

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- Todas as tabelas, incluindo tabelas não Iceberg, serão listadas. Para determinar se uma tabela pode ser carregada como uma tabela Iceberg ou não, chame a operação `LoadTable`.

CreateTable

Informações gerais

Nome da operação	CreateTable
Tipo	API do catálogo REST do Iceberg
Caminho REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables
Ação do IAM	glue:CreateTable
Permissões do Lake Formation	ALL, CREATE_TABLE
Evento do CloudTrail	glue:CreateTable
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L497

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.

- Não há suporte a `CreateTable` com preparação. Se o parâmetro de consulta `stageCreate` for especificado, a operação falhará. Isso significa que operações como `CREATE TABLE AS SELECT` não são permitidas, e você poderá usar uma combinação de `CREATE TABLE` e `INSERT INTO` como alternativa.
- A operação `CreateTable` da API não oferece suporte à opção `state-create = TRUE`.

StartCreateTableTransaction

Informações gerais

Nome da operação	CreateTable
Tipo	API de extensões do AWS Glue
Caminho REST	POST/extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables
Ação do IAM	glue:CreateTable
Permissões do Lake Formation	ALL, CREATE_TABLE
Evento do CloudTrail	glue:CreateTable
Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L107

Considerações e limitações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- Não há suporte a `CreateTable` com preparação. Se o parâmetro de consulta `stageCreate` for especificado, a operação falhará. Isso significa que não há suporte a operações como `CREATE TABLE AS SELECT`, e o usuário deve usar uma combinação de `CREATE TABLE` e `INSERT INTO` como solução alternativa.

- A API é assíncrona e retorna um ID de transação que você pode usar para rastreamento usando a chamada de API `CheckTransactionStatus`.
- A API só poderá ser usada se a chamada de API `GetCatalog` indicar `use-extensions=true` na resposta.

LoadTable

Informações gerais

Nome da operação	LoadTable
Tipo	API do catálogo REST do Iceberg
Caminho REST	GET /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Ação do IAM	glue:GeTTable
Permissões do Lake Formation	ALL, SELECT, DESCRIBE
Evento do CloudTrail	glue:GetTable
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L616

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- Não há suporte a `CreateTable` com preparação. Se o parâmetro de consulta `stageCreate` for especificado, a operação falhará. Isso significa que não há suporte a operações como `CREATE TABLE AS SELECT`, e o usuário deve usar uma combinação de `CREATE TABLE` e `INSERT INTO` como solução alternativa.
- A API é assíncrona e retorna um ID de transação que você pode usar para rastreamento usando a chamada de API `CheckTransactionStatus`.

- A API só poderá ser usada se a chamada de API `GetCatalog` indicar `use-extensions=true` na resposta.

ExtendedLoadTable

Informações gerais

Nome de operação	LoadTable
Tipo	API de extensões do AWS Glue
Caminho REST	GET /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Ação do IAM	glue:GetTable
Permissões do Lake Formation	ALL, SELECT, DESCRIBE
evento do CloudTrail	glue:GetTable
Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L134

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- Somente o modo `all` é suportado para o parâmetro de consulta de snapshots.
- Em comparação com a API `LoadTable`, a API `ExtendedLoadTable` difere das seguintes formas:
  - Não impõe estritamente que todos os campos estejam disponíveis.
  - Fornece os seguintes parâmetros adicionais no campo de configuração da resposta:

Parâmetros adicionais

Chave de configuração	Descrição
aws.server-side-capabilities.scan-planning	Indica se a tabela pode ser verificada com as APIs PreparePlan e PlanTable.
aws.server-side-capabilities.data-commit	Indica se a tabela pode ser confirmada com a transação StartUpdateTable.
aws.glue.staging.location	Usado para planejamento de verificação no lado do servidor ou confirmação de dados, um local de preparação gerenciado pelo serviço que pode ser usado para o mecanismo gravar arquivos de dados temporários
aws.glue.staging.access-key-id	Usado para planejamento da verificação no lado do servidor ou confirmação de dados, uma parte das credenciais temporárias da AWS para acessar o local de preparação gerenciado pelo serviço
aws.glue.staging.secret-access-key	Usado para planejamento de escaneamento do lado do servidor ou confirmação de dados, uma parte das AWS credenciais temporárias para acessar o local de preparação gerenciado pelo serviço.
aws.glue.staging.session-token	Usado para planejamento de escaneamento do lado do servidor ou confirmação de dados, uma parte das AWS credenciais temporárias para acessar o local de preparação gerenciado pelo serviço.
aws.glue.staging.expiration-ms	Usado para planejamento da verificação no lado do servidor ou confirmação de dados, tempo de expiração das credenciais de acesso ao local de preparação gerenciado pelo serviço.

Chave de configuração	Descrição
aws.glue.staging.data-transfer-role-arn	Usado para planejamento da verificação no lado do servidor ou confirmação de dados, um perfil do IAM que pode ser assumido para acessar o local de preparação gerenciado pelo serviço.

PreplanTable

Informações gerais

Nome de operação	PreplanTable
Tipo	API de extensões do AWS Glue
Caminho REST	POST /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}/preplan
Ação do IAM	glue:GetTable
Permissões do Lake Formation	ALL, SELECT, DESCRIBE
evento do CloudTrail	glue:GetTable
Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L211

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- O chamador dessa API deve sempre determinar se ainda há resultados a serem buscados com base no token da página. Uma resposta com um item de página vazio, mas um token de paginação, será possível se o lado do servidor ainda estiver processando, mas não for capaz de produzir nenhum resultado no tempo de resposta determinado.

- Você poderá usar essa API somente se a resposta da API `ExtendedLoadTable` contiver `aws.server-side-capabilities.scan-planning=true`.

PlanTable

Informações gerais

Nome de operação	PlanTable
Tipo	API de extensões do AWS Glue
Caminho REST	POST /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}/plan
Ação do IAM	glue:GetTable
Permissões do Lake Formation	ALL, SELECT, DESCRIBE
evento do CloudTrail	glue:GetTable
Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L243

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- O chamador dessa API deve sempre determinar se ainda há resultados a serem buscados com base no token da página. Uma resposta com um item de página vazio, mas um token de paginação, será possível se o lado do servidor ainda estiver processando, mas não for capaz de produzir nenhum resultado no tempo de resposta determinado.
- Você poderá usar essa API somente se a resposta da API `ExtendedLoadTable` contiver `aws.server-side-capabilities.scan-planning=true`.

TableExists

Informações gerais

Nome de operação	TableExists
Tipo	API do catálogo REST do Iceberg
Caminho REST	HEAD/iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Ação do IAM	glue:GetTable
Permissões do Lake Formation	ALL, SELECT, DESCRIBE
evento do CloudTrail	glue:GetTable
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L833

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.

UpdateTable

Informações gerais

Nome de operação	UpdateTable
Tipo	API do catálogo REST do Iceberg
Caminho REST	POST /iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Ação do IAM	glue:UpdateTable

Permissões do Lake Formation	ALL, ALTER
evento do CloudTrail	glue:UpdateTable
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L677

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called "Parâmetro do caminho do namespace".

StartUpdateTableTransaction

Informações gerais

Nome de operação	StartUpdateTableTransaction
Tipo	API de extensão do AWS Glue
Caminho REST	POST/extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Ação do IAM	glue:UpdateTable
Permissões do Lake Formation	ALL, ALTER
evento do CloudTrail	glue:UpdateTable
Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L154

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called “Parâmetros de prefixo e caminho do catálogo”.
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called “Parâmetro do caminho do namespace”.
- A API é assíncrona e retorna um ID de transação que você pode usar para rastreamento usando a chamada de API `CheckTransactionStatus`.
- Uma operação `RenamTable` também pode ser executada por meio dessa API. Quando isso acontece, o chamador também deve ter a permissão glue:CreateTable ou CREATE_TABLE do LakeFormation para que a tabela seja renomeada.
- Você poderá usar essa API somente se a resposta da API `ExtendedLoadTable` contiver `aws.server-side-capabilities.scan-planning=true`.

DeleteTable

Informações gerais

Nome de operação	DeleteTable
Tipo	API do catálogo REST do Iceberg
Caminho REST	DELETE/iceberg/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Ação do IAM	glue:DeleteTable
Permissões do Lake Formation	ALL, DROP
evento do CloudTrail	glue:DeleteTable
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L793

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called "Parâmetro do caminho do namespace".
- A operação da API `DeleteTable` oferece suporte a uma opção de expurgo. Quando a limpeza é definida como `true`, os dados da tabela são excluídos, caso contrário, os dados não são excluídos. Para tabelas no Amazon S3, a operação não exclui dados da tabela. A operação falha quando a tabela está armazenada no Amazon S3 e `purge = TRUE,`.

  Para tabelas que estão no armazenamento gerenciado do Amazon Redshift, a operação excluirá os dados da tabela, semelhante ao comportamento de `DROP TABLE` no Amazon Redshift. A operação falha quando a tabela está armazenada no Amazon Redshift e `purge = FALSE`.
- Não há suporte ao `purgeRequest=true`.

StartDeleteTableTransaction

Informações gerais

Nome de operação	StartDeleteTableTransaction
Tipo	API de extensões do AWS Glue
Caminho REST	DELETE /extensions/v1/catalogs/{catalog}/namespaces/{ns}/tables/{table}
Ação do IAM	glue:DeleteTable
Permissões do Lake Formation	ALL, DROP
evento do CloudTrail	glue:DeleteTable
Definição da Open API	https://github.com/apache/iceberg/blob/apache-iceberg-1.6.1/open-api/rest-catalog-open-api.yaml#L793

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".
- É possível especificar somente um namespace de nível único no parâmetro REST Path. Para obter mais informações, consulte a seção the section called "Parâmetro do caminho do namespace".
- Não há suporte ao `purgeRequest=false`.
- A API é assíncrona e retorna um ID de transação que pode ser rastreado via `CheckTransactionStatus`.

CheckTransactionStatus

Informações gerais

Nome de operação	CheckTransactionStatus
Tipo	API de extensões do AWS Glue
Caminho REST	POST/extensions/v1/transactions/status
Ação do IAM	A mesma permissão da ação que inicia a transação
Permissões do Lake Formation	A mesma permissão da ação que inicia a transação
Definição da Open API	https://github.com/awslabs/glue-extensions-for-iceberg/blob/main/glue-extensions-api.yaml#L273

Considerações

- O parâmetro do caminho do catálogo deve seguir o estilo descrito na seção the section called "Parâmetros de prefixo e caminho do catálogo".

Conectar ao Catálogo de Dados via aplicação Spark autônoma

É possível se conectar ao Catálogo de Dados por meio de uma aplicação autônoma usando um conector do Apache Iceberg.

1. Crie um perfil do IAM para a aplicação Spark.
2. Conecte-se ao endpoint REST do Iceberg do AWS Glue usando o conector do 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.SimpleAWSCredentialPr
```

3. Consulte os dados no Catálogo de Dados.

```
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()
```

Mapeamento de dados entre o Amazon Redshift e o Amazon Iceberg

O Redshift e o Iceberg oferecem suporte a vários tipos de dados. A matriz de compatibilidade a seguir descreve o suporte e as limitações ao mapear dados entre esses dois sistemas de dados. Consulte os Tipos de dados do Amazon Redshift e as Especificações de tabelas do Apache Iceberg para obter mais detalhes sobre os tipos de dados compatíveis nos respectivos sistemas de dados.

Tipo de dados do Redshift	Aliases	Tipo de dados do Iceberg
SMALLINT	INT2	int
INTEGER	INT, INT4	int
BIGINT	INT8	longo
DECIMAL	NUMERIC	decimal
REAL	FLOAT4	flutuação
REAL	FLOAT4	flutuação
DOUBLE PRECISION	FLOAT8, FLOAT	double
CHAR	CHARACTER, NCHAR	string
VARCHAR	CHARACTER VARYING, NVARCHAR	string
BPCHAR		string
TEXT		string
DATE		date
TIME	TIME WITHOUT TIMEZONE	horário
TIME	TIME WITH TIMEZONE	sem suporte
TIMESTAMP	TIMESTAMP WITHOUT TIMEZONE	TIMESTAMP

Tipo de dados do Redshift	Aliases	Tipo de dados do Iceberg
TIMESTAMPZ	TIMESTAMP WITH TIMEZONE	TIMESTAMPZ
INTERVALO ENTRE UM ANO E UM MÊS		Sem compatibilidade
INTERVALO ENTRE UM DIA E UM SEGUNDO		Sem compatibilidade
BOOLEAN	BOOL	bool
HLLSKETCH		Sem compatibilidade
SUPER		Sem compatibilidade
VARBYTE	VARBINARY, BINARY VARYING	binary
GEOMETRY		Sem compatibilidade
GEOGRAPHY		Sem compatibilidade

Considerações e limitações ao usar APIs do catálogo REST do Iceberg do AWS Glue

A seguir estão as considerações e limitações aplicáveis usar o comportamento de operação da linguagem de definição de dados (DDL) do Catálogo de Dados REST do Apache Iceberg.

Considerações

- Comportamento da API **`RenameTable`**: a operação `RenameTable` é válida em tabelas no Amazon Redshift, mas não no Amazon S3.
- Operações de DDL para namespaces e tabelas no Amazon Redshift: as operações de criação, atualização e exclusão de namespaces e tabelas no Amazon Redshift são operações assíncronas porque dependem de quando o grupo de trabalho gerenciado do Amazon Redshift está disponível e se uma transação conflitante de DDL e DML está em andamento e a operação precisa aguardar o bloqueio e, em seguida, tentar confirmar as alterações.

Limitações

- As APIs de visualização na especificação REST do Apache Iceberg não são aceitas no catálogo REST do Iceberg do AWS Glue.

Práticas recomendadas do Catálogo de Dados do AWS Glue

Esta seção aborda práticas recomendadas para gerenciar e utilizar com eficácia o AWS Glue Data Catalog. Ele enfatiza práticas como uso eficiente de crawlers, organização de metadados, segurança, otimização de performance, automação, governança de dados e integração com outros serviços da AWS.

- Use rastreadores de forma eficaz: execute crawlers regularmente para manter o Catálogo de Dados atualizado com as alterações em suas fontes de dados. Use crawls incrementais para alterar frequentemente as fontes de dados para melhorar a performance. Configure crawlers para adicionar automaticamente novas partições ou atualizar esquemas quando alterações forem detectadas.
- Organize e nomeie tabelas de metadados: estabeleça uma convenção de nomenclatura consistente para bancos de dados e tabelas no Catálogo de Dados. Agrupe fontes de dados relacionadas em bancos de dados ou pastas lógicas para alcançar uma melhor organização. Use nomes descritivos que transmitam a finalidade e o conteúdo de cada tabela.
- Gerencie esquemas de forma eficaz: utilize os recursos de inferência de esquemas dos crawlers do AWS Glue. Revise e atualize alterações no do esquema antes de aplicá-las para evitar a interrupção de aplicações mais à frente. Use os recursos de evolução de esquema para lidar suavemente com alterações no esquema.
- Proteja o Catálogo de Dados: habilite a criptografia de dados em repouso e em trânsito para o Catálogo de Dados. Implemente políticas de controle de acesso refinadas para restringir o acesso a dados confidenciais. Audite e analise regularmente as permissões e os logs de atividades do Catálogo de Dados.
- Integre com outros serviços da AWS Use o Catálogo de Dados como uma camada centralizada de metadados para serviços como Amazon Athena, Redshift Spectrum e AWS Lake Formation. Aproveite os trabalhos do AWS Glue ETL para transformar e carregar dados em vários armazenamentos de dados enquanto mantém os metadados no Catálogo de Dados.
- Monitore e otimize a performance O Catálogo de dados monitora a performance de crawlers e trabalhos de ETL usando métricas do Amazon CloudWatch. Particione grandes conjuntos de

dados no Catálogo de Dados para melhorar a performance das consultas. Implemente otimizações de performance para metadados acessados com frequência.

- Mantenha-se em dia com a documentação e as práticas recomendadas do AWS Glue O Catálogo de dados verifica regularmente a documentação do AWS Glue e os recursos do AWS Glue em busca de atualizações, práticas recomendadas e recomendações mais recentes. Participe de webinars, workshops e outros eventos do AWS Glue para aprender com especialistas e se manter em dia com novos recursos e capacidades.

Monitorar métricas de uso do Catálogo de Dados do Amazon CloudWatch

As métricas de uso do AWS Glue Data Catalog já estão disponíveis no Amazon CloudWatch, simplificando o monitoramento e a compreensão da utilização de recursos em seu Catálogo de Dados. Agora, você tem visibilidade imediata do uso de catálogos, bancos de dados, tabelas, partições e conexões pela API do Glue Catalog, facilitando a supervisão do seu Catálogo de Dados.

Visão geral das métricas do Catálogo de Dados

O AWS Glue Data Catalog publica automaticamente as métricas de uso no Amazon CloudWatch. Com a integração das métricas do CloudWatch, você pode acompanhar indicadores críticos de desempenho a cada minuto, incluindo:

- Solicitações de tabela
- Índices de partição criados
- Atualizações de conexão
- Atualizações de estatísticas

Essas métricas ajudam você a identificar gargalos, detectar anomalias e tomar decisões baseadas em dados para melhorar a confiabilidade geral do Catálogo de Dados. Você também pode configurar os alarmes do CloudWatch para receber notificações quando as métricas excederem os limites especificados, permitindo o gerenciamento proativo da implantação.

Adicionar métricas ao seu painel do CloudWatch

Você pode criar painéis personalizados para monitorar seus recursos do AWS Glue Data Catalog e configurar alarmes para ser notificado sobre qualquer atividade incomum.

Você pode adicionar métricas do Catálogo de Dados ao seu painel do CloudWatch seguindo estas etapas:

1. Abra o console do CloudWatch em https://console.aws.amazon.com/cloudwatch/.
2. No painel de navegação, selecione Métricas.
3. Escolha Todas as métricas.
4. Escolha Uso > Por recurso do AWS.
5. Filtre por Glue para ver as métricas disponíveis.
6. Selecione as métricas que deseja adicionar ao painel.
7. Adicione métricas de catálogos, bancos de dados, tabelas, partições e conexões ao seu gráfico do CloudWatch.

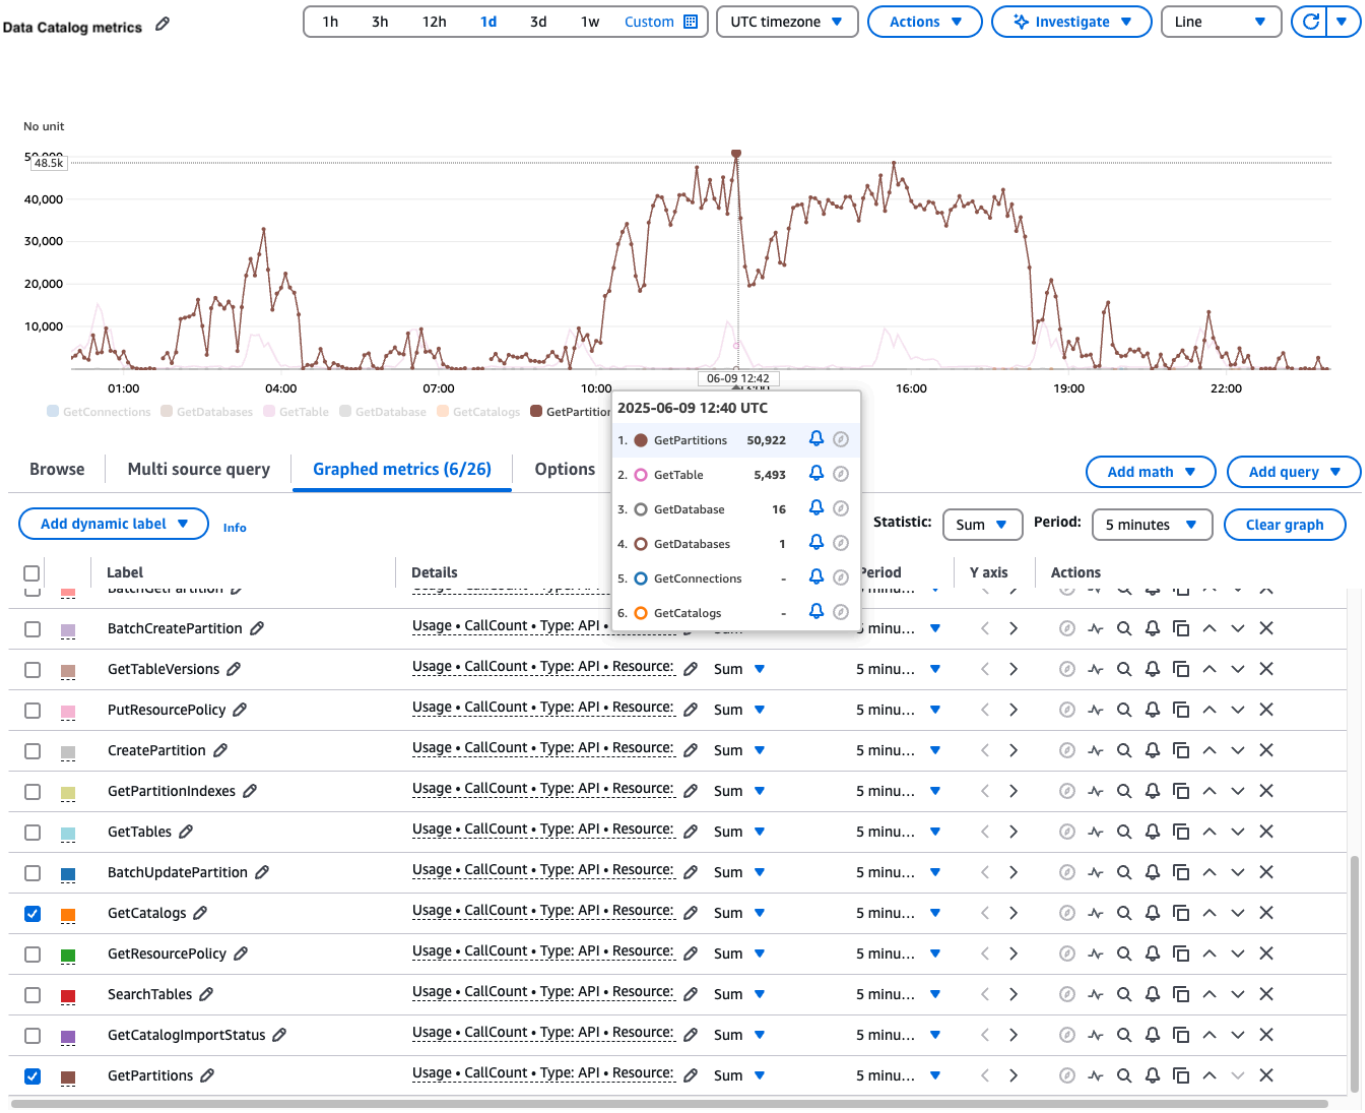

Você pode configurar alarmes personalizados que são acionados automaticamente quando o uso da API excede os limites definidos por você a fim de identificar anormalidades no uso do seu catálogo de dados.

Para obter instruções detalhadas sobre como definir alarmes, consulte Criação de um alarme do CloudWatch com o Metrics Insights.

Registro de esquemas do AWS Glue

> **Note**
>
> O registro de esquemas do AWS Glue não é compatível com o console do AWS Glue nas seguintes regiões: Ásia-Pacífico (Jacarta), Europa (Zurique) e Oriente Médio (EAU).

Com o registro de esquemas do AWS Glue, você pode descobrir, controlar e evoluir centralmente esquemas de fluxo de dados. O esquema define a estrutura e o formato de um registro de dados. Com o registro de esquemas do AWS Glue, você pode gerenciar e aplicar esquemas em suas aplicações de fluxo de dados usando integrações convenientes com o Apache Kafka, Amazon Managed Streaming for Apache Kafka, Amazon Kinesis Data Streams, Amazon Managed Service for Apache Flink e AWS Lambda.

O Schema Registry é compatível com o formato de dados AVRO (v1.11.4), o formato de dados JSON com formato JSON Schema para o esquema (especificações Draft-04, Draft-06 e Draft-07) com validação do esquema JSON usando a biblioteca do Everit, Protocol Buffers (Protobuf) versões proto2 e proto3 não compatíveis com `extensions` e `groups`, e compatíveis com a linguagem Java, e outros formatos de dados e linguagens a serem incluídos em breve. Os recursos com suporte incluem compatibilidade, fornecimento de esquema via metadados, registro automático de esquemas, compatibilidade com o IAM e compactação ZLIB opcional para reduzir o armazenamento e a transferência de dados. O registro de esquemas do O registro de esquemas é uma solução sem servidor e de uso gratuito.

O uso de um esquema como um contrato de formato de dados entre produtores e consumidores leva a uma melhor governança e maior qualidade dos dados, e ainda permite que os consumidores de dados sejam resilientes a alterações upstream compatíveis.

O registro de esquemas permite que sistemas diferentes compartilhem um esquema para serialização e desserialização. Por exemplo, suponha que você tenha um produtor e consumidor de

dados. O produtor conhece o esquema quando publica os dados. O registro de esquemas fornece um serializador e desserializador para determinados sistemas, como Amazon MSK ou Apache Kafka.

Para ter mais informações, consulte Como o registro de esquemas funciona.

Tópicos

- Esquemas
- Registros
- Versionamento e compatibilidade de esquema
- Bibliotecas Serde de código aberto
- Cotas do registro do esquemas
- Como o registro de esquemas funciona
- Conceitos básicos do registro de esquemas
- Integração com o registro de esquemas do AWS Glue
- Migração de um registro de esquemas de terceiros para o registro de esquemas do AWS Glue

Esquemas

O esquema define a estrutura e o formato de um registro de dados. Um esquema é uma especificação versionada para publicação, consumo ou datastore confiáveis.

Neste esquema de exemplo para Avro, o formato e a estrutura são definidos pelo layout e nomes de campo, e o formato dos nomes de campo é definido pelos tipos de dados (por exemplo,`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"
                    }
                ]
            }
        }
    ]
}
```

Neste exemplo de esquema JSON Draft-07 para JSON, o formato é definido pela organização do esquema 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
  }
 }
```

```
}
```

Neste exemplo para Protobuf, o formato é definido pela versão 2 da linguagem 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;
}
```

Registros

Um registro é um contêiner lógico de esquemas. Os registros permitem que você organize seus esquemas, bem como gerencie o controle de acesso para suas aplicações. Um registro tem um nome do recurso da Amazon (ARN) para permitir que você organize e defina diferentes permissões de acesso para operações de esquema dentro do registro.

Você pode usar o registro padrão ou criar quantos novos registros forem necessários.

Hierarquia do registro de esquemas do AWS Glue

- RegistryName: [string]
  - RegistryArn: [ARN da AWS]
  - CreatedTime: [carimbo de data e hora]
  - UpdatedTime: [carimbo de data e hora]
- SchemaName: [string]
  - SchemaArn: [ARN da AWS]
  - DataFormat: [Avro, Json ou Protobuf]
  - Compatibility: [ex.: BACKWARD, BACKWARD_ALL, FORWARD, FORWARD_ALL, FULL, FULL_ALL, NONE, DISABLED]
  - Status: [ex.: PENDING, AVAILABLE, DELETING]
  - SchemaCheckpoint: [inteiro]
  - CreatedTime: [carimbo de data e hora]
  - UpdatedTime: [carimbo de data e hora]
- SchemaVersion: [string]
  - SchemaVersionNumber: [inteiro]
  - Status: [ex.: PENDING, AVAILABLE, DELETING, FAILURE]
  - SchemaDefinition: [string, Valor: JSON]
  - CreatedTime: [carimbo de data e hora]
- SchemaVersionMetadata: [lista]
  - MetadataKey: [string]
  - MetadataInfo
  - MetadaValue: [string]
  - CreatedTime: [carimbo de data e hora]

Versionamento e compatibilidade de esquema

Cada esquema pode ter várias versões. O versionamento é regido por uma regra de compatibilidade aplicada em um esquema. As solicitações para registrar novas versões do esquema são verificadas quanto a essa regra pelo registro de esquemas antes de serem bem-sucedidas.

Uma versão de esquema que está marcada como um ponto de verificação é usada para determinar a compatibilidade em registrar novas versões de um esquema. Quando um esquema é criado pela primeira vez, o ponto de verificação padrão é a primeira versão. À medida que o esquema evolui com mais versões, você pode usar a CLI/SDK para alterar o ponto de verificação para uma versão de um esquema usando a API `UpdateSchema` que adere a um conjunto de restrições. No console, editar a definição do esquema ou o modo de compatibilidade alterará o ponto de verificação para a versão mais recente por padrão.

Os modos de compatibilidade permitem controlar como os esquemas podem ou não evoluir ao longo do tempo. Esses modos formam o contrato entre aplicações que produzem e consomem dados. Quando uma nova versão de um esquema é enviada para o registro, a regra de compatibilidade aplicada ao nome do esquema é usada para determinar se a nova versão pode ser aceita. Existem oito modos de compatibilidade: NONE (Nenhum), DISABLED (Desabilitado), BACKWARD (Anterior), BACKWARD_ALL (Todas as anteriores), FORWARD (Próxima), FORWARD_ALL (Todas as próximas), FULL (Completo), FULL_ALL (Completo total).

No formato de dados Avro, os campos podem ser opcionais ou obrigatórios. Um campo opcional é aquele em que o `Type` inclui nulo. Campos obrigatórios não possuem nulo como o `Type`.

No formato de dados Protobuf, os campos podem ser opcionais (inclusive repetidos) ou obrigatórios na sintaxe proto2, enquanto todos os campos são opcionais (inclusive repetidos) na sintaxe proto3. Todas as regras de compatibilidade são determinadas com base no entendimento das especificações de Protocol Buffers, bem como na orientação da Documentação do Google Protocol Buffers.

- NONE (Nenhum): nenhum modo de compatibilidade se aplica. Você pode usar essa opção em cenários de desenvolvimento ou se não souber os modos de compatibilidade que deseja aplicar aos esquemas. Qualquer nova versão adicionada será aceita sem ser submetida a uma verificação de compatibilidade.
- DISABLED (Desabilitado): essa opção de compatibilidade impede o versionamento de um esquema específico. Nenhuma nova versão pode ser adicionada.

- BACKWARD (Anterior): essa opção de compatibilidade é recomendada, pois permite que os consumidores de dados leiam a versão atual e anterior do esquema. Você pode usar essa opção para verificar a compatibilidade com a versão anterior do esquema ao excluir campos ou adicionar campos opcionais. Um caso de uso típico para BACKWARD (Anterior) é quando sua aplicação é criada para o esquema mais recente.

  AVRO

  Por exemplo, suponha que você tenha um esquema definido pelo nome (obrigatório), sobrenome (obrigatório), e-mail (obrigatório) e número de telefone (opcional).

  Se a próxima versão do esquema removesse o campo de e-mail obrigatório, isso seria registrado com êxito. A compatibilidade BACKWARD (Anterior) requer que os consumidores sejam capazes de ler a versão atual e anterior do esquema. Seus consumidores poderão ler o novo esquema, pois o campo de e-mail extra de mensagens antigas será ignorado.

  Se você tivesse uma nova versão de esquema proposta que adicionasse um campo obrigatório, por exemplo, CEP, isso não seria registrado com êxito com a compatibilidade BACKWARD (Anterior). Seus consumidores na nova versão não conseguiriam ler mensagens antigas antes da alteração do esquema, pois elas não teriam o campo CEP necessário. No entanto, se o campo CEP fosse definido como opcional no novo esquema, a versão proposta seria registrada com sucesso, pois os consumidores poderiam ler o esquema antigo sem o campo de CEP opcional.

  JSON

  Por exemplo, suponha que você tenha uma versão do esquema definida pelo nome (opcional), sobrenome (opcional), e-mail (opcional) e número de telefone (opcional).

  Se a próxima versão do esquema adicionasse a propriedade de número de telefone opcional, isso seria registrado com êxito, desde que a versão do esquema original não permitisse nenhuma propriedade adicional definindo o campo `additionalProperties` como false. A compatibilidade BACKWARD (Anterior) requer que os consumidores sejam capazes de ler a versão atual e anterior do esquema. Seus consumidores poderão ler dados produzidos com o esquema original onde a propriedade de número de telefone não existe.

  Se você tiver uma nova versão de esquema proposta que adiciona a propriedade de número de telefone opcional, isso não é registrado com êxito com a compatibilidade BACKWARD (Anterior) quando a versão original do esquema define o campo `additionalProperties` como true, ou seja, permitindo qualquer propriedade adicional. Seus consumidores na nova versão não

conseguiriam ler mensagens antigas antes da alteração do esquema, pois não podem ler dados com a propriedade número de telefone em um tipo diferente, por exemplo string em vez de número.

PROTOBUF

Por exemplo, suponha que você tenha uma versão do esquema definida por uma Mensagem `Person` com campos `first name` (obrigatório), `last name` (obrigatório), `email` (obrigatório) e `phone number` (opcional) sob sintaxe proto2.

Semelhante a cenários AVRO, se a próxima versão do esquema removesse o campo de `email` obrigatório, isso seria registrado com êxito. A compatibilidade BACKWARD (Anterior) requer que os consumidores sejam capazes de ler a versão atual e anterior do esquema. Seus consumidores poderão ler o novo esquema, pois o campo de `email` extra de mensagens antigas será ignorado.

Se você tivesse uma nova versão de esquema proposta que adicionasse um campo obrigatório, por exemplo, `zip code`, isso não seria registrado com êxito com a compatibilidade BACKWARD (Anterior). Seus consumidores na nova versão não conseguiriam ler mensagens antigas antes da alteração do esquema, pois elas não teriam o campo `zip code` necessário. No entanto, se o campo `zip code` fosse definido como opcional no novo esquema, a versão proposta seria registrada com sucesso, pois os consumidores poderiam ler o esquema antigo sem o campo de `zip code` opcional.

No caso de um caso de uso gRPC, adicionar novo serviço RPC ou método RPC é uma alteração compatível com versões anteriores. Por exemplo, suponha que você tenha uma versão do esquema definida por um serviço RPC `MyService` com dois métodos RPC `Foo` e `Bar`.

Se a próxima versão do esquema adicionar um novo método RPC chamado `Baz`, isso seria registrado com sucesso. Seus consumidores poderão ler dados produzidos com o esquema original de acordo com a compatibilidade BACKWARD pois o método RPC recém-adicionado `Baz` é opcional.

Se você tivesse uma nova versão de esquema proposta que removesse o método PRC existente `Foo`, isso não seria registrado com êxito com a compatibilidade BACKWARD. Seus consumidores na nova versão não conseguiriam ler mensagens antigas antes da alteração do esquema, pois não conseguem entender e ler dados com o método RPC `Foo` inexistente em uma aplicação gRPC.

- BACKWARD_ALL (Todas as anteriores): essa opção de compatibilidade é recomendada, pois permite que os consumidores de dados leiam a versão atual e todas as anteriores do esquema.

Você pode usar essa opção para verificar a compatibilidade com todas as versões anteriores do esquema ao excluir campos ou adicionar campos opcionais.

- FORWARD (Próxima): essa opção de compatibilidade permite que os receptores de dados leiam a versão atual e as versões subsequentes do esquema, mas não necessariamente versões mais recentes. Você pode usar essa opção para verificar a compatibilidade com a última versão do esquema ao adicionar campos ou excluir campos opcionais. Um caso de uso típico para FORWARD (Próxima) é quando sua aplicação é criada para um esquema anterior e deve ser capaz de processar um esquema mais recente.

  AVRO

  Por exemplo, suponha que você tenha uma versão do esquema definida pelo nome (obrigatório), sobrenome (obrigatório) e e-mail (opcional).

  Se você tivesse uma nova versão do esquema que adicionasse um campo obrigatório, por exemplo, número de telefone, isso seria registrado com sucesso. A compatibilidade FORWARD (Próxima) requer que os consumidores sejam capazes de ler dados produzidos com o novo esquema usando ainda a versão anterior.

  Se você tivesse uma nova versão de esquema proposta que excluísse o campo de nome obrigatório, isso não seria registrado com êxito com a compatibilidade FORWARD (Posterior). Seus consumidores na versão anterior não seriam capazes de ler os esquemas propostos, pois eles não teriam o campo de nome obrigatório. No entanto, se o campo de nome fosse originalmente opcional, então o novo esquema proposto seria registrado com sucesso, pois os consumidores poderiam ler dados com base no novo esquema que não tem o campo de nome opcional.

  JSON

  Por exemplo, suponha que você tenha uma versão do esquema definida pelo nome (opcional), sobrenome (opcional), e-mail (opcional) e número de telefone (opcional).

  Se a próxima versão do esquema removesse a propriedade de número de telefone opcional, isso seria registrado com êxito, desde que a versão do esquema original não permitisse nenhuma propriedade adicional definindo o campo `additionalProperties` como false. A compatibilidade FORWARD (Próxima) requer que os consumidores sejam capazes de ler dados produzidos com o novo esquema usando ainda a versão anterior.

Se você tiver uma versão de esquema proposta que exclui a propriedade número de telefone opcional, isso não é registrado com êxito com a compatibilidade FORWARD (Próxima) quando a nova versão do esquema define o campo `additionalProperties` como true, ou seja, permitindo qualquer propriedade adicional. Seus consumidores na versão anterior não conseguiriam ler mensagens antigas antes da alteração do esquema, pois não poderiam ler dados com a propriedade número de telefone em um tipo diferente, por exemplo string em vez de número.

PROTOBUF

Por exemplo, suponha que você tenha uma versão do esquema definida por uma Mensagem `Person` com campos `first name` (obrigatório), `last name` (obrigatório) e `email` (opcional) sob sintaxe proto2.

Semelhante a cenários AVRO, se você tivesse uma nova versão do esquema que adicionasse um campo obrigatório, por exemplo, `phone number`, isso seria registrado com sucesso. A compatibilidade FORWARD (Próxima) requer que os consumidores sejam capazes de ler dados produzidos com o novo esquema usando ainda a versão anterior.

Se você tivesse uma nova versão de esquema proposta que excluísse o campo de `first name`, isso não seria registrado com êxito com a compatibilidade FORWARD. Seus consumidores na versão anterior não seriam capazes de ler os esquemas propostos, pois eles não teriam o campo de `first name` obrigatório. No entanto, se o campo de `first name` fosse originalmente opcional, então o novo esquema proposto seria registrado com sucesso, pois os consumidores poderiam ler dados com base no novo esquema que não tem o campo de `first name` opcional.

No caso de um caso de uso gRPC, remover um serviço RPC ou método RPC é uma alteração compatível com o encaminhamento. Por exemplo, suponha que você tenha uma versão do esquema definida por um serviço RPC `MyService` com dois métodos RPC `Foo` e `Bar`.

Se a próxima versão do esquema excluir o método RPC existente chamado `Foo`, isso seria registrado com sucesso de acordo com a compatibilidade FORWARD, pois os consumidores podem ler dados produzidos com o novo esquema usando a versão anterior. Se você tivesse uma nova versão de esquema proposta que adicionasse o método RPC `Baz`, isso não seria registrado com êxito com a compatibilidade FORWARD. Seus consumidores na versão anterior não seriam capazes de ler os esquemas propostos, pois eles não teriam o método RPC `Baz` ausente.

- FORWARD_ALL (Todas as próximas): essa opção de compatibilidade permite que os consumidores leiam dados escritos por produtores de qualquer novo esquema registrado. Você

pode usar essa opção quando precisar adicionar campos ou excluir campos opcionais e verificar a compatibilidade com todas as versões anteriores do esquema.

- FULL (Completo): essa opção de compatibilidade permite que os consumidores leiam dados gravados por produtores usando a versão anterior ou seguinte do esquema, mas não versões anteriores ou posteriores. Você pode usar essa opção para verificar a compatibilidade com a última versão do esquema ao adicionar ou remover campos opcionais.
- FULL_ALL (Completo total): essa opção de compatibilidade permite que os receptores de dados leiam dados gravados por produtores usando todas as versões de esquema anteriores. Você pode usar essa opção para verificar a compatibilidade com todas as versões anteriores do esquema ao adicionar ou remover campos opcionais.

Bibliotecas Serde de código aberto

A AWS fornece bibliotecas Serde de código aberto como um framework para serialização e desserialização de dados. O design de código aberto dessas bibliotecas permite que aplicações e frameworks comuns de código aberto ofereçam suporte a elas em seus projetos.

Para obter mais detalhes sobre como as bibliotecas Serde funcionam, consulte Como o registro de esquemas funciona.

Cotas do registro do esquemas

As cotas, também conhecidas como limites na AWS, são os valores máximos para recursos, ações e itens na sua conta da AWS. A seguir estão os limites flexíveis para o registro de esquemas no AWS Glue.

Pares de chave-valor de metadados de versão de esquema

Você pode ter até dez pares de chave-valor por SchemaVersion por região da AWS.

Você pode visualizar ou definir os pares de metadados de chave-valor usando o Ação QuerySchemaVersionMetadata (Python: query_schema_version_metadata) ou APIs do Ação PutSchemaVersionMetadata (Python: put_schema_version_metadata).

A seguir estão os limites rígidos para o registro de esquemas no AWS Glue.

Registros

É possível ter até 100 registros por região da AWS para esta conta.

SchemaVersion

É possível ter até 10.000 versões de esquema por região da AWS para esta conta.

Cada novo esquema cria uma nova versão do esquema, portanto você poderá, teoricamente, ter até 10.000 esquemas por conta por região, se cada esquema tiver apenas uma versão.

Cargas úteis de esquema

Há um limite de tamanho de 170 KB para cargas úteis de esquema.

Como o registro de esquemas funciona

Esta seção descreve como os processos de serialização e desserialização no registro de esquemas funcionam.

1. Registrar um esquema: se o esquema ainda não existir no registro, ele pode ser registrado com um nome de esquema igual ao nome do destino (por exemplo, test_topic, test_stream, prod_firehose) ou o produtor pode fornecer um nome personalizado para ele. Os produtores também podem adicionar pares de chave-valor ao esquema como metadados, como a fonte: msk_kafka_topic_a ou aplicar tags da AWS para esquemas na criação do esquema. Depois que um esquema é registrado, o registro de esquemas retorna o ID da versão do esquema para o serializador. Se o esquema existir, mas o serializador estiver usando uma nova versão que não existe, o registro de esquemas verificará a referência do esquema a uma regra de compatibilidade, para garantir que a nova versão seja compatível antes de registrá-la como uma nova versão.

   Existem dois métodos de registro de um esquema: manual e automático. Você pode registrar um esquema manualmente por meio do console do AWS Glue ou CLI/SDK.

   Quando o registro automático é ativado nas configurações do serializador, o registro automático do esquema é realizado. Se `REGISTRY_NAME` não for fornecido nas configurações do produtor, o registro automático registrará a nova versão do esquema no registro padrão (default-registry). Consulte Instalar as bibliotecas SerDe para obter informações sobre como especificar a propriedade de registro automático.
2. O serializador valida registros de dados em relação ao esquema: quando a aplicação que produz os dados registra seu esquema, o serializador do registro de esquemas valida que o registro sendo produzido pela aplicação é estruturado com os campos e os tipos de dados correspondentes a um esquema registrado. Se o esquema do registro não corresponder a um

esquema registrado, o serializador retornará uma exceção e a aplicação falhará em entregar o registro ao destino.

Se nenhum esquema existir e o nome do esquema não for fornecido por meio das configurações do produtor, o esquema será criado com o mesmo nome que o nome do tópico (se Apache Kafka ou Amazon MSK) ou nome da transmissão (se Kinesis Data Streams).

Cada registro tem uma definição de esquema e dados. A definição de esquema é consultada em relação aos esquemas e versões existentes no registro de esquemas.

Por padrão, os produtores armazenam em cache as definições de esquema e IDs de versão de esquemas dos esquemas registrados. Se a definição da versão do esquema de um registro não corresponder ao que está disponível no cache, o produtor tentará validar o esquema com o registro de esquemas. Se a versão do esquema for válida, seu ID de versão e definição serão armazenados em cache localmente no produtor.

Você pode ajustar o período de cache padrão (24 horas) dentro das propriedades opcionais do produtor na etapa n.º 3 de Instalar as bibliotecas SerDe.

3. Serializar e entregar registros: se o registro estiver em conformidade com o esquema, o serializador decorará cada registro com o ID da versão do esquema, serializará o registro com base no formato de dados selecionado (AVRO, JSON ou Protobuf. Outros formatos em breve), compactará o registro (configuração opcional do produtor) e o entregará ao destino.
4. Os consumidores desserializam os dados: os consumidores que leem esses dados usam a biblioteca de desserialização do registro de esquemas, que analisa o ID da versão do esquema na carga útil do registro.
5. O desserializador pode solicitar o esquema do registro do esquemas: se esta for a primeira vez que o desserializador viu registros com um ID de versão do esquema específico, o desserializador, usando o ID da versão do esquema, solicitará o esquema do registro do esquemas e o armazenará localmente no consumidor. Se o registro de esquemas não puder desserializar o registro, o consumidor poderá registrar em log os dados do registro e seguir em frente, ou interromper a aplicação.
6. O desserializador usa o esquema para desserializar o registro: quando o desserializador recupera o ID da versão do esquema do registro do esquemas, ele descompacta o registro (se o registro enviado pelo produtor for compactado) e usa o esquema para o desserializar. Então, a aplicação processa o registro.

> **Note**
>
> Criptografia: seus clientes se comunicam com o registro de esquemas por meio de chamadas de API que criptografam dados em trânsito usando criptografia TLS em HTTPS. Os esquemas armazenados no registro de esquemas são sempre criptografados em repouso usando uma chave do AWS Key Management Service (AWS KMS) gerenciada por um serviço.

> **Note**
>
> Autorização do usuário: o registro de esquemas é compatível com políticas do IAM baseadas em identidade.

Conceitos básicos do registro de esquemas

As seções a seguir fornecem uma visão geral e orientações sobre como configurar e usar o registro de esquemas. Para obter informações sobre conceitos e componentes do registro de esquemas, consulte Registro de esquemas do AWS Glue.

Tópicos

- Instalar as bibliotecas SerDe
- Criar um registro
- Criar um esquema
- Atualizar um esquema ou registro
- Excluir um esquema ou registro
- Exemplos do IAM para serializadores
- Exemplos do IAM para desserializadores
- Conectividade privada usando AWS PrivateLink
- Acessar métricas do Amazon CloudWatch
- Exemplo de modelo do AWS CloudFormation para o registro de esquemas

Instalar as bibliotecas SerDe

> **Note**
>
> Pré-requisitos: antes de concluir as etapas a seguir, é necessário ter um cluster do Amazon Managed Streaming for Apache Kafka (Amazon MSK) ou do Apache Kafka em execução. Seus produtores e consumidores precisam estar em execução em Java 8 ou superior.

As bibliotecas SerDe fornecem um framework para serialização e desserialização de dados.

Você instalará o serializador de código aberto para suas aplicações que produzem dados (coletivamente os “serializadores”). O serializador manipula serialização, compactação e interação com o registro de esquemas. O serializador extrai automaticamente o esquema de um registro sendo gravado em um destino compatível com o registro de esquemas, como o Amazon MSK. Da mesma forma, você instalará o desserializador de código aberto em suas aplicações que consomem dados.

Para instalar as bibliotecas em produtores e consumidores:

1. Dentro dos arquivos pom.xml, tanto dos produtores quanto dos consumidores, adicione essa dependência com o código abaixo:

   ```
   <dependency>
       <groupId>software.amazon.glue</groupId>
       <artifactId>schema-registry-serde</artifactId>
       <version>1.1.5</version>
   </dependency>
   ```

   Como alternativa, você pode clonar o repositório do registro de esquemas do AWS Glue do GitHub.
2. Configure seus produtores com estas propriedades obrigatórias:

   ```
   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"
   ```

Se não houver esquemas existentes, o registro automático precisará ser ativado (próxima etapa). Se você tiver um esquema que gostaria de aplicar, substitua “my-schema” (meu esquema) pelo nome do seu esquema. Além disso, o “registry-name” (nome do registro) deve ser fornecido se o registro automático do esquema estiver desativado. Se o esquema é criado sob o “default-registry” (registro padrão), o nome do registro pode ser omitido.

3. (Opcional) defina qualquer uma destas propriedades opcionais do produtor. Para obter descrições detalhadas das propriedades, consulte o arquivo ReadMe.

```
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.DESCRIPTION, "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
```

O registro automático registra a versão do esquema no registro padrão (“default-registry”). Se um `SCHEMA_NAME` não for especificado na etapa anterior, então o nome do tópico será inferido como `SCHEMA_NAME`.

Consulte Versionamento e compatibilidade de esquema, para obter mais informações sobre os modos de compatibilidade.

4. Configure seus consumidores com estas propriedades obrigatórias:

```
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 Região da
 AWS
props.put(AWSSchemaRegistryConstants.AVRO_RECORD_TYPE,
 AvroRecordType.GENERIC_RECORD.getName()); // Only required for AVRO data format
```

5. (Opcional) defina essas propriedades opcionais do consumidor. Para obter descrições detalhadas das propriedades, consulte o arquivo ReadMe.

```
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
```

Criar um registro

Você pode usar o registro padrão ou criar quantos novos registros forem necessários usando as APIS do AWS Glue ou o console do AWS Glue.

APIs do AWS Glue

Você pode usar estas etapas para executar essa tarefa usando as APIs do AWS Glue.

Para usar a AWS CLI para APIs do registro de esquemas do AWS Glue, certifique-se de atualizar a AWS CLI para a versão mais recente.

Para adicionar um novo registro, use a API do Ação CreateRegistry (Python: create_registry). Especifique `RegistryName` como o nome do registro a ser criado, com um comprimento máximo de 255, contendo apenas letras, números, hífens, sublinhados, cifrões ou marcas de hash.

Especifique `Description` como uma string com não mais do que 2.048 bytes de comprimento, correspondente ao padrão de string com várias linhas de endereço URI.

Como alternativa, especifique um ou mais `Tags` para seu registro, como uma matriz de mapa de pares de chave-valor.

```
aws glue create-registry --registry-name registryName1 --description description
```

Quando seu registro é criado, ele recebe um nome do recurso da Amazon (ARN), que você pode visualizar no `RegistryArn` da resposta da API. Agora que você criou um registro, crie um ou mais esquemas para esse registro.

Console do AWS Glue

Para adicionar um novo registro no console do AWS Glue:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Schema registries (Registros de esquemas).
3. Escolha Add registry (Adicionar registro).
4. Digite um Registry name (Nome de registro) para o registro composto por letras, números, hifens ou sublinhados. Esse nome não pode ser alterado.
5. Digite uma Description (Descrição) (opcional) para o registro.
6. Opcionalmente, aplique uma ou mais tags ao registro. Escolha Add new tag (Adicionar nova tag), especifique um Tag key (Chave de tag) e, opcionalmente, um Tag value (Valor da tag).
7. Escolha Add registry (Adicionar registro).

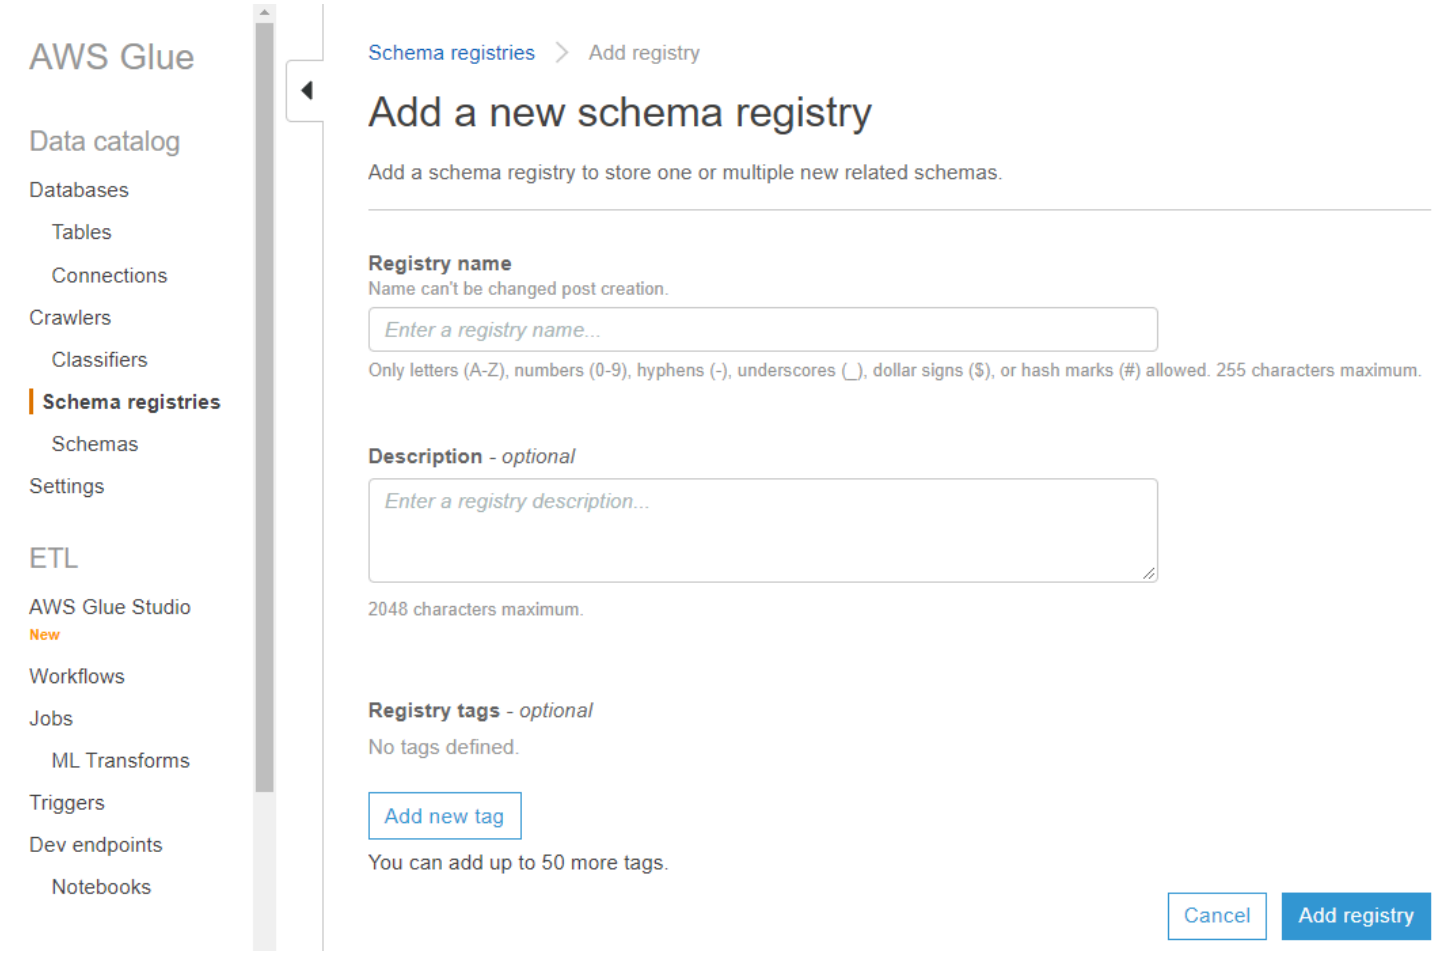

Quando seu registro é criado, ele recebe um nome do recurso da Amazon (ARN), que você pode visualizar escolhendo o registro na lista em Schema registries (Registros de esquemas). Agora que você criou um registro, crie um ou mais esquemas para esse registro.

Lidar com um registro específico (JAVA POJO) para JSON

Você pode usar um plain old Java object (POJO) e transmitir o objeto como um registro. Isso é semelhante à noção de um registro específico no AVRO. O mbknor-jackson-jsonschema pode gerar um esquema JSON para o POJO transmitido. Essa biblioteca também pode injetar informações adicionais no esquema JSON.

A biblioteca do registro de esquemas do AWS Glue usa o campo “className” injetado no esquema para fornecer um nome de classe totalmente classificado. O campo “className” é usado pelo desserializador para desserializar em um objeto dessa 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() {}
}
```

Criar um esquema

Você pode criar um esquema usando as APIs do AWS Glue ou o console do AWS Glue.

APIs do AWS Glue

Você pode usar estas etapas para executar essa tarefa usando as APIs do AWS Glue.

Para adicionar um novo esquema, use a API Ação CreateSchema (Python: create_esquema).

Especifique uma estrutura `RegistryId` para indicar um registro para o esquema. Ou omita o `RegistryId` para usar o registro padrão.

Especifique um `SchemaName` consistindo em letras, números, hifens ou sublinhados e `DataFormat` como **`AVRO`** ou **`JSON`**. O `DataFormat`, uma vez definido em um esquema, não pode ser alterado.

Especifique um modo de `Compatibility`:

- Backward (Anterior) (recomendado): o consumidor pode ler a versão atual e a anterior.
- Backward all (Todas as anteriores): o consumidor pode ler a versão atual e todas as anteriores.
- Forward (Próxima): o consumidor pode ler a versão atual e a subsequente.
- Forward all (Todas as próximas): o consumidor pode ler a versão atual e todas as subsequentes.
- Full (Completo): combinação de Backward e Forward.
- Full all (Completo total): combinação de Backward all e Forward all.
- None (Nenhum): nenhuma verificação de compatibilidade é realizada.
- Disabled (Desabilitado): impede qualquer versionamento para esse esquema.

Opcionalmente, especifique `Tags` para seu esquema.

Especifique uma `SchemaDefinition` para definir o esquema no formato de dados Avro, JSON ou Protobuf. Consulte os exemplos.

Para o formato de dados 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\"} ]}"
```

Para o formato de dados 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\"}}}"
```

Para o formato de dados 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;}"
```

Console do AWS Glue

Para adicionar um novo esquema usando o console do AWS Glue:

1. Faça login no Console de Gerenciamento da AWS e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Schema (Esquema).
3. Escolha Add schema (Adicionar esquema).
4. Digite um Schema name (Nome do esquema), consistindo em letras, números, hifens, sublinhados, cifrões ou marcas de hash. Esse nome não pode ser alterado.
5. Escolha o Registry (Registro) em que o esquema será armazenado no menu suspenso. O registro pai não pode ser alterado após a criação.
6. Deixe Data format (Formato de dados) como Apache Avro ou JSON. Esse formato se aplica a todas as versões desse esquema.
7. Escolha um Compatibility mode (Modo de compatibilidade).
   - Backward (Anterior) (recomendado): o receptor pode ler a versão atual e a anterior.
   - Backward all (Todas as anteriores): o receptor pode ler a versão atual e todas as anteriores.
   - Forward (Próxima): o remetente pode gravar a versão atual e a anterior.
   - Forward all (Todas as próximas): o remetente pode gravar a versão atual e todas as anteriores.
   - Full (Completo): combinação de Backward e Forward.
   - Full all (Completo total): combinação de Backward All e Forward All.
   - None (Nenhum): nenhuma verificação de compatibilidade é realizada.
   - Disabled (Desabilitado): impede qualquer versionamento para esse esquema.
8. Insira uma Description (Descrição) opcional de até 250 caracteres para o registro.

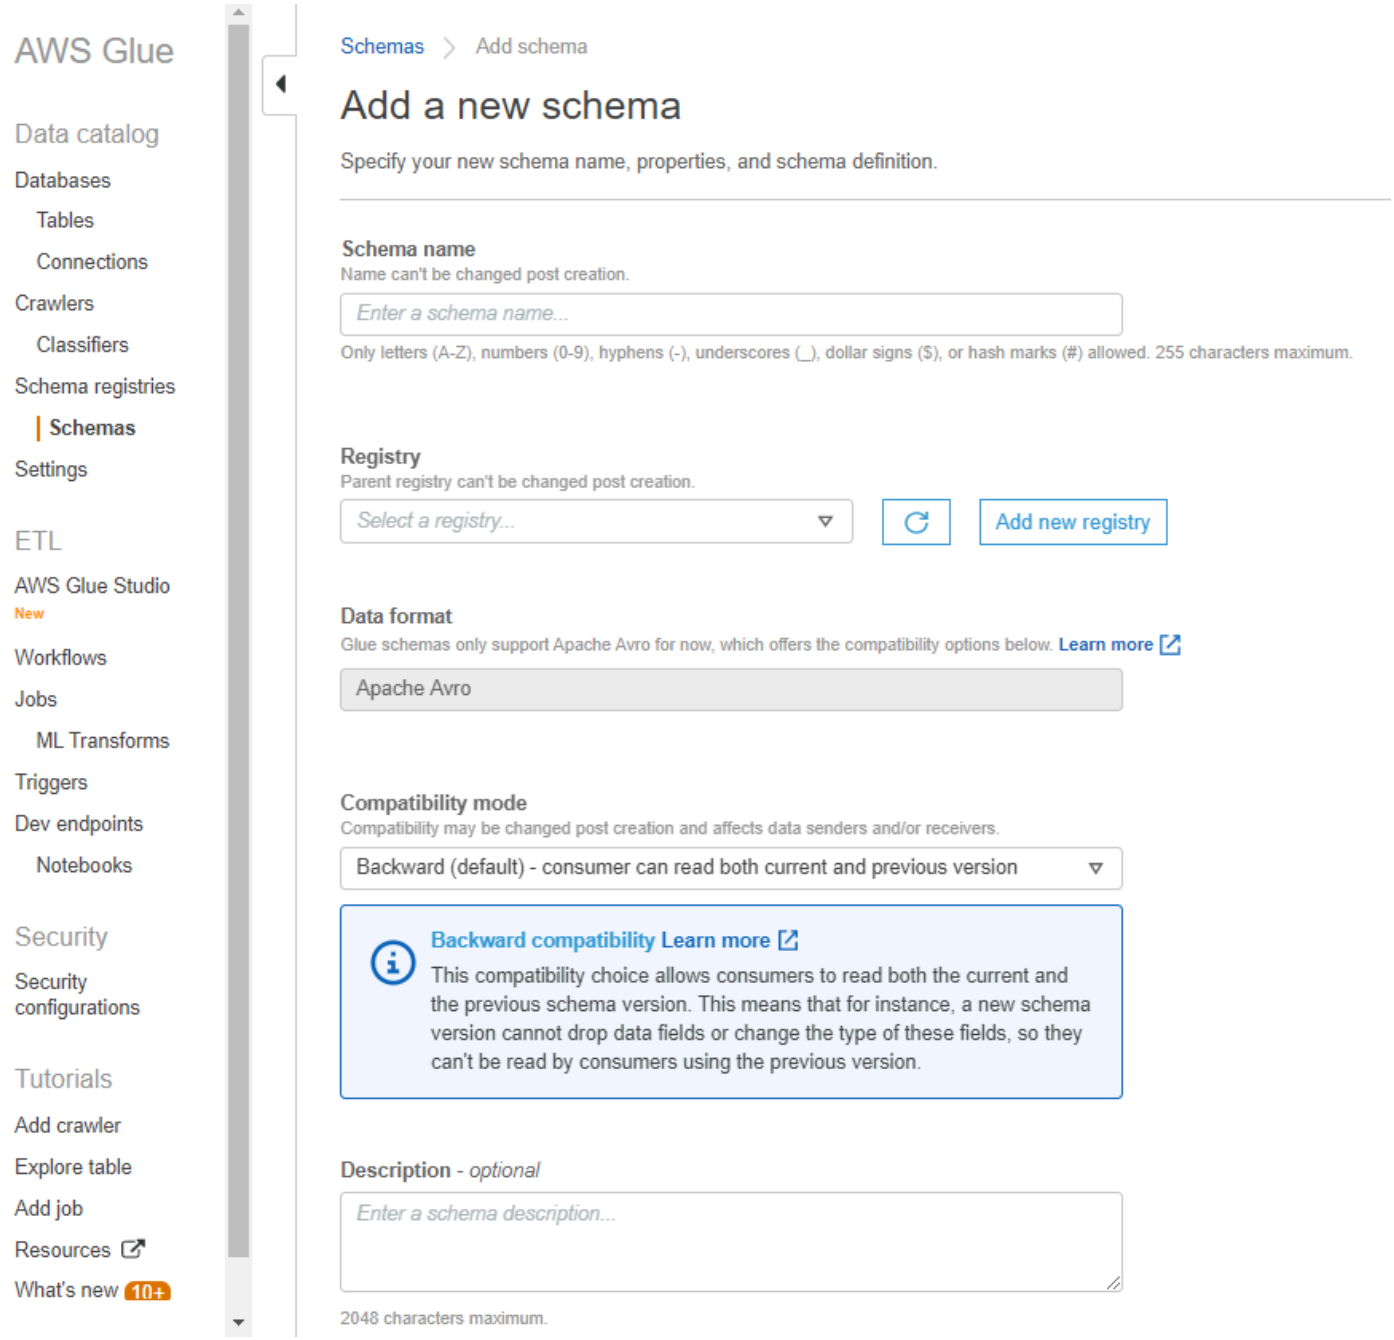

9. Opcionalmente, aplique uma ou mais tags ao esquema. Escolha Add new tag (Adicionar nova tag), especifique um Tag key (Chave de tag) e, opcionalmente, um Tag value (Valor da tag).
10. Na caixa First schema version (Primeira versão do esquema), insira ou cole o esquema inicial.

    Para o formato Avro, consulte Trabalhar com o formato de dados Avro

    Para o formato JSON, consulte Trabalhar com o formato de dados JSON

11. Opcionalmente, escolha Add metadata (Adicionar metadados) para adicionar metadados de versão para anotar ou classificar a versão do esquema.
12. Selecione Create schema and version (Criar esquema e versão).

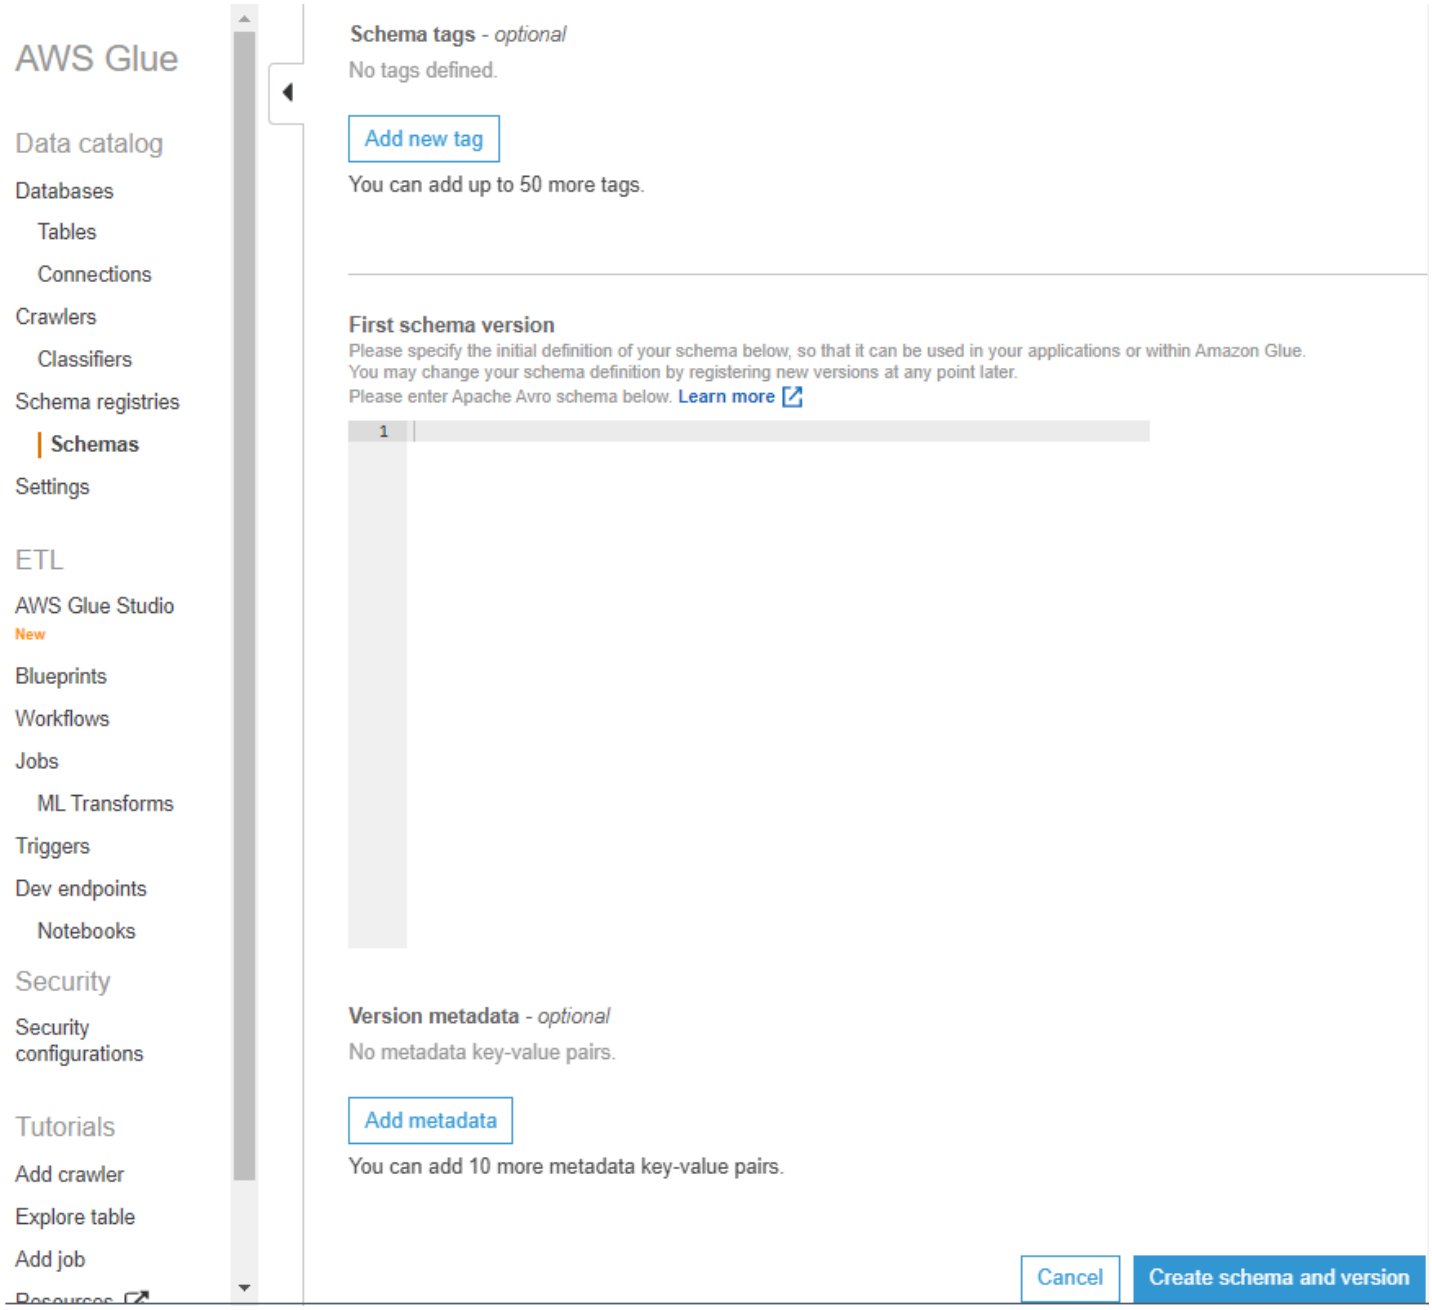

O esquema é criado e aparece na lista em Schemas (Esquemas).

Trabalhar com o formato de dados Avro

O Avro fornece serviços de serialização e troca de dados. O Avro armazena a definição de dados no formato JSON facilitando a leitura e interpretação. Os dados em si são armazenados em formato binário.

Para obter informações sobre como definir um esquema do Apache Avro, consulte a especificação do Apache Avro.

Trabalhar com o formato de dados JSON

Os dados podem ser serializados com o formato JSON. O formato do esquema JSON define o padrão para o formato de esquema JSON.

Atualizar um esquema ou registro

Uma vez criados, você pode editar seus esquemas, versões de esquema ou registro.

Atualizar um registro

Você pode atualizar um registro usando as APIs do AWS Glue ou o console do AWS Glue. O nome de um registro existente não pode ser editado. Você pode editar a descrição de um registro.

APIs do AWS Glue

Para atualizar um registro existente, use a API Ação UpdateRegistry (Python: update_registry).

Especifique uma estrutura `RegistryId` para indicar o registro que você deseja atualizar. Informe uma `Description` para alterar a descrição de um registro.

```
aws glue update-registry --description updatedDescription --registry-id
 RegistryArn="arn:aws:glue:us-east-2:901234567890:registry/registryName1"
```

Console do AWS Glue

Para atualizar um registro usando o console do AWS Glue:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Schema registries (Registros de esquemas).

3. Escolha um registro na lista de registros, marcando a caixa correspondente.
4. No menu Action (Ação), escolha Edit registry (Editar registro).

Atualizar um esquema

Você pode atualizar a descrição ou a configuração de compatibilidade de um esquema.

Para atualizar um esquema existente, use a API Ação UpdateSchema (Python: update_schema).

Especifique uma estrutura `SchemaId` para indicar o esquema que você deseja atualizar. Um de `VersionNumber` ou `Compatibility` tem de ser fornecido.

Exemplo de código 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
```

Adicionar uma versão de esquema

Quando você adiciona uma versão de esquema, precisa comparar as versões para se certificar de que o novo esquema será aceito.

Para adicionar uma nova versão a um esquema existente, use a API Ação RegisterSchemaVersion (Python: register_schema_version).

Especifique um estrutura `SchemaId` para indicar o esquema no qual você deseja adicionar uma versão e uma `SchemaDefinition` para definir o esquema.

Exemplo de código 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. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Schema (Esquema).
3. Escolha o esquema na lista de esquemas, marcando a caixa correspondente.
4. Escolha um ou mais esquemas na lista, marcando as caixas.
5. No menu Action (Ação), escolha Register new version (Registrar nova versão).
6. Na caixa New version (Nova versão), insira ou cole seu novo esquema.
7. Escolha Compare with previous version (Comparar com a versão anterior) para ver as diferenças em relação à versão anterior do esquema.
8. Opcionalmente, escolha Add metadata (Adicionar metadados) para adicionar metadados de versão para anotar ou classificar a versão do esquema. Digite a Key (Chave) e o Value (Valor) opcional.
9. Escolha Register version (Registrar versão).

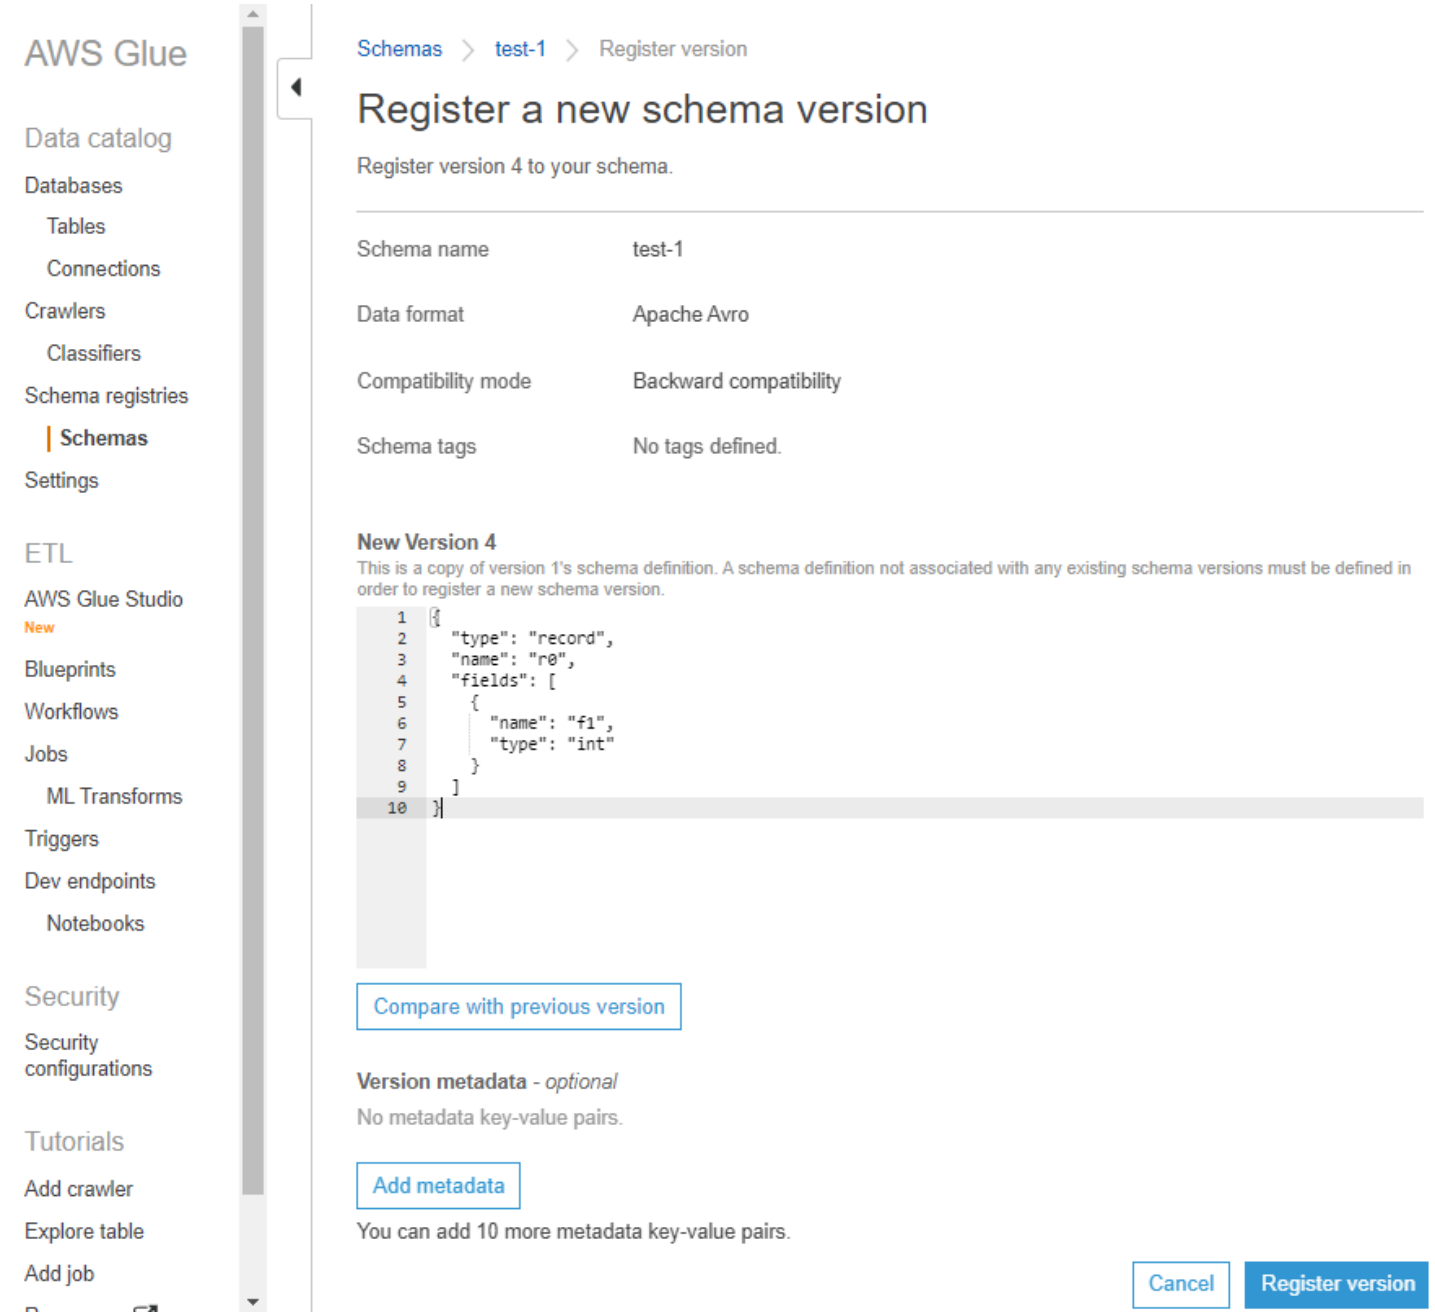

As versões dos esquemas aparecem na lista de versões. Se a versão alterou o modo de compatibilidade, ela será marcada como um ponto de verificação.

Exemplo de comparação de versões de esquema

Quando você escolher Compare with previous version (Comparar com a versão anterior), você verá a versão nova e a anterior exibidas juntas. As informações alteradas serão destacadas da seguinte forma:

- Amarelo: indica informações alteradas.
- Verde: indica o conteúdo adicionado na versão mais recente.
- Vermelho: indica o conteúdo removido da versão mais recente.

Você também pode comparar com versões anteriores.

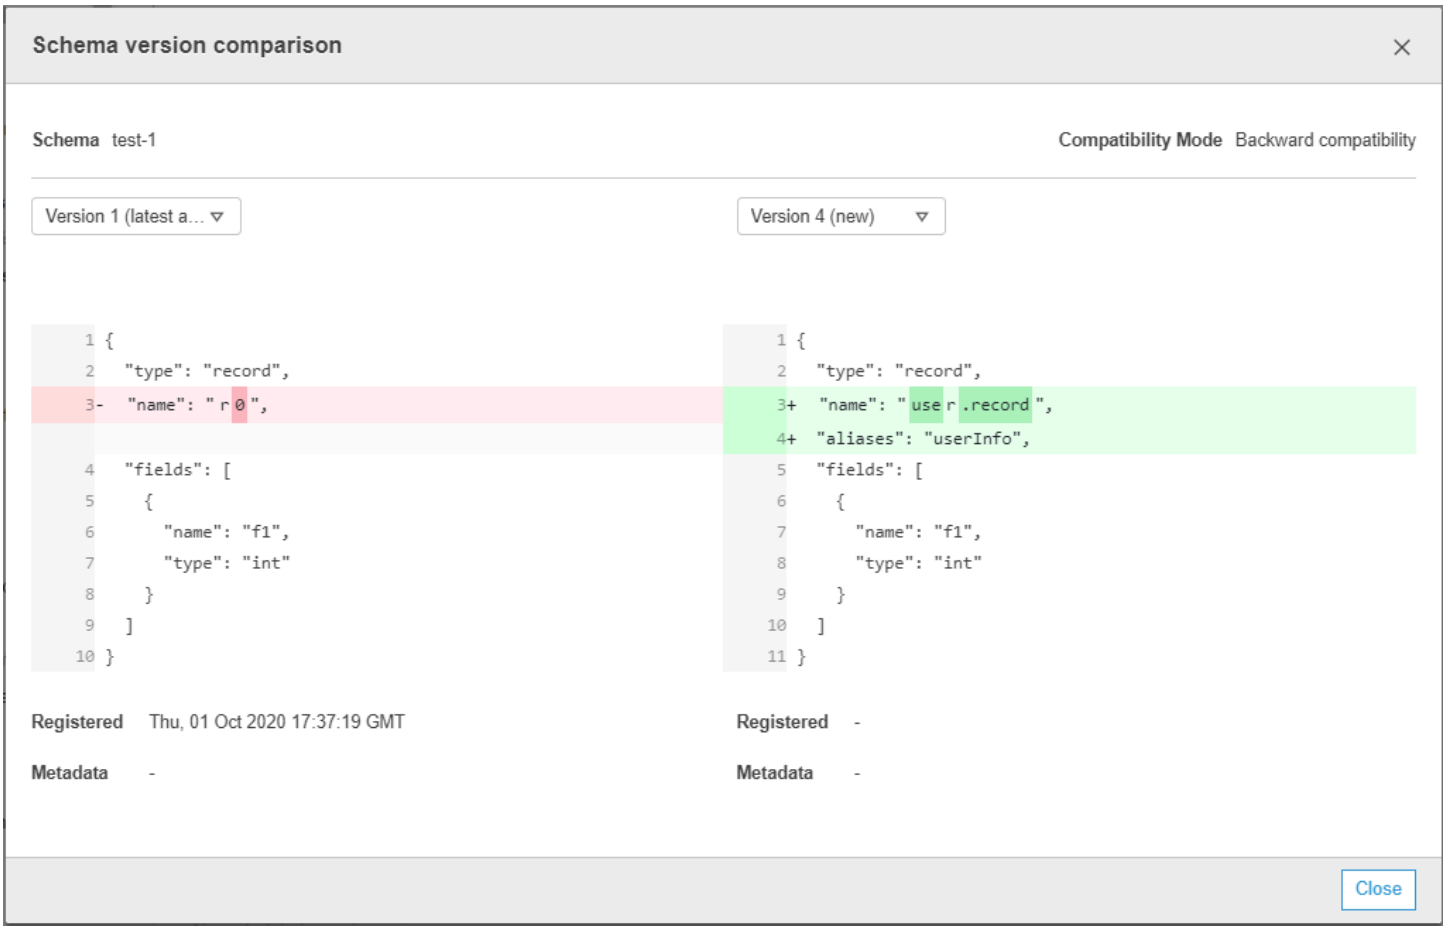

Excluir um esquema ou registro

Excluir um esquema, uma versão de esquema ou um registro são ações permanentes que não podem ser desfeitas.

Excluir um esquema

Você pode querer excluir um esquema quando ele não for mais usado dentro de um registro usando o AWS Management Console ou a API Ação DeleteSchema (Python: delete_schema).

Excluir um ou mais esquemas é uma ação permanente que não pode ser desfeita. Certifique-se de que o esquema ou esquemas não são mais necessários.

Para excluir um esquema do registro, chame a API Ação DeleteSchema (Python: delete_schema), especificando a estrutura `SchemaId` para identificar o esquema.

Por exemplo:

```
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-
deleteschemabyname",RegistryName="default-registry"
```

Console do AWS Glue

Para excluir um esquema com o console do AWS Glue:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Schema registries (Registros de esquemas).
3. Escolha o registro que contém o esquema na lista de registros.
4. Escolha um ou mais esquemas na lista, marcando as caixas.
5. No menu Actions (Ações), escolha Delete schema (Excluir esquema).
6. Insira o texto **`Delete`** no campo para confirmar a exclusão.
7. Escolha Excluir.

Os esquemas especificados são excluídos do registro.

Excluir uma versão de esquema

À medida que os esquemas se acumulam no registro, você pode querer excluir versões de esquema indesejadas usando o AWS Management Console ou a API Ação DeleteSchemaVersions (Python: delete_schema_versions). Excluir uma ou mais versões de esquema é uma ação permanente que não pode ser desfeita. Certifique-se de que as versões de esquema não são mais necessárias.

Ao excluir versões de esquema, observe as seguintes restrições:

- Você não pode excluir uma versão marcada como ponto de verificação.
- O intervalo de versões contíguas não pode ser superior a 25.

- A versão mais recente do esquema não deve estar em estado pendente.

Especifique a estrutura `SchemaId` para identificar o esquema e especifique `Versions` como um intervalo de versões a serem excluídas. Para obter mais informações sobre como especificar uma versão ou intervalo de versões, consulte Ação DeleteRegistry (Python: delete_registry). As versões de esquema especificadas são excluídas do registro.

Chamar a API Ação ListSchemaVersions (Python: list_schema_versions) após essa chamada listará o status das versões excluídas.

Por exemplo:

```
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. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Schema registries (Registros de esquemas).
3. Escolha o registro que contém o esquema na lista de registros.
4. Escolha um ou mais esquemas na lista, marcando as caixas.
5. No menu Actions (Ações), escolha Delete schema (Excluir esquema).
6. Insira o texto **`Delete`** no campo para confirmar a exclusão.
7. Escolha Excluir.

As versões de esquema especificadas são excluídas do registro.

Excluir um registro

Você pode querer excluir um registro quando os esquemas que ele contém não devem mais ser organizados nele. Você precisará reatribuir esses esquemas a outro registro.

Excluir um ou mais registros é uma ação permanente que não pode ser desfeita. Certifique-se de que o registro ou registros não são mais necessários.

O registro padrão pode ser excluído usando a AWS CLI.

API do AWS Glue

Para excluir todo o registro, incluindo o esquema e todas as suas versões, chame a API Ação DeleteRegistry (Python: delete_registry). Especifique uma estrutura `RegistryId` para identificar o registro.

Por exemplo:

```
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"
```

Para obter o status da operação de exclusão, é possível chamar a API `GetRegistry` após a chamada assíncrona.

Console do AWS Glue

Para excluir um registro do console do AWS Glue:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Schema registries (Registros de esquemas).
3. Escolha um registro na lista, marcando uma caixa.
4. No menu Action (Ação), escolha Delete registry (Excluir registro).
5. Insira o texto **`Delete`** no campo para confirmar a exclusão.
6. Escolha Excluir.

Os registros que você selecionou são excluídos do AWS Glue.

Exemplos do IAM para serializadores

> **Note**
>
> As políticas gerenciadas pela AWS concedem as permissões necessárias para casos de uso comuns. Para obter informações sobre como usar políticas gerenciadas para gerenciar o

registro do esquema, consulte Políticas gerenciadas pela AWS (predefinidas) para o AWS Glue.

Para serializadores, você deve criar uma política mínima semelhante à abaixo, para lhe dar a capacidade de encontrar o `schemaVersionId` para uma determinada definição de esquema. Observe que você deve ter permissões de leitura no registro para ler os esquemas no registro. Você pode limitar os registros que podem ser lidos usando a cláusula `Resource`.

Exemplo de código 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"
                     ]
}
```

Além disso, você também pode permitir que os produtores criem novos esquemas e versões ao incluir os seguintes métodos extras. Observe que você deve ser capaz de inspecionar o registro para adicionar/remover/evoluir os esquemas dentro dele. Você pode limitar os registros que podem ser inspecionados usando a cláusula `Resource`.

Exemplo de código 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"
                 ]
}
```

Exemplos do IAM para desserializadores

Para desserializadores (lado do consumidor), você deve criar uma política semelhante à abaixo para permitir que o desserializador busque o esquema do registro de esquemas para desserialização. Observe que você deve ser capaz de inspecionar o registro a fim de buscar os esquemas dentro dele.

Exemplo de código 15:

```
{
    "Sid" : "GetSchemaVersion",
    "Effect" : "Allow",
    "Action" :
 [
        "glue:GetSchemaVersion"
    ],
    "Resource" : ["*"]
}
```

Conectividade privada usando AWS PrivateLink

Você pode usar o AWS PrivateLink para conectar a VPC do produtor de dados ao AWS Glue definindo um endpoint da VPC de interface para o AWS Glue. Quando você usa um endpoint da VPC de interface, a comunicação entre sua VPC e o AWS Glue é realizada inteiramente dentro da rede da AWS. Para obter mais informações, consulte Usar o AWS Glue com endpoints da VPC.

Acessar métricas do Amazon CloudWatch

As métricas do Amazon CloudWatch estão disponíveis como parte do nível gratuito do CloudWatch. Também é possível visualizá-las no console do CloudWatch. As métricas de nível de API

incluem CreateSchema (sucesso e latência), GetSchemaByDefinition (sucesso e latência), GetSchemaVersion (sucesso e latência), RegisterSchemaVersion (sucesso e latência) e PutSchemaVersionMetadata (sucesso e latência). As métricas de nível de recurso incluem Registry.ThrottledByLimit, SchemaVersion.ThrottledByLimit e SchemaVersion.Size.

Exemplo de modelo do AWS CloudFormation para o registro de esquemas

Veja a seguir um modelo de exemplo para criar recursos do registro de esquemas no AWS CloudFormation. Para criar essa pilha em sua conta, copie o modelo acima em um arquivo `SampleTemplate.yaml` e execute o seguinte comando:

```
aws cloudformation create-stack --stack-name ABCSchemaRegistryStack --template-body
 "'cat SampleTemplate.yaml'"
```

Este exemplo usa `AWS::Glue::Registry` para criar um registro, `AWS::Glue::Schema` para criar um esquema, `AWS::Glue::SchemaVersion` para criar uma versão de esquema e `AWS::Glue::SchemaVersionMetadata` para preencher os metadados da versão do esquema.

```
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"
```

Integração com o registro de esquemas do AWS Glue

Estas seções descrevem integrações com o registro de esquemas do AWS Glue. Os exemplos nesta seção mostram um esquema com formato de dados AVRO. Para obter mais exemplos, incluindo esquemas com formato de dados JSON, consulte os testes de integração e as informações no arquivo ReadMe no repositório de código aberto do registro de esquemas do AWS Glue.

Tópicos

- Caso de uso: conectar registro de esquemas ao Amazon MSK ou Apache Kafka
- Caso de uso: integração do Amazon Kinesis Data Streams ao registro de esquemas do AWS Glue
- Caso de uso: Amazon Managed Service for Apache Flink
- Caso de uso: integração com o AWS Lambda
- Caso de uso: AWS Glue Data Catalog
- Caso de uso: transmissão no AWS Glue
- Caso de uso: Apache Kafka Streams

Caso de uso: conectar registro de esquemas ao Amazon MSK ou Apache Kafka

Vamos supor que você está gravando dados em um tópico do Apache Kafka. Você pode seguir estas etapas para começar.

1. Crie um cluster do Amazon Managed Streaming for Apache Kafka (Amazon MSK) ou do Apache Kafka com pelo menos um tópico. Se estiver criando um cluster do Amazon MSK, você pode usar o AWS Management Console. Para obter mais informações: Conceitos básicos do uso do Amazon MSK no Guia do desenvolvedor do Amazon Managed Streaming for Apache Kafka.
2. Siga o passo Instalar as bibliotecas SerDe acima.
3. Para criar registros de esquemas, esquemas ou versões de esquema, siga as instruções na seção Conceitos básicos do registro de esquemas deste documento.
4. Inicie seus produtores e consumidores para usar o registro de esquemas para gravar e ler registros de/para o tópico do Amazon MSK ou Apache Kafka. Um exemplo de código de produtor e consumidor pode ser encontrado no arquivo ReadMe das bibliotecas Serde. A biblioteca do registro de esquemas no produtor serializará automaticamente o registro e decorará o registro com um ID de versão do esquema.
5. Se o esquema desse registro tiver sido inserido, ou se o registro automático estiver ativado, o esquema será registrado no registro do esquemas.
6. O consumidor lendo do tópico do Amazon MSK ou Apache Kafka, usando a biblioteca do registro de esquemas do AWS Glue, pesquisará automaticamente o esquema no registro do esquemas.

Caso de uso: integração do Amazon Kinesis Data Streams ao registro de esquemas do AWS Glue

Essa integração requer que você tenha um fluxo de dados existente do Amazon Kinesis. Para obter mais informações, consulte Conceitos básicos do Amazon Kinesis Data Streams no Guia do desenvolvedor do Amazon Kinesis Data Streams.

Há duas maneiras de interagir com os dados em um fluxo de dados do Kinesis.

- Por meio das bibliotecas do Kinesis Producer Library (KPL) e Kinesis Client Library (KCL) em Java. Suporte a várias linguagens não é fornecido.
- Por maio das APIs `PutRecords`, `PutRecord` e `GetRecords` do Kinesis Data Streams disponíveis no AWS SDK para Java.

Se você usa atualmente as bibliotecas KPL/KCL, recomendamos continuar usando esse método. Há versões atualizadas da KCL e KPL com o registro de esquemas integrado, como mostrado nos exemplos. Caso contrário, você pode usar o código de exemplo para utilizar o registro do esquemas do AWS Glue se estiver usando as APIs do KDS diretamente.

A integração do registro de esquemas só está disponível com a KPL v0.14.2 ou posterior e com a KCL v2.3 ou posterior. A integração do registro de esquemas com JSON só está disponível com a KPL v0.14.8 ou posterior e com a KCL v2.3.6 ou posterior.

Interagir com dados usando o Kinesis SDK V2

Esta seção descreve a interação com o Kinesis usando o Kinesis SDK 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 = kinesisClient.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 = kinesisClient.getShardIterator(getShardIteratorRequest)
        .get()
        .shardIterator();

GetRecordsRequest getRecordRequest = GetRecordsRequest.builder()
        .shardIterator(shardIterator)
        .build();
GetRecordsResponse recordsResponse = kinesisClient.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 com dados usando as bibliotecas KPL/KCL

Esta seção descreve a integração do Kinesis Data Streams com o registro de esquemas usando as bibliotecas KPL/KCL. Para obter mais informações sobre o uso da KPL/KCL, consulte Desenvolver produtores usando a biblioteca de produtor do Amazon Kinesis no Guia do desenvolvedor do Amazon Kinesis Data Streams.

Configurar o registro de esquemas na KPL

1. Configure a definição do esquema para os dados, o formato de dados e o nome do esquema criados no registro de esquemas do AWS Glue.
2. Opcionalmente, configure o objeto `GlueSchemaRegistryConfiguration`.
3. Transmita o objeto de esquema para `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());
 }
```

Configurar a biblioteca do cliente Kinesis

Você desenvolverá seu consumidor da biblioteca do cliente Kinesis em Java. Para obter mais informações, consulte Desenvolver um consumidor da biblioteca do cliente Kinesis em Java no Guia do desenvolvedor do Amazon Kinesis Data Streams.

1. Crie uma instância de `GlueSchemaRegistryDeserializer` transmitindo um objeto `GlueSchemaRegistryConfiguration`.
2. Transmita o `GlueSchemaRegistryDeserializer` para `retrievalConfig.glueSchemaRegistryDeserializer`.
3. Acesse o esquema de mensagens recebidas chamando `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);
 }
```

Interagir com dados usando as APIs do Kinesis Data Streams

Esta seção descreve a integração do Kinesis Data Streams com o registro de esquemas usando as APIs do Kinesis Data Streams.

1. Atualize estas dependências do 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. No produtor, adicione as informações de cabeçalho do esquema usando a API `PutRecords` ou `PutRecord` no 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. No produtor, use a API `PutRecords` ou `PutRecord` para colocar o registro no fluxo de dados.
4. No consumidor, remova o registro do esquema do cabeçalho e serialize um registro do esquema 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);
```

```
        }
```

Interagir com dados usando as APIs do Kinesis Data Streams

O código de exemplo a seguir usa as APIs `PutRecords` e `GetRecords`.

```
//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;
    }
}
```

Caso de uso: Amazon Managed Service for Apache Flink

O Apache Flink é um framework de código aberto popular e mecanismo de processamento distribuído para computações com estado sobre fluxos de dados vinculados e não vinculados. O Amazon Managed Service for Apache Flink é um serviço totalmente gerenciado da AWS que permite a criação e o gerenciamento de aplicações do Apache Flink para processar dados de transmissão.

O Apache Flink de código aberto fornece uma série de fontes e coletores. Por exemplo, origens de dados predefinidas incluem leitura de arquivos, diretórios e soquetes e ingestão de dados de coleções e iteradores. Os conectores Apache Flink DataStream fornecem código para o Apache Flink para realizar a interface com vários sistemas de terceiros, como Apache Kafka ou Kinesis, como fontes e/ou coletores.

Para obter mais informações, consulte o Guia do desenvolvedor do Amazon Kinesis Data Analytics.

Conector Apache Flink Kafka

O Apache Flink fornece um conector de fluxo de dados Apache Kafka para leitura e gravação de dados em tópicos do Kafka com garantias do tipo exatamente uma. Consumidor Kafka do Flink, `FlinkKafkaConsumer`, fornece acesso à leitura de um ou mais tópicos do Kafka. O produtor Kafka

do Apache Flink, `FlinkKafkaProducer`, permite gravar uma transmissão de registros para um ou mais tópicos do Kafka. Para obter mais informações, consulte Conector do Apache Kafka.

Conector de fluxos do Kinesis do Apache Flink

O conector de transmissão de dados do Kinesis fornece acesso aos Amazon Kinesis Data Streams. O `FlinkKinesisConsumer` é uma origem de dados de transmissão paralelo do tipo exatamente uma vez que assina várias transmissões do Kinesis dentro da mesma região de produto da AWS e que pode manipular de forma transparente a refragmentação de transmissões enquanto o trabalho é executado. Cada subtarefa do consumidor é responsável por buscar registros de dados de vários fragmentos do Kinesis. O número de fragmentos obtidos por cada subtarefa será alterado à medida que os fragmentos forem fechados e criados pelo Kinesis. O `FlinkKinesisProducer` usa a Kinesis Producer Library (KPL) para colocar dados de uma transmissão do Apache Flink em uma transmissão do Kinesis. Para obter mais informações, consulte Conector do Amazon Kinesis Streams.

Para obter mais informações, consulte o repositório do GitHub de registro do AWS Glue.

Integração com o Apache Flink

A biblioteca SerDes fornecida com o registro de esquemas se integra com o Apache Flink. Para trabalhar com o Apache Flink, é necessário implementar as interfaces `SerializationSchema` e `DeserializationSchema` chamadas `GlueSchemaRegistryAvroSerializationSchema` e `GlueSchemaRegistryAvroDeserializationSchema`, que você pode vincular aos conectores Apache Flink.

Adicionar uma dependência do registro do esquemas do AWS Glue na aplicação do Apache Flink

Para configurar as dependências de integração para o registro de esquemas do AWS Glue na aplicação do Apache Flink:

1. Adicione a dependência ao arquivo `pom.xml`.

```
<dependency>
    <groupId>software.amazon.glue</groupId>
    <artifactId>schema-registry-flink-serde</artifactId>
    <version>1.0.0</version>
</dependency>
```

Integração do Kafka ou do Amazon MSK com o Apache Flink

Você pode usar o Managed Service for Apache Flink, com o Kafka como fonte ou com o Kafka como coletor.

Kafka como uma fonte

O diagrama a seguir mostra a integração do Kinesis Data Streams com o Managed Service for Apache Flink com o Kafka como uma fonte.

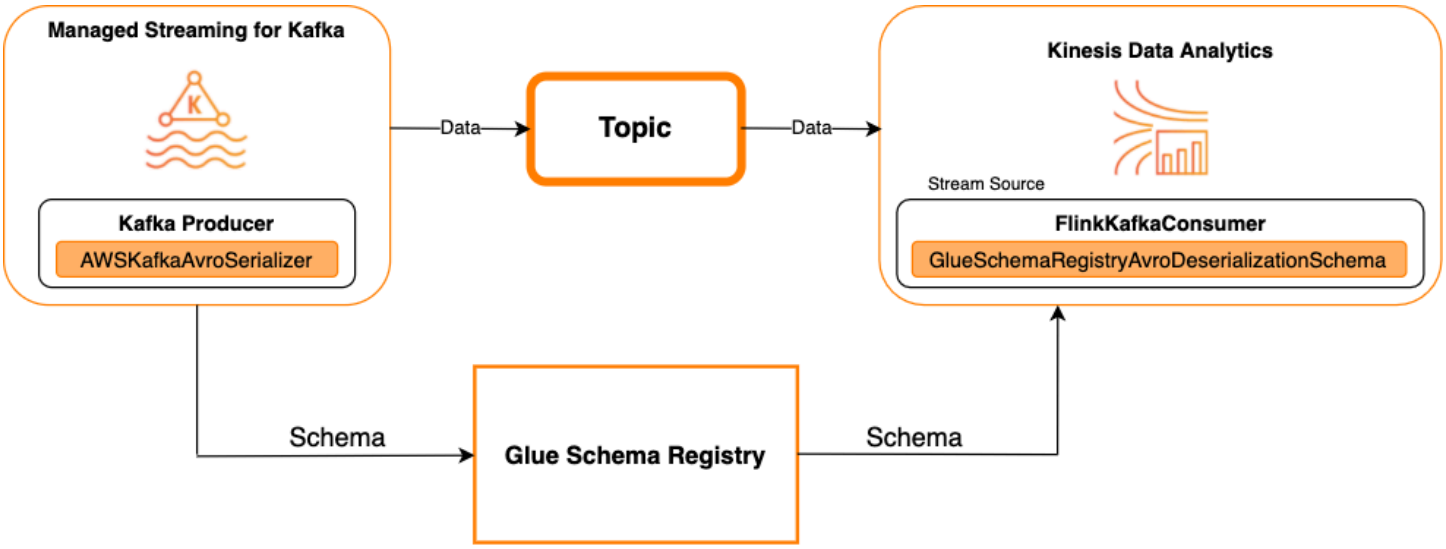

Kafka como um coletor

O diagrama a seguir mostra a integração do Kinesis Data Streams com o Managed Service for Apache Flink com o Kafka como uma coletor.

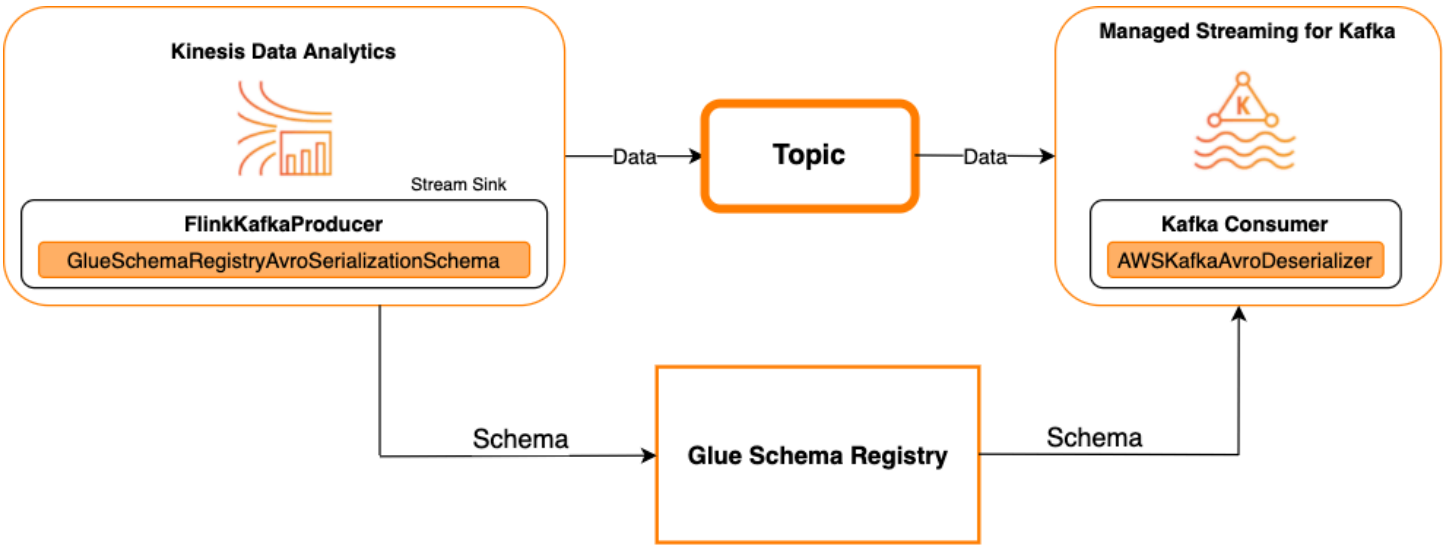

Para integrar o Kafka (ou o Amazon MSK) com o Managed Service for Apache Flink com o Kafka como uma fonte ou como um coletor, faça as alterações de código abaixo. Adicione os blocos de código em negrito ao seu respectivo código nas seções análogas.

Se o Kafka for a fonte, use o código de desserialização (bloco 2). Se o Kafka for o coletor, use o código serializador (bloco 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();
```

Integração do Kinesis Data Streams com o Apache Flink

Você pode usar o Managed Service for Apache Flink com o Kinesis Data Streams como fonte ou como coletor.

Kinesis Data Streams como uma fonte

O diagrama a seguir mostra a integração do Kinesis Data Streams com o Managed Service for Apache Flink com o Kinesis Data Streams como uma fonte.

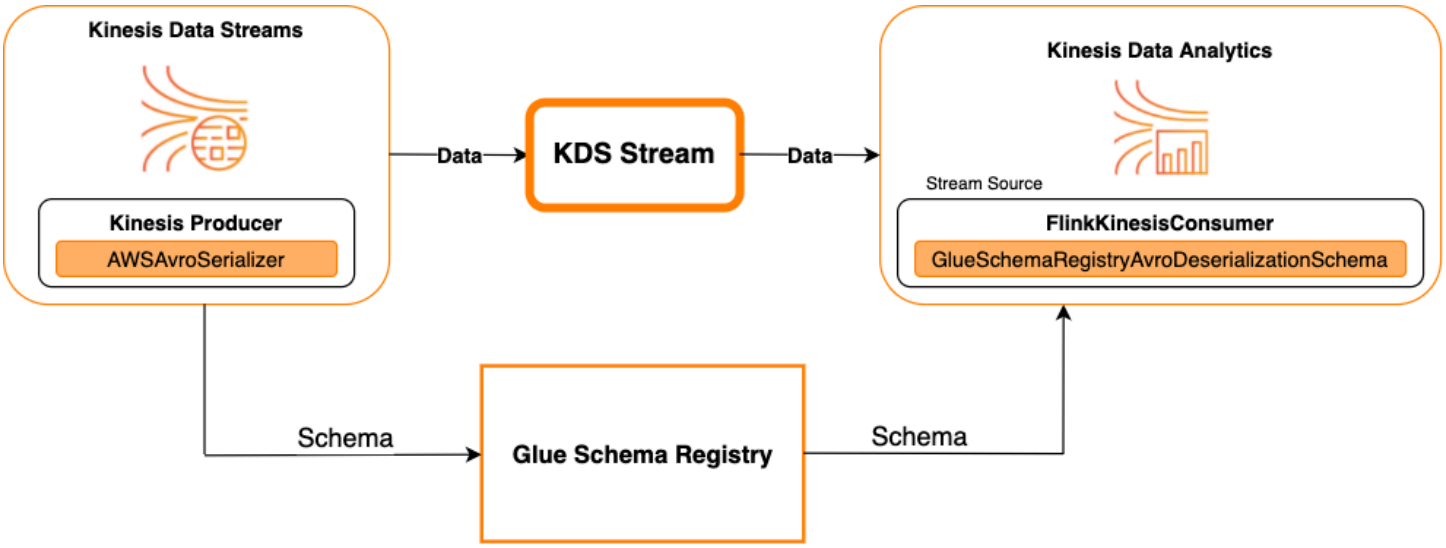

Kinesis Data Streams como um coletor

O diagrama a seguir mostra a integração do Kinesis Data Streams com o Managed Service for Apache Flink com o Kinesis Data Streams como uma coletor.

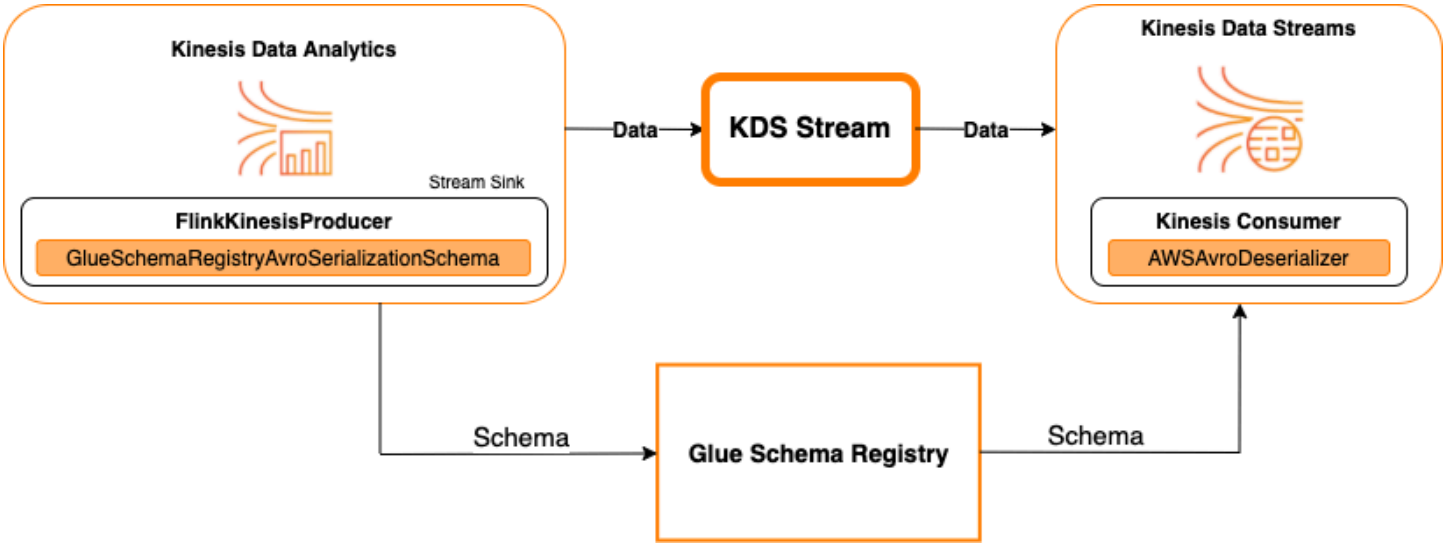

Para integrar o Kinesis Data Streams com o Managed Service for Apache Flink com o Kinesis Data Streams como uma origem ou como um coletor, faça as alterações de código abaixo. Adicione os blocos de código em negrito ao seu respectivo código nas seções análogas.

Se o Kinesis Data Streams for a fonte, use o código de desserialização (bloco 2). Se o Kinesis Data Streams for o coletor, use o código de serialização (bloco 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();
```

Caso de uso: integração com o AWS Lambda

Para usar uma função do AWS Lambda como um consumidor do Apache Kafka/Amazon MSK e desserializar mensagens codificadas em Avro usando o registro de esquemas do AWS Glue, acesse a página do MSK Labs.

Caso de uso: AWS Glue Data Catalog

As tabelas do AWS Glue suportam esquemas que você pode especificar manualmente ou por referência aoregistro de esquemas do AWS Glue. O registro de esquemas se integra ao Data Catalog para permitir que você opcionalmente use esquemas armazenados no registro de esquemas ao criar ou atualizar tabelas ou partições do AWS Glue no Data Catalog. Para identificar uma definição de esquema no registro de esquemas, no mínimo, você precisa saber o ARN do esquema do qual ele faz parte. Uma versão de esquema que contém uma definição de esquema pode ser referenciada por seu UUID ou número de versão. Há sempre uma versão de esquema, a versão "mais recente", que pode ser pesquisada sem saber seu número de versão ou UUID.

Ao chamar as operações `CreateTable` ou `UpdateTable`, você transmitirá uma estrutura `TableInput` que contém um `StorageDescriptor`, que pode ter uma `SchemaReference` para um esquema existente no registro de esquemas. Da mesma forma, quando você chama as APIs `GetTable` ou `GetPartition`, a resposta pode conter o esquema e a `SchemaReference`. Quando uma tabela ou partição é criada usando referências de esquema, o Data Catalog tenta buscar o esquema para essa referência. Caso não seja possível localizar o esquema no registro de esquemas, ele retorna um esquema vazio na reposta de `GetTable`. Caso contrário, a resposta possui o esquema e a referência do esquema.

Também é possível executar as ações no console do AWS Glue.

Para realizar essas operações e criar, atualizar ou exibir informações de esquema, você deve conceder ao usuário que faz a chamada um perfil do IAM que forneça permissões para a API `GetSchemaVersion`.

Adicionar uma tabela ou atualizar o esquema de uma tabela

A adição de uma nova tabela a partir de um esquema existente vincula a tabela a uma versão específica do esquema. Depois que as novas versões de esquema forem registradas, você poderá atualizar essa definição de tabela na página View table (Exibir tabela) no console do AWS Glue ou usando a API Ação UpdateTable (Python: update_table).

Adicionar uma tabela de um esquema existente

É possível criar uma tabela do AWS Glue a partir de uma versão de esquema no registro usando o console do AWS Glue ou a API `CreateTable`.

API do AWS Glue

Ao chamar a API `CreateTable`, você transmitirá uma `TableInput` que contém um `StorageDescriptor` que, por sua vez, contém uma `SchemaReference` para um esquema existente no registro de esquemas.

Console do AWS Glue

Para criar uma tabela no console do AWS Glue:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Tables (Tabelas).
3. No menu Add Tables (Adicionar tabelas), escolha Add table from existing schema (Adicionar tabela do esquema existente).
4. Configure as propriedades da tabela e o datastore de acordo com o guia do desenvolvedor do AWS Glue.
5. Na página Choose a Glue schema (Escolher um esquema do Glue), selecione o Registry (Registro) em que o esquema reside.
6. Escolha o Schema name (Nome do esquema) e selecione a Version (Versão) do esquema a ser aplicada.
7. Revise a pré-visualização do esquema e escolha Next (Próximo).
8. Revise e crie a tabela.

O esquema e a versão aplicada à tabela são exibidos na coluna Glue schema (Esquema do Glue) na lista de tabelas. Você pode exibir a tabela para ver mais detalhes.

Atualizar o esquema de uma tabela

Quando uma nova versão de esquema se torna disponível, você pode querer atualizar o esquema de uma tabela usando a API Ação UpdateTable (Python: update_table) ou o console do AWS Glue.

> **Important**
>
> Ao atualizar o esquema de uma tabela existente que tenha um esquema do AWS Glue especificado manualmente, o novo esquema referenciado no registro de esquemas pode ser incompatível. Isso pode resultar na falha de seus trabalhos.

API do AWS Glue

Ao chamar a API `UpdateTable`, você transmitirá uma `TableInput` que contém um `StorageDescriptor` que, por sua vez, contém uma `SchemaReference` para um esquema existente no registro de esquemas.

Console do AWS Glue

Para atualizar o esquema de uma tabela a partir do console do AWS Glue:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (Catálogo de dados), escolha Tables (Tabelas).
3. Exiba a tabela na lista de tabelas.
4. Clique em Update schema (Atualizar esquema) na caixa que informa sobre uma nova versão.
5. Revise as diferenças entre o esquema atual e o novo.
6. Escolha Show all schema differences (Mostrar todas as diferenças do esquema) para ver mais detalhes.
7. Escolha Save table (Salvar tabela) para aceitar a nova versão.

Caso de uso: transmissão no AWS Glue

A transmissão no AWS Glue consome dados de fontes de transmissão e executa operações de ETL antes de gravar em um coletor de saída. É possível especificar a fonte de entrada da transmissão usando uma tabela de dados ou diretamente, especificando a configuração da fonte.

A transmissão no AWS Glue oferece suporte a uma tabela do tipo Data Catalog para a fonte de transmissão criada com o esquema presente no AWS Glue Schema Registry. Você pode criar um esquema no AWS Glue Schema Registry e criar uma tabela do AWS Glue com uma fonte de transmissão usando esse esquema. Essa tabela do AWS Glue pode ser usada como entrada para um trabalho de transmissão do AWS Glue para desserialização de dados no fluxo de entrada.

É importante ressaltar que quando o esquema no AWS Glue Schema Registry muda, você precisa reiniciar o trabalho de transmissão do AWS Glue para refletir as alterações no esquema.

Caso de uso: Apache Kafka Streams

A API Apache Kafka Streams é uma biblioteca cliente para processamento e análise de dados armazenados no Apache Kafka. Esta seção descreve a integração do Apache Kafka Streams com o registro de esquemas do AWS Glue, que permite que você gerencie e imponha esquemas em suas

aplicações de transmissão de dados. Para obter mais informações sobre o Apache Kafka Streams, consulte Apache Kafka Streams.

Integração com as bibliotecas SerDes

Existe uma classe `GlueSchemaRegistryKafkaStreamsSerde` com a qual você pode configurar uma aplicação do Streams.

Código de exemplo da aplicação Kafka Streams

Para usar o registro de esquemas do AWS Glue dentro de uma aplicação Apache Kafka Streams:

1. Configure a aplicação 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. Crie uma transmissão a partir do tópico avro-input.

```
StreamsBuilder builder = new StreamsBuilder();
final KStream<String, GenericRecord> source = builder.stream("avro-input");
```

3. Processe os registros de dados (o exemplo filtra aqueles registros cujo valor de favorite_color é rosa ou onde o valor de quantidade é 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. Grave os resultados de volta no tópico avro-output.

```
result.to("avro-output");
```

5. Inicie a aplicação Apache Kafka Streams.

```
KafkaStreams streams = new KafkaStreams(builder.build(), props);
streams.start();
```

Resultados de implantação

Esses resultados mostram o processo de filtragem de registros que foram filtrados na etapa 3 como um favorite_color “rosa” ou o valor “15,0”.

Registros antes da filtragem:

```
{"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}
```

Registros após a filtragem:

```
{"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}
```

Caso de uso: Apache Kafka Connect

A integração do Apache Kafka Connect com o registro de esquemas do AWS Glue permite que você obtenha informações de esquema dos conectores. Os conversores Apache Kafka especificam o formato dos dados dentro do Apache Kafka e como traduzi-los em dados do Apache Kafka Connect. Cada usuário do Apache Kafka Connect precisará configurar esses conversores com base no formato em que deseja que seus dados sejam carregados do, ou armazenados no, Apache Kafka. Desta forma, você pode definir seus próprios conversores para traduzir os dados do Apache Kafka Connect para o tipo usado no registro de esquemas do AWS Glue (por exemplo: Avro) e utilizar nosso serializador para registrar seu esquema e fazer a serialização. Em seguida, os conversores também são capazes de usar nosso desserializador para desserializar os dados recebidos do Apache Kafka e convertê-los de volta em dados do Apache Kafka Connect. Um exemplo de diagrama de fluxo de trabalho é dado abaixo.

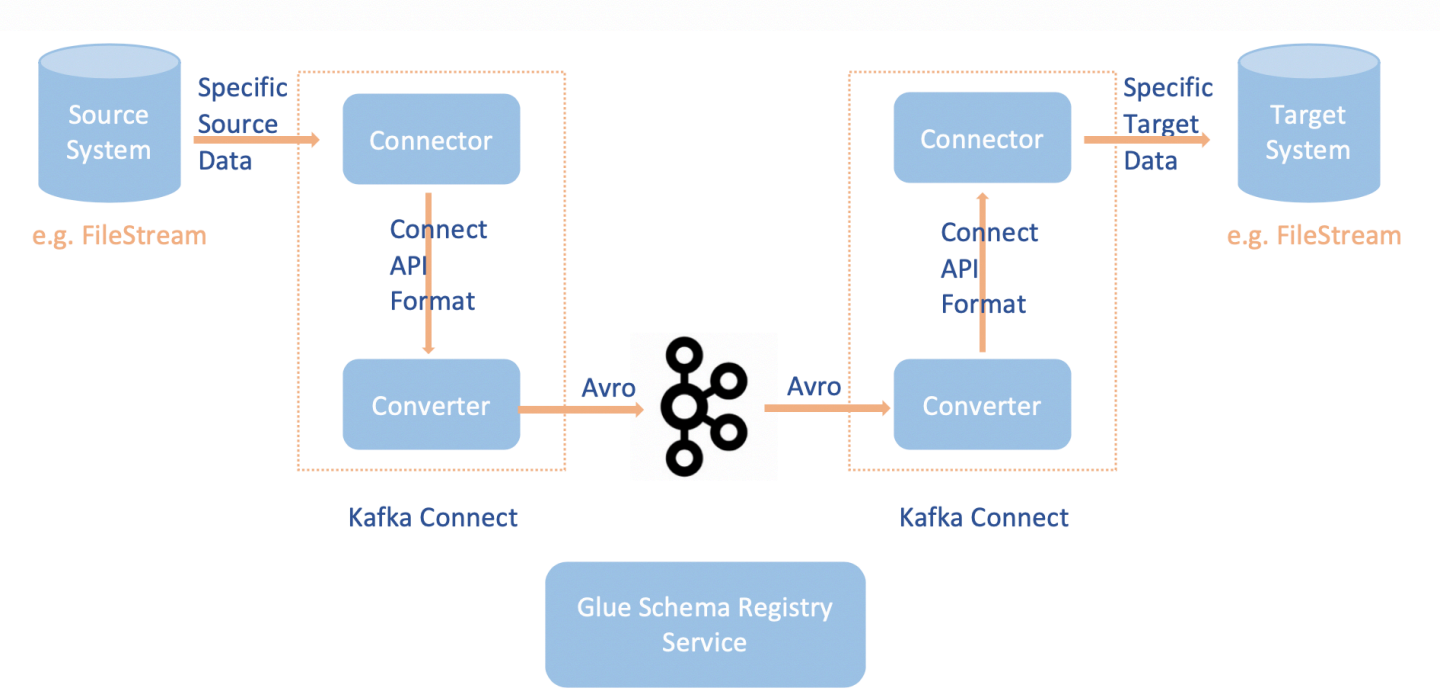

1. Instale o projeto `aws-glue-schema-registry` clonando o repositório do Github para o registro de esquemas do AWS Glue.

```
git clone git@github.com:awslabs/aws-glue-schema-registry.git
cd aws-glue-schema-registry
mvn clean install
mvn dependency:copy-dependencies
```

2. Se você planeja usar o Apache Kafka Connect no modo autônomo, atualize connect-standalone.properties usando as instruções abaixo para esta etapa. Se você planeja usar o Apache Kafka Connect no modo distribuído, atualize connect-avro-distributed.properties usando as mesmas instruções.

   a. Adicione essas propriedades também ao arquivo de propriedades de conexão do 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. Adicione o comando abaixo à seção Launch mode (Modo de execução) em kafka-run-class.sh:

   ```
   -cp $CLASSPATH:"<your AWS GlueSchema Registry base directory>/target/dependency/*"
   ```

3. Adicione o comando abaixo à seção Launch mode (Modo de execução) em kafka-run-class.sh

   ```
   -cp $CLASSPATH:"<your AWS GlueSchema Registry base directory>/target/dependency/*"
   ```

   A aparência deve ser semelhante a esta:

   ```
   # Launch mode
   if [ "x$DAEMON_MODE" = "xtrue" ]; then
     nohup "$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. Se estiver usando bash, execute os comandos abaixo para configurar seu CLASSPATH em seu bash_profile. Para qualquer outro shell, atualize o ambiente de acordo.

```
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. (Opcional) Se você quiser testar com uma fonte de arquivo simples, clone o conector da fonte do arquivo.

```
git clone https://github.com/mmolimar/kafka-connect-fs.git
cd kafka-connect-fs/
```

   a. Na configuração do conector da fonte, edite o formato de dados para Avro, leitor de arquivos para `AvroFileReader` e atualize um objeto Avro de exemplo a partir do caminho do arquivo em que você está lendo. Por exemplo:

```
vim config/kafka-connect-fs.properties
```

```
fs.uris=<path to a sample avro object>
policy.regexp=^.*\.avro$
file_reader.class=com.github.mmolimar.kafka.connect.fs.file.reader.AvroFileReader
```

   b. Instale o conector da fonte.

```
mvn clean package
echo "export CLASSPATH=\$CLASSPATH:\"\$(find target/ -type f -name '*.jar'| grep
 '\-package' | tr '\n' ':')\"" >>~/.bash_profile
source ~/.bash_profile
```

   c. Atualize as propriedades do coletor em *<your Apache Kafka installation directory>*`/config/connect-file-sink.properties`, atualize o nome do tópico e o nome do arquivo de saída.

```
file=<output file full path>
topics=<my topic>
```

6. Inicie o conector da fonte (neste exemplo, é um conector de fonte de arquivo).

```
$KAFKA_HOME/bin/connect-standalone.sh $KAFKA_HOME/config/connect-
standalone.properties config/kafka-connect-fs.properties
```

7. Execute o conector do coletor (neste exemplo, é um conector de coletor de arquivos).

```
$KAFKA_HOME/bin/connect-standalone.sh $KAFKA_HOME/config/connect-
standalone.properties $KAFKA_HOME/config/connect-file-sink.properties
```

Para obter um exemplo de uso do Kafka Connect, veja o script run-local-tests.sh na pasta de testes de integração no repositório do Github para o registro de esquemas do AWS Glue.

Migração de um registro de esquemas de terceiros para o registro de esquemas do AWS Glue

A migração de um registro de esquemas de terceiros para o registro de esquemas do AWS Glue tem uma dependência do registro de esquemas de terceiros existente e atual. Se houver registros em um tópico do Apache Kafka que tenham sido enviados usando um registro de esquemas de terceiros, os consumidores precisarão do registro de esquemas de terceiros para desserializar esses registros. O `AWSKafkaAvroDeserializer` fornece a capacidade de especificar uma classe secundária de desserialização que aponta para o desserializador de terceiros e é usada para desserializar esses registros.

Há dois critérios para desativação de um esquema de terceiros. Primeiro, a desativação pode ocorrer somente depois que os registros nos tópicos do Apache Kafka usando o registro de esquemas de terceiros não são mais exigidos por e para qualquer consumidor. Em segundo lugar, a desativação pode ocorrer com o vencimento dos tópicos do Apache Kafka, dependendo do período de retenção especificado para esses tópicos. Observe que, se você tiver tópicos com retenção infinita, ainda poderá migrar para o registro de esquemas do AWS Glue, mas não poderá desativar o registro de esquemas de terceiros. Como solução alternativa, você pode usar uma aplicação ou Mirror Maker 2 para ler o tópico atual e produzir para um novo tópico com o registro de esquemas do AWS Glue.

Migração de um registro de esquemas de terceiros para o registro de esquemas do AWS Glue:

1. Crie um registro no registro de esquemas do AWS Glue ou use o registro padrão.
2. Interrompa o consumidor. Modifique-o para incluir o registro de esquemas do AWS Glue como o principal desserializador e o registro de esquemas de terceiros como o secundário.
   - Defina as propriedades do consumidor. Neste exemplo, o secondary_deserializer é definido como um desserializador diferente. O comportamento é o seguinte: o consumidor recupera registros do Amazon MSK e primeiro tenta usar o `AWSKafkaAvroDeserializer`. Se não for possível ler o byte mágico que contém o ID do esquema Avro para o esquema do registro do esquemas do AWS Glue, o `AWSKafkaAvroDeserializer` tenta usar a classe do desserializador fornecida no secondary_deserializer. As propriedades específicas do desserializador secundário também precisam ser fornecidas nas propriedades do consumidor, como schema_registry_url_config e specific_avro_reader_config, como mostrado abaixo.

```
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. Reinicie o consumidor.
4. Interrompa o produtor e aponte o produtor para o registro de esquemas do AWS Glue.
   a. Defina as propriedades do produtor. Neste exemplo, o produtor usará as versões de esquema de registro padrão e registro automático.

```
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. (Opcional) Mova manualmente esquemas e versões de esquema existentes do registro de esquemas de terceiros atual para o registro de esquemas do AWS Glue, seja para o registro padrão no registro de esquemas do AWS Glue ou para um registro não padrão específico no registro de esquemas do AWS Glue. Isso pode ser feito exportando esquemas dos registros de esquemas de terceiros no formato JSON e criando novos esquemas no registro de esquemas do AWS Glue usando o AWS Management Console ou a AWS CLI.

   Esta etapa pode ser importante se você precisar habilitar verificações de compatibilidade com versões de esquema anteriores para versões de esquema recém-criadas usando a AWS CLI e o AWS Management Console. Ou quando os produtores enviam mensagens com um novo esquema com registro automático de versões de esquema ativado.
6. Inicie o produtor.

Conectar a dados

Uma conexão do AWS Glue é um objeto do Data Catalog que armazena credenciais de login, strings de URI, informações de nuvem privada virtual (VPC) e muito mais para determinado armazenamento de dados. Crawlers, trabalhos e endpoints de desenvolvimento do AWS Glue usam conexões do para acessar determinados tipos de armazenamento de dados. É possível usar conexões para fontes e destinos, além de reutilizar a mesma conexão em vários trabalhos de crawler ou de extração, transformação e carregamento (ETL).

A versão mais recente do esquema de conexões do AWS Glue oferece uma forma unificada de gerenciar conexões de dados entre serviços e aplicações da AWS, como AWS Glue, Amazon Athena e Amazon SageMaker AI Unified Studio.

Visão geral do uso de conectores e conexões

Uma conexão que contém as propriedades necessárias para se conectar a um datastore específico. Ao criar uma conexão, ela é armazenada no AWS Glue Data Catalog. Você escolhe um conector e, em seguida, cria uma conexão com base nele.

É possível assinar conectores para armazenamentos de dados não suportados nativamente no AWS Marketplace e, em seguida, usá-los ao criar conexões. Os desenvolvedores também podem criar seus próprios conectores, e é possível usá-los ao criar conexões.

> **Note**
>
> Conexões criadas usando conectores personalizados ou do AWS Marketplace no AWS Glue Studio aparecem no console do AWS Glue com o tipo definido como `UNKNOWN`.

As etapas a seguir descrevem o processo geral do uso de conectores no AWS Glue Studio:

1. Assine um conector no AWS Marketplace ou desenvolva seu próprio conector e carregue-o no AWS Glue Studio. Para obter mais informações, consulte Adição de conectores ao AWS Glue Studio.
2. Revise as informações de uso do conector. É possível encontrar essas informações na guia Uso na página de produto do conector. Por exemplo, se clicar na guia Utilização na página deste

produto, Conector do AWS Glue para o Google BigQuery, será possível ver, na seção Recursos adicionais, um link para um blog sobre o uso desse conector.

3. Crie uma conexão. Você escolhe qual conector usar e fornece informações adicionais para a conexão, como credenciais de login, strings de URI e informações da nuvem privada virtual (VPC). Para obter mais informações, consulte Criar conexões para conectores.
4. Crie um perfil do IAM para o seu trabalho. O trabalho assume a permissão de IAM role que você especificou ao criá-lo. Esse perfil do IAM precisa ter as permissões obrigatórias para autenticar com, extrair dados de e gravar dados em seus armazenamentos de dados.
5. Crie um trabalho de ETL e configure as propriedades da origem dos dados para o seu trabalho de ETL. Forneça as opções de conexão e as informações de autenticação conforme instruído pelo provedor de conector personalizado. Para obter mais informações, consulte Criação de trabalhos com conectores personalizados.
6. Personalize seu trabalho de ETL adicionando transformações ou armazenamentos de dados adicionais, conforme descrito em Iniciar trabalhos de ETL visual no AWS Glue Studio.
7. Se estiver usando um conector para o destino de dados, configure as propriedades de destino de dados para seu trabalho de ETL. Forneça as opções de conexão e as informações de autenticação conforme instruído pelo provedor de conector personalizado. Para obter mais informações, consulte the section called “Criação de trabalhos com conectores personalizados”.
8. Personalize o ambiente de execução de trabalho configurando as propriedades do trabalho, conforme descrito em Modificar as propriedades do trabalho.
9. Execute o trabalho.

Conexões unificadas

A AWS introduziu recentemente um novo recurso chamado “SageMaker LakeHouse Connections” ou “AWS Glue Unified Connections”. Esse recurso permite a criação de conexões que podem ser usadas por diversos serviços da AWS, como o AWS Glue e o Amazon Athena. Durante a criação de uma fonte de dados no Amazon Athena, será exibida uma seção que faz referência às entradas de conexão do AWS Glue. Nesse caso, o Amazon Athena criará uma conexão do AWS Glue automaticamente para você, incluindo as propriedades específicas do Amazon Athena na seção “AthenaProperties” da conexão.

Em contrapartida, ao criar uma conexão diretamente no AWS Glue, você receberá uma solicitação para fornecer apenas as propriedades específicas do AWS Glue e so Apache Spark, que serão armazenadas nas seções “ConnectionProperties” e “SparkProperties” da conexão.

Em ambos os cenários, o resultado é a criação de uma “conexão unificada”, porém as conexões criadas no Amazon Athena são configuradas exclusivamente para seu uso dentro do Amazon Athena, enquanto as conexões criadas no AWS Glue são limitadas ao uso dentro do AWS Glue. No entanto, é possível realizar a atualização dessas conexões, inserindo as propriedades ausentes (como as propriedades do Amazon Athena ou do Spark), de modo a torná-las compatíveis para uso em ambos os serviços. O Estúdio Unificado Amazon SageMaker AI realiza essa tarefa automaticamente ao preencher todas as propriedades necessárias (“ConnectionProperties”, “AthenaProperties” e “SparkProperties”) na conexão do AWS Glue, garantindo que a conexão possa ser usada tanto pelo AWS Glue quanto pelo Amazon Athena.

É importante observar que, embora nos refiramos a essas conexões como “conexões unificadas”, as conexões criadas individualmente no AWS Glue ou no Amazon Athena não são verdadeiramente unificadas, a menos que sejam configuradas adequadamente para uso em ambos os serviços. Somente as conexões criadas por meio do Estúdio Unificado SageMaker são completamente unificadas e podem ser usadas por vários serviços imediatamente, sem a necessidade de configurações adicionais.

Além disso, as conexões criadas no AWS Glue não são visíveis no Amazon Athena, pois o Amazon Athena exibe fontes de dados que fazem referência a uma conexão do AWS Glue, mas não correspondem diretamente à conexão do AWS Glue. De forma semelhante, as conexões criadas no Amazon Athena não são visíveis no AWS Glue Studio, pois o AWS Glue Studio exclui qualquer conexão que não tenha sido devidamente configurada com as configurações exigidas para o AWS Glue.

Por padrão, o AWS Glue Studio cria conexões unificadas. No console do AWS Glue, é possível ver a versão da conexão na tabela de conexões na página de conexões, na página de detalhes das conexões e na tabela de conexões na página de detalhes do trabalho.

A versão da conexão é visível nos detalhes da conexão:

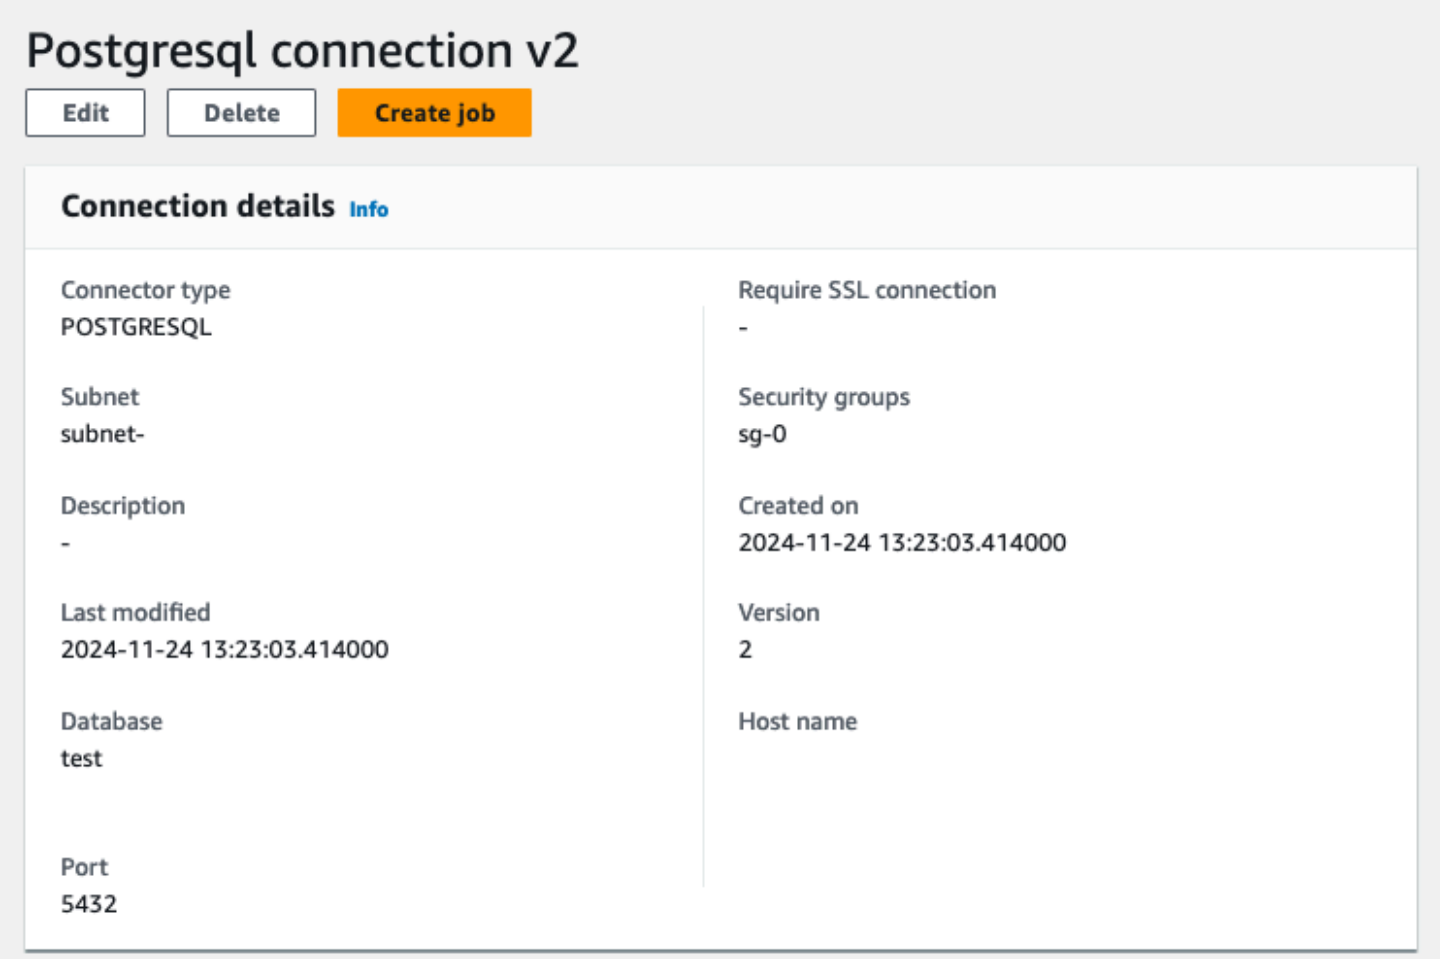

A versão da conexão também é visível ao visualizar todas as suas conexões.

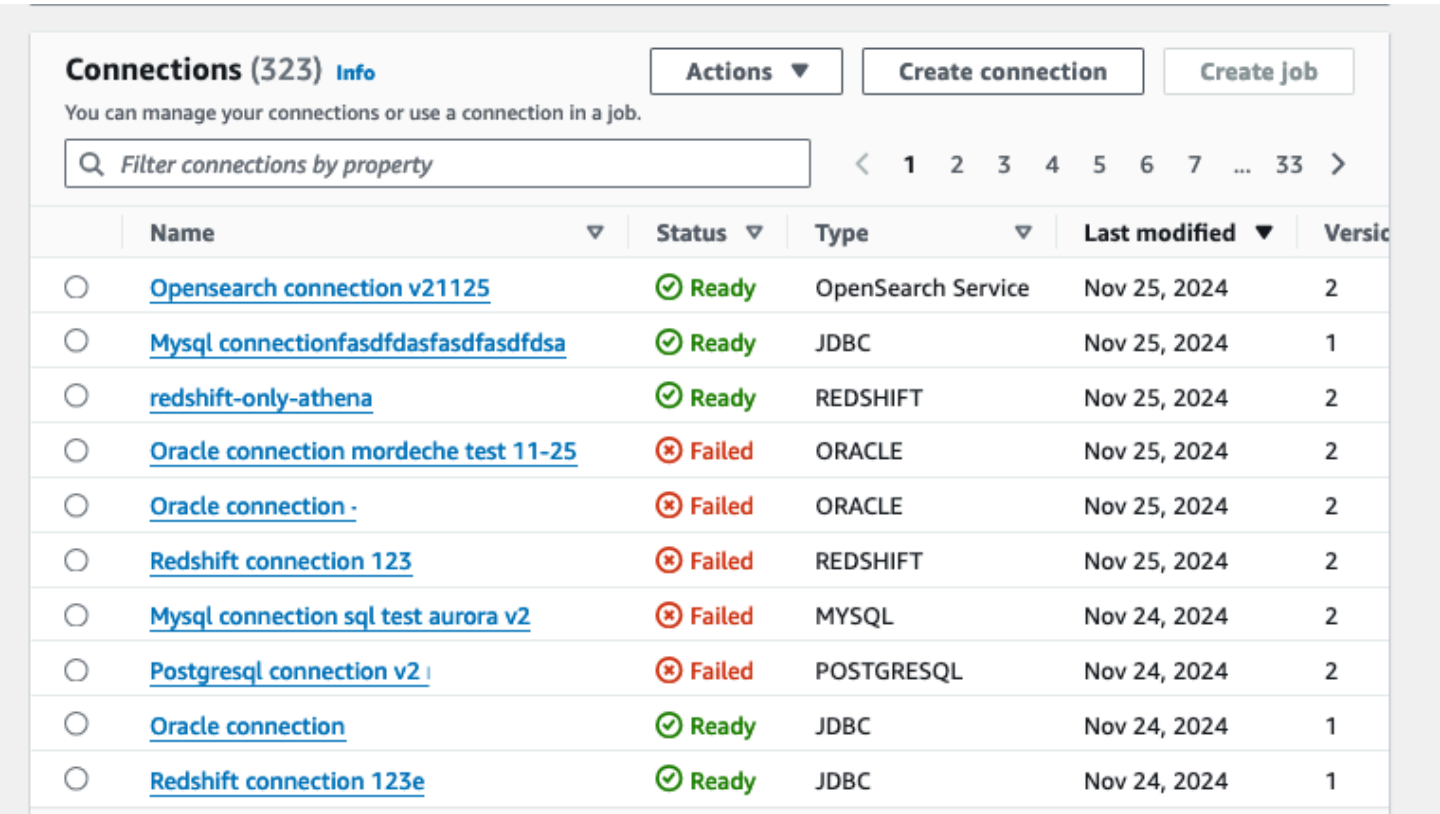

Finalmente, a versão da conexão está visível na guia Detalhes do trabalho para um trabalho.

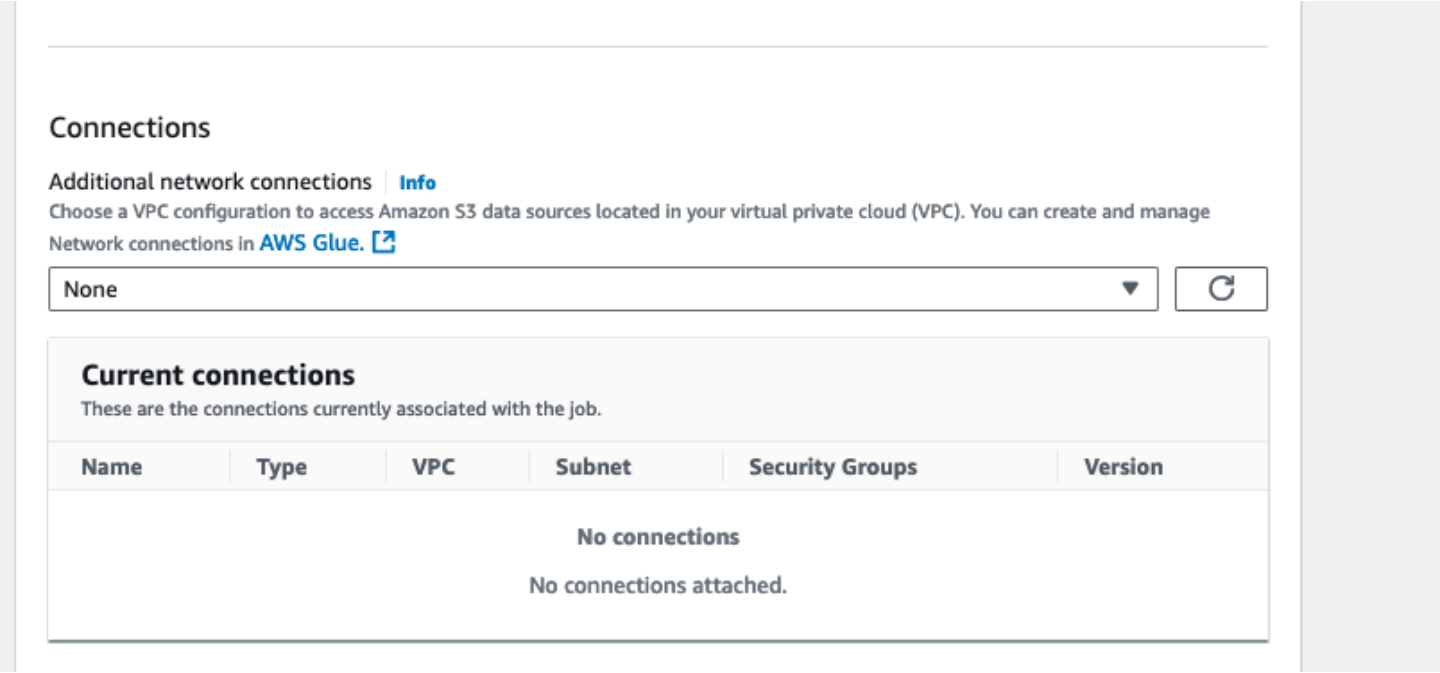

Com as conexões da versão 2, os seguintes recursos expandidos de conectividade de dados estão disponíveis:

- Descoberta do tipo de conexão: suporte à criação de conexões usando modelos padronizados. O AWS Glue descobre automaticamente os tipos de conexão acessíveis por você e as entradas necessárias e opcionais para um determinado tipo de conexão.
- Reutilização: definições de conexão que são reutilizáveis em mecanismos e ferramentas de processamento de dados da AWS, como AWS Glue, Amazon Athena e Amazon SageMaker AI. As conexões agora contêm AthenaProperties, SparkProperties e PythonProperties, que permitem especificar propriedades de conexão específicas do serviço/ambiente computacional, além das propriedades comuns armazenadas em ConnectionProperties. O Athena agora cria conexões no AWS Glue especificando propriedades específicas do Athena no mapa de propriedades AthenaProperties.
- Prévia de dados: capacidade de pesquisar metadados e visualizar uma prévia dos dados de fontes conectadas.
- Metadados do conector: conexões reutilizáveis podem ser usadas para descobrir os metadados da tabela.
- Segredos vinculados ao serviço: os usuários podem fornecer as credenciais de autenticação OAuth, básica ou personalizada necessárias na solicitação `CreateConnection`. A API CreateConnection cria um segredo vinculado ao serviço em sua conta e armazena as credenciais em seu nome.

Tipos de autenticação compatíveis

As conexões unificadas são compatíveis com os seguintes tipos de autenticação:

- BÁSICA: a maioria dos tipos de conexão de banco de dados e dos tipos de conexão existentes do AWS Glue oferecem suporte à autenticação básica, que é um nome de usuário e senha. Anteriormente, a nomenclatura das chaves no SecretsManager era específica do conector e, por exemplo, poderia ser user, username, userName, opensearch.net.http.auth.user etc. As conexões unificadas padronizaram esses tipos de conexão de autenticação básica nas chaves USERNAME e PASSWORD.
- OAUTH2: a maioria dos tipos de conexão SaaS lançados recentemente oferece suporte ao protocolo OAuth2.
- PERSONALIZADA: alguns tipos de conexão têm outro mecanismo de autenticação, como o Google BigQuery, em que os usuários precisam fornecer o JSON obtido do Google BigQuery.

Considerações

Ao criar uma conexão unificada para fontes de dados, considere as seguintes diferenças:

- Ao criar uma conexão unificada via AWS Glue Studio, as credenciais do usuário são armazenadas em AWS Secrets Manager em vez da própria conexão. Isso significa que os trabalhos agora precisam de acesso ao Secrets Manager.
- Se os trabalhos forem executados em uma VPC, eles precisarão de um endpoint da VPC ou de um gateway NAT para acessar AWS Secrets Manager e o Secure Token Service (STS), o que gerará custos adicionais.
- Para determinadas fontes de dados (Redshift, SQL Server, MySQL, Oracle, PostgreSQL), a criação de uma conexão unificada via AWS Glue Studio requer acesso ao AWS STS e ao AWS Secrets Manager. Isso é necessário para estabelecer uma conexão segura e recuperar as credenciais necessárias para acessar essas fontes de dados em sua nuvem privada virtual (VPC).
- A criação de uma conexão unificada via AWS Glue Studio requer um perfil do IAM com permissões para acessar AWS Secrets Manager e gerenciar recursos da VPC (se estiver usando uma VPC):
  - secretsmanager:GetSecretValue
  - secretsmanager:PutSecretValue
  - secretsmanager:DescribeSecret
  - ec2:CreateNetworkInterface
  - ec2:DeleteNetworkInterface
  - ec2:DescribeNetworkInterfaces
  - ec2:DescribeSubnets

Conexões disponíveis

O AWS Glue é compatível com os seguintes tipos de conexão:

- Adobe Analytics
- Adobe Marketo Engage
- Amazon Aurora (compatível se o driver JDBC nativo estiver sendo usado. Nem todos os recursos do driver podem ser aproveitados)
- Amazon DocumentDB
- Amazon DynamoDB

- Amazon OpenSearch Service para uso com o AWS Glue para Spark.
- Amazon Redshift
- Asana
- Azure Cosmos, para uso do Azure Cosmos DB para NoSQL com trabalhos do AWS Glue ETL
- Azure SQL, para uso com o AWS Glue para Spark.
- Blackbaud
- CircleCI
- Datadog
- Docusign Monitor
- Domo
- Dynatrace
- Facebook Ads
- Facebook Page Insights
- Freshdesk
- Freshsales
- Google Ads
- Google Analytics 4
- Google BigQuery, para uso com o AWS Glue para Spark.
- Google Search Console
- Planilhas Google
- HubSpot
- Instagram Ads
- Intercom
- JDBC
- Jira Cloud
- Kafka
- Kustomer
- LinkedIn
- Mailchimp

- Microsoft Teams
- Mixpanel
- Segunda-feira
- MongoDB
- MongoDB Atlas
- Okta
- Oracle NetSuite
- PayPal
- Pendo
- Pipedrive
- Productboard
- QuickBooks
- Salesforce
- Salesforce Commerce Cloud
- Salesforce Marketing Cloud
- Salesforce Marketing Cloud Account Engagement (anteriormente, Salesforce Pardot)
- SAP HANA, para uso com o AWS Glue para Spark.
- SAP OData
- SendGrid
- ServiceNow
- Slack
- Smartsheet
- Snapchat Ads
- Stripe
- Snowflake, para uso com o AWS Glue para Spark.
- Teradata Vantage, quando o AWS Glue para Spark é usado.
- Twilio
- Vertica, para uso com o AWS Glue para Spark.
- WooCommerce
- Zendesk

- Zoho CRM
- Zoom Meetings
- Várias ofertas do Amazon Relational Database Service (Amazon RDS).
- Rede (designa uma conexão para uma fonte de dados que esteja dentro de um ambiente da Amazon Virtual Private Cloud [Amazon VPC])

Com o AWS Glue Studio, você também pode criar uma conexão para um conector. Um conector é um pacote de código opcional que ajuda a acessar armazenamentos de dados no AWS Glue Studio. Para obter mais informações, consulte Uso de conectores e conexões com o AWS Glue Studio

Para obter informações sobre como se conectar a bancos de dados on-premises, consulte Como acessar e analisar armazenamentos de dados on-premises usando o AWS Glue no site do blog Big Data da AWS.

Para criar uma conexão com a configuração da VPC ao usar um perfil do IAM personalizado, é necessário que ele tenha as seguintes ações de acesso à VPC:

- secretsmanager:GetSecretValue
- secretsmanager:PutSecretValue
- secretsmanager:DescribeSecret
- ec2:CreateNetworkInterface
- ec2:DeleteNetworkInterface
- ec2:DescribeNetworkInterfaces
- ec2:DescribeSubnets

Limitações

- Você não poderá editar conexões via console do AWS Glue se tiver criado uma conexão v2 usando APIs do AWS Glue:
  - Amazon DocumentDB
  - Amazon Aurora
  - MariaDB
  - MongoDB Atlas
  - MongoDB

Propriedades da conexão do AWS Glue

Este tópico inclui informações sobre propriedades para conexões do AWS Glue.

Tópicos

- Requisitos de propriedades de conexão
- Propriedades da conexão JDBC do AWS Glue
- Propriedades de conexão do MongoDB e do MongoDB Atlas no AWS Glue
- Propriedades de conexão do Salesforce
- Conexão do Snowflake
- Conexão do Vertica
- Conexão do SAP HANA
- Conexão do Azure SQL
- Conexão do Teradata Vantage
- Conexão do OpenSearch Service
- Conexão do Azure Cosmos
- Propriedades de conexão SSL do AWS Glue
- Propriedades de conexão do Apache Kafka para autenticação do cliente
- Conexão do Google BigQuery
- Conexão do Vertica

Requisitos de propriedades de conexão

Quando você define uma conexão no console do AWS Glue, é necessário fornecer valores para as seguintes propriedades:

Connection name (Nome da conexão)

Insira um nome exclusivo para a conexão.

Tipo de conexão

Escolha JDBC ou um dos tipos de conexão específicos.

Para obter detalhes sobre o tipo de conexão JDBC, consulte the section called “Propriedades da conexão JDBC”

Escolha Network (Rede) para conectar a uma origem dos dados dentro de um ambiente da Amazon Virtual Private Cloud (Amazon VPC).

Dependendo do tipo escolhido, o console do AWS Glue exibe outros campos obrigatórios. Por exemplo, se você escolher Amazon RDS, deverá escolher o mecanismo de banco de dados.

Exigir conexão SSL

Ao selecionar essa opção, o AWS Glue deve verificar se a conexão com o datastore está conectada por meio de uma Secure Sockets Layer (SSL) confiável.

Para obter mais informações, incluindo opções adicionais que estão disponíveis quando ao escolher essa opção, consulte the section called “Propriedades de conexão SSL”.

Selecione o cluster do MSK (somente Amazon Managed Streaming for Apache Kafka [MSK])

Especifica um cluster do MSK de outra conta da AWS.

URLs do servidor de bootstrap do Kafka (somente Kafka)

Especifica uma lista separada por vírgulas de URLs de servidor de bootstrap. Inclua o número da porta. Por exemplo: 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

Propriedades da conexão JDBC do AWS Glue

O AWS Glue Studio agora cria conexões unificadas para fontes de dados de MySQL, Oracle, PostgreSQL, Redshift e SQL Server, o que requer etapas adicionais para acessar os recursos do Secrets Manager e da VPC, o que pode gerar custos adicionais. É possível acessar essas conexões em AWS Glue Studio escolhendo o nome da respectiva conexão.

Para ter mais informações, consulte Considerações.

O AWS Glue pode se conectar aos seguintes armazenamentos de dados por meio de uma conexão JDBC:

- Amazon Redshift
- Amazon Aurora
- Microsoft SQL Server

- MySQL
- Oracle
- PostgreSQL
- Snowflake, ao usar crawlers do AWS Glue.
- Aurora (compatível se o driver JDBC nativo estiver sendo usado. Nem todos os atributos do driver podem ser aproveitados)
- Amazon RDS for MariaDB

> **Important**
>
> Atualmente, um trabalho de ETL só pode usar uma conexão JDBC dentro de uma sub-rede. Se você tiver vários armazenamentos de dados em um trabalho, eles deverão estar na mesma sub-rede ou poder ser acessados na sub-rede.
> Se você optar por trazer suas próprias versões do driver JDBC para os crawlers do AWS Glue, eles consumirão recursos em trabalhos do AWS Glue e do Amazon S3 para garantir que os drivers fornecidos sejam executados em seu ambiente. O uso adicional de recursos será refletido em sua conta. Além disso, fornecer seu próprio driver JDBC não significa que o crawler seja capaz de aproveitar todos os recursos do driver. Os drivers estão limitados às propriedades descritas em Definir conexões no catálogo de dados.

Veja a seguir as propriedades adicionais para o tipo de conexão JDBC.

JDBC URL

Insira o URL do datastore JDBC. Para a maioria dos mecanismos de banco de dados, este campo estará no seguinte formato. Nesse formato, substitua *protocol* (protocolo), *host*, *port* (porta) e *db_name* (nome do bd) por suas próprias informações.

`jdbc:`*`protocol`*`://`*`host`*`:`*`port`*`/`*`db_name`*

Dependendo do mecanismo de banco de dados, pode ser necessário um formato diferente de URL JDBC. Esse formato pode ter um uso um pouco diferente do ponto e vírgula (:) e da barra (/) ou conter palavras-chave diferentes para especificar bancos de dados.

Para que o JDBC se conecte ao datastore, é necessário ter um `db_name` no datastore. O `db_name` é usado para estabelecer uma conexão de rede com `username` e `password`

fornecidos. Quando conectado, o AWS Glue pode acessar outros bancos de dados no datastore para executar um crawler ou um trabalho de ETL.

Os seguintes exemplos de URL JDBC mostram a sintaxe de vários mecanismos de banco de dados.

- Para se conectar a um datastore do cluster do Amazon Redshift com um banco de dados `dev`:

  ```
  jdbc:redshift://xxx.us-east-1.redshift.amazonaws.com:8192/dev
  ```

- Para se conectar a um datastore do Amazon RDS for MySQL com um banco de dados `employee`:

  ```
  jdbc:mysql://xxx-cluster.cluster-xxx.us-east-1.rds.amazonaws.com:3306/employee
  ```

- Para se conectar a um datastore do Amazon RDS for PostgreSQL com um banco de dados `employee`:

  ```
  jdbc:postgresql://xxx-cluster.cluster-xxx.us-east-1.rds.amazonaws.com:5432/employee
  ```

- Para se conectar a um datastore do Amazon RDS for Oracle com um nome de serviço `employee`:

  ```
  jdbc:oracle:thin://@xxx-cluster.cluster-xxx.us-east-1.rds.amazonaws.com:1521/employee
  ```

  A sintaxe do Amazon RDS for Oracle pode seguir os seguintes padrões. Nesses padrões, substitua *`host`*, *`port`* (porta), *`service_name`* (nome do serviço) e *`SID`* por suas próprias informações.

  - `jdbc:oracle:thin://@`*`host`*`:`*`port`*`/`*`service_name`*
  - `jdbc:oracle:thin://@`*`host`*`:`*`port`*`:`*`SID`*

- Para se conectar a um datastore do Amazon RDS for Microsoft SQL Server com um banco de dados `employee`:

  ```
  jdbc:sqlserver://xxx-cluster.cluster-xxx.us-east-1.rds.amazonaws.com:1433;databaseName=employee
  ```

  A sintaxe do Amazon RDS for SQL Server pode seguir os seguintes padrões. Nesses padrões, substitua *`server_name`*, *`port`* e *`db_name`* com suas próprias informações.

  - `jdbc:sqlserver://`*`server_name`*`:`*`port`*`;database=`*`db_name`*

  - `jdbc:sqlserver://server_name:port;databaseName=db_name`
- Para se conectar a uma instância do Amazon Aurora PostgreSQL do banco de dados `employee`, especifique o endpoint para a instância do banco de dados, a porta e o nome do banco de dados:

  ```
  jdbc:postgresql://employee_instance_1.xxxxxxxxxxxx.us-
  east-2.rds.amazonaws.com:5432/employee
  ```
- Para se conectar a um datastore Amazon RDS for MariaDB com um banco de dados `employee`, especifique o endpoint para a instância do banco de dados, a porta e o nome do banco de dados:

  ```
  jdbc:mysql://xxx-cluster.cluster-xxx.aws-
  region.rds.amazonaws.com:3306/employee
  ```
-

  > **Warning**
  >
  > As conexões JDBC do Snowflake só são compatíveis com crawlers do AWS Glue. Ao usar o conector do Snowflake em trabalhos do AWS Glue, use o tipo de conexão do Snowflake.

  Para se conectar a uma instância do banco de dados `sample` do Snowflake, especifique o endpoint para a instância do Snowflake, o usuário, o nome do banco de dados e o nome do perfil. É possível, opcionalmente, adicionar o parâmetro `warehouse`.

  ```
  jdbc:snowflake://account_name.snowflakecomputing.com/?
  user=user_name&db=sample&role=role_name&warehouse=warehouse_name
  ```

  > **Important**
  >
  > Para conexões do Snowflake por JDBC, a ordem dos parâmetros no URL é imposta e deve ser ordenada como `user`, db `role_name` e `warehouse`.
- Para se conectar a uma instância do banco de dados `sample` do Snowflake com link privado da AWS, especifique o URL JDBC do Snowflake da seguinte forma:

  ```
  jdbc:snowflake://account_name.region.privatelink.snowflakecomputing.com/?
  user=user_name&db=sample&role=role_name&warehouse=warehouse_name
  ```

Nome de usuário

> **Note**
>
> Em vez de fornecer seu nome de usuário e senha diretamente, recomendamos usar um segredo do AWS para armazenar credenciais de conexão. Para ter mais informações, consulte Armazenando credenciais de conexão em AWS Secrets Manager.

Forneça um nome de usuário que tenha permissão para acessar o datastore JDBC.

Senha

Insira a senha para o nome de usuário que tem permissão de acesso ao datastore JDBC.

Port (Porta)

Insira a porta usada no URL do JDBC para se conectar a uma instância do Amazon RDS para Oracle. Esse campo é exibido somente quando a opção Require SSL connection (Exigir conexão SSL) é selecionada para uma instância do Amazon RDS Oracle.

VPC

Escolha o nome da nuvem privada virtual (VPC) que contém seu datastore. O console do AWS Glue lista todas as VPCs da região atual.

> **Important**
>
> Ao trabalhar em uma conexão JDBC hospedada fora do AWS, como com dados do Snowflake, a VPC deve ter um gateway NAT que divida o tráfego em sub-redes públicas e privadas. A sub-rede pública é usada para conexão com a fonte externa e a sub-rede interna é usada para processamento pelo AWS Glue. Para obter informações sobre como configurar a Amazon VPC para conexões externas, leia Estabelecer conexão com a Internet ou a outras redes usando dispositivos NAT e Configurar um Amazon VPC para conexões JDBC aos armazenamentos de dados do Amazon RDS desde o AWS Glue.

Sub-rede

Escolha a sub-rede dentro da VPC que contém seu datastore. O console do AWS Glue lista todas as sub-redes do datastore na sua VPC.

Grupos de segurança

Escolha os grupos de segurança associados ao seu datastore. O AWS Glue requer um ou mais grupos de segurança com uma regra de origem de entrada que permita a conexão do AWS Glue. O console do AWS Glue lista todos os grupos de segurança que recebem acesso de entrada à sua VPC. O AWS Glue associa esses grupos de segurança à interface de rede elástica anexada à sua sub-rede VPC.

Nome da classe do driver JDBC - opcional

Forneça o nome da classe do driver JDBC personalizado:

- 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.SQLServerDriver

Caminho do driver JDBC do S3: optional

Forneça a localização do Amazon S3 para o driver JDBC personalizado. Esse é um caminho absoluto para um arquivo.jar. Se quiser fornecer seus próprios drivers JDBC para se conectar às fontes de dados dos bancos de dados compatíveis com crawlers, é possível especificar valores para parâmetros `customJdbcDriverS3Path` e `customJdbcDriverClassName`.
O uso de um driver JDBC fornecido por um cliente é limitado às Requisitos de propriedades de conexão necessárias.

Propriedades de conexão do MongoDB e do MongoDB Atlas no AWS Glue

As propriedades adicionais para o tipo de conexão do MongoDB ou do MongoDB Atlas são as que se seguem.

URL do MongoDB

Insira o URL do datastore MongoDB ou MongoDB Atlas:

- Para o MongoDB: mongodb://host:port/database. O host pode ser um nome de host, um endereço IP ou um soquete de domínio do UNIX. Se a string de conexão não especificar uma porta, a porta padrão do MongoDB, 27017, será usada.
- Para o MongoDB Atlas: mongodb+srv://server.example.com/database. O host pode ser um nome de host que corresponde a um registro SRV do DNS. O formato SRV não requer porta e usará a porta 27017, padrão do MongoDB.

Nome de usuário

> **Note**
>
> Em vez de fornecer seu nome de usuário e senha diretamente, recomendamos usar um segredo do AWS para armazenar credenciais de conexão. Para ter mais informações, consulte Armazenando credenciais de conexão em AWS Secrets Manager.

Forneça um nome de usuário que tenha permissão para acessar o datastore JDBC.

Senha

Insira a senha para o nome de usuário que tem permissão de acesso ao datastore MongoDB ou MongoDB Atlas.

Propriedades de conexão do Salesforce

Veja a seguir as propriedades adicionais para o tipo de conexão do Salesforce.

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Salesforce.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Salesforce que deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.

- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `IMPORT_DELETED_RECORDS`(string): (padrão): FALSE. Usado para leitura. Para obter os registros excluídos durante a consulta.
- `WRITE_OPERATION`(string): padrão: INSERT. Usado para gravação. O valor deve ser INSERT, UPDATE, UPSERT, DELETE.
- `ID_FIELD_NAMES`(string): padrão: null. Usado apenas para UPSERT.

Conexão do Snowflake

As propriedades a seguir são usadas para configurar uma conexão do Snowflake usada em trabalhos de ETL do AWS Glue. Ao fazer crawling no Snowflake, use uma conexão JDBC.

URL do Snowflake

O URL do endpoint do Snowflake. Para obter mais informações sobre as URLs de endpoint do Snowflake, consulte Connecting to Your Accounts na documentação do Snowflake.

Segredo do AWS

O Nome do segredo de um segredo no AWS Secrets Manager. O AWS Glue se conectará ao Snowflake usando as `sfUser` e `sfPassword` do seu segredo.

Perfil do Snowflake (opcional)

Um perfil de segurança do Snowflake que o AWS Glue usará ao se conectar.

Use as propriedades a seguir ao configurar uma conexão com um endpoint do Snowflake hospedado na Amazon VPC usando AWS PrivateLink.

VPC

Escolha o nome da nuvem privada virtual (VPC) que contém seu datastore. O console do AWS Glue lista todas as VPCs da região atual.

Sub-rede

Escolha a sub-rede dentro da VPC que contém seu datastore. O console do AWS Glue lista todas as sub-redes do datastore na sua VPC.

Grupos de segurança

Escolha os grupos de segurança associados ao seu datastore. O AWS Glue requer um ou mais grupos de segurança com uma regra de origem de entrada que permita a conexão do AWS Glue. O console do AWS Glue lista todos os grupos de segurança que recebem acesso de entrada à sua VPC. O AWS Glue associa esses grupos de segurança à interface de rede elástica anexada à sua sub-rede VPC.

Conexão do Vertica

Use as propriedades a seguir para configurar uma conexão do Vertica para trabalhos do AWS Glue ETL.

Host do Vertica

O nome do host da sua instalação do Vertica.

Porta do Vertica

A porta pela qual sua instalação do Vertica está disponível.

Segredo do AWS

O Nome do segredo de um segredo no AWS Secrets Manager. O AWS Glue se conectará ao Vertica usando as chaves do seu segredo.

Use as propriedades a seguir ao configurar uma conexão com um endpoint do Vertica hospedado na Amazon VPC.

VPC

Escolha o nome da nuvem privada virtual (VPC) que contém seu datastore. O console do AWS Glue lista todas as VPCs da região atual.

Sub-rede

Escolha a sub-rede dentro da VPC que contém seu datastore. O console do AWS Glue lista todas as sub-redes do datastore na sua VPC.

Grupos de segurança

Escolha os grupos de segurança associados ao seu datastore. O AWS Glue requer um ou mais grupos de segurança com uma regra de origem de entrada que permita a conexão do AWS Glue.

O console do AWS Glue lista todos os grupos de segurança que recebem acesso de entrada à sua VPC. O AWS Glue associa esses grupos de segurança à interface de rede elástica anexada à sua sub-rede VPC.

Conexão do SAP HANA

Use as propriedades a seguir para configurar uma conexão do SAP HANA para trabalhos do AWS Glue ETL.

URL DO SAP HANA

Um URL JDBC do SAP.

Os URLs JDBC do SAP HANA estão no formato `jdbc:sap://saphanaHostname:saphanaPort/?databaseName=saphanaDBname,ParameterNa`

O AWS Glue requer os seguintes parâmetros de URL do JDBC:

- `databaseName`: um banco de dados padrão no SAP HANA ao qual se conectar.

Segredo do AWS

O Nome do segredo de um segredo no AWS Secrets Manager. O AWS Glue se conectará ao SAP HANA usando as chaves do seu segredo.

Use as seguintes propriedades ao configurar uma conexão com um endpoint do SAP HANA hospedado na Amazon VPC:

VPC

Escolha o nome da nuvem privada virtual (VPC) que contém seu datastore. O console do AWS Glue lista todas as VPCs da região atual.

Sub-rede

Escolha a sub-rede dentro da VPC que contém seu datastore. O console do AWS Glue lista todas as sub-redes do datastore na sua VPC.

Grupos de segurança

Escolha os grupos de segurança associados ao seu datastore. O AWS Glue requer um ou mais grupos de segurança com uma regra de origem de entrada que permita a conexão do AWS Glue. O console do AWS Glue lista todos os grupos de segurança que recebem acesso de entrada à

sua VPC. O AWS Glue associa esses grupos de segurança à interface de rede elástica anexada à sua sub-rede VPC.

Conexão do Azure SQL

Use as propriedades a seguir para configurar uma conexão do Azure SQL para trabalhos do AWS Glue ETL.

URL do Azure SQL

O URL JDBC de um endpoint do Azure SQL.

Essa lista deve estar no seguinte formato: `jdbc:sqlserver://databaseServerName:databasePort;databaseName=azuresqlDBname;`.

O AWS Glue requer as seguintes propriedades de URL:

- `databaseName`: um banco de dados padrão no Azure SQL ao qual se conectar.

Para obter mais informações sobre URLs de JDBC para instâncias gerenciadas Azure SQL, consulte a Documentação da Microsoft.

Segredo do AWS

O Nome do segredo de um segredo no AWS Secrets Manager. O AWS Glue se conectará ao Azure SQL usando as chaves do seu segredo.

Conexão do Teradata Vantage

Use as propriedades a seguir para configurar uma conexão do Teradata Vantage para trabalhos do AWS Glue ETL.

URL do Teradata

Para se conectar a uma instância do Teradata, especifique o nome do host da instância do banco de dados e os parâmetros relevantes do Teradata:

`jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName=Pa`

O AWS Glue é compatível com os seguintes parâmetros de URL de JDBC:

- `DATABASE_NAME`: um banco de dados padrão no Teradata ao qual se conectar.
- `DBS_PORT`: especifica a porta do Teradata, caso não seja a padrão.

Segredo do AWS

O Nome do segredo de um segredo no AWS Secrets Manager. O AWS Glue se conectará ao Teradata Vantage usando as chaves do seu segredo.

Use as seguintes propriedades ao configurar uma conexão com um endpoint do Teradata Vantage hospedado na Amazon VPC:

VPC

Escolha o nome da nuvem privada virtual (VPC) que contém seu datastore. O console do AWS Glue lista todas as VPCs da região atual.

Sub-rede

Escolha a sub-rede dentro da VPC que contém seu datastore. O console do AWS Glue lista todas as sub-redes do datastore na sua VPC.

Grupos de segurança

Escolha os grupos de segurança associados ao seu datastore. O AWS Glue requer um ou mais grupos de segurança com uma regra de origem de entrada que permita a conexão do AWS Glue. O console do AWS Glue lista todos os grupos de segurança que recebem acesso de entrada à sua VPC. O AWS Glue associa esses grupos de segurança à interface de rede elástica anexada à sua sub-rede VPC.

Conexão do OpenSearch Service

Use as propriedades a seguir para configurar uma conexão do OpenSearch Service para trabalhos do AWS Glue ETL.

Endpoint de domínio

Um endpoint de domínio do Amazon OpenSearch Service terá o seguinte formato padrão, https://search-*domainName*-*unstructuredIdContent*.*region*.es.amazonaws.com. Para obter mais informações sobre a identificação do endpoint do domínio, consulte Criar e gerenciar domínios do Amazon OpenSearch Service na documentação do Amazon OpenSearch Service.

Porta

A porta aberta no endpoint.

Segredo do AWS

O Nome do segredo de um segredo no AWS Secrets Manager. O AWS Glue se conectará ao OpenSearch Service usando as chaves do seu segredo.

Use as seguintes propriedades ao configurar uma conexão com um endpoint do OpenSearch Service hospedado na Amazon VPC:

VPC

Escolha o nome da nuvem privada virtual (VPC) que contém seu datastore. O console do AWS Glue lista todas as VPCs da região atual.

Sub-rede

Escolha a sub-rede dentro da VPC que contém seu datastore. O console do AWS Glue lista todas as sub-redes do datastore na sua VPC.

Grupos de segurança

Escolha os grupos de segurança associados ao seu datastore. O AWS Glue requer um ou mais grupos de segurança com uma regra de origem de entrada que permita a conexão do AWS Glue. O console do AWS Glue lista todos os grupos de segurança que recebem acesso de entrada à sua VPC. O AWS Glue associa esses grupos de segurança à interface de rede elástica anexada à sua sub-rede VPC.

Conexão do Azure Cosmos

Use as propriedades a seguir para configurar uma conexão do Azure Cosmos para trabalhos do AWS Glue ETL.

URI do endpoint da conta do Azure Cosmos DB

O endpoint usado para se conectar ao Azure Cosmos. Para obter mais informações, consulte a Documentação do Azure.

Segredo do AWS

O Nome do segredo de um segredo no AWS Secrets Manager. O AWS Glue se conectará ao Azure Cosmos usando as chaves do seu segredo.

Propriedades de conexão SSL do AWS Glue

Veja a seguir detalhes sobre a propriedade Require SSL connection (Exigir conexão SSL).

Se você não precisar de uma conexão SSL, o AWS Glue ignorará falhas ao usar SSL para criptografar uma conexão com o datastore. Consulte a documentação do datastore para obter instruções de configuração. Quando você selecionar essa opção, a execução de trabalho, o crawler ou as declarações de ETL em um endpoint falharão quando o AWS Glue não conseguir estabelecer conexão.

> **Note**
>
> O Snowflake é compatível com uma conexão SSL por padrão, portanto, essa propriedade não se aplica ao Snowflake.

Essa opção é validada no lado do cliente do AWS Glue. Para conexões JDBC, o AWS Glue apenas se conecta via SSL com validação de certificado e nome de host. O suporte à conexão SSL está disponível para:

- Oracle Database
- Microsoft SQL Server
- PostgreSQL
- Amazon Redshift
- MySQL (apenas instâncias do Amazon RDS)
- Amazon Aurora MySQL (apenas instâncias do Amazon RDS)
- Amazon Aurora PostgreSQL (apenas instâncias do Amazon RDS)
- Kafka, que inclui o Amazon Managed Streaming for Apache Kafka
- MongoDB

> **Note**
>
> Para ativar um datastore do Amazon RDS Oracle para usar Require SSL connection (Exigir conexão SSL), é necessário criar e anexar um grupo de opções à instância do Oracle.

1. Faça login no AWS Management Console e abra o console do Amazon RDS em https://console.aws.amazon.com/rds/.
2. Adicione um Option group (Grupo de opções) à instância do Amazon RDS Oracle. Para obter mais informações sobre como adicionar um grupo de opções no console do Amazon RDS, consulte Criar um grupo de opções
3. Adicione uma Opção ao grupo de opções para SSL. A porta que você especifica para o SSL é posteriormente usada quando você cria um URL de conexão JDBC do AWS Glue para a instância do Amazon RDS Oracle. Para obter mais informações sobre como adicionar uma opção no console do Amazon RDS, consulte Adicionar uma opção a um grupo de opções no Manual do usuário do Amazon RDS. Para obter mais informações sobre a opção Oracle SSL, consulte Oracle SSL no Manual do usuário do Amazon RDS.
4. No console do AWS Glue, crie uma conexão com a instância do Amazon RDS Oracle. Na definição da conexão, selecione Require SSL connection (Exigir conexão SSL). Quando solicitado, insira a porta usada na opção Oracle SSL do Amazon RDS.

As propriedades opcionais adicionais a seguir estarão disponíveis quando Require SSL connection (Exigir conexão SSL) for selecionado para uma conexão:

Certificado JDBC personalizado no S3

Se tiver um certificado que está sendo usado para comunicação SSL com os bancos de dados on-premises ou na nuvem, será possível usar esse certificado para conexões SSL com destinos ou fontes de dados do AWS Glue. Insira um local do Amazon Simple Storage Service (Amazon S3) que contenha um certificado raiz personalizado. O AWS Glue usa esse certificado para estabelecer uma conexão SSL com o banco de dados. O AWS Glue lida apenas com certificados X.509. O certificado deve ter codificação DER e ser fornecido no formato PEM de codificação base64.

Se esse campo for deixado em branco, o certificado padrão será usado.

String de certificado JDBC personalizado

Insira informações de certificado específicas do banco de dados JDBC. Essa string é usada para correspondência de domínio ou para correspondência de nome distinto (DN). Para o Oracle Database, essa string é mapeada para o parâmetro `SSL_SERVER_CERT_DN` na seção de segurança do arquivo `tnsnames.ora`. Para o Microsoft SQL Server, essa string é usada como `hostNameInCertificate`.

Veja a seguir um exemplo para o parâmetro `SSL_SERVER_CERT_DN` do Oracle Database.

```
cn=sales,cn=OracleContext,dc=us,dc=example,dc=com
```

Localização do certificado CA privado do Kafka

Se você tiver um certificado que está usando atualmente para comunicação SSL com seu datastore do Kafka, poderá usar esse certificado com a sua conexão do AWS Glue. Esta opção é necessária para armazenamentos de dados do Kafka e é opcional para armazenamentos de dados do Amazon Managed Streaming for Apache Kafka. Insira um local do Amazon Simple Storage Service (Amazon S3) que contenha um certificado raiz personalizado. O AWS Glue usa esse certificado para estabelecer uma conexão SSL com o datastore do Kafka. O AWS Glue lida apenas com certificados X.509. O certificado deve ter codificação DER e ser fornecido no formato PEM de codificação base64.

Ignorar validação de certificado

Marque a caixa de seleção Skip certificate validation (Ignorar validação do certificado) para ignorar a validação do certificado personalizado pelo AWS Glue. Se você optar por validar, o AWS Glue validará o algoritmo de assinatura e o algoritmo de chave pública de assunto para o certificado. Se o certificado falhar na validação, qualquer trabalho de ETL ou crawler que usar a conexão falhará.

Os únicos algoritmos de assinatura permitidos são SHA256withRSA, SHA384withRSA ou SHA512withRSA. Para o algoritmo de chave pública do assunto, o comprimento da chave deve ser pelo menos 2048.

Localização do repositório de chaves do cliente Kafka

A localização no Amazon S3 do arquivo de repositório de chaves para autenticação do lado do cliente Kafka. O caminho deve estar no formato s3://bucket/prefix/filename.jks. Ele deve terminar com o nome do arquivo e a extensão .jks.

Senha do repositório de chaves do cliente Kafka (opcional)

A senha para acessar o repositório de chaves fornecido.

Senha da chave do cliente Kafka (opcional)

Um repositório de chaves pode consistir em várias chaves. Essa é a senha para acessar a chave do cliente a ser usada com a chave do lado do servidor Kafka.

Propriedades de conexão do Apache Kafka para autenticação do cliente

O AWS Glue é compatível com a estrutura Simple Authentication and Security Layer (SASL) para autenticação quando você cria uma conexão do Apache Kafka. A estrutura SASL é compatível com vários mecanismos de autenticação e o AWS Glue oferece os protocolos SCRAM (nome de usuário e senha) e GSSAPI (protocolo Kerberos) e PLAIN.

Use o AWS Glue Studio para configurar um dos seguintes métodos de autenticação de cliente. Para obter mais informações, consulte Creating connections for connectors no AWS Glue Studio User Guide.

- Nenhum - Sem autenticação. Isso é útil se criar uma conexão para fins de teste.
- SASL/SCRAM-SHA-512 - Escolher esse método de autenticação permitirá que você especifique credenciais de autenticação. Existem duas opções disponíveis:
  - Usar o AWS Secrets Manager (recomendado): se você selecionar essa opção, poderá armazenar seu nome de usuário e senha no AWS Secrets Manager e deixar que o AWS Glue acesse esses dados quando necessário. Especifique o segredo que armazena as credenciais de autenticação SSL ou SASL. Para ter mais informações, consulte Armazenando credenciais de conexão em AWS Secrets Manager.
  - Forneça um nome de usuário e senha diretamente.
- SASL/GSSAPI (Kerberos) - se você selecionar essa opção, poderá selecionar o local do arquivo keytab, arquivo krb5.conf e inserir o nome principal do Kerberos e o nome do serviço Kerberos. Os locais do arquivo keytab e do arquivo krb5.conf devem estar em um local do Amazon S3. Como o MSK ainda não oferece suporte a SASL/GSSAPI, essa opção está disponível apenas para clusters Apache Kafka gerenciados pelo cliente. Para obter mais informações, consulte Documentação do MIT Kerberos: Keytab.
- SASL/PLAIN: escolha esse método de autenticação para especificar as credenciais de autenticação. Existem duas opções disponíveis:
  - Usar o AWS Secrets Manager (recomendado): se você selecionar essa opção, poderá armazenar suas credenciais no AWS Secrets Manager e deixar que o AWS Glue acesse as informações quando necessário. Especifique o segredo que armazena as credenciais de autenticação SSL ou SASL.
  - Forneça o nome de usuário e a senha diretamente.
- Autenticação de cliente SSL - se você selecionar essa opção, poderá selecionar o local do keystore do cliente Kafka navegando no Amazon S3. Opcionalmente, é possível inserir a senha do keystore do cliente Kafka e a senha da chave do cliente Kafka.

Conexão do Google BigQuery

As propriedades a seguir são usadas para configurar uma conexão do Google BigQuery usada em trabalhos de ETL do AWS Glue. Para ter mais informações, consulte the section called “Conexões BigQuery”.

Segredo do AWS

O nome secreto de um segredo em AWS Secrets Manager. AWS Glue Os trabalhos de ETL se conectarão ao Google BigQuery usando a `credentials` chave do seu segredo.

Conexão do Vertica

As propriedades a seguir são usadas para configurar uma conexão do Vertica usada em trabalhos do AWS Glue ETL. Para ter mais informações, consulte the section called “Conexões do Vertica”.

Armazenando credenciais de conexão em AWS Secrets Manager

Recomendamos que você use AWS Secrets Manager para fornecer credenciais de conexão para seu armazenamento de dados. Usar o Secrets Manager dessa forma permite AWS Glue acessar seu segredo em tempo de execução para ETL trabalhos e execuções de rastreadores, além de ajudar a manter suas credenciais seguras.

Pré-requisitos

Para usar o Secrets Manager com AWS Glue, você deve conceder AWS Glue permissão à sua IAMfunção para recuperar valores secretos. A política AWS gerenciada `AWSGlueServiceRole` não inclui AWS Secrets Manager permissões. Por exemplo, IAM políticas, consulte Exemplo: permissão para recuperar valores secretos no Guia do AWS Secrets Managerusuário.

Dependendo da configuração da rede, talvez você também precise criar um VPC endpoint para estabelecer uma conexão privada entre você VPC e o Secrets Manager. Para obter mais informações, consulte Usando um AWS Secrets Manager VPC endpoint.

Para criar um segredo para AWS Glue

1. Siga as instruções em Criar e gerenciar segredos no Guia do usuário do AWS Secrets Manager . O exemplo a seguir JSON mostra como especificar suas credenciais na guia Texto simples ao criar um segredo para. AWS Glue

```
{
  "username": "EXAMPLE-USERNAME",
  "password": "EXAMPLE-PASSWORD"
}
```

2. Associe seu segredo a uma conexão usando a AWS Glue Studio interface. Para obter as instruções detalhadas, consulte Creating connections for connectors no AWS Glue Studio User Guide.

Adicionar uma conexão do AWS Glue

Você pode se conectar a fontes de dados no Spark AWS Glue de forma programática. Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.

É possível usar também o console do AWS Glue para adicionar, editar, excluir e testar conexões. Para obter informações sobre as conexões do AWS Glue, consulte Conectar a dados.

Tópicos

- Conexão com o Adobe Analytics
- Conexão com o Adobe Marketo Engage
- Conectar ao Amazon Redshift no AWS Glue Studio
- Conexão com o Asana
- Conectar ao Azure Cosmos DB no AWS Glue Studio
- Conectar ao Azure SQL no AWS Glue Studio
- Conexão ao Raiser's Edge NXT da Blackbaud
- Conexão ao CircleCI
- Conexão ao Datadog
- Conexão ao Docusign Monitor
- Conexão ao Domo
- Conexão ao Dynatrace
- Conexão com o Facebook Ads
- Conexão com o Facebook Page Insights
- Conexão com o Freshdesk
- Conexão com o Freshsales

- Conexão com o Google Ads
- Conectando-se ao Google Analytics 4
- Conectar ao Google BigQuery em AWS Glue Studio
- Conectar ao Google Search Console
- Conectando-se ao Google Sheets
- Conectando-se a HubSpot
- Conexão com o Instagram Ads
- Conexão com o Intercom no AWS Glue Studio
- Conectando-se ao Jira Cloud
- Conexão ao Kustomer
- Conexão com o LinkedIn
- Conexão ao Mailchimp
- Conexão ao Microsoft Teams
- Conexão com o Mixpanel
- Conexão ao Monday
- Conectar ao MongoDB no AWS Glue Studio
- Conectando-se ao Oracle NetSuite
- Conectar ao OpenSearch Service no AWS Glue Studio
- Conexão ao Okta
- Conexão com o PayPal
- Conexão ao Pendo
- Conexão ao Pipedrive
- Conexão ao Productboard
- Conexão com o QuickBooks
- Conectar ao Salesforce
- Conexão com o Salesforce Marketing Cloud
- Conexão ao Salesforce Commerce Cloud
- Conexão com o Salesforce Marketing Cloud Account Engagement
- Conectar ao SAP HANA no AWS Glue Studio
- Conexão com o SAP OData

- Conexão com o SendGrid
- Conectando-se a ServiceNow
- Conexão com o Slack no AWS Glue Studio
- Conectar ao Smartsheet
- Conexão com o Snapchat Ads no AWS Glue Studio
- Conectar ao Snowflake no AWS Glue Studio
- Conexão com o Stripe no AWS Glue Studio
- Conectar ao Teradata Vantage no AWS Glue Studio
- Conexão com o Twilio
- Conectar ao Vertica no AWS Glue Studio
- Conexão com o WooCommerce
- Conectando-se ao Zendesk
- Conexão com o Zoho CRM
- Conexão com o Zoom Meetings
- Adicionar uma conexão JDBC usando seus próprios drivers JDBC

Conexão com o Adobe Analytics

O Adobe Analytics é uma plataforma robusta de análise de dados que coleta dados de experiências digitais multicanais que apoiam a jornada do cliente e fornecem ferramentas para analisar os dados. É uma plataforma comumente usada por profissionais de marketing e analistas de negócios para fins de análise de negócios. Se você usa o Adobe Analytics, pode conectar o AWS Glue à sua conta do Adobe Analytics. Em seguida, será possível usar o Adobe Analytics como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Adobe Analytics e os serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para Adobe Analytics
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Adobe Analytics
- Configuração de conexões do Adobe Analytics
- Leitura de entidades do Adobe Analytics

- Opções de conexão do Adobe Analytics
- Criação de uma conta do Adobe Analytics
- Limitações

Suporte do AWS Glue para Adobe Analytics

O AWS Glue oferece suporte ao Adobe Analytics da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do Adobe Analytics.

Compatível como destino?

Nº

Versões da API do Adobe Analytics com suporte

v2.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Adobe Analytics

Antes de poder usar o AWS Glue para transferir dados do Adobe Analytics, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Adobe Analytics com e-mail e senha. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Adobe Analytics.
- Sua conta do Adobe Analytics está habilitada para acesso à API. O acesso à API está ativado por padrão para as edições Select, Prime e Ultimate.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Adobe Analytics. Para conexões típicas, você não precisa fazer mais nada no Adobe Analytics.

Configuração de conexões do Adobe Analytics

O Adobe Analytics oferece suporte ao tipo de concessão `AUTHORIZATION_CODE` para `OAuth2`.

Esse tipo de concessão é considerado um `OAuth` de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Os usuários ainda podem optar por criar sua própria aplicação conectada no Adobe Analytics e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue.

Nesse cenário, eles ainda serão redirecionados para o Adobe Analytics para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter a documentação pública do Adobe Analytics sobre a criação de uma aplicação conectada para o fluxo OAuth AUTHORIZATION_CODE, consulte APIs do Adobe Analytics.

Para configurar uma conexão do Adobe Analytics:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

   Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

   > **Note**
   >
   > É preciso criar um segredo por conexão em AWS Glue.

2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Adobe Analytics.
   b. Forneça o `x_api_key, instanceUrl` do Adobe Analytics ao qual deseja se conectar.
   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
    "Version": "2012-10-17",
        "Statement": [
            {
                "Effect": "Allow",
                "Action": [
                    "secretsmanager:DescribeSecret",
                    "secretsmanager:GetSecretValue",
                    "secretsmanager:PutSecretValue",
                    "ec2:CreateNetworkInterface",
                    "ec2:DescribeNetworkInterface",
                    "ec2:DeleteNetworkInterface",
                ],
```

```
                "Resource": "*"
            }
        ]
    }
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Adobe Analytics

Pré-requisitos

Um objeto do Adobe Analytics do qual você gostaria de ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Anotação	Sim	Sim	Sim	Sim	Não
Métricas calculadas	Sim	Sim	Sim	Sim	Não
Função de métricas calculadas	Sim	Não	Não	Sim	Não
Compartil hamentos de metadados de componentes	Sim	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Intervalos de datas	Sim	Sim	Não	Sim	Não
Dimensões	Sim	Não	Não	Sim	Não
Métricas	Sim	Não	Não	Sim	Não
Projetos	Sim	Não	Não	Sim	Não
Item principal dos relatórios	Sim	Sim	Não	Sim	Não
Segmentos	Sim	Sim	Sim	Sim	Não
Logs de uso	Sim	Sim	Não	Sim	Não

Exemplo

```
adobeAnalytics_read = glueContext.create_dynamic_frame.from_options(
     connection_type="adobeanalytics",
     connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "annotation/ex*****",
        "API_VERSION": "v2.0"
 })
```

Detalhes de entidade e campo do Adobe Analytics

- Anotações
- Métricas calculadas
- Metadados do componente
- Intervalos de datas
- Dimensões

- Métricas
- Projetos
- Relatórios
- Segmentos
- Usuários
- Logs de uso

Opções de conexão do Adobe Analytics

Estas são as opções de conexão do Adobe Analytics:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Adobe Analytics.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Adobe Analytics que você deseja usar. Por exemplo, v2.0.
- `X_API_KEY`(string): (obrigatório) usado para leitura/gravação. É necessário para autenticar o desenvolvedor ou a aplicação que faz solicitações à API.
- `SELECTED_FIELDS`(lista<string>): padrão: vazio (SELECT *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

Criação de uma conta do Adobe Analytics

1. Registre-se no programa de parceiros de intercâmbio acessando o programa Adobe Partner.
2. Escolha Participar do Programa de intercâmbio.
3. Registre-se ou crie uma conta usando seu endereço de e-mail corporativo.
4. Na caixa de sugestões, selecione a empresa apropriada que tenha uma assinatura do produto Adobe Analytics.
5. Certifique-se de que a conta seja registrada em uma organização válida (da lista disponível) que tenha uma assinatura ativa do Adobe Analytics.
6. Após a aprovação da administração da empresa, ative sua conta clicando no link no e-mail de aprovação.

Verificação se a conta criada tem acesso ao serviço Adobe Analytics

1. Faça login no Adobe Admin Console.
2. Verifique o nome da organização no canto superior direito da página para garantir que você tenha feito login na empresa correta.
3. Selecione Produtos e verifique se o Adobe Analytics está disponível.

> **Note**
>
> Se nenhuma organização estiver disponível ou se o produto Adobe Analytics estiver esmaecido ou indisponível, é provável que sua conta não esteja associada a uma organização e/ou não tenha uma assinatura ativa do Adobe Analytics. Entre em contato com o administrador do sistema para solicitar acesso a esse serviço para sua conta.

Criação de um projeto e de credenciais do **`OAuth2.0`**

1. Faça login na conta do Adobe Analytics na qual você deseja que a aplicação do OAuth 2.0 seja criada.
2. Selecione Projeto e, em seguida, Criar um novo projeto.
3. Para adicionar um projeto, selecione Adicionar ao projeto e, em seguida, selecione API.
4. Selecione API do Adobe Analytics.
5. Selecione OAUTH como autenticação do usuário.
6. Selecione Web como OAUTH e forneça o URI de redirecionamento.

   Para o URI de redirecionamento e seu padrão, veja o seguinte:

   - URI de redirecionamento padrão do `OAuth 2.0`: um URI de redirecionamento padrão é o URL da página que a Adobe acessará durante o processo de autenticação. Por exemplo, `https://ap-southeast-2.console.aws.amazon.com/appflow/oauth`
   - Padrão de URI de redirecionamento do OAuth 2.0: um padrão de URI de redirecionamento é um caminho de URI (ou uma lista de caminhos separados por vírgula) para o qual a Adobe pode redirecionar (se solicitado) quando o fluxo de login for concluído. Por exemplo, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`
7. Adicione os seguintes escopos:

   - `openid`

- `read_organizations`
- `additional_info.projectedProductContext`
- `additional_info.job_function`

8. Escolha Salvar credencial.
9. Depois que a aplicação for criada, copie os valores `Client ID` e `Client Secret` para um arquivo de texto.

Limitações

Estas são as limitações do conector do Adobe Analytics:

- O Adobe Analytics não oferece suporte ao particionamento baseado em campos e baseado em registros. Não há suporte para o particionamento baseado em campos, pois não é possível consultar os campos particionados. Não pode haver suporte ao particionamento baseado em registros, pois não há provisão para obter 'offset' para paginação.
- Na entidade `Report Top Item`, os parâmetros de consulta `startDate` e `endDate` não estão funcionando conforme o esperado. A resposta não está sendo filtrada com base nesses parâmetros, o que está causando problemas com o filtro e o fluxo incremental dessa entidade.
- Para as entidades `Annotation`, `Calculated Metrics`, `Calculated Metrics Function`, `Date Ranges`, `Dimension`, `Metric`, `Project`, `Report Top Items` e `Segment`, o parâmetro de consulta `locale` especifica qual idioma deve ser usado para seções localizadas de respostas e não filtra os registros. Por exemplo, `locale="ja_JP"` exibirá os dados em japonês.
- Entidade `Report Top Item`: os filtros nos campos `dateRange` e `lookupNoneValues` não estão funcionando no momento.
- Entidade `Segment`: com o valor do filtro `includeType=“templates”`, os filtros em outros campos não estão funcionando.
- Entidade `Date Range`: o filtro no campo `curatedRsid` não está funcionando.
- Entidade `Metric entity`: o filtro no campo segmentável com valor "falso" fornece resultados para valores verdadeiros e falsos.

Conexão com o Adobe Marketo Engage

O Adobe Marketo Engage é uma plataforma de automação de marketing que permite aos profissionais de marketing gerenciar programas e campanhas multicanais personalizados para clientes atuais e potenciais.

Tópicos

- AWS Glue compatível com o Adobe Marketo Engage
- Políticas contendo as API operações para criar e usar conexões
- Configurando o Adobe Marketo Engage
- Configuração de conexões do Adobe Marketo Engage
- Leitura de entidades do Adobe Marketo Engage
- Opções de conexão do Adobe Marketo Engage
- Limitações e notas do conector do Adobe Marketo Engage

AWS Glue compatível com o Adobe Marketo Engage

O AWS Glue é compatível com o Adobe Marketo Engage da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Adobe Marketo Engage.

Compatível como destino?

Não.

Versões da API compatíveis com o Adobe Marketo Engage

As seguintes versões da API do Adobe Marketo Engage são compatíveis:

- v1

Para conferir a compatibilidade das entidades por versão específica, consulte as entidades compatíveis para a fonte.

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS IAM permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, use as seguintes IAM políticas gerenciadas:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configurando o Adobe Marketo Engage

Antes de usar AWS Glue para transferir dados do Adobe Marketo Engage, você deve atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Adobe Marketo Engage com credenciais de cliente.
- Sua conta do Adobe Marketo Engage tem API acesso com uma licença válida.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua conta do Adobe Marketo Engage. Para conexões típicas, você não precisa fazer mais nada no Adobe Marketo Engage.

Obtendo credenciais OAuth 2.0

Para obter API credenciais para que você possa fazer chamadas autenticadas para sua instância, consulte RESTAPIo Guia do desenvolvedor do Adobe Marketo Engage.

Configuração de conexões do Adobe Marketo Engage

O Adobe Marketo Engage oferece suporte ao tipo de concessão CLIENT CREDENTIALS para OAuth2.

- Esse tipo de concessão é considerado OAuth 2.0 de 2 pernas, pois é usado pelos clientes para obter um token de acesso fora do contexto de um usuário. O AWS Glue é capaz de usar o ID do cliente e o segredo do cliente para autenticar as APIs do Adobe Marketo Engage, que são fornecidas pelos serviços personalizados que você define.
- Cada serviço personalizado é de propriedade de um usuário somente de API que tem um conjunto de perfis e permissões que autorizam o serviço a realizar ações específicas. Um token de acesso é associado a um único serviço personalizado.
- Esse tipo de concessão resulta em um token de acesso de curta duração, que pode ser renovado com uma chamada a um endpoint de identidade.
- Para obter a documentação pública do Adobe Marketo Engage sobre OAuth 2.0 com credenciais de cliente, consulte Autenticação no Guia do desenvolvedor do Adobe Marketo Engage.

Para configurar uma conexão do Adobe Marketo Engage:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

b. Nota: é preciso criar um segredo por conexão em AWS Glue.

2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

a. Ao selecionar um Tipo de conexão, escolha Adobe Marketo Engage.

b. Forneça o `INSTANCE_URL` da instância do Adobe Marketo Engage à qual você deseja se conectar.

c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Adobe Marketo Engage

Pré-requisito

Um objeto do Adobe Marketo Engage do qual você deseja ler. Você precisará do nome do objeto, como leads, atividades ou customobjects. As tabelas a seguir mostram as entidades compatíveis.

Entidades compatíveis quanto à origem (síncronas):

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
leads	Sim	Sim	Não	Sim	Não
atividades	Sim	Sim	Não	Sim	Não
customobj ects	Sim	Sim	Não	Sim	Não

Entidades compatíveis quanto à origem (assíncronas):

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
leads	Sim	Não	Não	Sim	Sim
atividades	Sim	Não	Não	Sim	Não
customobj ects	Sim	Não	Não	Sim	Sim

Exemplo:

```
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**.mktorest.com"
    }
```

Detalhes da entidades e dos campos do Adobe Marketo Engage:

Entidades com metadados estáticos:

Entidade	Campo	Tipo de dados	Operadores compatíveis
atividades	sinceDatetime (compatível somente no modo síncrono)	DateTime	>= (somente para o modo síncrono)
	createdAt (compatível somente no modo assíncrono)	DateTime	entre (somente para o modo assíncrono)
	activitiesTypeId	Inteiro	=
	adobe-marketo-engageGUID	Longo	= (somente para o modo síncrono)
	leadId	Longo	N/D
	activityDate	DateTime	N/D
	campaignId	Longo	N/D
	primaryAttributeValueId	Inteiro	N/D
	primaryAttributeValue	String	N/D
	attributes	String	N/D

Entidades com metadados dinâmicos:

Para as entidades a seguir, o Adobe Marketo Engage fornece endpoints para buscar metadados dinamicamente, para que o suporte do operador seja capturado no nível do tipo de dados de cada entidade.

Entidade	Tipo de dados	Operadores compatíveis
leads	Inteiro	= (somente para o modo síncrono)
	DateTime	entre (somente para o modo assíncrono)
	String	= (somente para o modo síncrono)
	Longo	N/D
	Booleano	N/D
	Data	N/D
	Float	N/D
customobjects	Inteiro	N/D
	DateTime	entre (somente para o modo assíncrono)
	String	= (somente para o modo síncrono)
	Data	N/D
	Longo	N/D
	Booleano	N/D
	Float	N/D

Consultas de particionamento

É possível fornecer as opções adicionais do Spark PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND e NUM_PARTITIONS se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo DateTime, aceitamos o valor no formato ISO.

  Exemplo de valor válido:

  ```
  "2024-07-01T00:00:00.000Z"
  ```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

A tabela a seguir descreve os detalhes do suporte do campo de particionamento da entidade:

Nome da entidade	Campos de particionamento	Tipo de dados
leads	createdAt	DateTime
	updateAt	DateTime
customobjects	updatedAt	DateTime

Exemplo:

```
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"
    }
```

Opções de conexão do Adobe Marketo Engage

Confira abaixo as opções de conexão do Adobe Marketo Engage:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Adobe Marketo Engage.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API REST do Adobe Marketo Engage que você deseja usar. Por exemplo: v1.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `TRANSFER_MODE`(String): padrão: SYNC. Usado para leitura assíncrona.

Limitações e notas do conector do Adobe Marketo Engage

Estas são as limitações ou notas do conector do Adobe Marketo Engage:

- 'sinceDatetime' e 'activityTypeId' são parâmetros de filtro obrigatórios para a entidade Sync Activities.
- As assinaturas recebem 50.000 chamadas de API por dia (que são reiniciadas diariamente às 00:00 CST). Uma capacidade diária adicional pode ser adquirida como parte de uma assinatura do Adobe Marketo Engage.
- O período máximo para o filtro do intervalo de datas (`createdAt` ou `updatedAt`) é de 31 dias.

- As assinaturas recebem no máximo 10 trabalhos de extração em lote na fila a qualquer momento.
- Por padrão, os trabalhos de extração são limitados a 500 MB por dia (que são redefinidos diariamente às 00:00 CST). Uma capacidade diária adicional pode ser adquirida como parte de uma assinatura do Adobe Marketo Engage.
- O número máximo de trabalhos de exportação simultâneos é 2.
- O número máximo de trabalhos de exportação em fila (incluindo os trabalhos que estão sendo exportados atualmente) é 10.
- O tamanho máximo de arquivo permitido é de 1 GB para extrair de um trabalho em lote.
- Depois que um trabalho assíncrono for criado, o período de retenção do arquivo será de 7 dias antes da expiração.
- `createdAt` ou `updatedAt` são parâmetros de filtro obrigatórios para a entidade Async Leads.
- `createdAt` é um parâmetro de filtro obrigatório para a entidade Async Activities.
- `updatedAt` é um parâmetro de filtro obrigatório para a entidade Async Custom Object.

Para obter mais informações, consulte Práticas recomendadas de integração do Adobe Marketo Engage e Extração em lote.

Conectar ao Amazon Redshift no AWS Glue Studio

> **Note**
>
> Você pode usar o AWS Glue para Spark para ler e gravar tabelas nos Amazon Redshift bancos de dados do AWS Glue Studio. Para configurar Amazon Redshift com AWS Glue trabalhos de forma programática, consulte Conexões do Redshift.

O AWS Glue fornece suporte integrado para o Amazon Redshift. O AWS Glue Studio fornece uma interface visual para se conectar ao Amazon Redshift, criar trabalhos de integração de dados e executá-los no runtime do AWS Glue Studio Spark sem servidor.

Tópicos

- Criar uma conexão do Amazon Redshift
- Criar um nó de origem do Amazon Redshift
- Criar um nó de destino do Amazon Redshift

- Opções avançadas

Criar uma conexão do Amazon Redshift

Permissões necessárias

São necessárias permissões adicionais para usar clusters do Amazon Redshift clusters e ambientes sem servidor do Amazon Redshift. Para obter mais informações sobre como adicionar permissões a trabalhos de ETL, consulte Review IAM permissions needed for ETL jobs.

- redshift:DescribeClusters
- redshift-serverless:ListWorkgroups
- redshift-serverless:ListNamespaces

Visão geral

Ao adicionar uma conexão do Amazon Redshift, você pode escolher uma do Amazon Redshift existente ou criar uma nova conexão ao adicionar um nó Fonte de dados - Redshift no AWS Glue Studio.

O AWS Glue oferece suporte a clusters do Amazon Redshift e ambientes sem servidor do Amazon Redshift. Quando você cria uma conexão, os ambientes sem servidor do Amazon Redshift exibem o rótulo serverless ao lado da opção de conexão.

Para obter mais informações sobre como criar uma conexão do Amazon Redshift, consulte Moving data to and from Amazon Redshift.

Criar um nó de origem do Amazon Redshift

Permissões necessárias

Trabalhos do AWS Glue Studio usando fontes de dados do Amazon Redshift exigem permissões adicionais. Para obter mais informações sobre como adicionar permissões a trabalhos de ETL, consulte Review IAM permissions needed for ETL jobs.

As seguintes permissões são necessárias para usar uma conexão com Amazon Redshift.

- redshift-data:ListSchemas
- redshift-data:ListTables

- redshift-data:DescribeTable
- redshift-data:ExecuteStatement
- redshift-data:DescribeStatement
- redshift-data:GetStatementResult

Adicionar de uma fonte de dados do Amazon Redshift

Para adicionar um nó fonte de dados - Amazon Redshift:

1. Escolha o tipo de acesso ao Amazon Redshift:

   - Conexão direta de dados (recomendada): escolha essa opção se quiser acessar seus dados do Amazon Redshift diretamente. Essa é a opção recomendada e também a padrão.
   - Data Catalog tables: escolha essa opção se você tiver tabelas do catálogo de dados que deseja usar.

2. Se você escolher Conexão de dados direta, escolha a conexão para sua fonte de dados do Amazon Redshift. Isso pressupõe que a conexão já exista e que você possa selecionar entre as conexões existentes. Se precisar criar uma conexão, escolha Criar conexão com o Redshift. Para obter mais informações, consulte Visão geral do uso de conectores e conexões.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades. As informações sobre a conexão estão visíveis, incluindo URL, grupos de segurança, sub-rede, zona de disponibilidade, descrição e timestamps de criação (UTC) e última atualização (UTC).

3. Escolha uma opção de origem do Amazon Redshift:

   - Escolher uma única tabela: essa é a tabela que contém os dados que você deseja acessar de uma única tabela do Amazon Redshift.
   - Inserir consulta personalizada: permite que você acesse um conjunto de dados de várias tabelas do Amazon Redshift com base na sua consulta personalizada.

4. Se você escolheu uma única tabela, escolha o esquema do Amazon Redshift. A lista de esquemas disponíveis para escolha é determinada pela tabela selecionada.

   Ou escolha Inserir consulta personalizada. Escolha essa opção para acessar um conjunto de dados personalizado de várias tabelas do Amazon Redshift. Ao escolher essa opção, insira a consulta do Amazon Redshift.

Ao se conectar a um ambiente Amazon Redshift sem servidor, adicione a seguinte permissão à consulta personalizada:

```
GRANT SELECT ON ALL TABLES IN <schema> TO PUBLIC
```

Você pode escolher Inferir esquema para ler o esquema com base na consulta que você inseriu. Você também pode escolher Abrir editor de consultas do Redshift para inserir uma consulta do Amazon Redshift. Para obter mais informações, acesse Consultar um banco de dados usando o editor de consultas.

5. Em Desempenho e segurança, escolha o diretório de teste do Amazon S3 e o perfil do IAM.
   - Diretório de teste do Amazon S3: escolha o local do Amazon S3 para armazenar temporariamente os dados do teste.
   - Perfil do IAM: escolha o perfil do IAM que pode gravar no local do Amazon S3 que você selecionou.
6. Em Parâmetros personalizados do Redshift - opcional, insira o parâmetro e o valor.

Criar um nó de destino do Amazon Redshift

Permissões necessárias

Trabalhos do AWS Glue Studio usando destino de dados do Amazon Redshift exigem permissões adicionais. Para obter mais informações sobre como adicionar permissões a trabalhos de ETL, consulte Review IAM permissions needed for ETL jobs.

As seguintes permissões são necessárias para usar uma conexão com Amazon Redshift.

- redshift-data:ListSchemas
- redshift-data:ListTables

Adicionar um nó de destino do Amazon Redshift

Para criar um nó de destino do Amazon Redshift:

1. Escolha uma tabela existente do Amazon Redshift como destino ou insira um novo nome de tabela.
2. Ao usar o nó de destino Destino de dados: Redshift, você pode escolher entre as seguintes opções:

   - APPEND: se uma tabela já existir, despejar todos os novos dados na tabela como uma inserção. Se a tabela não existir, criar e inserir todos os novos dados.

     Além disso, marque a caixa se quiser atualizar (UPSERT) os registros existentes na tabela de destino. A tabela deve existir primeiro, caso contrário, a operação falhará.
   - MERGE: o AWS Glue atualizará ou anexará dados à sua tabela de destino com base nas condições que você especificar.

     > **Note**
     >
     > Para usar a ação de mesclagem no AWS Glue, você deve habilitar a funcionalidade de mesclagem do Amazon Redshift. Para obter instruções sobre como habilitar a mesclagem para sua instância do Amazon Redshift, consulte MERGE (pré-visualização).

     Escolha as opções:

     - Escolher chaves e ações simples: escolha as colunas a serem usadas como chaves de correspondência entre os dados de origem e seu conjunto de dados de destino.

       Especifique as seguintes opções quando correspondidas:

       - Atualizar o registro em seu conjunto de dados de destino com os dados da fonte.
       - Excluir o registro em seu conjunto de dados de destino.

       Especifique as seguintes opções quando não correspondidas:

       - Inserir os dados de origem como uma nova linha em seu conjunto de dados de destino.
       - Não executar nenhuma ação.

    - Inserir declaração MERGE personalizada: você pode então escolher Validar declaração de Merge para verificar se a declaração é válida ou inválida.
- TRUNCATE: se uma tabela já existir, truncar os dados da tabela limpando primeiro o conteúdo da tabela de destino. Se o truncamento for bem-sucedido, inserir todos os dados. Se a tabela não existir, criar a tabela e inserir todos os novos dados. Se o truncamento não tiver sucesso, a operação falhará.
- DROP: se uma tabela já existir, excluir os metadados e os dados da tabela. Se a exclusão for bem-sucedida, inserir todos os dados. Se a tabela não existir, criar a tabela e inserir todos os novos dados. Se o drop não tiver sucesso, a operação falhará.
- CREATE: Criar uma nova tabela com o nome padrão. Se o nome da tabela já existir, criar uma nova tabela com um aposto do nome de `job_datetime` para fins de exclusividade. Isso inserirá todos os dados na nova tabela. Se a tabela existir, o nome final da tabela terá o aposto anexado. Se a tabela não existir, uma tabela será criada. Em ambos os casos, uma nova tabela será criada.

Opções avançadas

Consulte Using the Amazon Redshift Spark connector AWS Glue.

Conexão com o Asana

O Asana é uma solução de colaboração em equipe baseada na nuvem que ajuda as equipes a organizar, planejar e concluir tarefas e projetos. Se você é usuário do Asana, sua conta contém dados sobre seus espaços de trabalho, projetos, tarefas, equipes e muito mais. É possível transferir dados do Asana para determinados serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para Asana
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Asana
- Configuração de conexões do Asana
- Leitura de entidades do Asana
- Opções de conexão do Asana
- Criação de uma conta do Asana
- Limitações

Suporte do AWS Glue para Asana

O AWS Glue oferece suporte ao Asana da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do Asana.

Compatível como destino?

Nº

Versões da API do Asana com suporte

1,0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM,

CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.

- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Asana

Antes de poder usar o AWS Glue para transferir dados do Asana, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta Asana com e-mail e senha. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Asana.
- Você deve ter uma conta da AWS criada com acesso de serviço ao AWS Glue.
- Certifique-se de ter criado um dos recursos a seguir na sua conta do Asana:
  - Uma aplicação para desenvolvedores que ofereça suporte à autenticação `OAuth 2.0`. Para obter mais instruções, consulte OAuth na documentação dos desenvolvedores do Asana. Como alternativa, consulte the section called “Criação de uma conta do Asana”.
  - Um token de acesso pessoal Para obter mais informações, consulte o Token de acesso pessoalhttps://developers.asana.com/docs/personal-access-token na documentação dos desenvolvedores do Asana.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Adobe Analytics. Para conexões típicas, você não precisa fazer mais nada no Adobe Analytics.

Configuração de conexões do Asana

O Asana oferece suporte ao tipo de concessão `AUTHORIZATION_CODE` para `OAuth2`.

Esse tipo de concessão é considerado um `OAuth` de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário.

Os usuários podem optar por criar sua própria aplicação conectada no Asana e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Asana para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter a documentação pública da Asana sobre como criar uma aplicação conectada para o fluxo `AUTHORIZATION_CODE OAuth`, consulte APIs do Asana.

Para configurar uma conexão do Asana:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   - Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   -
     > **Note**
     >
     > É necessário criar um segredo para a conexão no AWS Glue.
2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Asana.
   b. Forneça o ambiente do Asana.
   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
```

```
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para inserir os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Asana

Pré-requisitos

Um objeto do Asana do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades com suporte para a fonte

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Espaço de trabalho	Não	Sim	Não	Sim	Não
Tag	Não	Sim	Não	Sim	Não
Usuário	Não	Sim	Não	Sim	Não
Portfólio	Não	Sim	Não	Sim	Não
Team	Não	Sim	Não	Sim	Não
Projeto	Sim	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Seção	Não	Sim	Não	Sim	Não
Tarefa	Sim	Não	Não	Sim	Sim
Objetivo	Sim	Sim	Não	Sim	Não
AuditLogEvent	Sim	Sim	Não	Sim	Não
Atualização de status	Sim	Sim	Não	Sim	Não
Campo personalizado	Não	Sim	Não	Sim	Não
Resumo do projeto	Sim	Não	Não	Sim	Sim

Exemplo

```
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"
    }
```

Detalhes de entidade e campo do Asana

- Espaço de trabalho
- Tag
- Usuário
- Portfólio
- Equipe
- Projeto
- Seção
- Tarefa
- Objetivo
- AuditLogEvent
- Atualização de status
- Campo personalizado
- Resumo do projeto

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valores válidos: `2024-06-07T13:30:00.134Z`.
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na tabela a seguir.

Entity Name	Campo de particionamento	Tipo de dado
Tarefa	created_at	DateTime
Tarefa	modified_at	DateTime

Exemplo

```
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"
    }
```

Opções de conexão do Asana

Estas são as opções de conexão do Asana:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Asana.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Asana que você deseja usar. Por exemplo: 1.0.
- `SELECTED_FIELDS`(lista<string>): padrão: vazio (SELECT *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.

- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Criação de uma conta do Asana

1. Cadastre-se para obter uma conta do Asana e escolha Inscrever-se.
2. Depois de fazer login, você será redirecionado para a página Configuração da conta. Execute as etapas a seguir:
   - Revise o formulário de configuração da conta.
   - Preencha todos os detalhes relevantes para criar sua conta do Asana.
   - Verifique novamente as informações para garantir a precisão.
3. Escolha Criar conta ou Enviar (o texto exato do botão pode variar) para finalizar a configuração da sua conta.

Criação de uma aplicação no Asana para **`OAuth2.0`**

1. Faça login na conta do Asana usando suas Credenciais de cliente do Asana.
2. Escolha o ícone do seu perfil de usuário no canto superior direito e selecione Minhas configurações no menu suspenso.
3. Selecione a guia Aplicações e, em seguida, selecione Gerenciar aplicações do desenvolvedor.
4. Selecione Criar nova aplicação e insira os detalhes relevantes.
5. Escolha Criar aplicações.
6. Na página Minhas aplicações:
   a. Selecione OAuth e, na seção Credenciais da aplicação, anote seu ID do cliente e o segredo do cliente.
   b. Na seção URLs de redirecionamento, adicione os URLs de redirecionamento necessárias.

> **Note**
>
> Insira o URI de redirecionamento usando este formato: `https://{aws-region-code}.console.aws.amazon.com/gluestudio/oauth`.
> Exemplo: para a região Leste dos EUA (Norte da Virgínia), use `https://us-east-1.console.aws.amazon.com/gluestudio/oauth`

Criação da aplicação no Asana para o token **PAT**

1. Faça login na conta do Asana usando suas Credenciais de cliente do Asana.
2. Clique no ícone do seu perfil de usuário no canto superior direito e selecione Minhas configurações de perfil no menu suspenso.
3. Selecione a guia Aplicações e, em seguida, selecione Contas de serviço.
4. Selecione Criar nova aplicação e insira os detalhes relevantes.
5. Escolha Adicionar conta de serviço.
6. A próxima página exibe seu token. Copie-o e armazene-o com segurança.

> **Important**
>
> Esse token só será exibido uma vez. Certifique-se de copiá-lo e armazená-lo com segurança.

Limitações

Estas são as limitações do conector do Asana:

- As contas de serviço em domínios corporativos só podem acessar endpoints da API de log de auditoria. A autenticação com o token de acesso pessoal de uma conta de serviço é necessária para acessar esses endpoints.
- A entidade Goal só pode ser acessada para contas de usuário com plano Premium ou superior.
- `Audit Log Event Entity`: no conector, os campos `start_at` e `end_at` são combinados em um único campo "start_end_at" para oferecer suporte a filtragem e transferência incremental.
- Não pode haver suporte ao particionamento para o campo `Date`, embora ele ofereça suporte a operadores maior ou igual a e menor ou igual a. Cenário: foi criado um trabalho com `partitionField` como `due_on` (tipo de dados: data), `lowerBound` como `2019-09-14`, `upperBound` como `2019-09-16` e `numPartition` como 2. A parte do filtro do URL do endpoint é criada da seguinte forma:
  - partição1: due_on.before=2019-09-14&due_on.after=2019-09-14
  - partição2: due_on.before=2019-09-15&due_on.after=2019-09-15 Output:
  - Na partição1, obtemos dados com due_date como 2019-09-14 e 2019-09-15

  - Na partição2, obtemos os mesmos dados com due_date de 2019-09-15 (que estava na partição1) junto com outros dados, causando duplicação de dados.
- Não pode haver suporte para a filtragem e o particionamento no mesmo campo, pois um erro de solicitação inválida é gerado pela extremidade do SaaS.
- A entidade Tarefa exige no mínimo 1 campo nos critérios de filtro. Há uma limitação no Asana em que a paginação não é identificada sem a classificação dos registros com base em um campo baseado em tempo. Portanto, o campo Created_at é usado junto com a paginação para distinguir o próximo conjunto de registros. O campo Created_at é marcado como obrigatório no filtro, com um valor padrão de 2000-01-01T00:00:00Z se não for fornecido. Para obter mais informações sobre paginação, consulte Tarefas em um espaço de trabalho.

Conectar ao Azure Cosmos DB no AWS Glue Studio

O AWS Glue oferece suporte integrado ao Azure Cosmos DB. O AWS Glue Studio fornece uma interface visual para conectar ao Azure Cosmos DB para NoSQL, criar trabalhos de integração de dados e executá-los no runtime Spark do AWS Glue Studio sem servidor.

Tópicos

- Criar uma conexão do Azure Cosmos DB
- Criar um nó de origem do Azure Cosmos DB
- Criar um nó de destino do Azure Cosmos DB
- Opções avançadas

Criar uma conexão do Azure Cosmos DB

Pré-requisitos:

- No Azure, será necessário identificar ou gerar uma chave do Azure Cosmos DB para uso pelo AWS Glue, `cosmosKey`. Para obter mais informações, consulte Acesso seguro a dados no Azure Cosmos DB na documentação do Azure.

Para configurar uma conexão com o Azure Cosmos DB:

1. No AWS Secrets Manager, crie um segredo usando sua chave do Azure Cosmos DB. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager

segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

- Ao selecionar Pares chave/valor, crie um par para a chave `spark.cosmos.accountKey` com o valor *cosmosKey*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para uso futuro em AWS Glue.

   - Ao selecionar um Tipo de conexão, selecione Azure Cosmos DB.
   - Ao selecionar um Segredo da AWS, forneça o *secretName*.

Criar um nó de origem do Azure Cosmos DB

Pré-requisitos necessários

- Uma conexão AWS Glue Azure Cosmos DB configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called "Criar uma conexão do Azure Cosmos DB".
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Um contêiner do Azure Cosmos DB para NoSQL do qual você gostaria de ler. Você precisará de informações de identificação para o contêiner.

  Um contêiner do Azure Cosmos para NoSQL é identificado por seu banco de dados e contêiner. É necessário fornecer os nomes do banco de dados, *cosmosDBName* e do contêiner, *cosmosContainerName*, ao se conectar à API do Azure Cosmos para NoSQL.

Adicionar uma fonte de dados do Azure Cosmos DB

Para adicionar um nó de Fonte de dados – Azure Cosmos DB:

1. Escolha a conexão para sua fonte de dados do Azure Cosmos DB. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão do Azure Cosmos DB. Para mais informações, consulte a seção the section called "Criar uma conexão do Azure Cosmos DB" anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.

2. Escolha o Nome do banco de dados do Cosmos DB: forneça o nome do banco de dados do qual você deseja ler, *cosmosDBName*.
3. Escolha Contêiner do Azure Cosmos DB: forneça o nome do contêiner do qual você deseja ler, *cosmosContainerName*.
4. Opcionalmente, escolha Consulta personalizada do Azure Cosmos DB: forneça uma consulta SQL SELECT para recuperar informações específicas do Azure Cosmos DB.
5. Em Propriedades personalizadas do Azure Cosmos, insira parâmetros e valores conforme necessário.

Criar um nó de destino do Azure Cosmos DB

Pré-requisitos necessários

- Uma conexão AWS Glue Azure Cosmos DB configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão do Azure Cosmos DB”.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do Azure Cosmos DB em que você deseja escrever. Você precisará de informações de identificação para o contêiner. É necessário criar o contêiner antes de chamar o método de conexão.

  Um contêiner do Azure Cosmos para NoSQL é identificado por seu banco de dados e contêiner. É necessário fornecer os nomes do banco de dados, *cosmosDBName* e do contêiner, *cosmosContainerName*, ao se conectar à API do Azure Cosmos para NoSQL.

Adicionar um destino de dados do Azure Cosmos DB

Para adicionar um nó de Destino de dados – Azure Cosmos DB:

1. Escolha a conexão para sua fonte de dados do Azure Cosmos DB. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão do Azure Cosmos DB. Para mais informações, consulte a seção the section called “Criar uma conexão do Azure Cosmos DB” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.

2. Escolha o Nome do banco de dados do Cosmos DB: forneça o nome do banco de dados do qual você deseja ler, *cosmosDBName*.
3. Escolha Contêiner do Azure Cosmos DB: forneça o nome do contêiner do qual você deseja ler, *cosmosContainerName*.
4. Em Propriedades personalizadas do Azure Cosmos, insira parâmetros e valores conforme necessário.

Opções avançadas

É possível fornecer opções avançadas ao criar um nó do Azure Cosmos DB. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexões do Azure Cosmos DB”.

Conectar ao Azure SQL no AWS Glue Studio

O AWS Glue oferece suporte integrado ao Azure SQL. O AWS Glue Studio fornece uma interface visual para conectar ao Azure SQL, criar trabalhos de integração de dados e executá-los no runtime Spark do AWS Glue Studio sem servidor.

Tópicos

- Criar uma conexão do Azure SQL
- Criar um nó de origem do Azure SQL
- Criar um nó de destino do Azure SQL
- Opções avançadas

Criar uma conexão do Azure SQL

Para se conectar ao Azure SQL via AWS Glue, será necessário criar e armazenar sua credenciais do Azure SQL em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão do Azure SQL AWS Glue.

Para configurar uma conexão com o Azure SQL:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do Azure SQL. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager

segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

- Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *azuresqlUsername*.
- Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *azuresqlPassword*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para uso futuro em AWS Glue.

   - Ao selecionar um Tipo de conexão, selecione Azure SQL.
   - Ao fornecer o URL do Azure SQL, forneça um URL de endpoint do JDBC.

     Essa lista deve estar no seguinte formato: `jdbc:sqlserver://`*databaseServerName*`:`*databasePort*`;databaseName=`*azuresqlDBnam*

     O AWS Glue requer as seguintes propriedades de URL:

     - `databaseName`: um banco de dados padrão no Azure SQL ao qual se conectar.

     Para obter mais informações sobre URLs de JDBC para instâncias gerenciadas Azure SQL, consulte a Documentação da Microsoft.

   - Ao selecionar um Segredo da AWS, forneça o *secretName*.

Criar um nó de origem do Azure SQL

Pré-requisitos necessários

- Uma conexão AWS Glue Azure SQL configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called "Criar uma conexão do Azure SQL".
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do Azure SQL da qual você deseja ler, *tableName*.

  Uma tabela do Azure SQL é identificada por seu banco de dados, esquema e nome da tabela. É necessário fornecer o nome do banco de dados e o nome da tabela ao se conectar ao Azure SQL. Você também deverá fornecer o esquema se ele não for o padrão, "public". O banco de dados

é fornecido por meio de uma propriedade de URL em *connectionName*, esquema e nome da tabela via `dbtable`.

Adicionar uma fonte de dados do Azure SQL

Para adicionar um nó de Fonte de dados – Azure SQL:

1. Escolha a conexão para sua fonte de dados do Azure SQL. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão do Azure SQL. Para mais informações, consulte a seção the section called “Criar uma conexão do Azure SQL” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Escolha uma opção de Fonte do Azure SQL:
   - Escolher uma única tabela: acesse todos os dados de uma única tabela.
   - Inserir consulta personalizada: acesse um conjunto de dados de várias tabelas com base em sua consulta personalizada.
3. Se você escolheu uma única tabela, insira *tableName*.

   Se você escolheu Inserir consulta personalizada, insira uma consulta TransactSQL SELECT.
4. Em Propriedades personalizadas do Azure SQL, insira parâmetros e valores conforme necessário.

Criar um nó de destino do Azure SQL

Pré-requisitos necessários

- Uma conexão AWS Glue Azure SQL configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão do Azure SQL”.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do Azure SQL em que você deseja escrever, *tableName*.

  Uma tabela do Azure SQL é identificada por seu banco de dados, esquema e nome da tabela. É necessário fornecer o nome do banco de dados e o nome da tabela ao se conectar ao Azure SQL. Você também deverá fornecer o esquema se ele não for o padrão, "public". O banco de dados

é fornecido por meio de uma propriedade de URL em *connectionName*, esquema e nome da tabela via dbtable.

Adicionar um destino de dados do Azure SQL

Para adicionar um nó de Destino de dados – Azure SQL:

1. Escolha a conexão para sua fonte de dados do Azure SQL. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão do Azure SQL. Para mais informações, consulte a seção the section called “Criar uma conexão do Azure SQL” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Configure o nome da tabela fornecendo o *tableName*.
3. Em Propriedades personalizadas do Azure SQL, insira parâmetros e valores conforme necessário.

Opções avançadas

É possível fornecer opções avançadas ao criar um nó do Azure SQL. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexões do Azure SQL”.

Conexão ao Raiser’s Edge NXT da Blackbaud

O Blackbaud Raiser’s Edge NXT é uma solução completa de software para arrecadação de fundos e gerenciamento de doadores baseada em nuvem criada especificamente para organizações sem fins lucrativos e todas as comunidades dedicadas a causas sociais. Esse conector foi criado com base na API SKY do Blackbaud Raiser’s Edge NXT e oferece operações para ajudar no gerenciamento de entidades encontradas no Raiser’s Edge NXT.

Tópicos

- Suporte do AWS Glue para o Blackbaud Raiser’s Edge NXT
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Blackbaud Raiser’s Edge NXT

- Configuração de conexões do Blackbaud Raiser’s Edge NXT
- Leitura de entidades do Blackbaud Raiser’s Edge NXT
- Opções de conexão do Blackbaud Raiser's Edge NXT
- Limitações do Blackbaud Raiser's Edge NXT

Suporte do AWS Glue para o Blackbaud Raiser’s Edge NXT

O AWS Glue oferece suporte ao Blackbaud Raiser’s Edge NXT da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Blackbaud Raiser’s Edge NXT.

Compatível como destino?

Não.

Versões compatíveis da API do Blackbaud Raiser’s Edge NXT

Estas são as versões compatíveis da API do Blackbaud Raiser’s Edge NXT:

- v1

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
```

```
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Blackbaud Raiser's Edge NXT

Antes de usar o AWS Glue para transferir dados do Blackbaud Raiser's Edge NXT, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Blackbaud Raiser's Edge NXT.
- Você gerou um token de acesso na conta do Blackbaud Raiser's Edge NXT com o escopo apropriado de leitura/gravação atribuído para acessar as APIs. Para obter mais informações, consulte Authorization.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Blackbaud Raiser's Edge NXT.

Configuração de conexões do Blackbaud Raiser's Edge NXT

O Blackbaud Raiser's Edge NXT oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2.

- Esse tipo de concessão é considerado um OAuth de "três pernas", pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O Console do AWS Glue redirecionará o usuário para o Blackbaud Raiser's Edge NXT, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Blackbaud Raiser's Edge NXT.
- Os usuários podem optar por criar sua própria aplicação conectada no Blackbaud Raiser's Edge NXT e fornecer seus próprios ID do cliente, chave de assinatura e URL de instância ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Blackbaud Raiser's Edge NXT para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Blackbaud Raiser's Edge NXT sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Authorization.

Para configurar uma conexão do Blackbaud Raiser's Edge NXT:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a chave da API da aplicação conectada com *USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET* como a chave.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar uma Fonte de dados, selecione o Blackbaud Raiser's Edge NXT.
   b. Forneça o `INSTANCE_URL` da conta do Blackbaud Raiser's Edge NXT à qual você deseja se conectar.
   c. Forneça o `clientId` da aplicação cliente gerenciada pelo usuário.

d. Forneça a chave de assinatura associada à sua conta.

e. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

f. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

g. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Blackbaud Raiser's Edge NXT

Pré-requisito

Um objeto do Blackbaud Raiser's Edge NXT do qual você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Endereço do constituinte	Sim	Sim	Não	Sim	Sim
Educação do constituinte	Sim	Sim	Não	Sim	Sim
Endereço de e-mail do constituinte	Sim	Sim	Não	Sim	Sim
Telefone do constituinte	Sim	Sim	Não	Sim	Sim
Observação do constitui nte	Sim	Sim	Não	Sim	Sim
Relaciona mento do constituinte	Sim	Sim	Não	Sim	Sim
Presença on-line do constituinte	Sim	Sim	Não	Sim	Sim
Oportunidade	Sim	Sim	Não	Sim	Sim
Recurso	Sim	Sim	Não	Sim	Sim
Campaign	Sim	Sim	Não	Sim	Sim
Fundo	Sim	Sim	Não	Sim	Sim
Pacote	Sim	Sim	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Lote da doação	Sim	Sim	Não	Sim	Não
Participante do evento	Sim	Sim	Sim	Sim	Sim
Atribuição de arrecadaç ão de fundos para constitui ntes	Não	Não	Não	Sim	Não
Doação	Sim	Sim	Sim	Sim	Sim
Associação	Sim	Sim	Não	Sim	Sim
Ação	Sim	Sim	Não	Sim	Não
Constituinte	Sim	Sim	Sim	Sim	Sim
Bens do constituinte	Sim	Sim	Não	Sim	Sim
Event	Sim	Sim	Sim	Sim	Sim
Campo personali zado da doação	Sim	Sim	Não	Sim	Sim

Exemplo:

```
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>
    }
```

Detalhes das entidades e dos campos do Blackbaud Raiser's Edge NXT

Para obter mais informações sobre os detalhes das entidades e dos campos, consulte:

- Ação
- Constituinte
- Endereço do constituinte
- Associação do constituinte
- Atribuição de arrecadação de fundos para constituintes
- Educação do constituinte
- Endereço de e-mail do constituinte
- Telefone do constituinte
- Observação do constituinte
- Presença on-line do constituinte
- Relacionamento do constituinte
- Evento
- Participante do evento
- Recurso
- Campanha
- Fundo
- Pacote
- Doação
- Campo personalizado da doação
- Lote da doação
- Oportunidade
- Códigos do constituinte

> **Note**
>
> Os tipos de dados Struct e List são convertidos no tipo de dados String, e o tipo de dados DateTime é convertido em Timestamp na resposta dos conectores.

Particionamento de consultas

Particionamento com base em campo:

O Blackbaud Raiser's Edge NXT não oferece suporte ao particionamento baseado em campos ou em registros.

Particionamento com base em registros:

É possível fornecer a opção adicional `NUM_PARTITIONS` do Spark se quiser utilizar a simultaneidade no Spark. Com esse parâmetro, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

No particionamento baseado em registros, o número total de registros presentes é consultado na API do Blackbaud Raiser's Edge NXT e dividido pelo número `NUM_PARTITIONS` fornecido. O número resultante de registros é então buscado simultaneamente por cada subconsulta.

- `NUM_PARTITIONS`: o número de partições.

Exemplo: .

```
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>
    }
```

Opções de conexão do Blackbaud Raiser's Edge NXT

Estas são as opções de conexão do Blackbaud Raiser's Edge NXT:

- ENTITY_NAME(string): (obrigatório) usado para leitura. O nome do seu objeto no Blackbaud Raiser's Edge NXT.
- API_VERSION(string): (obrigatório) usado para leitura. A versão da API Rest do Blackbaud Raiser's Edge NXT que você deseja usar.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- FILTER_PREDICATE(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- NUM_PARTITIONS(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura. Exemplo de valor: 10.
- SUBSCRIPTION_KEY(string): (obrigatório) o padrão é vazio. Usado para leitura. Chave de assinatura associada à conta de um desenvolvedor.

Limitações do Blackbaud Raiser's Edge NXT

Estas são as limitações ou observações do Blackbaud Raiser's Edge NXT:

- O SaaS oferece suporte apenas ao operador EQUAL_T0, que retorna resultados criados ou modificados na data especificada ou após ela. Além disso, o campo "id" é um tipo de dados String. Também não há a identificação de campos não anuláveis. Sendo assim, não há suporte para o particionamento baseado em campos.
- Apenas a entidade Event oferece suporte à extração incremental com frequências diárias, mensais e semanais.
- A entidade Constituent Fundraiser Assignment retorna no máximo 20 registros.
- Particionamento com base em registros:
  - Sem suporte para as entidades Action, Constituent Fundraiser Assignment ou Gift Batch.
  - Apenas as entidades Event e Event Participant oferecem suporte ao particionamento baseado em registros com o predicado de filtro. Se um predicado de filtro for usado com qualquer outra entidade com suporte ao particionamento baseado em registros, uma exceção será lançada.
- Na entidade Gift Custom Field, o campo "valor" deverá ser usado em conjunto com o campo "categoria". Caso contrário, será gerada uma resposta não filtrada. Sendo assim, para obrigar o

usuário a inserir o campo “categoria” ao filtrar com o campo “valor”, uma exceção será lançada se o requisito mencionado acima não for atendido.

- Os campos `date_added` e `last_modified` de todas as entidades aplicáveis não oferecem suporte a nenhum operador comparativo. Eles aceitam apenas o operador de igualdade. Além disso, não há nenhum campo que possa ser combinado com os campos mencionados acima para fornecer um intervalo de registros. Portanto, esses campos são apenas consultáveis e não oferecem suporte à transferência incremental.
- O campo `added_by` na entidade `Gift Batch` não será considerado filtrável, pois é possível que ele não gere os resultados corretos.
- Há uma latência de aproximadamente 30 minutos para que os registros sejam recuperados por meio do endpoint `/GET Gift List` após a inserção dos dados na entidade `Gift`.
- O suporte para transferência incremental foi descontinuado para a entidade Gift devido a limitações por parte da fonte de dados.
- Existe uma latência de dez minutos para o campo de status na entidade Opportunity.
- A entidade `Fundraiser Assignment` tem `Constituent` como entidade dependente. O conector carrega no máximo 5 mil IDs para escolher, de modo a evitar que o tamanho da resposta exceda o tamanho máximo permitido da carga útil.

Conexão ao CircleCI

O CircleCI é uma plataforma de integração e entrega contínuas. A conta do CircleCI contém dados sobre seus projetos, pipelines, fluxos de trabalho e muito mais. Se você usa o CircleCI, pode conectar o AWS Glue à conta do CircleCI. Em seguida, será possível usar o CircleCI como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o CircleCI e serviços da AWS ou outras aplicações compatíveis.

Tópicos

- Suporte do AWS Glue para o CircleCI
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do CircleCI
- Configuração de conexões do CircleCI
- Leitura de entidades do CircleCI
- Opções de conexão do CircleCI

- Limitações do CircleCI

Suporte do AWS Glue para o CircleCI

O AWS Glue oferece suporte ao CircleCI da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do CircleCI.

Compatível como destino?

Não.

Versões compatíveis da API do CircleCI

Estas são as versões compatíveis da API do CircleCI:

- v2

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
     "Statement": [
      {
             "Effect": "Allow",
             "Action": [
                 "glue:ListConnectionTypes",
                 "glue:DescribeConnectionType",
                 "glue:RefreshOAuth2Tokens",
                 "glue:ListEntities",
                 "glue:DescribeEntity"
             ],
             "Resource": "*"
         }
     ]
 }
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do CircleCI

Antes de usar o AWS Glue para transferir dados do CircleCI, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta no CircleCI que contém os dados que deseja transferir.
- Nas configurações de usuário da conta, você criou um token de API pessoal. Para obter mais informações, consulte Creating a personal API token.
- Você fornece o token de API pessoal para o AWS Glue ao criar a conexão.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do CircleCI.

Configuração de conexões do CircleCI

O CircleCI oferece suporte à autenticação personalizada.

Para configurar uma conexão do CircleCI:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a chave da API da aplicação conectada com `Circle-Token` como a chave.

b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

   a. Ao selecionar uma Fonte de dados, selecione o CircleCI.

   b. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   c. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

   d. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do CircleCI

Pré-requisito

Um objeto do CircleCI do qual você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Contexto	Sim	Não	Não	Sim	Não
Métrica de resumo da organização	Sim	Não	Não	Sim	Não
Pipeline	Não	Não	Não	Sim	Não
Fluxo de trabalho do pipeline	Sim	Não	Não	Sim	Não
Ramificação do projeto	Sim	Não	Não	Sim	Não
Teste instável do projeto	Não	Não	Não	Sim	Não
Métrica de resumo do projeto	Sim	Não	Não	Sim	Não
Programação	Não	Não	Não	Sim	Não
Séries temporais de trabalhos do fluxo de trabalho	Sim	Não	Não	Sim	Não
Métrica e tendência	Sim	Não	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
do fluxo de trabalho					
Execução recente do fluxo de trabalho	Sim	Não	Não	Sim	Não
Métrica de resumo do fluxo de trabalho	Sim	Não	Não	Sim	Não
Métrica de teste do fluxo de trabalho	Sim	Não	Não	Sim	Não

Exemplo:

```
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"
    }
```

Detalhes das entidades e dos campos do CircleCI

Para obter mais informações sobre os detalhes das entidades e dos campos, consulte:

- Contextos
- Métricas de resumo do projeto
- Séries temporais de trabalhos do fluxo de trabalho

- Métricas de resumo da organização
- Ramificações do projeto
- Testes instáveis do projeto
- Execuções recentes do fluxo de trabalho
- Métricas de resumo do fluxo de trabalho
- Métricas e tendências do fluxo de trabalho
- Métricas de teste do fluxo de trabalho
- Pipelines
- Fluxos de trabalho do pipeline
- Programações

Entidades com metadados estáticos:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Contexto	Criado em	String	
	ID	String	
	Name	String	
	Tipo de proprietário	String	EQUAL_TO
Métrica de resumo da organização	Todos os projetos	Lista	
	Dados da organização	Struct	
	Dados do projeto da organização	Lista	
	Nomes de projetos	String	EQUAL_TO
	Janela de relatórios	String	EQUAL_TO
Pipeline	Ramificação	String	EQUAL_TO

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Criado em	String	
	Erros	Lista	
	ID	String	
	Número	Inteiro	
	Slug do projeto	String	
	Estado	String	
	Trigger	Struct	
	Parâmetros de gatilhos	Struct	
	Atualizado em	String	
	VCS	Struct	
Fluxo de trabalho do pipeline	Cancelado por	String	
	Criado em	String	
	Erro causado por	String	
	ID	String	
	Name	String	
	ID do pipeline	String	
	Número do pipeline	Inteiro	
	Slug do projeto	String	
	Iniciado por	String	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Status	String	
	Parado em	String	
	Tag	String	
Ramificação do projeto	Ramificações	Lista	
	ID da organização	String	
	ID do projeto	String	
	Nome do fluxo de trabalho	String	EQUAL_TO
Teste instável do projeto	Nome da classe	String	
	Arquivo	String	
	Nome do trabalho	String	
	Número do trabalho	Inteiro	
	Número do pipeline	Inteiro	
	Origem	String	
	Nome do teste	String	
	Tempo desperdiçado	Inteiro	
	Ocorrências com falha	Inteiro	
	Fluxo de trabalho criado em	String	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	ID do fluxo de trabalho	String	
	Nome do fluxo de trabalho	String	
Métrica de resumo do projeto	Todas as ramificaç ões	Lista	
	Todos os fluxos de trabalho	Lista	
	Ramificações	String	EQUAL_TO
	ID da organização	String	
	Dados do projeto	Struct	
	ID do projeto	String	
	Dados da ramificação do fluxo de trabalho do projeto	Lista	
	Dados de fluxos de trabalho do projeto	Lista	
	Janela de relatórios	String	EQUAL_TO
	Nomes de fluxos de trabalho	String	EQUAL_TO
Programação	Ator	Struct	
	Criado em	String	
	Descrição	String	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	ID	String	
	Name	String	
	Parâmetros	Struct	
	Slug do projeto	String	
	Cronograma	Struct	
	Atualizado em	String	
Séries temporais de trabalhos do fluxo de trabalho	Ramificação	String	EQUAL_TO
	Granularity	String	EQUAL_TO
	Término máximo em	String	
	Métricas	Struct	
	Início mínimo em	String	
	Name	String	
	Data de início e término	DateTime	EQUAL_TO, BETWEEN
	Timestamp	String	
Métrica e tendência do fluxo de trabalho	Todas as ramificaç ões	Booliano	EQUAL_TO
	Ramificações	String	EQUAL_TO
	Métricas	Struct	
	Tendências	Struct	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Nomes de fluxos de trabalho	Lista	
Execução recente do fluxo de trabalho	Todas as ramificaç ões	Booliano	EQUAL_TO
	Ramificação	String	EQUAL_TO
	Criado em	String	
	Créditos usados	Inteiro	
	Duração	Inteiro	
	ID	String	
	É aprovação	Booliano	
	Data de início e término	DateTime	EQUAL_TO, BETWEEN
	Status	String	
	Parado em	String	
Métrica de resumo do fluxo de trabalho	Todas as ramificaç ões	Booliano	EQUAL_TO
	Ramificação	String	EQUAL_TO
	Métricas	Struct	
	Name	String	
	ID do projeto	String	
	Janela de relatórios	String	EQUAL_TO

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Fim da janela	String	
	Início da janela	String	
Métrica de teste do fluxo de trabalho	Contagem média de testes	Inteiro	
	Ramificação	String	EQUAL_TO
	Testes com mais falhas	Lista	
	Testes com mais falhas adicionais	Inteiro	
	Testes mais lentos	Lista	
	Testes mais lentos adicionais	Inteiro	
	Execuções de testes	Lista	
	Total de execuções de testes	Inteiro	

> **Note**
>
> Os tipos de dados Struct e List são convertidos no tipo de dados String na resposta do conector.

Particionamento de consultas

O CircleCI não oferece suporte ao particionamento baseado em campos ou em registros.

Opções de conexão do CircleCI

Estas são as opções de conexão do CircleCI:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no CircleCI.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do CircleCI que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.

Limitações do CircleCI

Estas são as limitações ou observações do CircleCI:

- O CircleCI não oferece suporte ao particionamento baseado em campos ou em registros.
- Os campos de filtro que contiverem “-” (hífen) só funcionarão se estiverem entre backticks (crase). Por exemplo: `workflow-name` = "abc"
- Não é possível oferecer suporte ao tipo de VCS GitLab porque não existe uma forma programática de recuperar o “ID do projeto” necessário para o caminho da entidade GitLab VCS.

Conexão ao Datadog

O Datadog é uma plataforma de monitoramento e análise para aplicações em escala de nuvem, incluindo infraestrutura, aplicações, serviços e ferramentas.

Tópicos

- Suporte do AWS Glue para o Datadog
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Datadog
- Configuração de conexões do Datadog
- Leitura de entidades do Datadog
- Opções de conexão do Datadog
- Criação de uma conta do Datadog

- Limitações

Suporte do AWS Glue para o Datadog

O AWS Glue oferece suporte ao Datadog da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do Datadog.

Compatível como destino?

Nº

Versões da API do Datadog com suporte

- v1
- v2

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Datadog

Antes de poder usar o AWS Glue para transferir dados do Datadog, os seguintes requisitos precisarão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Datadog com DD-API-KEY e DD-APPLICATION-KEY. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Datadog.
- Sua conta do Datadog tem acesso à API com uma licença válida.

O Datadog oferece suporte aos seis URLs a seguir. Todos os clientes da API do Datadog são configurados por padrão para consumir as APIs do site Datadog US1. Se você estiver no site Datadog EU, você deve selecionar o URL https://api.datadoghq.eu com a `DD-API-KEY` e `DD-APPLICATION-KEY` do site Datadog EU para acessar as APIs. Da mesma forma, para outros sites, você deverá selecionar os respectivos URLs com a `DD-API-KEY and DD-APPLICATION-KEY` do respectivo site.

- URL da API US1: https://api.datadoghq.comhttps://api.datadoghq.com
- URL da API EU: https://api.datadoghq.eu
- URL da API US3: https://api.us3.datadoghq.com

- URL da API US5: https://api.us5.datadoghq.com
- URL da API S1-FED: https://api.ddog-gov.com
- URL da API do Japão: https://api.ap1.datadoghq.com

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Datadog.

Configuração de conexões do Datadog

O Datadog oferece suporte à autenticação personalizada. A seguir estão as etapas para configurar a conexão do Datadog:

Para configurar uma conexão do Datadog:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

   Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com **`API_KEY`** e **`APPLICATION_KEY`** como chaves.

   > **Note**
   >
   > É preciso criar um segredo por conexão em AWS Glue.

2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Datadog.
   b. Forneça o `Instance_Url` do Datadog ao qual você deseja se conectar.
   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
```

```
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Datadog

Pré-requisitos

Um objeto do Datadog do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Série temporal de métricas	Sim	Não	Não	Sim	Não
Consultas de log	Sim	Sim	Sim	Sim	Não

Exemplo

```
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`"
    }
```

Detalhes de entidades e campos do Datadog

Entidade	Campo	Tipo de dado	Operadores com suporte
Série temporal de métricas	erro	String	NA
	aggr	String	NA
	attributes	Struct	NA
	display_name	String	NA
	end	DateTime	NA
	expressão	String	NA
	intervalo	Inteiro	NA
	length	Inteiro	NA
	métrica	String	NA
	pointlist	Lista	NA
	query_index	Inteiro	NA
	scope	String	NA
	rápido	DateTime	NA
	tag_set	Lista	NA
	unidade	Struct	NA

Entidade	Campo	Tipo de dado	Operadores com suporte
	from_to_date	DateTime	BETWEEN
	consulta	String	EQUAL_TO
	status	String	NA
	type	String	NA
	host	String	NA
Consultas de log	id	String	NA
	attributes	Struct	NA
	timestamp	DateTime	NA
	type	String	NA
	from	DateTime	BETWEEN,EQUAL_TO
	secundários	Lista	EQUAL_TO
	storage_tier	String	EQUAL_TO
	consulta	String	EQUAL_TO

Opções de conexão do Datadog

Estas são as opções de conexão do Datadog:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Datadog.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Datadog que você deseja usar. A versão `v1` oferece suporte à entidade `metrics-timeseries`, enquanto a versão `v2` oferece suporte à entidade `log-queries`.

- `INSTANCE_URL`(string): (obrigatório) usado para leitura. URL da instância do Datadog. O URL da instância do Datadog varia de acordo com a região.
- `SELECTED_FIELDS`(lista<string>): padrão: vazio (SELECT *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

Criação de uma conta do Datadog

1. Acesse https://www.datadoghq.com/.
2. Escolha COMEÇAR GRATUITAMENTE.
3. Insira as informações necessárias e cadastre-se.
4. Instale o Instalador do agente do Datadog conforme sugerido.
5. Certifique-se de que a conta seja registrada em uma organização válida (da lista disponível) que tenha uma assinatura ativa do Datadog.
6. Depois de fazer login na sua conta do Datadog, passe o mouse sobre seu nome de usuário no canto superior direito para ver os detalhes das Chaves:
   a. Para obter sua chave de API, escolha Chaves de API.
   b. Para obter sua chave de aplicação, escolha Chaves de aplicação.

Limitações

Estas são as limitações do conector do Datadog:

- O Datadog não oferece suporte ao particionamento baseado em campos ou baseado em registros.
- `from` é um parâmetro de filtro obrigatório para a entidade `Log Queries`.
- `from_to_date` e `query` são parâmetros de filtro obrigatórios para a entidade `Metrics Timeseries`.

Conexão ao Docusign Monitor

O Docusign Monitor ajuda as organizações a proteger seus contratos com o monitoramento de atividades 24 horas por dia. A API do Monitor fornece essas informações de rastreamento de

atividades diretamente às pilhas de segurança ou ferramentas de visualização de dados existentes, permitindo às equipes detectar atividades não autorizadas, investigar incidentes e responder rapidamente às ameaças verificadas. Ele também oferece a flexibilidade de que as equipes de segurança precisam para personalizar painéis e alertas a fim de atender às necessidades específicas dos negócios.

Tópicos

- Suporte do AWS Glue para o Docusign Monitor
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Docusign Monitor
- Configuração de conexões do Docusign Monitor
- Leitura de entidades do Docusign Monitor
- Opções de conexão do Docusign Monitor
- Limitações do Docusign Monitor

Suporte do AWS Glue para o Docusign Monitor

O AWS Glue oferece suporte ao Docusign Monitor da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Docusign Monitor.

Compatível como destino?

Não.

Versões compatíveis da API do Docusign Monitor

Estas são as versões compatíveis da API do Docusign Monitor:

- v2.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
```

```
"Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Docusign Monitor

Antes de usar o AWS Glue para transferir dados do Docusign Monitor aos destinos compatíveis, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Docusign na qual usa o produto de software Docusign no Docusign Monitor.
- No console do desenvolvedor da sua conta do Docusign, você criou uma aplicação de integração OAuth 2.0 para o AWS Glue.

  Essa aplicação fornece as credenciais de cliente que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para obter mais informações, consulte OAuth 2.0 na documentação do Docusign Monitor.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Docusign Monitor.

Configuração de conexões do Docusign Monitor

O Docusign Monitor oferece suporte ao tipo de concessão AUTHORIZATION_CODE.

- Esse tipo de concessão é considerado um OAuth de três pernas, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue.
- Os usuários podem optar por criar sua própria aplicação conectada no Docusign Monitor e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Docusign Monitor para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Docusign Monitor sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte OAuth for Docusign Connect.

Para configurar uma conexão do Docusign Monitor:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a chave da API da aplicação conectada com `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como a chave.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Em Conexões, escolha Criar conexão.
   b. Ao selecionar uma Fonte de dados, selecione o Docusign Monitor.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Forneça o ClientId da aplicação cliente gerenciada pelo usuário da aplicação Docusign Monitor.
   e. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   f. Selecione as opções de rede se quiser usar sua rede.
2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Docusign Monitor

Pré-requisito

Um objeto do Docusign Monitor do qual você deseja ler.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Monitorar dados	Sim	Sim	Não	Sim	Não

Exemplo:

```
docusignmonitor_read = glueContext.create_dynamic_frame.from_options(
    connection_type="docusign_monitor",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "monitoring-data",
        "API_VERSION": "v2.0"
    }
```

Detalhes das entidades e dos campos do Docusign Monitor

Entidades com metadados estáticos:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Monitorar dados	timestamp	DateTime	N/D
	eventId	String	N/D
	aplicação	String	N/D
	ambiente	String	N/D
	site	String	N/D
	traceToken	String	N/D
	organizationId	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	accountId	String	N/D
	userId	String	N/D
	objeto	String	N/D
	action	String	N/D
	property	String	N/D
	Campo	String	N/D
	resultado	String	N/D
	IntegratorKey	String	N/D
	customerVisible	String	N/D
	version	String	N/D
	userAgent	String	N/D
	userAgentClientInfo	Struct	N/D
	ipAddress	String	N/D
	ipAddressLocation	Struct	N/D
	dados	String	N/D
	origem	String	N/D
	latitude	Duplo	N/D
	longitude	Duplo	N/D
	city	String	N/D
	estado	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	country	String	N/D
	usUserMemberOfDomain	Booliano	N/D
	affectedUserIsMemberOfDomain	Booliano	N/D
	proxyStatus	String	N/D
	proxyType	String	N/D
	proxyLevel	String	N/D
	referencedUserId	String	N/D
	Dispositivo	String	N/D
	navegador	String	N/D
	cursor	DateTime	EQUAL_TO

Particionamento de consultas

O Docusign Monitor não oferece suporte ao particionamento baseado em campos ou em registros.

Opções de conexão do Docusign Monitor

Estas são as opções de conexão do Docusign Monitor:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Docusign Monitor.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Docusign Monitor que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.

- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.

Limitações do Docusign Monitor

Estas são as limitações ou observações do Docusign Monitor:

- Quando um filtro é aplicado usando o campo `cursor`, a API recupera registros dos próximos sete dias a partir da data especificada.
- Se nenhum filtro for fornecido, a API recuperará os registros dos sete dias anteriores à data atual da solicitação da API.
- O Docusign Monitor não oferece suporte ao particionamento baseado em campos ou em registros.
- O Docusign Monitor não oferece suporte ao recurso Ordenar por.

Conexão ao Domo

O Domo é uma ferramenta de painéis baseada na nuvem. Com a plataforma de aplicações corporativas do Domo, a base necessária para expandir o Domo já está pronta, permitindo que você crie suas soluções personalizadas com mais rapidez.

Tópicos

- Suporte do AWS Glue para o Domo
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Domo
- Configuração de conexões do Domo
- Leitura de entidades do Domo
- Opções de conexão do Domo
- Limitações do Domo

Suporte do AWS Glue para o Domo

O AWS Glue oferece suporte ao Domo da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Domo.

Compatível como destino?

Não.

Versões compatíveis da API do Domo

Estas são as versões compatíveis da API do Domo:

- v1

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
 }
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.

- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Domo

Antes de usar o AWS Glue para transferir dados do Domo aos destinos compatíveis, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Domo habilitada para acesso à API.
- Você tem uma aplicação na conta do desenvolvedor do Domo que fornece as credenciais de cliente que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para ter mais informações, consulte Criação de uma aplicação de desenvolvedor do Domo.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Domo.

Criação de uma aplicação de desenvolvedor do Domo

Para obter o ID e o segredo do cliente, crie uma conta de desenvolvedor.

1. Acesse a página de login do desenvolvedor do Domo.
2. Escolha Fazer login.
3. Forneça o nome do domínio e clique em Continue.
4. Passe o mouse sobre My Account e escolha New Client.
5. Forneça o nome e a descrição, selecione o escopo (“data”) e escolha Create.
6. Recupere o Client Id e o Client Secret gerados para o novo cliente criado.

Configuração de conexões do Domo

O Domo oferece suporte ao tipo de concessão CLIENT_CREDENTIALS para OAuth2.

- Esse tipo de concessão é considerado um OAuth de “duas pernas”, pois somente a aplicação cliente faz a própria autenticação no servidor, sem o envolvimento do usuário.
- Os usuários podem optar por criar sua própria aplicação conectada no Domo e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue.
- Para obter a documentação pública do Domo sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte OAuth Authentication.

Para configurar uma conexão do Domo:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter o token de acesso da aplicação conectada, `client_id` e `client_secret`.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Em Conexões, escolha Criar conexão.
   b. Ao selecionar uma Fonte de dados, selecione o Domo.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Domo

Pré-requisito

Um objeto do Domo do qual você deseja ler. Você precisará do nome do objeto, como Conjunto de dados ou Políticas de permissões de dados. A tabela a seguir mostra as entidades compatíveis.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Data Set	Sim	Sim	Sim	Sim	Sim
Políticas de permissões de dados	Não	Não	Não	Sim	Não

Exemplo:

```
Domo_read = glueContext.create_dynamic_frame.from_options(
    connection_type="domo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "dataset",
        "API_VERSION": "v1"
    }
```

Detalhes das entidades e dos campos do Domo

Entidades com metadados estáticos:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Políticas de permissões de dados	id	Longo	N/D
	type	String	N/D
	nome	String	N/D
	filtros	Lista	N/D
	usuários	Lista	N/D
	virtualUsers	Lista	N/D
	groups	Lista	N/D

Para as entidades a seguir, o Domo fornece endpoints para buscar metadados dinamicamente, para que o suporte do operador seja capturado no nível do tipo de dados da entidade.

Entidade	Tipo de dados	Operadores compatíveis
Data Set	Inteiro	=, !=, <, >, >=, <=
	Longo	=, !=, <, >, >=, <=
	String	=, !=, CONTAINS
	Data	=, >, >=, <, <=, BETWEEN
	DateTime	=, >, >=, <, <=, BETWEEN
	Booliano	=, !=
	Duplo	=, !=, <, >, >=, <=

Entidade	Tipo de dados	Operadores compatíveis
	Lista	N/D
	Struct	N/D

Particionamento de consultas

Particionamento com base em campo

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo DateTime, aceitamos o valor no formato ISO.

  Exemplo de valor válido:

  ```
  "2023-01-15T11:18:39.205Z"
  ```

  Para o campo de Data, aceitamos o valor no formato ISO.

  Exemplo de valor válido:

  ```
  "2023-01-15"
  ```

- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.

  Exemplo de valor válido:

  ```
  "2023-02-15T11:18:39.205Z"
  ```

- `NUM_PARTITIONS`: o número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na seguinte tabela:

Nome da entidade	Campos de particionamento	Tipo de dados
Conjunto de dados	Qualquer campo baseado em data/hora [metadados dinâmicos]	DateTime
	Qualquer campo baseado em data [metadados dinâmicos]	Data

Exemplo: .

```
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"
    }
```

Particionamento com base em registros

É possível fornecer a opção adicional `NUM_PARTITIONS` do Spark se quiser utilizar a simultaneidade no Spark. Com esse parâmetro, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

No particionamento baseado em registros, o número total de registros presentes é consultado no Domo e dividido pelo número `NUM_PARTITIONS` fornecido. O número resultante de registros é então buscado simultaneamente por cada subconsulta.

Exemplo: .

```
Domo_read = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="domo",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "dataset",
        "API_VERSION": "v1",
        "NUM_PARTITIONS": "2"
    }
```

Opções de conexão do Domo

Estas são as opções de conexão do Domo:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Domo.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Domo que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações do Domo

Estas são as limitações ou observações do Domo:

- Devido a uma limitação do SDK, a filtragem não funciona conforme o esperado para os campos consultáveis que começam com “_” (por exemplo: _BATCH_ID).
- Devido a uma limitação da API, a filtragem funciona para a data anterior à data que você informar. Isso também afeta a extração incremental. Para contornar essa limitação, selecione uma data de acordo com seu fuso horário em relação ao UTC, para obter os dados para a data necessária.

Conexão ao Dynatrace

O Dynatrace é uma plataforma que oferece analytics e automação para observabilidade e segurança abrangentes. Sua especialidade é monitorar e otimizar a performance de aplicações, a infraestrutura e a experiência dos usuários.

Tópicos

- Suporte do AWS Glue para o Dynatrace
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Dynatrace
- Configuração de conexões do Dynatrace
- Leitura de entidades do Dynatrace
- Opções de conexão do Dynatrace
- Limitações do Dynatrace

Suporte do AWS Glue para o Dynatrace

O AWS Glue oferece suporte ao Dynatrace da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Dynatrace.

Compatível como destino?

Não.

Versões compatíveis da API do Dynatrace

Estas são as versões compatíveis da API do Dynatrace:

- v2

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
 }
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Dynatrace

Antes de usar o AWS Glue para transferir dados do Dynatrace, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Dynatrace.
- Você gerou um token de acesso na conta do Dynatrace com o escopo apropriado de leitura/gravação atribuído para acessar as APIs. Para obter mais informações, consulte Generate a token.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Dynatrace.

Configuração de conexões do Dynatrace

O Dynatrace oferece suporte à autenticação personalizada.

Para configurar uma conexão do Dynatrace:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a chave da API da aplicação conectada com *apiToken* como a chave.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar uma Fonte de dados, selecione o Dynatrace.
   b. Forneça o `INSTANCE_URL` da conta do Dynatrace à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
```

```
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Dynatrace

Pré-requisito

Um objeto do Dynatrace do qual você deseja ler. Você precisará do nome do objeto, como “problema”.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Problema	Sim	Sim	Sim	Sim	Não

Exemplo:

```
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"
    }
```

Detalhes das entidades e dos campos do Dynatrace:

O Dynatrace fornece endpoints para buscar metadados dinamicamente para entidades compatíveis. Portanto, o suporte do operador é capturado no nível do tipo de dados.

Entidade	Campo	Tipo de dados	Operadores compatíveis
Problema	affectedEntities	Lista	EQUAL_TO
	displayId	String	EQUAL_TO
	endTime	DateTime	
	entityTags	Lista	
	evidenceDetails	Struct	
	impactAnalysis	Struct	
	impactLevel	String	EQUAL_TO
	impactedEntities	Lista	EQUAL_TO
	linkedProblemInfo	Struct	
	managementZones	Lista	EQUAL_TO
	problemFilters	Lista	
	recentComments	Struct	
	rootCauseEntity	Struct	EQUAL_TO
	problemId	String	EQUAL_TO
	severityLevel	String	EQUAL_TO
	startTime	DateTime	BETWEEN
	status	String	EQUAL_TO
	título	String	
	from	DateTime	EQUAL_TO, BETWEEN

Entidade	Campo	Tipo de dados	Operadores compatíveis
	problemFilterIds	String	EQUAL_TO
	problemFilterNames	String	EQUAL_TO
	managementZoneIds	String	EQUAL_TO
	text	String	EQUAL_TO
	underMaintenance	Booliano	EQUAL_TO
	message	String	

Particionamento de consultas

O Dynatrace não oferece suporte ao particionamento baseado em campos ou em registros.

Opções de conexão do Dynatrace

Estas são as opções de conexão do Dynatrace:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Dynatrace.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Dynatrace que você deseja usar.
- `INSTANCE_URL`(string): usado para leitura. Um URL de instância válida do Dynatrace.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.

Limitações do Dynatrace

Estas são as limitações ou observações do Dynatrace:

- O Dynatrace não oferece suporte ao particionamento baseado em campos ou em registros.

- Para o recurso Selecionar tudo, se você fornecer o “campo” no filtro, ele não permitirá mais de dez registros por página.
- O tamanho máximo aceito para a página é 500. Se você selecionar qualquer um dos campos [`evidenceDetails, impactAnalysis, recentComments`] ao criar o fluxo, serão mostrados por padrão dez registros por página.

Conexão com o Facebook Ads

O Facebook Ads é uma poderosa plataforma de publicidade digital usada por empresas de todos os tamanhos para atingir seu público-alvo e cumprir objetivos variados de marketing. A plataforma permite que os anunciantes criem anúncios personalizados que podem ser exibidos em toda a família de aplicações e serviços do Facebook, incluindo o Facebook e o Messenger. Com seus recursos avançados de segmentação, o Facebook Ads permite que as empresas atinjam dados demográficos, interesses, comportamentos e locais específicos.

Tópicos

- Suporte do AWS Glue para o Facebook Ads
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Facebook Ads
- Configuração de conexões do Facebook Ads
- Leitura de entidades do Facebook Ads
- Opções de conexão do Facebook Ads
- Limitações e notas do conector do Facebook Ads

Suporte do AWS Glue para o Facebook Ads

O AWS Glue oferece suporte ao Facebook Ads da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Facebook Ads.

Compatível como destino?

N.º

Versões da API do Facebook Ads compatíveis

As seguintes versões da API do Facebook Ads são compatíveis:

- v17.0
- v18.0
- v19.0
- v20.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.

- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Facebook Ads

Antes de poder usar o AWS Glue para transferir dados do Facebook Ads, você precisa atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- As contas padrão do Facebook são acessadas diretamente pelo Facebook.
- A autenticação do usuário é necessária para gerar o token de acesso.
- O conector do SDK do Facebook Ads implementará o fluxo do OAuth para tokens de acesso do usuário.
- Estamos usando o OAuth2.0 para autenticar nossas solicitações de API para o Facebook Ads. Essa autenticação baseada na Web se enquadra na arquitetura autenticação multifator (MFA), que é um superconjunto de 2FA.
- O usuário precisa conceder permissões para acessar os endpoints. Para acessar os dados do usuário, a autorização do endpoint é processada por meio de permissões e recursos.

Obtenção de credenciais do Outh 2.0

Para obter credenciais de API para que você possa fazer chamadas autenticadas para instâncias, consulte API REST no Facebook Ads Developer Guide.

Configuração de conexões do Facebook Ads

O Facebook Ads é compatível com o tipo de concessão AUTHORIZATION_CODE para OAuth2.

- Esse tipo de concessão é considerado um OAuth de três pernas, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue.

- Os usuários ainda podem optar por criar sua própria aplicação conectada no Facebook Ads e fornecer os próprios ID e segredo de cliente quando criarem conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Facebook Ads para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de acesso. Um token de usuário do sistema prestes a expirar é válido por 60 dias a partir de uma data gerada ou atualizada. Para criar continuidade, o desenvolvedor deve atualizar o token de acesso em até 60 dias. Se isso não for feito, o token de acesso será perdido e será exigido que o desenvolvedor obtenha um novo token para recuperar o acesso à API. Consulte Atualizar token de acesso.
- Para obter a documentação pública do Facebook Ads sobre a criação de uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Uso do OAuth 2.0 para acessar APIs do Google no guia Google para desenvolvedores.

Para configurar uma conexão com o Facebook Ads:

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Facebook Ads.
   b. Forneça o `INSTANCE_URL` da instância do Facebook Ads à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Facebook Ads

Pré-requisito

Um objeto do Facebook Ads do qual você deseja ler. Você precisará do nome do objeto. As tabelas a seguir mostram as entidades compatíveis.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Campaign	Sim	Sim	Não	Sim	Sim
Conjunto de anúncios	Sim	Sim	Não	Sim	Sim
Ads	Sim	Sim	Não	Sim	Sim
Anúncio criativo	Não	Sim	Não	Sim	Não
Insights: conta	Não	Sim	Não	Sim	Não
Adaccounts	Sim	Sim	Não	Sim	Não
Insights: anúncio	Sim	Sim	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Insights: AdSet	Sim	Sim	Não	Sim	Sim
Insights: campanha	Sim	Sim	Não	Sim	Sim

Exemplo:

```
FacebookAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="FacebookAds",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0"
    }
```

Detalhes das entidades e dos campos do Facebook Ads

Para obter mais informações sobre os detalhes das entidades e dos campos, consulte:

- Conta de anúncios
- Campanha
- Conjunto de anúncios
- Ad
- Anúncio criativo
- Conta de anúncios de insight
- Anúncios de insights
- Conjuntos de anúncios de insights
- Campanhas de insights

Para obter mais informações, consulte API de marketing.

> **Note**
>
> Os tipos de dados Struct e List são convertidos no tipo de dados String na resposta dos conectores.

Consultas de particionamento

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Data e hora, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

  Exemplo de valor válido:

  ```
  "2022-01-01"
  ```

- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: o número de partições.

Exemplo:

```
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"
    }
```

Opções de conexão do Facebook Ads

Estas são as opções de conexão do Facebook Ads:

- `ENTITY_NAME`(String): (obrigatório) usado para leitura. O nome do objeto no Facebook Ads.
- `API_VERSION`(String): (obrigatório) usado para leitura. Versão da API Rest do Facebook Ads que você deseja usar. Por exemplo: v1.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `TRANSFER_MODE`(String): padrão: SYNC. Usado para leitura assíncrona.

Limitações e notas do conector do Facebook Ads

Estas são as limitações ou notas do conector do Facebook Ads:

- Como o Facebook Ads é compatível com metadados dinâmicos, todos os campos podem ser consultados. Todos os campos oferecem suporte a filtragem e os registros serão buscados quando os dados estiverem disponíveis. Caso contrário, o Facebook retornará uma resposta de solicitação inválida (400) com uma mensagem de erro adequada.
- A contagem de chamadas de uma aplicação é o número de chamadas que um usuário pode fazer durante uma janela contínua de uma hora, 200 multiplicado pelo número de usuários. Para conhecer detalhes sobre o limite de taxa, consulte Limites de taxa e Limites de taxa de casos de uso empresarial.

Conexão com o Facebook Page Insights

O Facebook Pages permite que empresas e outros grupos de interesse criem páginas para a rede social Facebook.com. As empresas usam essas páginas para compartilhar o horário de funcionamento, fazer anúncios e interagir com os clientes online. Se você for usuário do Facebook Page Insights, poderá conectar o AWS Glue à sua conta do Facebook Page Insights. É possível usar o Facebook Page Insights como fonte de dados em suas tarefas de ETL. Execute essas tarefas para transferir dados do Facebook Page Insights para serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para o Facebook Page Insights
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Facebook Page Insights
- Configuração de conexões do Facebook Page Insights
- Leitura de entidades do Facebook Page Insights
- Opções de conexão do Facebook Page Insights
- Limitações e notas do conector do Facebook Page Insights

Suporte do AWS Glue para o Facebook Page Insights

O AWS Glue oferece suporte ao Facebook Page Insights da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do Facebook Page Insights.

Compatível como destino?

Nº

Versões da API do Facebook Page Insights com suporte

Versões da API do Facebook Page Insights com suporte:

- v17
- v18
- v19

- v20
- v21

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
 }
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Facebook Page Insights

Antes de poder usar o AWS Glue para transferir dados do Facebook Page Insights, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- As contas padrão do Facebook são acessadas diretamente pelo Facebook.
- A autenticação do usuário é necessária para gerar o token de acesso.
- O conector do Facebook Page Insights implementa o fluxo do OAuth para tokens de acesso do usuário.
- O conector usa OAuth 2.0 para autenticar nossas solicitações de API no Facebook Page Insights. Isso se enquadra na arquitetura de autenticação multifator (MFA), que é um superconjunto de 2FA. É uma autenticação baseada na Web.
- O usuário precisa conceder permissões para acessar os endpoints. Para acessar os dados do usuário, a autorização do endpoint é processada por meio de permissões e recursos.

Configuração de conexões do Facebook Page Insights

Para configurar uma conexão com o Facebook Page Insights:

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Facebook Page Insights.
   b. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
```

```
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

c. Selecione o URL do código de autorização.

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Facebook Page Insights

Pré-requisito

Um objeto do Facebook Page Insights do qual você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Conteúdo da página	Sim	Não	Sim	Sim	Sim
Cliques em CTA da página	Sim	Não	Não	Sim	Sim
Engajamento da página	Sim	Não	Não	Sim	Sim
Impressões da página	Sim	Não	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Publicações da página	Sim	Não	Não	Sim	Sim
Engajamento de publicação da página	Não	Não	Não	Sim	Não
Reações à publicação da página	Não	Não	Não	Sim	Não
Reações à página	Sim	Não	Não	Sim	Sim
Histórias	Sim	Não	Não	Sim	Sim
Demografia dos usuários da página	Sim	Não	Não	Sim	Sim
Visualizações de vídeo da página	Sim	Não	Não	Sim	Sim
Visualizações da página	Sim	Não	Não	Sim	Sim
Publicações de vídeo da página	Sim	Não	Não	Sim	Sim
Páginas	Não	Sim	Não	Sim	Não
Feeds	Sim	Sim	Não	Sim	Sim

Exemplo:

```
facebookPageInsights_read = glueContext.create_dynamic_frame. from options(
    connection_type="facebookpageinsights",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v21"
   }
```

Detalhes de campo do Facebook Page Insights:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Conteúdo da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Cliques em CTA da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Engajamento da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Impressões da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Id	String	N/D
Publicações da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Engajamento de publicação da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Reações à publicação da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Valores	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Demografia dos usuários da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Visualizações de vídeo da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	description_from_api_doc	String	N/D
	Id	String	N/D
Visualizações da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D
Publicações de vídeo da página	Name	String	N/D
	Período	Período	EQUAL_TO
	Since	DateTime	EQUAL_TO
	Valores	Lista	N/D
	Cargo	String	N/D
	Descrição	String	N/D
	description_from_api_doc	String	N/D
	Id	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
Páginas	Name	String	N/D
	Sobre	String	N/D
	access_token	String	N/D
	ad_campaign	String	N/D
	Afiliação	String	N/D
	app_id	String	N/D
	artists_we_like	String	N/D
	Traje	String	N/D
	Prêmios	String	N/D
	band_interests	String	N/D
	band_members	String	N/D
	best_page	String	N/D
	Bio	String	N/D
	Aniversário	String	N/D
	booking_agent	String	N/D
	Construído	String	N/D
	can_checkin	String	N/D
	can_post	String	N/D
	Categoria	String	N/D
	category_list	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Check-ins	Inteiro	N/D
	company_overview	String	N/D
	connected_instagram_account	String	N/D
	contact_address	String	N/D
	country_page_likes	Inteiro	N/D
	Cobertura	Struct	N/D
	culinary_team	String	N/D
	current_location	String	N/D
	delivery_and_pickup_option_info	Lista	N/D
	Descrição	String	N/D
	description_html	String	N/D
	differently_open_offerings	Lista	N/D
	directed_by	String	N/D
	display_subtext	String	N/D
	displayed_message_response_time	String	N/D
	E-mails	String	N/D
	Engajamento	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	fan_count	Inteiro	N/D
	featured_video	String	N/D
	Atributos	String	N/D
	followers_count	Inteiro	N/D
	food_styles	Lista	N/D
	Fundada	String	N/D
	general_info	String	N/D
	general_manager	String	N/D
	Gênero	String	N/D
	global_brand_page_name	String	N/D
	global_brand_root_id	String	N/D
	has_added_app	Booleano	N/D
	has_transitioned_to_new_page_experience	Booleano	N/D
	has_whatsapp_business_number	Booleano	N/D
	has_whatsapp_number	Booleano	N/D
	Cidade natal	String	N/D
	Horas	Struct	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Impressum	String	N/D
	Influências	String	N/D
	instagram_business_account	String	N/D
	is_always_open	Booleano	N/D
	is_chain	Booleano	N/D
	is_community_page	Booleano	N/D
	is_eligible_for_branded_content	Booleano	N/D
	is_messenger_bot_get_started_enabled	Booleano	N/D
	is_messenger_platform_bot	Booleano	N/D
	is_owned	Booleano	N/D
	is_permanently_closed	Booleano	N/D
	is_published	Booleano	N/D
	Name	String	N/D
	Tarefas	Lista	N/D
	is_unclaimed	Booleano	N/D
	is_webhooks_subscribed	Booleano	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	leadgen_tos_acceptance_time	DateTime	N/D
	leadgen_tos_accepted	Booleano	N/D
	leadgen_tos_accepting_user	String	N/D
	leadgen_tos_accepting_user	Struct	N/D
	Link	Link	N/D
	Local	Struct	N/D
	Membros	String	N/D
	merchant_review_status	String	N/D
	messenger_ads_default_icebreakers	Lista	N/D
	messenger_ads_default_page_welcome_message	Struct	N/D
	messenger_ads_default_quick_replies	Lista	N/D
	messenger_ads_quick_replies_type	String	N/D
	Missão	String	N/D
	Mpg	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	name_with_location_descriptor	String	N/D
	Rede	String	N/D
	new_like_count	Inteiro	N/D
	offer_eligible	Booleano	N/D
	overall_star_rating	Float	N/D
	page_token	String	N/D
	parent_page	String	N/D
	Estacionamento	String	N/D
	payment_options	Struct	N/D
	personal_info	String	N/D
	personal_interests	String	N/D
	pharma_safety_info	String	N/D
	Telefone	String	N/D
	pickup_options	Lista	N/D
	place_type	String	N/D
	plot_outline	String	N/D
	press_contact	String	N/D
	price_range	String	N/D
	privacy_info_url	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	produced_by	String	N/D
	Produtos	String	N/D
	promotion_eligible	Booleano	N/D
	promotion_ineligible_reason	String	N/D
	public_transit	String	N/D
	rating_count	Inteiro	N/D
	record_label	String	N/D
	release_date	String	N/D
	restaurant_services	Struct	N/D
	especialidades_restaurante	Struct	N/D
	Programação	String	N/D
	screenplay_by	String	N/D
	Temporada	String	N/D
	single_line_address	String	N/D
	Estrelando	String	N/D
	start_info	Struct	N/D
	store_code	String	N/D
	store_location_descriptor	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	store_number	Inteiro	N/D
	Studio	String	N/D
	suporta_botão_de_doação_em_vídeo_ao_vivo	Booleano	N/D
	talking_about_count	Inteiro	N/D
	temporary_status	String	N/D
	unread_message_count	Inteiro	N/D
	unread_notif_count	Inteiro	N/D
	unseen_message_count	Inteiro	N/D
	Nome de usuário	String	N/D
	verification_status	String	N/D
	voip_info	Struct	N/D
	Website	String	N/D
	were_here_count	Inteiro	N/D
	whatsapp_number	String	N/D
written_by	String	N/D	
Feeds	Id	String	N/D
	Ações	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	admin_creator	Objeto	N/D
	Aplicação	Objeto	N/D
	Anexos	Objetos	N/D
	backdated_time	DateTime	N/D
	call_to_action	Objeto	N/D
	can_reply_privately	Booleano	N/D
	child_attachments	Lista	N/D
	Coordenadas	Struct	N/D
	created_time	DateTime	N/D
	Event	Struct	N/D
	expanded_height	Inteiro	N/D
	expanded_width	Inteiro	N/D
	feed_targeting	Objeto	N/D
	De	Objeto	N/D
	full_picture	String	N/D
	Altura	Inteiro	N/D
	Ícone	String	N/D
	instagram_eligibility	String	N/D
	is_eligible_for_promotion	Booleano	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	is_expired	Booleano	N/D
	is_hidden	Booleano	N/D
	is_inline_created	Booleano	N/D
	is_instagram_eligible	Booleano	N/D
	is_popular	Booleano	N/D
	is_published	Booleano	N/D
	is_spherical	Booleano	N/D
	Mensagem	String	N/D
	message_tags	Lista	N/D
	multi_share_end_card	Booleano	N/D
	multi_share_optimized	Booleano	N/D
	parent_id	String	N/D
	permalink_url	String	N/D
	Local	String	N/D
	Privacy (Privacidade)	Objeto	N/D
	promotable_id	String	N/D
	promotion_status	String	N/D
	Propriedades	Lista	N/D
	scheduled_publish_time	Float	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	Compartilhamentos	Objeto	N/D
	status_type	String	N/D
	História	String	N/D
	story_tags	Lista	N/D
	Inscrito	Booleano	N/D
	Alvo	Struct	N/D
	Definição de destino	Objeto	N/D
	Para	Objeto	N/D
	timeline_visibility	String	N/D
	updated_time	DateTime	N/D
	Via	Struct	N/D
	video_buying_eligibility	Lista	N/D
	Largura	Inteiro	N/D
	Since	DateTime	EQUAL_TO

Particionamento de consultas

Particionamento baseado em filtro:

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Datetime, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

  Exemplos de valores válidos:

  ```
  "2024-09-30T01:01:01.000Z"
  ```
- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

Exemplo: .

```
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"
     }
```

Opções de conexão do Facebook Page Insights

Estas são as opções de conexão do Facebook Page Insights:

- ENTITY_NAME(string): (obrigatório) usado para leitura. O nome do objeto no Facebook Page Insights.
- API_VERSION(string): (obrigatório) usado para leitura. Versão da API Rest do Facebook Page Insights que você deseja usar.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- FILTER_PREDICATE(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL`(string): (obrigatório) usado para leitura. Um URL de instância válida do Facebook Page Insights.

Limitações e notas do conector do Facebook Page Insights

Estas são as limitações ou notas do conector do Facebook Page Insights:

- A maioria das métricas será atualizada uma vez a cada 24 horas.
- Somente os últimos dois anos de dados de insights estão disponíveis.
- Somente 90 dias de insights podem ser visualizados ao mesmo tempo usando os parâmetros `since` e `until`.

Conexão com o Freshdesk

O Freshdesk é um software de suporte ao cliente baseado em nuvem que é rico em atributos e fácil de usar. Com vários canais de suporte disponíveis, incluindo chat ao vivo, e-mail, telefone e mídias sociais, é possível ajudar os clientes por meio dos seus métodos de comunicação preferidos. Se você for um usuário do Freshdesk, poderá conectar o AWS Glue à sua conta do Freshdesk. Em seguida, será possível usar o Freshdesk como fonte de dados nos seus trabalhos de ETL. Execute essas tarefas para transferir dados do Freshdesk para serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para o Freshdesk
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Freshdesk
- Configuração de conexões do Freshdesk
- Leitura de entidades do Freshdesk

- Opções de conexão do Freshdesk
- Limitações e notas do conector do Freshdesk

Suporte do AWS Glue para o Freshdesk

O AWS Glue oferece suporte ao Freshdesk da seguinte forma:

Compatível como fonte?

Sim: SYNC e ASYNC. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do Freshdesk.

Compatível como destino?

Nº

Versões da API do Freshdesk com suporte

Versões da API do Freshdesk com suporte:

- v2

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
```

```
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Freshdesk

Antes de poder usar o AWS Glue para transferir dados do Freshdesk, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Uma conta Freshdesk. Você pode escolher entre as edições Gratuita, Growth, Pro ou Enterprise.
- Uma chave de API do usuário do Freshdesk.

Configuração de conexões do Freshdesk

O Freshdesk é compatível com a autenticação personalizada.

Para obter a documentação pública do Freshdesk sobre a geração das chaves de API necessárias para autenticação personalizada, consulte Freshdesk authentication.

Confira abaixo as etapas para configurar a conexão do Freshdesk:

- No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

  - Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a chave da API da aplicação conectada com `apiKey` como a chave. Observação: é preciso criar um segredo por conexão no AWS Glue.
- No AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
  - Ao selecionar uma Fonte de dados, selecione Freshdesk.
  - Forneça o `INSTANCE_URL` da instância do Freshdesk à qual você deseja se conectar.
  - Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

  - Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para inserir os tokens.
  - Selecione as opções de rede se quiser usar sua rede.
- Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
- Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Freshdesk

Pré-requisito

Um objeto do Freshdesk do qual você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis com a fonte de Sync:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Agentes	Sim	Sim	Não	Sim	Sim
Horário comercial	Não	Sim	Não	Sim	Sim
Empresa	Sim	Sim	Não	Sim	Sim
Contatos	Sim	Sim	Não	Sim	Sim
Conversas	Não	Sim	Não	Sim	Não
Configura ções de e-mail	Não	Sim	Não	Sim	Não
Caixas de entrada de e-mail	Sim	Sim	Sim	Sim	Não
Categorias do fórum	Não	Sim	Não	Sim	Não
Fóruns	Não	Sim	Não	Sim	Não
Grupos	Não	Sim	Não	Sim	Não
Produtos	Não	Sim	Não	Sim	Não
Perfis	Não	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Classificação de satisfação	Sim	Sim	Não	Sim	Não
Habilidades	Não	Sim	Não	Sim	Não
Soluções	Sim	Sim	Não	Sim	Não
Pesquisas	Não	Sim	Não	Sim	Não
Tíquetes	Sim	Sim	Sim	Sim	Sim
Registros de tempo	Sim	Sim	Não	Sim	Não
Tópicos	Não	Sim	Não	Sim	Não
Comentários do tópico	Não	Sim	Não	Sim	Não

Entidades compatíveis com a fonte de ASYNC:

Entidade	Versão da API	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Empresas	v2	Não	Não	Não	Não	Não
Contatos	v2	Não	Não	Não	Não	Não

Exemplo:

```
freshdesk_read = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="freshdesk",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v2"
    }
```

Detalhes de entidades e campos do Slack

Entidade	Campo
Agentes	https://developers.freshdesk.com/api/#list_all_agents
Horário comercial	https://developers.freshdesk.com/api/#list_all_business_hours
Comentários	https://developers.freshdesk.com/api/#comment_attributess
Empresa	https://developers.freshdesk.com/api/#companies
Contatos	https://developers.freshdesk.com/api/#list_all_contacts
Conversas	https://developers.freshdesk.com/api/#list_all_ticket_notes
Configurações de e-mail	https://developers.freshdesk.com/api/#list_all_email_configs
Caixas de entrada de e-mail	https://developers.freshdesk.com/api/#list_all_email_mailboxes
Categorias do fórum	https://developers.freshdesk.com/api/#category_attributes
Fóruns	https://developers.freshdesk.com/api/#forum_attributes

Entidade	Campo
Grupos	https://developers.freshdesk.com/api/#list_all_groups
Produtos	https://developers.freshdesk.com/api/#list_all_products
Perfis	https://developers.freshdesk.com/api/#list_all_roles
Classificação de satisfação	https://developers.freshdesk.com/api/#view_all_satisfaction_ratingss
Habilidades	https://developers.freshdesk.com/api/#list_all_skills
Soluções	https://developers.freshdesk.com/api/#solution_content
Pesquisas	https://developers.freshdesk.com/api/#list_all_survey
Tíquetes	https://developers.freshdesk.com/api/#list_all_tickets
Registros de tempo	https://developers.freshdesk.com/api/#list_all_time_entries
Tópicos	https://developers.freshdesk.com/api/#topic_attributes

Particionamento de consultas

Particionamento baseado em filtro:

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses

parâmetros, a consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Datetime, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

  Exemplos de valores válidos:

  ```
  "2024-09-30T01:01:01.000Z"
  ```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

Exemplo:

```
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"
     }
```

Opções de conexão do Freshdesk

Estas são as opções de conexão do Freshdesk:

- ENTITY_NAME(string): (obrigatório) usado para leitura. O nome do seu objeto no Freshdesk.
- API_VERSION(string): (obrigatório) usado para leitura. Versão da API Rest do Freshdesk que você deseja usar.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.

- FILTER_PREDICATE(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- PARTITION_FIELD(string): usado para leitura. Campo a ser usado para particionar a consulta.
- LOWER_BOUND(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- UPPER_BOUND(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- INSTANCE_URL (String): (obrigatório) usado para leitura. Um URL de instância válida do Freshdesk.
- TRANSFER_MODE (String): usado para indicar se o tipo de processamento como SYNC ou ASYNC está definido como SYNC por padrão. (Opcional)

Limitações e notas do conector do Freshdesk

Estas são as limitações ou notas do conector do Freshdesk:

- As entidades Company, Contacts e Tickets com filtragem têm limitações de paginação. Elas retornam somente 30 registros por página, e o valor da página pode ser configurado até um máximo de 10 (obtendo no máximo 300 registros).
- A entidade Tickets não busca registros com mais de 30 dias.
- As entidades Company, Contacts e Tickets oferecem suporte ao tipo de dados 'Data' na filtragem. Você deve selecionar as frequências de acionamento de "Diária" em diante para essas três entidades. Selecionar "Minutos" ou "Horária" pode resultar em dados duplicados. Além disso, ao selecionar esses campos para filtragem, somente o valor da data deve ser selecionado, pois ele considerará apenas a parte da data do carimbo de data/hora selecionado.
- O número de chamadas de API por minuto é baseado no seu plano. Esse limite é aplicado em toda a conta, independentemente de fatores como o número de agentes ou endereços IP usados para fazer as chamadas. Para todos os usuários de teste, há um limite padrão de APIs de 50 chamadas/minuto. Para obter mais detalhes, consulte Freshdesk
- Para qualquer entidade, somente um trabalho de exportação/assíncrono é processado por vez. Um novo trabalho só será processado quando o trabalho existente tiver sido concluído com sucesso ou falhar. Para obter mais detalhes, consulte Freshdesk

- Os campos a seguir são compatíveis com chamadas de API Sync, mas não são compatíveis/permitidos para serem passados no corpo da solicitação da API Async.
  - id
  - created_at
  - updated_at
  - updated_since
  - active
  - company_id
  - other_companies
  - avatar
  - view_all_tickets
  - deleted
  - other_emails
  - estado
  - tag
  - tags

Conexão com o Freshsales

O Freshsales é um CRM intuitivo que ajuda os representantes de vendas a eliminar o trabalho de suposição das vendas. Com telefone e e-mail integrados, tarefas, compromissos e notas, os representantes de vendas não precisam alternar entre as guias para acompanhar os clientes potenciais. É possível gerenciar melhor seus negócios com a visualização do pipeline e direcionar mais negócios para o fechamento. Se você for um usuário do Freshsales, poderá conectar o AWS Glue à sua conta do Freshsales. Em seguida, será possível usar o Freshsales como fonte de dados nos seus trabalhos de ETL. Execute essas tarefas para transferir dados do Freshsales para serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para o Freshsales
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Freshsales
- Configuração de conexões do Freshsales

- Leitura de entidades do Freshsales
- Opções de conexão do Freshsales
- Limitações do Freshsales

Suporte do AWS Glue para o Freshsales

O AWS Glue oferece suporte ao Freshsales da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do Freshsales.

Compatível como destino?

Nº

Versões da API do Freshsales com suporte

Versões da API do Freshsales cpm suporte:

- v1.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
     "Statement": [
      {
             "Effect": "Allow",
             "Action": [
                 "glue:ListConnectionTypes",
                 "glue:DescribeConnectionType",
                 "glue:RefreshOAuth2Tokens",
                 "glue:ListEntities",
                 "glue:DescribeEntity"
             ],
             "Resource": "*"
         }
```

```
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Freshsales

Antes de poder usar o AWS Glue para transferir dados do Freshsales, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Freshsales.
- Você tem uma chave de API do usuário.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Freshsales. Para conexões típicas, você não precisa fazer mais nada no Freshsales.

Configuração de conexões do Freshsales

O Freshsales oferece suporte à autenticação personalizada.

Para obter a documentação pública do Freshdesk sobre a geração das chaves de API necessárias para autenticação personalizada, consulte Autenticação.

Para configurar uma conexão do Freshsales:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a chave da API da aplicação conectada com *apiSecretKey* como a chave. O segredo também precisa conter outro par de chave-valor com *apiKey* como chave e *token* como valor.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar uma Fonte de dados, selecione o Freshsales.
   b. Forneça o `INSTANCE_URL` da conta do Freshsales à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   e. Selecione as opções de rede se quiser usar sua rede.
2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Freshsales

Pré-requisito

Um objeto do Freshsales do qual você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Contas	Sim	Sim	Sim	Sim	Sim
Contatos	Sim	Sim	Sim	Sim	Sim

Exemplo:

```
freshSales_read = glueContext.create_dynamic_frame.from_options(
     connection_type="freshsales",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "entityName",
         "API_VERSION": "v1.0"
     }
```

Detalhes de entidade e campo do Freshsales:

O Freshsales fornece endpoints para a busca de metadados de forma dinâmica para entidades com suporte. Portanto, o suporte do operador é capturado no nível do tipo de dados.

Entidade	Tipo de dados	Operadores compatíveis
Entidades do Freshsales (todas)	Inteiro	!=,=,<,<=,>,>=,BETWEEN
	String	Like, =, !=
	BigInteger	!=,=,<,<=,>,>=,BETWEEN

Entidade	Tipo de dados	Operadores compatíveis
	Booleano	=
	Duplo	!=,=,<,<=,>,>=,BETWEEN
	BigDecimal	!=,=,<,<=,>,>=,BETWEEN
	Data	!=,=,<,<=,>,>=,BETWEEN
	DateTime	!=,=,<,<=,>,>=,BETWEEN
	Struct	N/D
	Lista	N/D

Particionamento de consultas

Particionamento baseado em filtro:

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo Datetime, aceitamos o valor no formato ISO.

  Exemplos de valores válidos:

  ```
  "2024-09-30T01:01:01.000Z"
  ```

- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: o número de partições.

Exemplo: .

```
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"
     }
```

Opções de conexão do Freshsales

Estas são as opções de conexão do Freshsales:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Freshsales.
- `API_VERSION`(string): (obrigatório) usado para leitura. Versão da API Rest do Freshsales que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL`(string): usado para leitura. Um URL válido da instância do Freshsales.

Limitações do Freshsales

Estas são as limitações ou notas do Freshsales:

- No Freshsales, o limite da taxa de API é de 1.000 solicitações de API por hora, por conta (consulte Erros). Mas esse limite pode ser estendido com o plano de assinatura Enterprise (veja a comparação de planos).

Conexão com o Google Ads

A API do Google Ads é a interface programática do Google Ads, usada para gerenciar contas e campanhas grandes ou complexas do Google Ads. Se você for um usuário do Google Ads, poderá conectar o AWS Glue à sua conta do Google Ads. Em seguida, será possível usar o Google Ads como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Google Ads e serviços da AWS ou outras aplicações com suporte.

Tópicos

- Compatibilidade do AWS Glue com o Google Ads
- Políticas contendo as API operações para criar e usar conexões
- Configurando o Google Ads
- Configuração de conexões do Google Ads
- Leitura de entidades do Google Ads
- Opções de conexão do Google Ads
- Criação de uma conta do Google Ads
- Limitações

Compatibilidade do AWS Glue com o Google Ads

O AWS Glue é compatível com o Google Ads da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados no Google Ads.

Compatível como destino?

Não.

Versões da API do Google Ads compatíveis

v18

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Você também pode usar as seguintes IAM políticas gerenciadas para permitir o acesso:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configurando o Google Ads

Antes de usar AWS Glue para transferir do Google Ads, você precisa atender aos seguintes requisitos:

Requisitos mínimos

- Você tem uma conta do Google Ads com e-mail e senha. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Google Ads.
- Sua conta do Google Ads está ativada para API acesso. Todo o uso do Google Ads API está disponível sem custo adicional.
- Sua conta do Google Ads permite que você instale aplicativos conectados. Se você não tiver acesso a essa funcionalidade, entre em contato com o administrador do Google Ads.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua conta do Google Ads.

Configuração de conexões do Google Ads

O Google Ads oferece suporte ao tipo de concessão `AUTHORIZATION_CODE` para OAuth2.

Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O console do AWS Glue redirecionará o usuário para o Google Ads, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Google Ads.

Os usuários podem optar por criar sua própria aplicação conectada no Google Ads e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Google Ads para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter mais informações, consulte a documentação pública do Google Ads sobre a criação de uma aplicação conectada para o fluxo de código de autorização do OAuth.

Para configurar uma conexão com o Google Ads:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.

a. Para o tipo de concessão AuthorizationCode:

- Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

a. Ao selecionar um tipo de conexão, escolha Google Ads.

b. Forneça o `developer token` do Google Ads ao qual deseja se conectar.

c. Forneça o `MANAGER ID` do Google Ads se você quiser fazer login como gerente.

d. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

e. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

f. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Google Ads

Pré-requisitos

- Um objeto do Google Ads do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Anúncio de grupo de anúncios	Sim	Sim	Sim	Não	Sim
Grupo de anúncios	Sim	Sim	Sim	Não	Sim
Orçamento da campanha	Sim	Sim	Sim	Sim	Sim
Orçamento da conta	Sim	Não	Sim	Sim	Não
Campaign	Sim	Sim	Sim	Sim	Sim
Conta	Sim	Não	Sim	Não	Não

Exemplo

```
googleAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googleads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "campaign-3467***",
        "API_VERSION": "v16"
    }
```

Detalhes das entidades e dos campos do Google Ads

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conta	resourceName	String	!=, =
Conta	callReportingEnabled	Booleano	!=, =
Conta	callConversionReportingEnabled	Booleano	!=, =
Conta	callConversionAction	String	!=, =
Conta	conversionTrackingId	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	crossAccountConversionTrackingId	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	payPerConversionEligibilityFailureReasons	Lista	
Conta	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	currencyCode	String	!=, =, LIKE
Conta	timeZone	String	!=, =, LIKE
Conta	autoTaggingEnabled	Booleano	!=, =
Conta	hasPartnersBadge	Booleano	!=, =
Conta	manager	Booleano	!=, =
Conta	testAccount	Booleano	!=, =
Conta	date	Data	BETWEEN, =, <, >, <=, >=

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conta	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	acceptedCustomerDataTerms	Booleano	
Conta	conversionTrackingStatus	String	!=, =, LIKE
Conta	enhancedConversionsForLeadsEnabled	Booleano	
Conta	googleAdsConversionCustomer	String	
Conta	status	String	!=, =
Conta	allConversionsByConversionDate	Duplo	!=, =, <, >
Conta	allConversionsValueByConversionDate	Duplo	!=, =, <, >
Conta	conversionsByConversionDate	Duplo	!=, =, <, >
Conta	conversionsValueByConversionDate	Duplo	!=, =, <, >
Conta	valuePerAllConversionsByConversionDate	Duplo	!=, =, <, >
Conta	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conta	cliques	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	invalidClicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	costPerAllConversions	Duplo	!=, =, <, >
Conta	costPerConversion	Duplo	!=, =, <, >
Conta	conversões	Duplo	!=, =, <, >
Conta	absoluteTopImpressionPercentage	Duplo	!=, =, <, >
Conta	impressões	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	topImpressionPercentage	Duplo	!=, =, <, >
Conta	averageCpc	Duplo	!=, =, <, >
Conta	activeViewMeasurableCostMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Conta	averageCost	Duplo	!=, =, <, >
Conta	ctr	Duplo	!=, =, <, >
Conta	activeViewCtr	Duplo	!=, =, <, >
Conta	searchImpressionShare	Duplo	!=, =, <, >
Conta	conversionAction	String	!=, =

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conta	conversionActionCategory	String	!=, =
Conta	conversionActionName	String	!=, =, LIKE
Orçamento da conta	resourceName	String	!=, =
Orçamento da conta	status	String	!=, =
Orçamento da conta	proposedEndTimeType	String	!=, =
Orçamento da conta	approvedEndTimeType	String	!=, =
Orçamento da conta	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da conta	billingSetup	String	!=, =
Orçamento da conta	nome	String	!=, =, LIKE
Orçamento da conta	approvedStartDateTime	DateTime	BETWEEN, =, <, >, <=, >=
Orçamento da conta	proposedSpendingLimitMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da conta	approvedSpendingLimitMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da conta	adjustedSpendingLimitMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da conta	amountServedMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidade	Campo	Tipo de dado	Operadores compatíveis
Grupo de anúncios	resourceName	String	!=, =, LIKE
Grupo de anúncios	status	String	!=, =, LIKE
Grupo de anúncios	type	String	!=, =, LIKE
Grupo de anúncios	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	nome	String	!=, =, LIKE
Grupo de anúncios	campaign	String	!=, =
Grupo de anúncios	cpcBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	targetCpaMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	cpmBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	cpvBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	targetCpmMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	effectiveTargetCpaMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	date	Data	BETWEEN, =, <, >, <=, >=
Grupo de anúncios	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidade	Campo	Tipo de dado	Operadores compatíveis
Grupo de anúncios	useAudienceGrouped	Booleano	!=, =
Grupo de anúncios	effectiveCpcBidMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	allConversionsByConversionDate	Duplo	!=, =, <, >
Grupo de anúncios	allConversionsValueByConversionDate	Duplo	!=, =, <, >
Grupo de anúncios	conversionsByConversionDate	Duplo	!=, =, <, >
Grupo de anúncios	conversionsValueByConversionDate	Duplo	!=, =, <, >
Grupo de anúncios	valuePerAllConversionsByConversionDate	Duplo	!=, =, <, >
Grupo de anúncios	valuePerConversionsByConversionDate	Duplo	!=, =, <, >
Grupo de anúncios	averageCost	Duplo	!=, =, <, >
Grupo de anúncios	costPerAllConversions	Duplo	!=, =, <, >
Grupo de anúncios	costPerConversion	Duplo	!=, =, <, >
Grupo de anúncios	averagePageViews	Duplo	!=, =, <, >
Grupo de anúncios	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidade	Campo	Tipo de dado	Operadores compatíveis
Grupo de anúncios	cliques	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	allConversions	Duplo	!=, =, <, >
Grupo de anúncios	averageCpc	Duplo	!=, =, <, >
Grupo de anúncios	absoluteTopImpressionPercentage	Duplo	!=, =, <, >
Grupo de anúncios	impressões	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Grupo de anúncios	topImpressionPercentage	Duplo	!=, =, <, >
Grupo de anúncios	activeViewCtr	Duplo	!=, =, <, >
Grupo de anúncios	ctr	Duplo	!=, =, <, >
Grupo de anúncios	searchTopImpressionShare	Duplo	!=, =, <, >
Grupo de anúncios	searchImpressionShare	Duplo	!=, =, <, >
Grupo de anúncios	searchAbsoluteTopImpressionShare	Duplo	!=, =, <, >
Grupo de anúncios	relativeCtr	Duplo	!=, =, <, >
Grupo de anúncios	conversionAction	String	!=, =
Grupo de anúncios	conversionActionCategory	String	!=, =

Entidade	Campo	Tipo de dado	Operadores compatíveis
Grupo de anúncios	conversionActionName	String	!=, =, LIKE
Grupo de anúncios	updateMask	String	
Grupo de anúncios	criar	Struct	
Grupo de anúncios	atualizar	Struct	
Grupo de anúncios	primaryStatus	String	!=, =
Grupo de anúncios	primaryStatusReasons	Lista	
Anúncio de grupo de anúncios	resourceName	String	!=, =
Anúncio de grupo de anúncios	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anúncio de grupo de anúncios	status	String	!=, =
Anúncio de grupo de anúncios	rótulos	Lista	
Anúncio de grupo de anúncios	adGroup	String	!=, =
Anúncio de grupo de anúncios	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anúncio de grupo de anúncios	approvalStatus	String	!=, =
Anúncio de grupo de anúncios	reviewStatus	String	!=, =

Entidade	Campo	Tipo de dado	Operadores compatíveis
Anúncio de grupo de anúncios	adStrength	String	!=, =
Anúncio de grupo de anúncios	type	String	!=, =
Anúncio de grupo de anúncios	businessName	String	!=, =, LIKE
Anúncio de grupo de anúncios	date	Data	BETWEEN, =, <, >, <=, >=
Anúncio de grupo de anúncios	allConversionsByConversionDate	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	allConversionsValueByConversionDate	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	conversionsByConversionDate	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	conversionsValueByConversionDate	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	valuePerAllConversionsByConversionDate	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	valuePerConversionsByConversionDate	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	activeViewMeasurableCostMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anúncio de grupo de anúncios	averageCost	Duplo	!=, =, <, >

Entidade	Campo	Tipo de dado	Operadores compatíveis
Anúncio de grupo de anúncios	costPerAllConversions	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	costPerConversion	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	cliques	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anúncio de grupo de anúncios	averagePageViews	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anúncio de grupo de anúncios	allConversions	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	averageCpc	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	topImpressionPercentage	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	impressões	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Anúncio de grupo de anúncios	absoluteTopImpressionPercentage	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	activeViewCtr	Duplo	!=, =, <, >
Anúncio de grupo de anúncios	ctr	Duplo	!=, =, <, >

Entidade	Campo	Tipo de dado	Operadores compatíveis
Anúncio de grupo de anúncios	conversionAction	String	!=, =
Anúncio de grupo de anúncios	conversionActionCategory	String	!=, =
Anúncio de grupo de anúncios	conversionActionName	String	!=, =, LIKE
Anúncio de grupo de anúncios	updateMask	String	
Anúncio de grupo de anúncios	criar	Struct	
Anúncio de grupo de anúncios	atualizar	Struct	
Anúncio de grupo de anúncios	policyValidationParameter	Struct	
Anúncio de grupo de anúncios	primaryStatus	String	!=, =
Anúncio de grupo de anúncios	primaryStatusReasons	Lista	
Campaign	resourceName	String	!=, =
Campaign	status	String	!=, =
Campaign	baseCampaign	String	!=, =
Campaign	nome	String	!=, =, LIKE
Campaign	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidade	Campo	Tipo de dado	Operadores compatíveis
Campaign	campaignBudget	String	!=, =, LIKE
Campaign	startDate	Data	BETWEEN, =, <, >, <=, >=
Campaign	endDate	Data	BETWEEN, =, <, >, <=, >=
Campaign	adServingOptimizationStatus	String	!=, =
Campaign	advertisingChannelType	String	!=, =
Campaign	advertisingChannelSubType	String	!=, =
Campaign	experimentType	String	!=, =
Campaign	servingStatus	String	!=, =
Campaign	biddingStrategyType	String	!=, =
Campaign	domainName	String	!=, =, LIKE
Campaign	languageCode	String	!=, =, LIKE
Campaign	useSuppliedUrlsOnly	Booleano	!=, =
Campaign	positiveGeoTargetType	String	!=, =
Campaign	negativeGeoTargetType	String	!=, =
Campaign	paymentMode	String	!=, =

Entidade	Campo	Tipo de dado	Operadores compatíveis
Campaign	optimizationGoalTypes	Lista	
Campaign	date	Data	BETWEEN, =, <, >, <=, >=
Campaign	averageCost	Duplo	
Campaign	cliques	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaign	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaign	impressões	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaign	useAudienceGrouped	Booleano	!=, =
Campaign	activeViewMeasurableCostMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaign	costPerAllConversions	Duplo	!=, =, <, >
Campaign	costPerConversion	Duplo	!=, =, <, >
Campaign	invalidClicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaign	publisherPurchasedClicks	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Campaign	averagePageViews	Duplo	!=, =, <, >
Campaign	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=

Entidade	Campo	Tipo de dado	Operadores compatíveis
Campaign	allConversionsByConversionDate	Duplo	!=, =, <, >
Campaign	allConversionsValueByConversionDate	Duplo	!=, =, <, >
Campaign	conversionsByConversionDate	Duplo	!=, =, <, >
Campaign	conversionsValueByConversionDate	Duplo	!=, =, <, >
Campaign	valuePerAllConversionsByConversionDate	Duplo	!=, =, <, >
Campaign	valuePerConversionsByConversionDate	Duplo	!=, =, <, >
Campaign	allConversions	Duplo	!=, =, <, >
Campaign	absoluteTopImpressionPercentage	Duplo	!=, =, <, >
Campaign	searchAbsoluteTopImpressionShare	Duplo	!=, =, <, >
Campaign	averageCpc	Duplo	!=, =, <, >
Campaign	searchImpressionShare	Duplo	!=, =, <, >
Campaign	searchTopImpressionShare	Duplo	!=, =, <, >
Campaign	activeViewCtr	Duplo	!=, =, <, >

Entidade	Campo	Tipo de dado	Operadores compatíveis
Campaign	ctr	Duplo	!=, =, <, >
Campaign	relativeCtr	Duplo	!=, =, <, >
Campaign	updateMask	String	
Campaign	criar	Struct	
Campaign	atualizar	Struct	
Orçamento da campanha	resourceName	String	!=, =
Orçamento da campanha	id	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	status	String	!=, =
Orçamento da campanha	deliveryMethod	String	!=, =
Orçamento da campanha	período	String	!=, =
Orçamento da campanha	type	String	!=, =
Orçamento da campanha	nome	String	!=, =, LIKE
Orçamento da campanha	amountMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	explicitlyShared	Booleano	!=, =

Entidade	Campo	Tipo de dado	Operadores compatíveis
Orçamento da campanha	referenceCount	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	hasRecommendedBudget	Booleano	!=, =
Orçamento da campanha	date	Data	BETWEEN, =, <, >, <=, >=
Orçamento da campanha	costMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	startDate	Data	BETWEEN, =, <, >, <=, >=
Orçamento da campanha	endDate	Data	BETWEEN, =, <, >, <=, >=
Orçamento da campanha	maximizeConversionValueTargetRoas	Duplo	!=, =, <, >
Orçamento da campanha	maximizeConversionsTargetCpaMicros	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	selectiveOptimizationConversionActions	String	
Orçamento da campanha	averageCost	Duplo	!=, =, <, >
Orçamento da campanha	costPerAllConversions	Duplo	!=, =, <, >
Orçamento da campanha	costPerConversion	Duplo	!=, =, <, >

Entidade	Campo	Tipo de dado	Operadores compatíveis
Orçamento da campanha	videoViews	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	cliques	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	allConversions	Duplo	!=, =, <, >
Orçamento da campanha	valuePerAllConversions	Duplo	!=, =, <, >
Orçamento da campanha	averageCpc	Duplo	!=, =, <, >
Orçamento da campanha	impressões	BigInteger	BETWEEN, =, !=, <, >, <=, >=
Orçamento da campanha	ctr	Duplo	!=, =, <, >
Orçamento da campanha	updateMask	String	
Orçamento da campanha	criar	Struct	
Orçamento da campanha	atualizar	Struct	

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na tabela a seguir.

Entity Name	Campo de particionamento	Tipo de dado
Anúncio de grupo de anúncios	date	Data
Grupo de anúncios	date	Data
Campaign	date	Data
Orçamento da campanha	date	Data

Exemplo

```
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"
    }
)
```

Opções de conexão do Google Ads

Estas são as opções de conexão do Google Ads:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do objeto no Google Ads.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Google Ads que você deseja usar. Exemplo: v16.
- `DEVELOPER_TOKEN`(string): (obrigatório) usado para leitura/gravação. Necessário para autenticar o desenvolvedor ou a aplicação que faz solicitações à API.
- `MANAGER_ID`(string): usado para leitura/gravação. Um identificador exclusivo que permite gerenciar várias contas do Google Ads. Este é o ID do cliente do gerente autorizado. Se o seu acesso à conta do cliente for por meio de uma conta de gerente, o `MANAGER_ID` é necessário. Para obter mais informações, consulte login-customer-id.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Criação de uma conta do Google Ads

1. Faça login na conta de desenvolvedor do Google Ads com suas credenciais e acesse *MyProject.

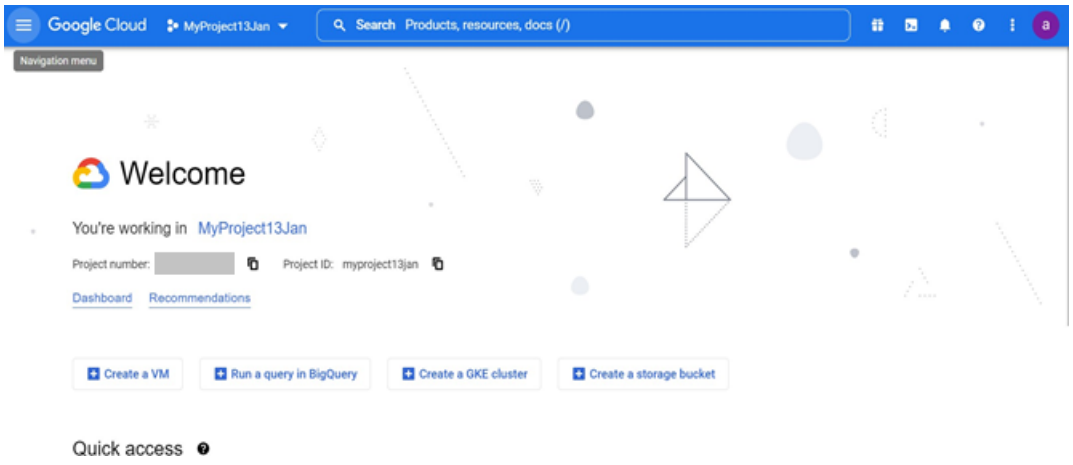

2. Escolha Novo projeto e forneça as informações necessárias para criar um projeto do Google, caso você não tenha nenhum aplicativo registrado nele.

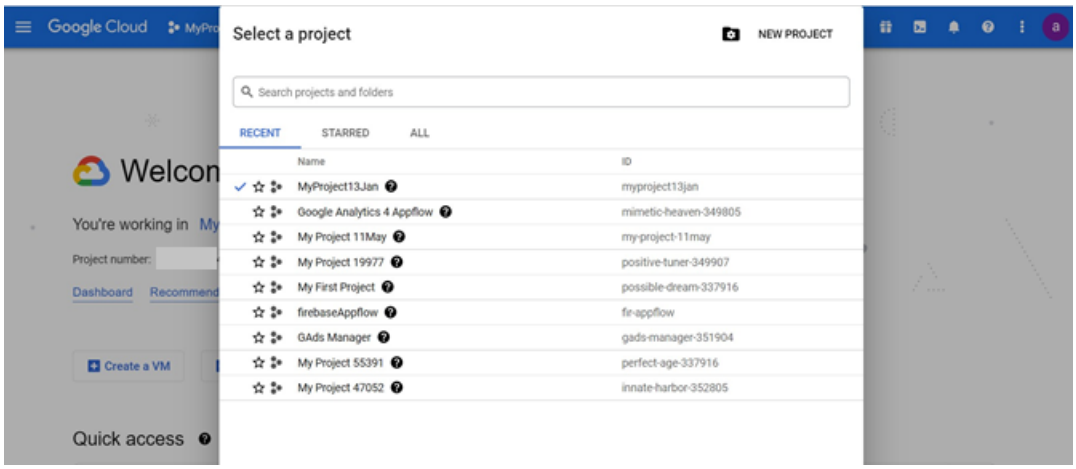

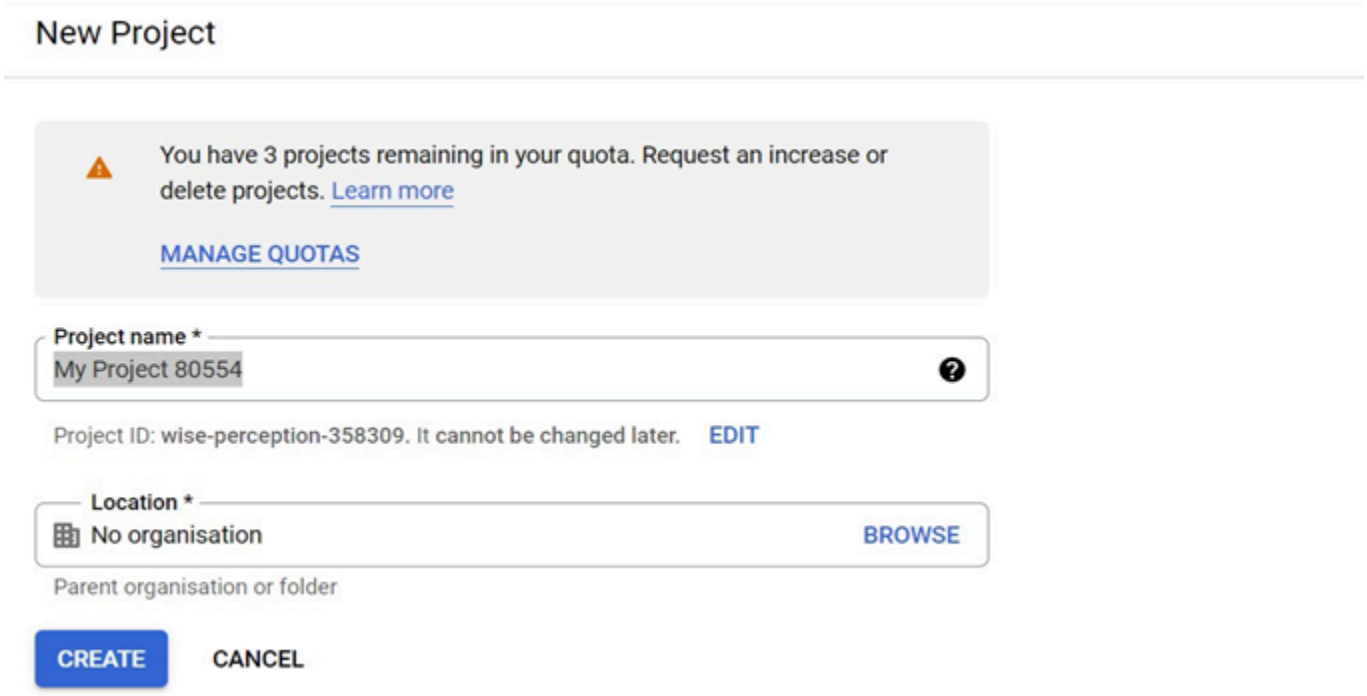

3. Escolha a guia Navegação, depois Configuração API e Criar ID do cliente, ClientSecretque exigirá configuração adicional para criar uma conexão entre AWS Glue GoogleAds e. Para obter mais informações, consulte APIcredenciais.

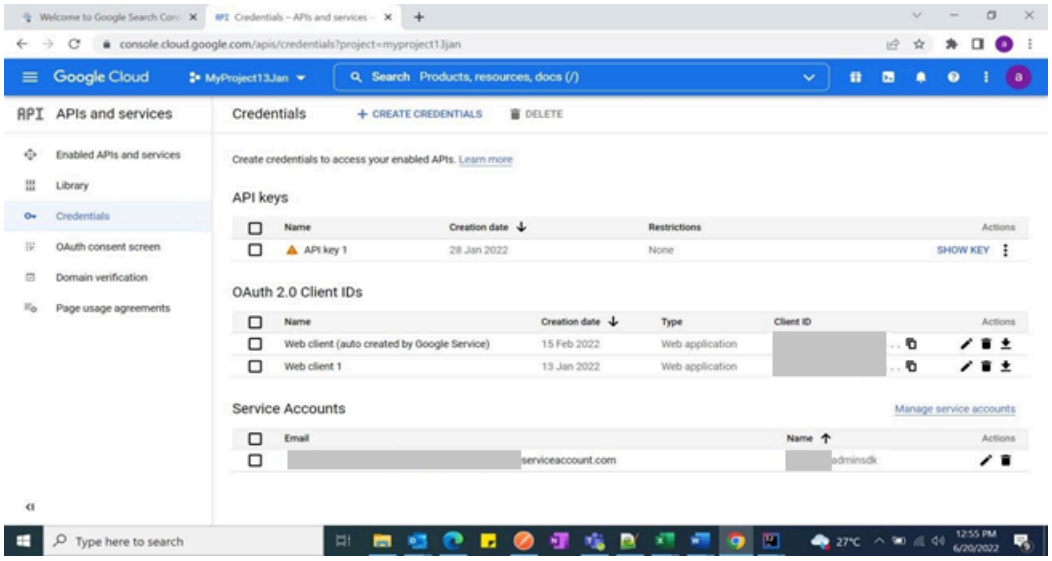

4. Escolha CREATECREDENTIALSe escolha a ID OAuth do cliente.

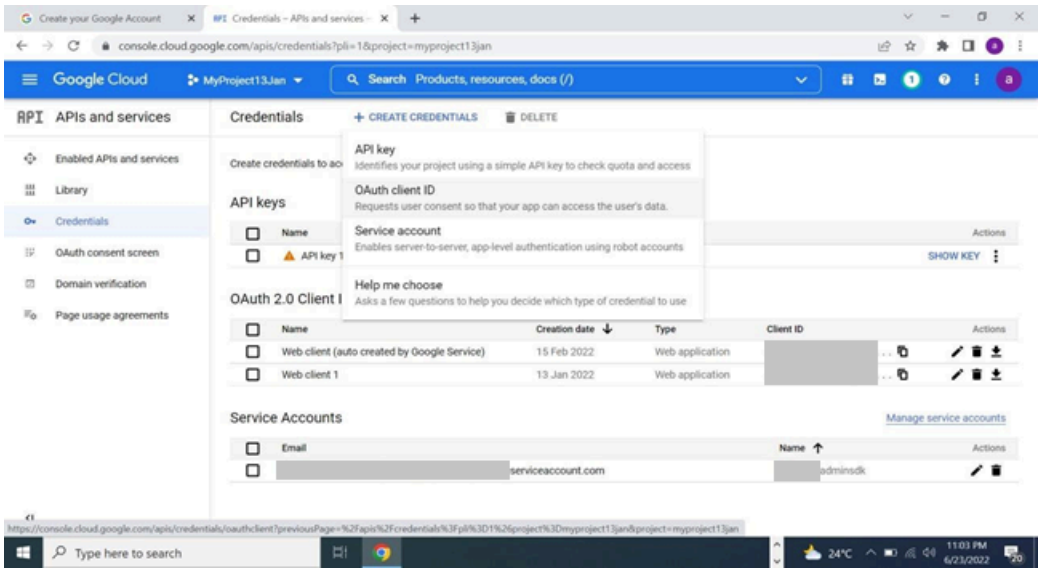

5. Selecione o tipo de aplicativo como aplicativo Web.

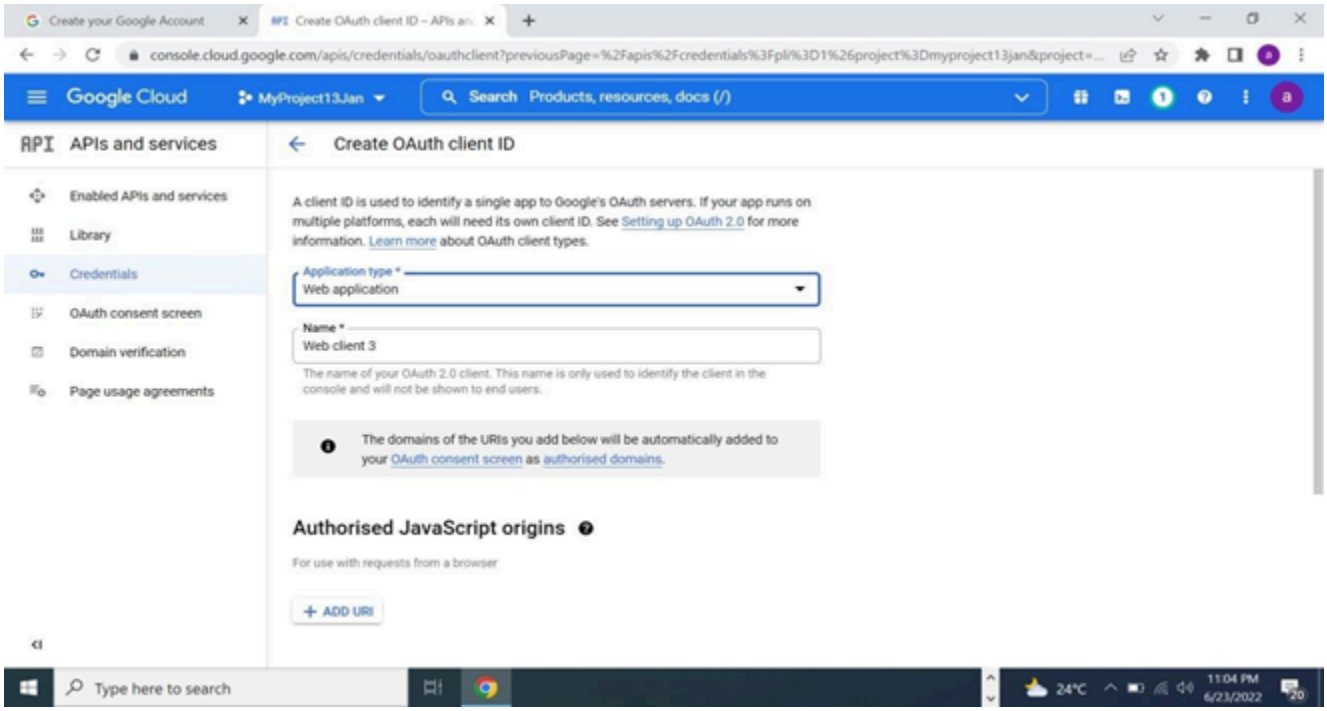

6. Em Redirecionamento autorizadoURIs, adicione o OAuth redirecionamento URIs e escolha Criar. Você pode adicionar vários redirecionamentos, URIs se necessário.

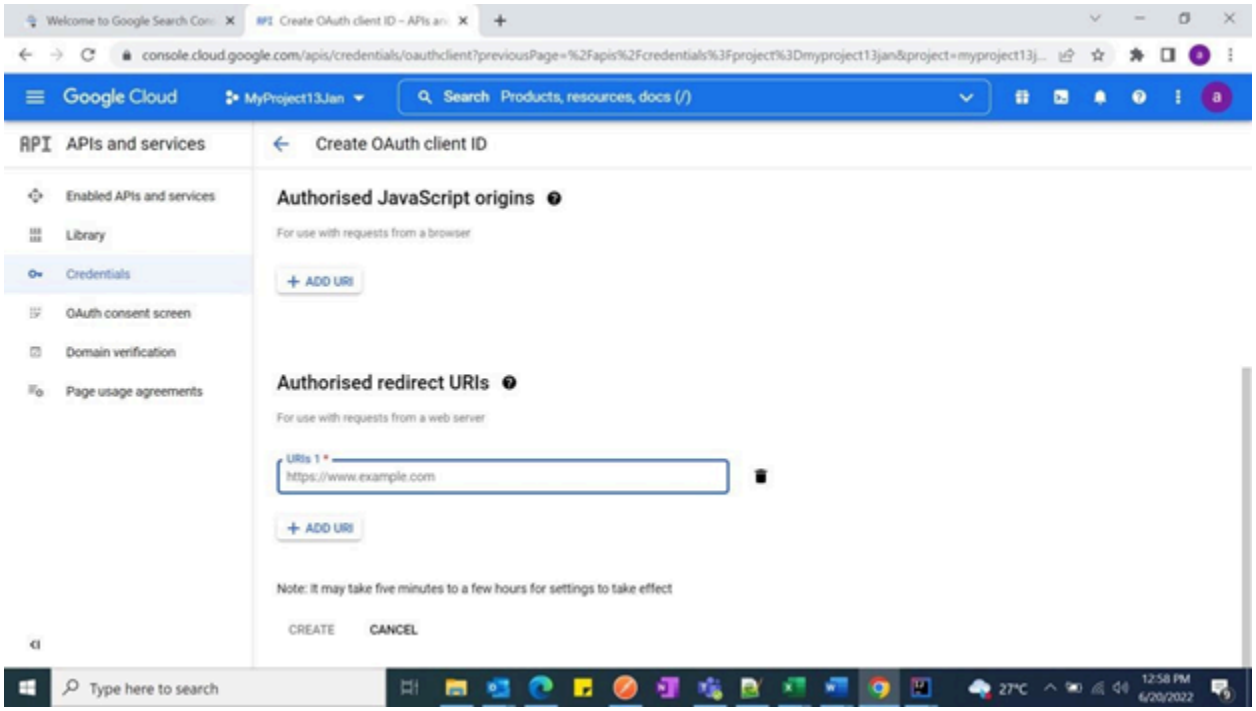

7. Seu ID do cliente e o segredo do cliente serão gerados ao criar uma conexão entre o Google Ads AWS Glue e o Google Ads.

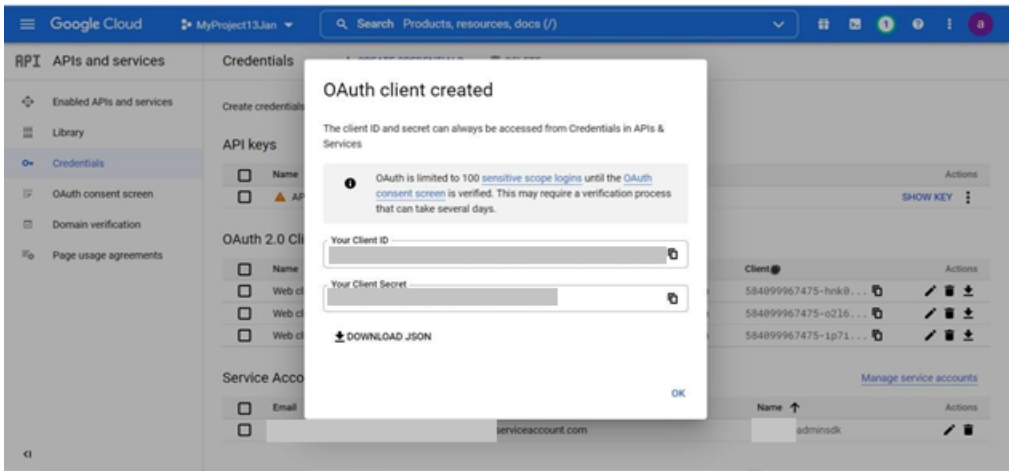

8. Adicione os escopos de acordo com as necessidades do seu aplicativo, escolha a tela de OAuth consentimento e forneça as informações necessárias e adicione os escopos com base nos requisitos.

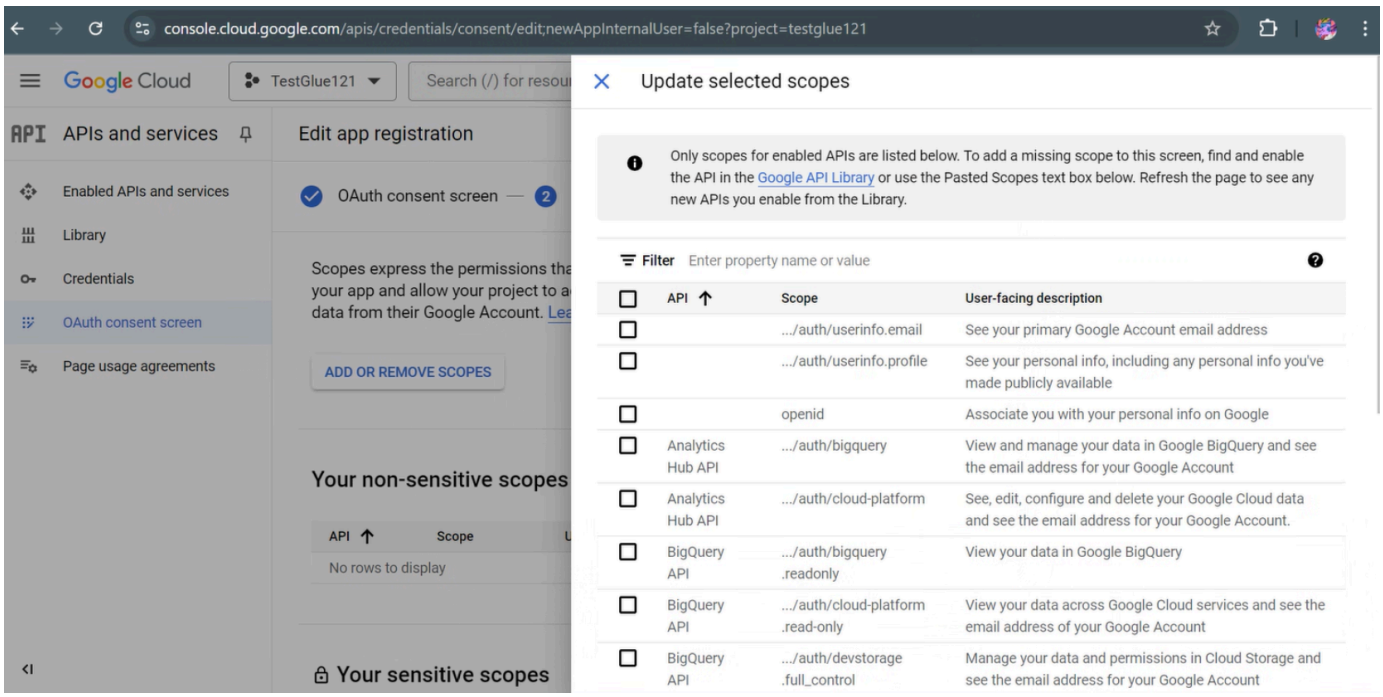

Limitações

Estas são as limitações do conector do Google Ads:

- `MANAGER_ID` é uma entrada opcional na criação de uma conexão. Porém, quando você deseja acessar os clientes sob um gerente específico, `MANAGER_ID` é uma entrada obrigatória. A tabela abaixo explica as limitações de acesso com base no fato de `MANAGER_ID` estar ou não incluído em uma conexão.

MANAGER_ID fornecido na criação da conexão?	Clientes acessíveis
Sim	Os clientes listados sob o MANAGER_ID fornecido junto com o MANAGER_ID.
Não	Todos os clientes serão listados, mas os clientes sob qualquer gerente não estarão acessíveis.

- Quando uma conta de gerente for escolhida como objeto, apenas `Account` aparecerá como subobjeto. No conector do Google Ads, entidades como campanhas, anúncios etc. são recuperadas com base em contas de clientes individuais, não na conta de gerente.
- Você não pode recuperar métricas para a conta de gerente. Em vez disso, é possível recuperar métricas para contas de clientes individuais.
- Cada conta pode ter até 10 mil campanhas, incluindo campanhas ativas e pausadas. Para obter mais informações, acesse Campanha por conta.
- Ao criar um relatório, se você escolher determinadas métricas para exibir, as linhas cujas métricas selecionadas forem todas zero não serão retornadas. Para obter mais informações, consulte Métricas zero.
- Com os campos a seguir, o fluxo de mapeamento completo não funcionará para entidades de conta, grupo de anúncios e anúncios de grupos de anúncios, especificamente para conversionAction, conversionActionCategory e conversionActionName. Para obter mais informações, consulte Segmento e métricas.
- Um filtro de intervalo de datas é obrigatório quando o campo `segments.date` é selecionado.

Conectando-se ao Google Analytics 4

O Google Analytics 4 é um serviço de análise que rastreia e relata métricas sobre as interações dos visitantes com seus aplicativos e sites. Essas métricas incluem visualizações de página, usuários ativos e eventos. Se você for usuário do Google Analytics 4, poderá se conectar AWS Glue à sua conta do Google Analytics 4. Você pode usar o Google Analytics 4 como fonte de dados em seus ETL trabalhos. Execute esses trabalhos para transferir dados do Google Analytics 4 para AWS serviços ou outros aplicativos compatíveis.

Tópicos

- AWS Glue suporte para o Google Analytics 4
- Políticas contendo as API operações para criar e usar conexões
- Configurando o Google Analytics 4
- Configuração de conexões do Google Analytics 4
- Leitura de 4 entidades do Google Analytics
- Opções de conexão do Google Analytics 4
- Criando uma conta do Google Analytics 4
- Etapas para criar um aplicativo cliente e credenciais OAuth 2.0
- Limitações e considerações

AWS Glue suporte para o Google Analytics 4

AWS Glue suporta o Google Analytics 4 da seguinte forma:

Compatível como fonte?

Sim. Você pode usar AWS Glue ETL trabalhos para consultar dados do Google Analytics 4.

Compatível como destino?

Não.

APIVersões compatíveis do Google Analytics 4

versão 1 Beta.

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
```

```
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Você também pode usar as seguintes IAM políticas gerenciadas para permitir o acesso:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configurando o Google Analytics 4

Antes de usar AWS Glue para transferir do Google Analytics 4, você precisa atender aos seguintes requisitos:

Requisitos mínimos

- Você tem uma conta do Google Analytics com um ou mais fluxos de dados que coletam os dados que você deseja transferir.
- Você tem uma conta do Google Cloud Platform e um projeto do Google Cloud.
- No seu projeto do Google Cloud, você habilitou o seguinteAPIs:
  - Google Analytics API
  - Administrador do Google Analytics API

  - Dados do Google Analytics API
- No seu projeto do Google Cloud, você configurou uma tela de OAuth consentimento para usuários externos. Para obter informações sobre a tela de OAuth consentimento, consulte Configurar sua tela de OAuth consentimento na Ajuda do console do Google Cloud Platform.
- No seu projeto do Google Cloud, você configurou um ID de cliente OAuth 2.0. Para obter mais informações, consulte Configurando OAuth 2.0.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua conta do Google Analytics 4.

Configuração de conexões do Google Analytics 4

Para configurar uma conexão com o Planilhas Google:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para o tipo de concessão AuthorizationCode:
      - Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Google Analytics 4.
   b. Forneça o `INSTANCE_URL` do Google Analytics 4 ao qual deseja se conectar.
   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
```

```
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Tipo de concessão `AUTHORIZATION_CODE`.

Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O Console do AWS Glue redirecionará o usuário para o Google Analytics 4, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Google Analytics 4.

Os usuários ainda podem optar por criar sua própria aplicação conectada no Google Analytics 4 e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Google Analytics 4 para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter mais informações, consulte Uso do Auth 2.0 para acessar APIs do Google.

Leitura de 4 entidades do Google Analytics

Pré-requisitos

- Um objeto do Google Analytics 4 do qual você gostaria de ler. Consulte a tabela de entidades suportadas abaixo para verificar as entidades disponíveis.

Entidades apoiadas

Entidade	Pode ser filtrado	Limite de suporte	Suporta Order By	Suporta Select *	Suporta particion amento
Relatório em tempo real	Sim	Sim	Sim	Sim	Não
Relatório principal	Sim	Sim	Sim	Sim	Sim

Exemplo

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(
    connection_type="GoogleAnalytics4",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1beta"
    }
```

Detalhes da entidade e do campo do Google Analytics 4

Entidade	Campo	Tipo de dado	Operadores compatíveis
Relatório principal	Campos dinâmicos		
Relatório principal	Campos de dimensão	String	LIKE, =
Relatório principal	Campos de dimensão	Data	LIKE, =
Relatório principal	Campos métricos	String	>, <, >=, <=, = BETWEEN
Relatório principal	Dimensão personali zada e campos métricos personali zados	String	N/D

Entidade	Campo	Tipo de dado	Operadores compatíveis
Relatório em tempo real	appVersion	String	LIKE, =
Relatório em tempo real	audienceId	String	LIKE, =
Relatório em tempo real	audienceName	String	LIKE, =
Relatório em tempo real	city	String	LIKE, =
Relatório em tempo real	cityId	String	LIKE, =
Relatório em tempo real	country	String	LIKE, =
Relatório em tempo real	countryId	String	LIKE, =
Relatório em tempo real	deviceCategory	String	LIKE, =
Relatório em tempo real	eventName	String	LIKE, =
Relatório em tempo real	minutesAgo	String	LIKE, =
Relatório em tempo real	platform	String	LIKE, =
Relatório em tempo real	streamId	String	LIKE, =

Entidade	Campo	Tipo de dado	Operadores compatíveis
Relatório em tempo real	streamName	String	LIKE, =
Relatório em tempo real	unifiedScreenName	String	LIKE, =
Relatório em tempo real	activeUsers	String	>, <, >=, <=, = BETWEEN
Relatório em tempo real	conversões	String	>, <, >=, <=, = BETWEEN
Relatório em tempo real	eventCount	String	>, <, >=, <=, = BETWEEN
Relatório em tempo real	screenPageViews	String	>, <, >=, <=, = BETWEEN

Consultas de particionamento

1. Partição baseada em filtro

   Opções adicionais do SparkPARTITION_FIELD,LOWER_BOUND,UPPER_BOUND, NUM_PARTITIONS podem ser fornecidas se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em NUM_PARTITIONS várias subconsultas que podem ser executadas pelas tarefas do Spark simultaneamente.

   - PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
   - LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

     Para data, aceitamos o formato de data do Spark usado nas consultas do SparkSQL. Exemplo de valores válidos:"2024-02-06".
   - UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
   - NUM_PARTITIONS: número de partições.

   Exemplo

```
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. Partição baseada em registros

   Opções adicionais do Spark `NUM_PARTITIONS` podem ser fornecidas se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` várias subconsultas que podem ser executadas pelas tarefas do Spark simultaneamente.

   - `NUM_PARTITIONS`: número de partições.

   Exemplo

```
googleAnalytics4_read = glueContext.create_dynamic_frame.from_options(
    connection_type="GoogleAnalytics4",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v1beta",
        "NUM_PARTITIONS": "10"
    }
```

Opções de conexão do Google Analytics 4

A seguir estão as opções de conexão para o Google Analytics 4:

- `ENTITY_NAME`(String) - (Obrigatório) Usado para leitura. O nome do seu objeto no Google Analytics 4.
- `API_VERSION`(String) - (Obrigatório) Usado para leitura. APIVersão Rest do Google Analytics 4 que você deseja usar.

- `SELECTED_FIELDS`(Lista<String>) - Padrão: vazio (SELECT*). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Ele deve estar no SQL formato Spark.
- `QUERY`(String): padrão: vazia. Usado para leitura. SQLConsulta completa do Spark.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL`(Integer) - Usado para leitura. (Optional)

Criando uma conta do Google Analytics 4

Siga as etapas para criar uma conta do Google Analytics 4: https://support.google.com/analytics/answer/9304153? hl=en

Etapas para criar um aplicativo cliente e credenciais OAuth 2.0

Para obter mais informações, consulte a documentação do Google Analytics4 API.

1. Crie e configure sua conta fazendo login na sua conta do Google Analytics com suas credenciais. Em seguida, navegue até Administrador > Criar conta.
2. Crie uma propriedade para a conta que você criou escolhendo Criar propriedade. Configure a propriedade com os detalhes necessários. Assim que todos os detalhes forem fornecidos, o ID da propriedade correspondente será gerado.
3. Adicione fluxo de dados para a propriedade criada escolhendo Fluxos de dados > Adicionar fluxo > Web no menu suspenso. Forneça os detalhes do site, como URL e outros campos obrigatórios. Depois de fornecer todos os detalhes, o ID de fluxo e o ID de medição correspondentes serão gerados.
4. Configure o Google Analytics em seu site copiando o ID de medição e adicionando-o à configuração do seu site.
5. Crie um relatório do Google Analytics navegando até Relatórios e gerando o relatório necessário.

6. Autorize seu aplicativo navegando até console.cloud.google.com, pesquise os dados do Google Analytics e, em seguida, ative o. API API
    1. Navegue até a página API e Serviços e escolha Credenciais > configuração OAuth 2.0 Client IDs.
    2. Forneça o redirecionamento URL adicionando o AWS Glue redirecionamentoURL.
7. Copie o ID do cliente e o segredo do cliente, que serão necessários mais para criar a conexão.

Limitações e considerações

A seguir estão as limitações do conector do Google Analytics 4:

- Para a entidade Core Report, somente 9 campos de dimensão e 10 campos métricos podem enviar uma solicitação. Se o número permitido de campos for excedido, a solicitação falhará e o conector lançará uma mensagem de erro.
- Para a entidade Realtime Report, somente 4 campos de dimensão podem enviar uma solicitação. Se o número permitido de campos for excedido, a solicitação falhará e o conector lançará uma mensagem de erro.
- O Google Analytics 4 é uma ferramenta gratuita da versão beta, portanto, haverá atualizações regulares sobre novos recursos, aprimoramento de entidades, adição de novos campos e descontinuação de campos existentes.
- Os campos do relatório principal são preenchidos dinamicamente, portanto, haverá adição, depreciação e renomeação de campos, e a imposição de novos limites aos campos pode ser feita a qualquer momento.
- A data de início padrão é 30 dias e a data de término é ontem (um dia antes da data atual), e essas datas serão substituídas no código da expressão de filtro se o usuário tiver definido o valor OU se o fluxo for incremental.
- De acordo com a documentação, a entidade de relatório em tempo real retorna 10.000 registros se o limite não for ultrapassado na solicitação, caso contrário, API retornará no máximo 250.000 linhas por solicitação, não importa quantas você solicite. Para obter mais informações, consulte Método: propriedades. runRealtimeReportna documentação do Google Analytics.
- A entidade Real-Time Report não oferece suporte à partição baseada em registros, pois não oferece suporte à paginação. Além disso, ele não oferece suporte à partição baseada em campo, pois nenhum dos campos atende aos critérios definidos.

- Devido à limitação no número de campos que podem ser passados em uma solicitação. Estamos definindo campos de dimensão e métrica padrão dentro dos limites designados. Se “selecionar tudo” for escolhido, somente os dados desses campos predeterminados serão recuperados.
  - Relatório principal
    - De acordo com a limitação de SAAS -, as solicitações são permitidas até 9 dimensões e apenas 10 métricas (ou seja, uma solicitação pode conter no máximo 19 campos (métricas + dimensão).
    - De acordo com a implementação - Se o usuário utilizar SELECT _ ALL ou campos selecionados com mais de 25, os campos padrão serão passados na solicitação.
    - Os campos a seguir são considerados campos padrão para o relatório principal: “país”, “cidade”, "eventName“," “, cityId “navegador”, “data”, ""," currencyCode “," deviceCategory “," transactionId “, active1 DayUsers “, “active28 “, DayUsers “active7 “," DayUsers “," activeUsers “," averageRevenuePer Usuário”, "averagePurchaseRevenue“," “," averageSessionDuration “,"engagedSessions”. eventCount engagementRate
  - Relatório em tempo real
    - De acordo com a limitação das SAAS solicitações, são permitidas até 4 dimensões.
    - Se o usuário passar SELECT _ ALL ou selecionar campos com mais de 15, os campos padrão serão passados na solicitação.
    - Os campos a seguir são considerados campos padrão para o RealTime Relatório - “país”, "deviceCategory“, “cidade”, "cityId“," activeUsers “, “conversões”, "eventCount“,"screenPageViews”.
- Na entidade Core-Report, se a partição no campo de data e o filtro ativado estiverem presentes startDate simultaneamente. Nesse caso, o dateRange valor é substituído pelo valor do startDate filtro, mas, como a partição deve sempre ser a prioridade, descarte o startDate filtro se a partição no campo de data já estiver presente.
- Como agora também cohortSpecs faz parte do corpo da solicitação do relatório principal, aprimoramos a entidade atual do relatório principal para incluir suporte ao atributo. cohortSpec No corpo da cohortSpecs solicitação, quase todos os campos exigem a entrada do usuário. Para resolver isso, definimos valores padrão para esses atributos/campos e fornecemos provisões para que o usuário substitua esses valores, se necessário.

FieldName	Valores padrão	Exemplo de consulta para transmitir filterPredicate opções para substituir os valores padrão
startDate	30 dias atrás a partir da data atual	“startDate entre “2023-05-09" e “2023-05-10"
endDate	1 dia atrás a partir da data atual	“startDate entre “2023-05-09" e “2023-05-10"
startOffset	0	startOffset=2
endOffset	1	endOffset=10
granularidade	DAILY	granularidade =”” WEEKLY

- Você também pode passar todos esses filtros juntos de uma só vez ou com outros filtros.
  - Exemplo 1 -filterPredicate: startDate entre “2023-05-09" e “2023-05-10" =1 =2 granularity=”” AND startOffset AND endOffset AND WEEKLY
  - Exemplo 2 -filterPredicate: city= “xyz” AND startOffset =1 =2 granularity= ANDendOffset”” AND WEEKLY
- Na solicitação de coorte:
  - Se 'cohortNthMonth' for passado na solicitação, o valor interno da granularidade será definido como “” MONTHLY
  - Da mesma forma, se cohortNthWeek '' for passado, o valor da granularidade será definido como “” WEEKLY
  - E, para 'cohortNthDay', o valor da granularidade será definido como “”DAILY. Para obter mais informações, consulte:
    - https://developers.google.com/analytics/devguides/reporting/data/v1/advanced
    - https://developers.google.com/analytics/devguides/reporting/data/v1/rest/v1beta/CohortSpec
  - A provisão é fornecida para que o usuário substitua um valor dateRange padrão de granularidade. Consulte a tabela acima.

Conectar ao Google BigQuery em AWS Glue Studio

> **Note**
>
> É possível usar o AWS Glue Spark para ler e gravar tabelas no Google BigQuery no AWS Glue 4.0 e versões posteriores. Para configurar o Google BigQuery com AWS Glue trabalhos de forma programática, consulte Conexões BigQuery.

AWS Glue Studio fornece uma interface visual para conectar-se ao BigQuery, criar jobs de integração de dados e executá-los no runtime Spark sem servidor AWS Glue Studio.

Ao criar uma conexão com o Google BigQuery no AWS Glue Studio, uma conexão unificada é criada. Para ter mais informações, consulte Considerações.

Em vez de criar um segredo com as credenciais em um formato específico, `{"credentials": "base64 encoded JSON"}`, agora, com a conexão unificada com o Google BigQuery, é possível criar um segredo que inclua diretamente o JSON do Google BigQuery: `{"type": "service-account", ...}`.

Tópicos

- Criar uma conexão BigQuery
- Criar um nó de origem do BigQuery
- Criar um nó de destino do BigQuery
- Opções avançadas

Criar uma conexão BigQuery

Para se conectar ao Google BigQuery a partir do AWS Glue, você precisará criar e armazenar suas credenciais do Google Cloud Platform em um segredo e, em seguida, associar esse AWS Secrets Manager segredo a uma conexão do Google BigQuery AWS Glue.

Para configurar uma conexão com o BigQuery:

1. No Google Cloud Platform, crie e identifique recursos relevantes:

- Crie ou identifique um projeto do GCP contendo tabelas do BigQuery às quais você gostaria de se conectar.
- Ative a API BigQuery. Para obter mais informações, consulte Use the BigQuery Storage Read API to read na tabela.

2. No Google Cloud Platform, crie e exporte as credenciais da conta de serviço:

   Você pode usar o assistente de credenciais do BigQuery para acelerar essa etapa: criar credenciais.

   Para criar uma conta de serviço no GCP, siga o tutorial disponível em Criar contas de serviço.

   - Ao selecionar o projeto, selecione o projeto que contém sua tabela do BigQuery.
   - Ao selecionar perfis do IAM do GCP para sua conta de serviço, adicione ou crie um papel que conceda permissões apropriadas para executar jobs do BigQuery para ler, gravar ou criar tabelas do BigQuery.

   Para criar credenciais para a sua conta de serviço, siga o tutorial disponível em Criar uma chave da conta de serviço.

   - Ao selecionar o tipo de chave, selecione JSON.

   Agora você deve ter baixado um arquivo JSON com credenciais para sua conta de serviço. A aparência deve ser semelhante à seguinte:

```
{
  "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. No AWS Secrets Manager, crie um segredo usando seu arquivo de credenciais baixado. Você pode escolher a guia Texto simples e colar o conteúdo do arquivo formatado em JSON. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.
4. No catálogo de dados do AWS Glue, crie uma conexão seguindo as etapas em https://docs.aws.amazon.com/glue/latest/dg/console-connections.html. Depois de criar a conexão, guarde o nome da conexão, *`connectionName`*, para a próxima etapa.
   - Ao selecionar um tipo de conexão, selecione Google BigQuery.
   - Ao selecionar um Segredo da AWS, forneça o *`secretName`*.
5. Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *`secretName`*.
6. Na configuração do trabalho do AWS Glue, forneça *`connectionName`* como uma conexão de rede adicional.

Criar um nó de origem do BigQuery

Pré-requisitos necessários

- Uma conexão de catálogo de dados do AWS Glue do tipo Snowflake
- Um AWS Secrets Manager segredo para suas credenciais do Google BigQuery, usado pela conexão.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- O nome e o conjunto de dados da tabela e do projeto do Google Cloud correspondente no qual você deseja gravar.

Adicionar uma fonte de dados do BigQuery

Para adicionar um destino de dados — nó do BigQuery:

1. Escolha a conexão para seu destino de dados do BigQuery. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o Redshift. Para obter mais informações, consulte Visão geral do uso de conectores e conexões.

Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.

2. Identifique quais dados do BigQuery você gostaria de ler e escolha uma opção de origem do BigQuery

   - Escolha uma única tabela — permite extrair todos os dados de uma tabela.
   - Insira uma consulta personalizada — permite que você personalize quais dados são recuperados fornecendo uma consulta.

3. Descreva os dados que você gostaria de ler

   (Obrigatório) defina Projeto principal como o projeto que contém sua tabela ou um projeto principal de cobrança, se relevante.

   Se você escolheu uma única tabela, defina Tabela com o nome de uma tabela do Google BigQuery no seguinte formato: `[dataset].[table]`

   Se você escolheu uma consulta, forneça-a ao Query. Em sua consulta, consulte as tabelas com seu nome de tabela totalmente qualificado, no formato:`[project].[dataset].[tableName]`.

4. Forneça propriedades do BigQuery

   Se você escolheu uma única tabela, não é necessário fornecer propriedades adicionais.

   Se você escolher uma consulta, deverá fornecer as seguintes propriedades personalizadas do Google BigQuery:

   - Defina `viewsEnabled` como verdadeiro.
   - Defina `materializationDataset` como um conjunto de dados. O principal do GCP autenticado pelas credenciais fornecidas pela AWS Glue conexão precisa ser capaz de criar tabelas nesse conjunto de dados.

Criar um nó de destino do BigQuery

Pré-requisitos necessários

- Uma conexão de catálogo de dados do AWS Glue do tipo Snowflake

- Um AWS Secrets Manager segredo para suas credenciais do Google BigQuery, usado pela conexão.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- O nome e o conjunto de dados da tabela e do projeto do Google Cloud correspondente no qual você deseja gravar.

Adicionar um destino de dados do BigQuery

Para adicionar um destino de dados — nó do BigQuery:

1. Escolha a conexão para seu destino de dados do BigQuery. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o Redshift. Para obter mais informações, consulte Visão geral do uso de conectores e conexões.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Identifique em qual tabela do BigQuery você gostaria de gravar e escolha um método de gravação.

   - Direto — grava diretamente no BigQuery usando a API BigQuery Storage Write.
   - Indireto — grava no Google Cloud Storage e depois copia no BigQuery.

   Se você quiser escrever indiretamente, forneça um local de destino do GCS com um bucket temporário do GCS. Você precisará fornecer configurações adicionais em sua AWS Glue conexão. Para obter mais informações, consulte Usar a gravação indireta com o Google BigQuery.
3. Descreva os dados que você gostaria de ler

   (Obrigatório) defina Projeto principal como o projeto que contém sua tabela ou um projeto principal de cobrança, se relevante.

   Se você escolheu uma única tabela, defina Tabela com o nome de uma tabela do Google BigQuery no seguinte formato: `[dataset].[table]`

Opções avançadas

É possível fornecer opções avançadas ao criar um node do BigQuery. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte a referência da opção de conexão do BigQuery no guia do AWS Glue desenvolvedor.

Conectar ao Google Search Console

O Google Search Console é uma plataforma gratuita disponível para proprietários de sites para monitorar a forma como o Google vê o site e para otimizar sua presença orgânica. Isso inclui a visualização de domínios de referência, performance do site móvel, resultados de pesquisa avançados e as consultas e páginas com maior tráfego. Se você for usuário do Google Search Console, poderá conectar o AWS Glue à sua conta do Google Search Console. É possível usar o Google Search Console como fonte de dados em suas tarefas de ETL. Execute essas tarefas para transferir dados do Google Search Console para serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para o Google Search Console
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Google Search Console
- Configuração de conexões do Google Search Console
- Leitura de entidades do Google Search Console
- Opções de conexão do Google Search Console
- Limitações do Google Search Console

Suporte do AWS Glue para o Google Search Console

O AWS Glue oferece suporte ao Google Search Console da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do Google Search Console.

Compatível como destino?

Nº

Versões da API do Google Search Console com suporte

Versões da API do Google Search Console com suporte:

- v3

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
 }
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você

seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Google Search Console

Antes de poder usar o AWS Glue para transferir dados do Google Search Console, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Google Search Console.
- Você tem uma conta de do Google Cloud Platform e um projeto do Google Cloud.
- No seu projeto do Google Cloud, você ativou a API do Google Search Console.
- No seu projeto do Google Cloud, você configurou uma tela de consentimento de OAuth para usuários externos. Para obter mais informações, consulte Configuração da sua tela de consentimento do OAuth na Ajuda do console da Google Cloud Platform.
- No seu projeto do Google Cloud, você configurou um ID de cliente OAuth 2.0. Consulte Configuração do OAuth 2.0 para ver as credenciais do cliente que o AWS Glue usa para acessar seus dados com segurança ao fazer chamadas autenticadas para sua conta.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Google Search Console. Para conexões típicas, você não precisa fazer mais nada no Google Search Console.

Configuração de conexões do Google Search Console

O Google Search Console oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2. O tipo de concessão determina como o AWS Glue se comunica com o Google Search Console para solicitar acesso aos seus dados.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no Google Search Console e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console

do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Google Search Console para fazer login e autorizar o acesso do AWS Glue aos recursos.

- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Google Search Console sobre a criação de uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Uso do OAuth 2.0 para acessar APIs do Google.

Para configurar uma conexão com o Google Search Console:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Google Search Console.
   b. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
```

```
}
```

c. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

d. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Google Search Console

Pré-requisito

Um objeto do Google Search Console do qual você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Análise de pesquisas	Sim	Sim	Não	Sim	Não
Sites	Não	Não	Não	Sim	Não
Mapas de sites	Não	Não	Não	Sim	Não

Exemplo:

```
googleSearchConsole_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googlesearchconsole",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v3"
    }
```

Detalhes de entidade e campo do Google Search Console:

O Google Search Console fornece endpoints para a busca de metadados de forma dinâmica para entidades com suporte. Portanto, o suporte do operador é capturado no nível do tipo de dados.

Entidade	Campo	Tipo de dados	Operadores compatíveis	Observação
Análise de pesquisas	keys	Lista	N/D	
	cliques	Duplo	N/D	
	impressões	Duplo	N/D	
	ctr	BigDecimal	N/D	Para o tipo de dados BigDecimal, o valor '0' é formatado como '0E-18'
	position	Duplo	N/D	
	start_end_date	Data	BETWEEN	O valor padrão para `start_end_date` está entre <30 dias antes da data atual> AND <ontem: ou seja, 1 dia antes da data atual> Observação: é esperado que você passe um valor de data UTC.

Entidade	Campo	Tipo de dados	Operadores compatíveis	Observação
				Exemplo: start_end _date entre '2022-01-01' AND '2024-09-09'
	country	String	EQUAL_TO, NOT_EQUAL _TO, CONTAINS	Os valores válidos são "IND", "CAN" etc.
	type	String	EQUAL_TO, NOT_EQUAL _TO	Os valores válidos são "discover", "googleNews", "news", "image", "video", "web"
	searchApp earance	String	EQUAL_TO, NOT_EQUAL _TO, CONTAINS	Consulte Aparência da pesquisa para obter uma lista de valores válidos.
	Dispositivo	String	EQUAL_TO, NOT_EQUAL _TO, CONTAINS	Os valores válidos são "DESKTOP" , "MOBILE", "TABLET"
	dimensões	String	EQUAL_TO	Os valores válidos são "country", "device"

Entidade	Campo	Tipo de dados	Operadores compatíveis	Observação
	page	String	EQUAL_TO, NOT_EQUAL_TO, CONTAINS	
	consulta	String	EQUAL_TO, NOT_EQUAL_TO, CONTAINS	
	dataState	String	EQUAL_TO	Os valores válidos são "all" e "final"
Sites	siteUrl	String	N/D	
	permissionLevel	String	N/D	
Mapas de sites	caminho	String	N/D	
	type	String	N/D	
	lastSubmitted	DateTime	N/D	
	isPending	Booleano	N/D	
	isSitemapsIndex	Booleano	N/D	
	lastDownloaded	DateTime	N/D	
	avisos	Longo	N/D	
	erros	Longo	N/D	
	tópicos	Lista	N/D	

> **Note**
>
> Para ver uma lista atualizada de valores válidos para filtros, consulte os documentos da API do Google Search Console.
> O campo `start_end_date` é uma combinação de `start_date` e `end_date`.

Particionamento de consultas

Não há suporte para o particionamento baseado em filtros e o particionamento baseado em registros.

Opções de conexão do Google Search Console

Estas são as opções de conexão do Google Search Console:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Google Search Console.
- `API_VERSION`(string): (obrigatório) usado para leitura. Versão da API Rest do Google Search Console que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: "start_end_date between <30 dias antes da data atual> AND <ontem: ou seja, 1 dia antes da data atual>". Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: "start_end_date between <30 dias antes da data atual> AND <ontem: ou seja, 1 dia antes da data atual>". Usado para Leitura. Consulta completa do Spark SQL.
- `INSTANCE_URL`(string): usado para leitura. Um URL de instância válida do Google Search Console.

Limitações do Google Search Console

A seguir estão as limitações ou notas do Google Search Console:

- O Google Search Console impõe limites de uso na API. Para obter mais informações, consulte Limites de uso.

- Quando nenhum filtro é passado para a entidade `Search Analytics`, a API soma todos os cliques, impressões, CTR e outros dados de todo o site dentro do intervalo de datas padrão especificado e os apresenta como um único registro.
- Para dividir os dados em segmentos menores, você precisa introduzir dimensões em sua consulta. As dimensões informam à API como você deseja segmentar seus dados.
  - Por exemplo, se você adicionar `filterPredicate: dimensions="country"`, obterá um registro para cada país em que seu site recebeu tráfego durante o período especificado.
  - Exemplo de passagem de várias dimensões: `filterPredicate: dimensions="country" AND dimensions="device" AND dimensions="page"`. Nesse caso, você receberá uma linha na resposta para cada combinação exclusiva dessas três dimensões.
- Os valores padrão são definidos para os campos `start_end_date` e `dataState`.

Nome do campo	Expressão de filtro padrão	Expressão para substituir valores padrão
start_end_date	start_end_date between <30 dias antes da data atual> AND <ontem: ou seja, 1 dia antes da data atual>	start_end_date between "2024-01-01" AND "2024-05-05"
dateState	dataState="all"	dataState="final"

Conectando-se ao Google Sheets

O Google Sheets é um software de planilhas on-line que permite organizar grandes quantidades de dados, criar relatórios personalizados, automatizar cálculos e colaborar com outras pessoas. Se você for usuário do Google Sheets, poderá se conectar AWS Glue à sua conta do Google Sheets. Em seguida, você pode usar o Planilhas Google como fonte de dados em seus ETL trabalhos. Execute esses trabalhos para transferir dados entre o Google Sheets e AWS os serviços ou outros aplicativos compatíveis.

Tópicos

- AWS Glue suporte para Google Sheets
- Políticas que contêm as operações de API para criar e usar conexões
- Configurando o Google Sheets

- Configuração de conexões do Planilhas Google
- Leitura de entidades do Planilhas Google
- Opções de conexão do Google Sheets
- Configurar o OAuth fluxo de código de autorização para o Google Sheets
- Limitações do conector do Planilhas Google

AWS Glue suporte para Google Sheets

AWS Glue é compatível com o Google Sheets da seguinte forma:

Compatível como fonte?

Sim. Você pode usar AWS Glue ETL trabalhos para consultar dados do Planilhas Google.

Compatível como destino?

Não.

APIVersões compatíveis do Google Sheets

Planilhas Google API v4 e Google Drive API v3

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
```

```
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configurando o Google Sheets

Antes de usar AWS Glue para transferir do Planilhas Google, você deve atender aos seguintes requisitos:

Requisitos mínimos

- Você tem uma conta do Google Sheets com e-mail e senha.
- Sua conta do Google Sheets está habilitada para API acesso. Todo o uso das Planilhas Google API está disponível sem custo adicional.
- Sua conta do Google Sheets permite que você instale aplicativos conectados. Se você não tiver acesso a essa funcionalidade, entre em contato com o administrador do Planilhas Google.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua conta do Google Sheets.

Configuração de conexões do Planilhas Google

Para configurar uma conexão com o Planilhas Google:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para o tipo de concessão AuthorizationCode:
      - Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar uma Fonte de dados, selecione Planilhas Google.
   b. Forneça o ambiente do Planilhas Google.
      i. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
      ii. Selecione as opções de rede se quiser usar sua rede.
3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

Tipo de concessão AUTHORIZATION_CODE

Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O Console do AWS Glue

redirecionará o usuário para o Planilhas Google, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Planilhas Google.

Os usuários podem optar por criar sua própria aplicação conectada no Planilhas Google e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Planilhas Google para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter mais informações, consulte a documentação pública do Planilhas Google sobre a criação de uma aplicação conectada para o fluxo de código de autorização do OAuth.

Leitura de entidades do Planilhas Google

Pré-requisitos

- Uma planilha do Google da qual você gostaria de ler. Você precisará do ID da planilha e do nome da aba da planilha.

Detalhes de entidades e campos do Planilhas Google:

Entidade	Tipo de dado	Operadores compatíveis
Planilha	String	N/D (não há suporte para filtros)

Exemplo

```
googleSheets_read = glueContext.create_dynamic_frame.from_options(
    connection_type="googlesheets",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "{SpreadSheetID}#{SheetTabName}",
        "API_VERSION": "v4"
    }
```

Particionamento de consultas

Para o particionamento baseado em registros somente, `NUM_PARTITIONS` ser fornecido como opções adicionais do spark se você quiser utilizar a simultaneidade no Spark. Com esse parâmetro, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

Exemplo com **`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"
    }
```

Opções de conexão do Google Sheets

A seguir estão as opções de conexão para o Google Sheets:

- `ENTITY_NAME`(String) - (Obrigatório) Usado para leitura. O `SpreadSheet ID` e `sheetTabName` no Google Sheets. Exemplo: `{SpreadSheetID}#{SheetTabName}`.
- `API_VERSION`(String) - (Obrigatório) Usado para leitura. APIVersão Rest do Google Sheets que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>) - Padrão: vazio (SELECT*). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Ele deve estar no SQL formato Spark.
- `QUERY`(String): padrão: vazia. Usado para leitura. SQLConsulta completa do Spark.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Configurar o OAuth fluxo de código de autorização para o Google Sheets

Pré-requisitos

- Uma conta do Google na qual você pode fazer login para usar o aplicativo Planilhas Google. Na sua conta do Google, o Planilhas Google contém os dados que você deseja transferir.

- Uma conta do Google Cloud Platform e um projeto do Google Cloud. Consulte Criar projeto do Google Cloud para obter mais detalhes.

Para configurar sua conta do Google e obter credenciais OAuth 2.0:

1. Depois que o projeto do Google Cloud estiver configurado, ative o Google Sheets API e o Google Drive APIs no projeto. Para ver as etapas para ativá-las, consulte Ativar e desativar APIs na Ajuda do API console do Google Cloud Platform.
2. Em seguida, configure uma tela de OAuth consentimento para usuários externos. Para mais informações sobre a tela de OAuth consentimento, consulte Configurar sua tela de OAuth consentimento na Ajuda do console do Google Cloud Platform.
3. Na tela de OAuth consentimento, adicione os seguintes escopos:

   - O escopo somente para API leitura do Google Sheets
   - O escopo somente para API leitura do Google Drive

   Para obter mais informações sobre esses escopos, consulte OAuth2.0 Scopes for Google APIs na documentação do Google Identity.
4. Gere ID de cliente OAuth 2.0 e segredo. Para ver as etapas para criar esse ID de cliente, consulte Configuração OAuth 2.0 na Ajuda do console do Google Cloud Platform.

   O ID do cliente OAuth 2.0 deve ter um ou mais URLs redirecionamentos autorizados.

   O redirecionamento URLs tem o seguinte formato:

   - <aws-region>https://.console.aws.amazon. com/gluestudio/oauth
5. Observe o ID do cliente e o segredo do cliente nas configurações do seu ID de cliente OAuth 2.0.

Limitações do conector do Planilhas Google

Estas são as limitações do conector do Planilhas Google:

- O conector do Planilhas Google não oferece suporte a filtros. Portanto, não pode haver suporte ao particionamento baseado em filtros.

- No particionamento baseado em registros, não há provisão para retornar a contagem exata de registros pelo SaaS. Como resultado, pode haver cenários em que arquivos com registros vazios sejam criados.
- Como o conector do Planilhas Google não oferece suporte ao particionamento baseado em filtros, `partitionField`, `lowerbound` e `upperbound` não são opções de conexão válidas. Se essas opções forem fornecidas, espera-se que o trabalho do AWS Glue falhe.
- É essencial designar a primeira linha da planilha como a linha do cabeçalho para evitar problemas no processamento dos dados.
  - Se não for fornecida, a linha do cabeçalho será substituída por `Unnamed:1`, `Unnamed:2`, `Unnamed:3`... se a planilha contiver dados com a primeira linha vazia.
  - Se a linha do cabeçalho for fornecida, os nomes das colunas vazias serão substituídos por `Unnamed:<number of column>`. Por exemplo, se a linha do cabeçalho for `['ColumnName1', 'ColumnName2', '', '', 'ColumnName5', 'ColumnName6']`, ela passará a ser `['ColumnName1', 'ColumnName2', 'Unnamed:3', 'Unnamed:4', 'ColumnName5', 'ColumnName6'].`
- O conector do Google Sheets não é compatível com a transferência incremental.
- O conector do Google Sheets é compatível apenas com o tipo de dados String.
- Os cabeçalhos duplicados em uma planilha serão renomeados iterativamente com um sufixo numérico. Os nomes dos cabeçalhos fornecidos pelo usuário terão precedência ao renomear os cabeçalhos duplicados. Por exemplo, se a linha do cabeçalho for ["Name", "", "Name", null, "Unnamed:6", ""], ela será alterada para: ["Name", "Unnamed:2", "Name1", "Unnamed:4", "Unnamed:6", "Unnamed:61"].
- O conector do Google Sheets não permite espaços em um nome de guia.
- O nome de uma pasta não pode conter os seguintes caracteres especiais:
  - #
  - /

Conectando-se a HubSpot

HubSpotA CRM plataforma da tem todas as ferramentas e integrações de que você precisa para marketing, vendas, gerenciamento de conteúdo e atendimento ao cliente.

- Marketing Hub - Software de marketing para ajudar você a aumentar o tráfego, converter mais visitantes e executar campanhas completas de inbound marketing em grande escala.

- Sales Hub - CRM Software de vendas para ajudá-lo a obter informações mais profundas sobre clientes potenciais, automatizar as tarefas que você tem e fechar mais negócios com mais rapidez.
- Service Hub - Software de atendimento ao cliente para ajudar você a se conectar com os clientes, superar as expectativas e transformá-los em promotores que expandem seus negócios.
- Operations Hub — Software de operações que sincroniza seus aplicativos, limpa e cria dados de clientes e automatiza processos, para que todos os seus sistemas e equipes trabalhem melhor juntos.

Tópicos

- AWS Glue compatível com o HubSpot
- Políticas contendo as API operações para criar e usar conexões
- Configuração do HubSpot
- Configuração de conexões do HubSpot
- Leitura de entidades do HubSpot
- Opções de conexão do HubSpot
- Limitações e observações do conector do HubSpot

AWS Glue compatível com o HubSpot

O AWS Glue é compatível com o HubSpot da seguinte forma:

Compatível como fonte?

Sim: SYNC e ASYNC. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do HubSpot.

Compatível como destino?

Não.

Versões da API compatíveis com o HubSpot

Estas são as versões da API compatíveis com o HubSpot:

- v1
- v2

- v3
- v4

Para conferir a compatibilidade de entidades por versão específica, consulte Entidades compatíveis com a fonte de SYNC e Entidades compatíveis com a fonte de ASYNC.

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS IAM permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, use as seguintes IAM políticas gerenciadas:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão

acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configuração do HubSpot

Antes de usar o AWS Glue para transferir dados do HubSpot, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do HubSpot. Para obter mais informações, consulte Criação de uma conta do HubSpot.
- Sua conta do HubSpot está habilitada para acesso à API.
- Você deve ter uma aplicação na conta do desenvolvedor do HubSpot que forneça as credenciais de cliente que o AWS Glue usará para acessar seus dados com segurança quando fizer chamadas autenticadas para sua conta. Para obter mais informações, consulte Criação de uma aplicação de desenvolvedor do HubSpot.

Caso atenda a esses requisitos, você poderá conectar o AWS Glue à sua conta do HubSpot. Para conexões normais, você não precisa fazer mais nada no HubSpot.

Criação de uma conta do HubSpot

Para criar uma conta do HubSpot:

1. Acesse o URL de inscrição do CRM do HubSpot.
2. Insira seu endereço de e-mail e escolha Verificar e-mail (como alternativa, você pode optar por se inscrever com uma conta do Google, Microsoft ou Apple).
3. Verifique sua caixa de entrada para obter o código de verificação do HubSpot.
4. Insira o código de verificação de seis dígitos e clique em Próximo.
5. Insira uma senha e clique em Próximo.
6. Insira seu nome e sobrenome e clique em Próximo, ou inscreva-se usando o link Inscrever-se com o Google.
7. Insira seu setor e clique em Próximo.

8. Insira sua função e clique em Próximo.
9. Insira o nome da sua empresa e clique em Próximo.
10. Selecione o tamanho da sua empresa (número de funcionários trabalhando na sua empresa) e clique em Próximo.
11. Insira o site da sua empresa e clique em Próximo.
12. Selecione onde seus dados devem ser hospedados (Estados Unidos ou Europa) e clique em Criar conta.
13. Selecione a finalidade da criação da sua conta e clique em Próximo.
14. Escolha Conectar conta do Google ou escolha adicionar contatos você mesmo para vincular seus contatos à sua conta do HubSpot.
15. Faça login na sua conta do Google se tiver escolhido a opção Conectar conta do Google para vincular seus contatos e começar a usar sua conta do HubSpot.

Criação de uma aplicação de desenvolvedor do HubSpot

As contas de desenvolvedores de aplicações são destinadas à criação e ao gerenciamento de aplicações, integrações e contas de teste de desenvolvedores. Elas também se encontram onde você pode criar e gerenciar listagens da aplicação do Marketplace. No entanto, as contas de desenvolvedores de aplicações e suas contas de teste associadas não estão conectadas a uma conta padrão do HubSpot. Eles não podem sincronizar dados ou ativos de ou para outra conta do HubSpot. Para obter o ID e o segredo do cliente, crie uma conta de desenvolvedor.

1. Acesse https://developers.hubspot.com/
2. Escolha Criar conta de desenvolvedor e role para baixo.
3. Você será perguntado se deseja criar uma conta de desenvolvedor de aplicação, uma conta privada de aplicação ou uma conta Sandbox de desenvolvedor do CMS. Escolha Criar conta de desenvolvedor de aplicação.
4. Como você já criou uma conta com o HubSpot, você pode escolher Continuar com este usuário.
5. Clique em Iniciar inscrição.
6. Insira sua função e clique em Próximo.
7. Dê um nome à sua conta de desenvolvedor, clique em Próximo e depois em Ignorar.
8. Escolha Criar aplicativo.
9. Depois que sua aplicação for criado, escolha Autenticação.
10. Em Autenticação, anote o ID e o segredo do cliente.

11. Adicione o URL de redirecionamento específico da sua região como https://*<aws-region>*.console.aws.amazon.com/gluestudio/oauth. Por exemplo, adicione https://us-east-1.console.aws.amazon.com/gluestudio/oauth para a região us-east-1.
12. Role para baixo e encontre os escopos. Há dois tipos de escopos que você deve selecionar nos cabeçalhos “CRM” e “Standard”.
13. Adicione os seguintes escopos:

```
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. Clique em Salvar e sua conta de desenvolvedor agora está pronta para uso.
15. Role acima para encontrar o ID do cliente.
16. Na mesma página, clique em Mostrar para obter o Segredo do cliente.

Criação de uma conta de teste de desenvolvedor do HubSpot

Nas contas de desenvolvedores de aplicações, você pode criar contas de teste de desenvolvedor para testar aplicações e integrações sem afetar nenhum dado real do HubSpot. As contas de teste de desenvolvedor não espelham as contas de produção, mas elas têm acesso a um teste de 90 dias das versões Enterprise do Marketing, Sales, Service, CMS e Operations Hub, oferecendo a capacidade de testar a maioria das ferramentas e APIs do HubSpot.

1. Clique em Início.

2. Clique em Criar conta de teste.
3. Clique em Criar conta de teste de aplicação.
4. Uma nova janela aparece. Insira o nome da conta de teste de aplicação e clique em Criar.

   Sua conta de teste de aplicação foi criada.

> **Note**
>
> A conta de desenvolvedor está relacionada às atividades de desenvolvimento, como integração de API, e a conta de teste da aplicação é usada para visualizar os dados criados ou extraídos pela conta do desenvolvedor.

Configuração de conexões do HubSpot

O HubSpot oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O usuário que estiver criando uma conexão precisa fornecer as informações relacionadas ao OAuth, como o ID do cliente e o segredo do cliente, para sua aplicação cliente do HubSpot. O console do AWS Glue redirecionará o usuário para o HubSpot, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do HubSpot.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no HubSpot e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o HubSpot para fazer login e autorizar o acesso do AWS Glue aos seus recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do HubSpot sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Aplicações públicas.

Para configurar uma conexão do HubSpot:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Observação: é necessário criar um segredo para a conexão no AWS Glue.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha HubSpot.
   b. Forneça o ambiente do HubSpot.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   e. Selecione as opções de rede se quiser usar sua rede.
3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do HubSpot

Pré-requisito

Um objeto do HubSpot do qual você deseja ler. Você precisará do nome do objeto, como contato ou tarefa. A tabela a seguir mostra as entidades compatíveis com a fonte de SYNC.

Entidades compatíveis com a fonte de SYNC

Entidade	Versão da API	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particionamento
Campanhas	v1	Não	Sim	Não	Sim	Não
Empresas	v3	Sim	Sim	Sim	Sim	Sim
Contatos	v3	Sim	Sim	Sim	Sim	Sim
Listas de contatos	v1	Não	Sim	Não	Sim	Não
Ofertas	v3	Sim	Sim	Sim	Sim	Sim
Pipeline de CRM (Pipelines de ofertas)	v1	Não	Não	Não	Sim	Não
Eventos de e-mail	v1	Não	Sim	Não	Sim	Não
Calls	v3	Sim	Sim	Sim	Sim	Sim
Observações	v3	Sim	Sim	Sim	Sim	Sim
E-mails	v3	Sim	Sim	Sim	Sim	Sim
Reuniões	v3	Sim	Sim	Sim	Sim	Sim

Entidade	Versão da API	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particionamento
Tarefas	v3	Sim	Sim	Sim	Sim	Sim
Correspondências postais	v3	Sim	Sim	Sim	Sim	Sim
Objetos personalizados	v3	Sim	Sim	Sim	Sim	Sim
Formulários	v2	Não	Não	Não	Sim	Não
Proprietários	v3	Não	Sim	Não	Sim	Não
Produtos	v3	Sim	Sim	Sim	Sim	Sim
Tíquetes	v3	Sim	Sim	Sim	Sim	Sim
Fluxos de trabalho	v3	Não	Não	Não	Sim	Não
Associations	v4	Sim	Não	Não	Sim	Não
Etiquetas de associações	v4	Não	Não	Não	Sim	Não

Exemplo:

```
hubspot_read = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "contact",
        "API_VERSION": "v3"
    }
```

Entidades compatíveis com a fonte de ASYNC

Entidade	Versão da API	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particionamento
Empresas	v3	Sim	Não	Sim	Sim	Não
Contatos	v3	Sim	Não	Sim	Sim	Não
Ofertas	v3	Sim	Não	Sim	Sim	Não
Calls	v3	Sim	Não	Sim	Sim	Não
Observações	v3	Sim	Não	Sim	Sim	Não
E-mails	v3	Sim	Não	Sim	Sim	Não
Reuniões	v3	Sim	Não	Sim	Sim	Não
Tarefas	v3	Sim	Não	Sim	Sim	Não
Correspondências postais	v3	Sim	Não	Sim	Sim	Não
Objetos personalizados	v3	Sim	Não	Sim	Sim	Não
Produtos	v3	Sim	Não	Sim	Sim	Não

Entidade	Versão da API	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Tíquetes	v3	Sim	Não	Sim	Sim	Não

Exemplo:

```
hubspot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="hubspot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "contact",
        "API_VERSION": "v3",
        "TRANSFER_MODE": "ASYNC"
    }
```

Detalhes das entidades e dos campos do HubSpot:

API do HubSpot v4:

Entidade	Versão da API	Campo	Tipo de dados	Operadores compatíveis
Etiqueta de associação	v4	categoria	String	N/D
		typeId	Inteiro	N/D
		rótulo	String	N/D
Associations		from	Struct	N/D
		id	String	"="
		com	Lista	N/D

> **Note**
>
> Para o objeto `Associations`, para buscar associações entre dois objetos, você precisa fornecer o “Id da origem” (o ID do primeiro objeto) por meio de um filtro obrigatório enquanto criar um trabalho do AWS Glue. Se você quiser buscar associações para vários IDs da origem, nesse caso precisará fornecer vários IDs na cláusula `where`. Por exemplo: para buscar os IDs de contato “1' e '151” em `Associations`, você precisa fornecer um filtro, como `where id=1 AND id=151`.

API do HubSpot v3:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Proprietário	firstName	String	N/D
	lastName	String	N/D
	createdAt	DateTime	N/D
	archived	Booleano	N/D
	equipes	Lista	N/D
	id	String	N/D
	userId	Inteiro	N/D
	email	String	N/D
	updatedAt	DateTime	N/D
Fluxo de trabalho	nome	String	N/D
	id	Inteiro	N/D
	type	String	N/D
	enabled	Booleano	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	insertedAt	Longo	N/D
	updatedAt	Longo	N/D
	contactListIds	Struct	N/D
	personaTagIds	Lista	N/D

Para as entidades a seguir, o HubSpot fornece endpoints para buscar metadados dinamicamente, para que o suporte do operador seja capturado no nível do tipo de dados de cada entidade.

> **Note**
>
> `DML_STATUS` é um campo virtual adicionado a cada registro no runtime para determinar seu status (CREATED/UPDATED) no modo SYNC. O operador `CONTAINS/LIKE` não é compatível no modo ASYNC.

Entidade	Tipo de dados	Operadores compatíveis
Contato	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D

Entidade	Tipo de dados	Operadores compatíveis
Empresa	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
Oferta	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
Tíquete	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D

Entidade	Tipo de dados	Operadores compatíveis
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
Produto	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
Objeto personalizado	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D

Entidade	Tipo de dados	Operadores compatíveis
Chame	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
E-mail	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
Reunião	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D

Entidade	Tipo de dados	Operadores compatíveis
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
Observação	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D
Tarefa	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D

Entidade	Tipo de dados	Operadores compatíveis
Correspondência postal	Inteiro	"=, !=, <, >, >=, <="
	Longo	"=, !=, <, >, >=, <="
	String	"=, !=, LIKE"
	Data	N/D
	DateTime	“entre”
	Booleano	"="
	Lista	N/D
	Struct	N/D

API do HubSpot v2:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Formulário	portalId	Inteiro	N/D
	guid	String	N/D
	nome	String	N/D
	method	String	N/D
	cssClass	String	N/D
	redirecionar	String	N/D
	submitText	String	N/D
	notifyRecipients	String	N/D
	createdAt	Longo	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	updatedAt	Longo	N/D
	ignoreCurrentValues	Booleano	N/D
	deletável	Booleano	N/D
	inlineMessage	Booleano	N/D
	captchaEnabled	Booleano	N/D
	clonável	Booleano	N/D
	formFieldGroups	Lista	N/D
	editable	Booleano	N/D
	deletedAt	Inteiro	N/D
	themeName	String	N/D
	parentId	Inteiro	N/D
	estilo	String	N/D
	isPublished	Booleano	N/D
	publishAt	Inteiro	N/D
	unpublishAt	Inteiro	N/D
	publishedAt	Inteiro	N/D
	kickbackEmailWorkflowId	String	N/D
	kickbackEmailsJson	Inteiro	N/D
	customUid	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	createMarketableContact	Booleano	N/D
	editVersion	Inteiro	N/D
	thankYouMessageJson	String	N/D
	themeColor	String	N/D
	alwaysCreateNewCompany	Booleano	N/D
	internalUpdatedAt	Longo	N/D
	businessUnitId	Inteiro	N/D
	portableKey	String	N/D
	paymentSessionTemplateIds	Lista	N/D
	selectedExternalOptions	Lista	N/D

API do HubSpot v1:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Campaign	id	Inteiro	N/D
	appId	Inteiro	N/D
	appName	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	lastUpdatedTime	Longo	N/D
Contact_List	dynamic	Booleano	N/D
	nome	String	N/D
	portalId	Inteiro	N/D
	createdAt	Longo	N/D
	listId	Inteiro	N/D
	updatedAt	Longo	N/D
	ListType	String	N/D
	filtros	Lista	N/D
	authorId	Inteiro	N/D
	metaData	Struct	N/D
	archived	Booleano	N/D
	ilsFilterBranch	String	N/D
	filterIds	Lista	N/D
	limitExempt	Booleano	N/D
	interno	Booleano	N/D
	readOnly	Booleano	N/D
	parentId	Inteiro	N/D
Email_Event	id	String	N/D
	type	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	recipient (destinatário)	String	N/D
	portalId	Inteiro	N/D
	appId	Inteiro	N/D
	appName	String	N/D
	emailCampaignId	Longo	N/D
	tentativa	Inteiro	N/D
	created	Longo	N/D
	sentBy	Struct	N/D
	smtpId	String	N/D
	Retorno	String	N/D
	subject	String	N/D
	cc	Lista	N/D
	bcc	Lista	N/D
	replyTo	Lista	N/D
	from	String	N/D
	dropReason	String	N/D
	dropMessage	String	N/D
	navegador	Struct	N/D
	userAgent	String	N/D
	duration	Longo	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	local	Struct	N/D
	filteredEvent	Booleano	N/D
	deviceType	String	N/D
	suppressedReason	String	N/D
	suppressedMessage	String	N/D
CRM_Pipeline	pipelineId	String	N/D
	createdAt	Longo	N/D
	updatedAt	Longo	N/D
	objectType	String	N/D
	rótulo	String	N/D
	displayOrder	Inteiro	N/D
	active	Booleano	N/D
	estágios	Lista	N/D
	objectTypeId	String	N/D
	padrão	Booleano	N/D

Consultas de particionamento

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.

- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo DateTime, aceitamos o valor no formato ISO.

  Exemplos de valores válidos:

  ```
  “2024-01-01T10:00:00.115Z"
  ```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

A tabela a seguir descreve os detalhes do suporte do campo de particionamento da entidade:

Nome da entidade	Campos de particionamento	Tipo de dados
contact	hs_object_id	Longo
	createdate, lastmodifieddate	DateTime
company	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
oferta	hs_object_id	Longo
	createdate, hs_createdate, hs_lastmodifieddate	DateTime
bilhete	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
product	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
custom_object	hs_object_id	Longo

Nome da entidade	Campos de particionamento	Tipo de dados
	createdate, hs_lastmodifieddate	DateTime
call	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
email	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
reunião	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
note	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
task	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime
postal_mail	hs_object_id	Longo
	createdate, hs_lastmodifieddate	DateTime

Exemplo:

```
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"
    }
```

Opções de conexão do HubSpot

Estas são as opções de conexão do HubSpot:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no HubSpot.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API REST do HubSpot que você deseja usar. Por exemplo: v1, v2, v3, v4.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `TRANSFER_MODE` (String): usado para indicar se a consulta deve ser executada no modo ASYNC.

Limitações e observações do conector do HubSpot

Estas são as limitações ou observações do conector do HubSpot:

- Os endpoints de pesquisa estão limitados a um total de 10 mil resultados para qualquer consulta. Qualquer partição com mais de 10 mil registros resultará em um erro 400.
- Outras limitações importantes do conector estão descritas em Limitações.
- Um máximo de três instruções de filtragem são aceitas pelo HubSpot.

- Atualmente, o HubSpot é compatível com associações entre os objetos padrão do HubSpot (por exemplo, contato, empresa, negócio ou tíquete) e os objetos personalizados.
  - Para uma conta gratuita: você pode criar apenas até dez tipos de associação entre cada par de objetos (por exemplo, contatos e empresas).
  - Para uma conta Super Admin: você pode criar apenas até cinquenta tipos de associação entre cada par de objetos.
  - Para obter mais informações, consulte Associations v4 e Create and use association labels.
- Os objetos “Cotação” e “Comunicações” não estão presentes para Associações, pois atualmente não são compatíveis no conector.
- Para ASYNC, o SaaS classifica os valores somente em ordem ascendente.
- Para a entidade `Ticket`, o SaaS não retorna o campo `hs_object_id` no modo ASYNC.

Conexão com o Instagram Ads

O Instagram é uma aplicação popular de compartilhamento de fotos que permite que você se conecte com marcas, celebridades, lideranças inovadoras, amigos, familiares e muito mais. É um serviço de compartilhamento de fotos e de rede social. Os usuários podem tirar fotos ou vídeos curtos e compartilhá-los com seus seguidores. Os anúncios do Instagram são publicações pelas quais as empresas podem pagar para veicular aos usuários do Instagram.

Tópicos

- Suporte do AWS Glue para o Instagram Ads
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Instagram Ads
- Configuração de conexões do Instagram Ads
- Leitura de entidades do Instagram Ads
- Opções de conexão do Instagram Ads
- Limitações e notas do conector do Instagram Ads

Suporte do AWS Glue para o Instagram Ads

O AWS Glue oferece suporte ao Instagram Ads da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Instagram Ads.

Compatível como destino?

N.º

Versões compatíveis da API do Instagram Ads

As seguintes versões da API do Instagram Ads são compatíveis:

- v17.0
- v18.0
- v19.0
- v20.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Instagram Ads

Antes de poder usar o AWS Glue para transferir dados do Instagram Ads, você precisa atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- As contas padrão do Instagram são acessadas diretamente pelo Facebook.
- A autenticação do usuário é necessária para gerar o token de acesso.
- O conector do SDK do Instagram Ads implementará o fluxo do OAuth para tokens de acesso do usuário.
- Estamos usando o OAuth2.0 para autenticar nossas solicitações de API para o Instagram Ads. Essa autenticação baseada na Web se enquadra na arquitetura autenticação multifator (MFA), que é um superconjunto de 2FA.
- O usuário precisa conceder permissões para acessar os endpoints. Para acessar os dados do usuário, a autorização do endpoint é processada por meio de permissões e recursos.

Obtenção de credenciais do Outh 2.0

Para obter credenciais de API para que você possa fazer chamadas autenticadas para instâncias, consulte API de gráfico.

Configuração de conexões do Instagram Ads

O Instagram Ads é compatível com o tipo de concessão AUTHORIZATION_CODE para OAuth2.

- Esse tipo de concessão é considerado um OAuth de três pernas, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue.
- Os usuários podem optar por criar sua própria aplicação conectada no Instagram Ads e fornecer os próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Instagram Ads para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de acesso. Um token de usuário do sistema prestes a expirar é válido por 60 dias a partir de uma data gerada ou atualizada. Para criar continuidade, o desenvolvedor deve atualizar o token de acesso em até 60 dias. Se isso não for feito, o token de acesso será perdido e será exigido que o desenvolvedor obtenha um novo token para recuperar o acesso à API. Consulte Atualizar token de acesso.

Para configurar uma conexão com o Instagram Ads:

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Instagram Ads.
   b. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e que tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
```

```
    ]
}
```

c. Forneça o ID do cliente da aplicação cliente gerenciada pelo usuário.

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens. O segredo selecionado precisa ter uma chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` com o valor sendo o segredo do cliente da aplicação conectada.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Instagram Ads

Pré-requisito

Um objeto do Instagram Ads do qual você deseja ler. Você precisará do nome do objeto. As tabelas a seguir mostram as entidades compatíveis.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Campaign	Sim	Sim	Não	Sim	Sim
Conjunto de anúncios	Sim	Sim	Não	Sim	Sim
Ads	Sim	Sim	Não	Sim	Sim
Anúncio criativo	Não	Sim	Não	Sim	Não
Insights: conta	Não	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Imagem do anúncio	Sim	Sim	Não	Sim	Não
Insights: anúncio	Sim	Sim	Não	Sim	Sim
Insights: AdSet	Sim	Sim	Não	Sim	Sim
Insights: campanha	Sim	Sim	Não	Sim	Sim

Exemplo:

```
instagramAds_read = glueContext.create_dynamic_frame.from_options(
    connection_type="instagramads",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v20.0"
    }
```

Detalhes das entidades e dos campos do Instagram Ads

Para obter mais informações sobre os detalhes das entidades e dos campos, consulte:

- Campanha
- Conjunto de anúncios
- Ad
- Anúncio criativo
- Insight da conta de anúncios
- Imagem do anúncio

- Insights do anúncio
- Insights de AdSets
- Insights de campanhas

Para obter mais informações, consulte API de marketing.

> **Note**
>
> Os tipos de dados Struct e List são convertidos no tipo de dados String na resposta dos conectores.

Consultas de particionamento

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Data e hora, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

  Exemplo de valor válido:

  ```
  "2022-01-01T00:00:00.000Z"
  ```

- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.

  Exemplo de valor válido:

  ```
  "2024-01-02T00:00:00.000Z"
  ```

- `NUM_PARTITIONS`: o número de partições.

Exemplo:

```
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"
    }
```

Opções de conexão do Instagram Ads

Estas são as opções de conexão do Instagram Ads:

- `ENTITY_NAME`(String): (obrigatório) usado para leitura. O nome do objeto no Instagram Ads.
- `API_VERSION`(String): (obrigatório) usado para leitura. Versão da API de gráfico do Instagram Ads que você deseja usar. Por exemplo: v21.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações e notas do conector do Instagram Ads

Estas são as limitações ou notas do conector do Instagram Ads:

- A contagem de chamadas de uma aplicação é o número de chamadas que um usuário pode fazer durante uma janela contínua de uma hora, 200 multiplicado pelo número de usuários. Para

conhecer detalhes sobre o limite de taxa, consulte Limites de taxa e Limites de taxa de casos de uso empresarial.

Conexão com o Intercom no AWS Glue Studio

O Intercom é o Engagement OS, um canal aberto entre sua empresa e seus clientes no produto, no momento e nos termos deles, criando um diálogo contínuo que permite que você aproveite ao máximo cada envolvimento ao longo da jornada do cliente.

Tópicos

- Suporte do AWS Glue para o Intercom
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Intercom
- Configuração de conexões do Intercom
- Leitura de entidades do Intercom
- Opções de conexão do Intercom
- Limitações
- Criação de uma conta do Intercom e configuração da aplicação cliente

Suporte do AWS Glue para o Intercom

O AWS Glue oferece suporte ao Intercom da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Intercom.

Compatível como destino?

N.º

Versões compatíveis da API do Intercom

v2.5. Para suporte de entidades por versão específica, consulte Leitura de entidades do Intercom.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Intercom

Antes de poder usar o AWS Glue para transferir dados do Intercom, você precisa atender aos seguintes requisitos:

Requisitos mínimos

- Ter uma conta do Intercom. Para ter mais informações, consulte Criação de uma conta do Intercom e configuração da aplicação cliente.

- A conta do Intercom precisa estar habilitada para acesso à API.
- Você deve ter uma aplicação no desenvolvedor do Intercom que fornece as credenciais que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para obter mais informações, consulte Intercom - New Account and Client App Creation Steps.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Intercom.

Configuração de conexões do Intercom

O Intercom é compatível com o tipo de concessão `AUTHORIZATION_CODE` para OAuth 2.

Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O Console do AWS Glue redirecionará o usuário para o Google Ads, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Intercom.

Os usuários devem fornecer seus próprios ID e segredo do cliente quando criarem conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Intercom para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter mais informações sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte a API do Amazon Ads.

Para configurar uma conexão do Intercom:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para a aplicação conectada gerenciado pelo cliente, o segredo deve conter o token de acesso à aplicação conectada, o token de atualização, o client_id e o client_secret.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Intercom.
   b. Forneça o ambiente do Intercom.

c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Intercom

Pré-requisitos

- Um objeto do Intercom do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	API_Version	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particionamento
Admins	v2.5	Não	Não	Não	Sim	Não
Empresas	v2.5	Não	Sim	Não	Sim	Não
Conversas	v2.5	Sim	Sim	Sim	Sim	Sim
Atributos de dados	v2.5	Não	Não	Não	Sim	Não
Contatos	v2.5	Sim	Sim	Sim	Sim	Sim
Segmentos	v2.5	Não	Não	Não	Sim	Não
Tags	v2.5	Não	Não	Não	Sim	Não
Equipes	v2.5	Não	Não	Não	Sim	Não

Exemplo

```
Intercom_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Intercom",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "company",
        "API_VERSION": "V2.5"
    }
)
```

Detalhes das entidades e dos campos do Intercom

Entidade	Campo	Tipo de dado	Operadores compatíveis
Admins	type	String	NA

Entidade	Campo	Tipo de dado	Operadores compatíveis
Admins	id	String	NA
Admins	avatar	Struct	NA
Admins	nome	String	NA
Admins	email	String	NA
Admins	away_mode_enabled	Booleano	NA
Admins	away_mode_reassign	Booleano	NA
Admins	has_inbox_seat	Booleano	NA
Admins	teams_ids	Lista	NA
Admins	job_title	String	NA
Empresas	type	String	NA
Empresas	id	String	NA
Empresas	app_id	String	NA
Empresas	created_at	DateTime	NA
Empresas	remote_created_at	DateTime	NA
Empresas	updated_at	DateTime	NA
Empresas	last_request_at	DateTime	NA
Empresas	planejar	Struct	NA
Empresas	company_id	String	NA
Empresas	nome	String	NA
Empresas	custom_attributes	Struct	NA

Entidade	Campo	Tipo de dado	Operadores compatíveis
Empresas	session_count	Inteiro	NA
Empresas	monthly_spend	Inteiro	NA
Empresas	user_count	Inteiro	NA
Empresas	setor	String	NA
Empresas	size	Inteiro	NA
Empresas	site	String	NA
Empresas	tags	Struct	NA
Empresas	segmentos	Struct	NA
Contatos	id	String	EQUAL_TO. NOT_EQUAL_TO
Contatos	type	String	NA
Contatos	workspace_id	String	NA
Contatos	external_id	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	perfil	String	EQUAL_TO. NOT_EQUAL_TO
Contatos	email	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	phone	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO

Entidade	Campo	Tipo de dado	Operadores compatíveis
Contatos	nome	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	avatar	String	NA
Contatos	owner_id	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	social_profiles	Struct	NA
Contatos	has_hard_bounced	Booleano	EQUAL_TO
Contatos	marked_email_as_spam	Booleano	EQUAL_TO
Contatos	unsubscribed_from_emails	Booleano	EQUAL_TO
Contatos	created_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	updated_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	signed_up_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	last_seen_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN

Entidade	Campo	Tipo de dado	Operadores compatíveis
Contatos	last_replied_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	last_contacted_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	last_email_opened_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	last_email_clicked_at	DateTime	EQUAL_TO, GREATER_THAN, LESS_THAN
Contatos	language_override	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	navegador	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	browser_version	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	browser_language	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	os	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO

Entidade	Campo	Tipo de dado	Operadores compatíveis
Contatos	local	Struct	NA
Contatos	location_country	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	location_region	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	location_city	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	android_app_name	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	android_app_version	String	NA
Contatos	android_device	String	NA
Contatos	android_os_version	String	NA
Contatos	android_sdk_version	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	android_last_seen_at	Data	NA
Contatos	ios_app_name	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	ios_app_version	String	NA
Contatos	ios_device	String	NA

Entidade	Campo	Tipo de dado	Operadores compatíveis
Contatos	ios_os_version	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	ios_sdk_version	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Contatos	ios_last_seen_at	DateTime	NA
Contatos	custom_attributes	Struct	NA
Contatos	tags	Struct	NA
Contatos	notes	Struct	NA
Contatos	empresas	Struct	NA
Contatos	unsubscribed_from_sms	Booleano	NA
Contatos	sms_consent	Booleano	NA
Contatos	opted_out_subscription_types	Struct	NA
Contatos	indicador	String	NA
Contatos	utm_campaign	String	NA
Contatos	utm_content	String	NA
Contatos	utm_medium	String	NA
Contatos	utm_source	String	NA
Contatos	utm_term	String	NA

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conversas	type	String	NA
Conversas	id	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	created_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	updated_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	origem	Struct	NA
Conversas	source_id	String	EQUAL_TO, NOT_EQUAL_TO
Conversas	source_type	String	EQUAL_TO, NOT_EQUAL_TO,
Conversas	source_delivered_as	String	EQUAL_TO, NOT_EQUAL_TO,
Conversas	source_subject	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	source_body	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conversas	source_author_id	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	source_author_type	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	source_author_name	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	source_author_email	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	source_url	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	contacts	Struct	NA
Conversas	colegas de equipe	Struct	NA
Conversas	título	String	NA
Conversas	admin_assignee_id	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	team_assignee_id	Inteiro	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	custom_attributes	Struct	NA

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conversas	aberto	Booleano	EQUAL_TO
Conversas	estado	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	leitura	Booleano	EQUAL_TO
Conversas	waiting_since	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	snoozed_until	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	tags	Struct	NA
Conversas	first_contact_reply	Struct	NA
Conversas	priority	String	EQUAL_TO, NOT_EQUAL_TO
Conversas	tópicos	Struct	NA
Conversas	sla_applied	Struct	NA
Conversas	conversation_rating	Struct	NA
Conversas	conversation_rating_requested_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conversas	conversation_rating_replied_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	conversation_rating_score	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	conversation_rating_remark	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	conversation_rating_contact_id	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	conversation_rating_admin_id	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	estatísticas	Struct	NA
Conversas	statistics_time_to_assignment	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_time_to_admin_reply	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conversas	statistics_time_to_first_close	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_time_to_last_close	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_median_time_to_reply	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_first_contact_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_first_assignment_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_first_admin_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_first_close_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conversas	statistics_last_assignment_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_last_assignment_admin_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_last_contact_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_last_admin_reply_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_last_close_at	DateTime	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_last_closed_by_id	String	CONTAINS, EQUAL_TO, NOT_EQUAL_TO
Conversas	statistics_count_reopens	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN

Entidade	Campo	Tipo de dado	Operadores compatíveis
Conversas	statistics_count_assignments	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	statistics_count_conversation_parts	Inteiro	EQUAL_TO, NOT_EQUAL_TO, GREATER_THAN, LESS_THAN
Conversas	conversation_parts	Lista	NA
Atributos de dados	id	Inteiro	NA
Atributos de dados	type	String	NA
Atributos de dados	modelo	String	NA
Atributos de dados	nome	String	NA
Atributos de dados	full_name	String	NA
Atributos de dados	rótulo	String	NA
Atributos de dados	description	String	NA
Atributos de dados	data_type	String	NA
Atributos de dados	options	Lista	NA
Atributos de dados	api_writable	Booleano	NA
Atributos de dados	ui_writable	Booleano	NA
Atributos de dados	personalizado	Booleano	NA
Atributos de dados	archived	Booleano	NA

Entidade	Campo	Tipo de dado	Operadores compatíveis
Atributos de dados	created_at	Booleano	NA
Atributos de dados	updated_at	DateTime	NA
Atributos de dados	admin_id	String	NA
Segmentos	type	String	NA
Segmentos	id	String	NA
Segmentos	nome	String	NA
Segmentos	created_at	DateTime	NA
Segmentos	updated_at	DateTime	NA
Segmentos	person_type	String	NA
Segmentos	contagem	Inteiro	NA
Tags	type	String	NA
Tags	id	String	NA
Tags	nome	String	NA
Equipes	type	String	NA
Equipes	id	String	NA
Equipes	nome	String	NA
Equipes	admin_ids	Lista	NA

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses

parâmetros, a consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valores válidos: "2024-02-06".
- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na tabela a seguir.

Entity Name	Campo de particionamento	Tipo de dado
Contatos	created_at, updated_at,last_seen_at	DateTime
Conversas	id	Inteiro
Conversas	created_at, updated_at	DateTime

Exemplo

```
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"
    }
)
```

Opções de conexão do Intercom

Estas são as opções de conexão do Intercom:

- `ENTITY_NAME` (String): (obrigatório) usado para leitura. O nome do seu objeto no Intercom.
- `API_VERSION` (String): (obrigatório) usado para leitura. Versão da API Rest do Intercom que você deseja usar. Exemplo: v2.5.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL`(String): URL da instância em que o usuário deseja executar as operações. Por exemplo: https://api.intercom.io.

Limitações

Estas são as limitações do conector do Intercom:

- Quando a entidade Empresa é usada, existe um limite de 10 mil empresas que podem ser retornadas. Para obter mais informações, consulte API da lista de todas as empresas.
- Ao ser aplicado ordenar por, o filtro é obrigatório para as entidades Contato e Conversa.
- O Contrato de Cliente da Microsoft (MCA) é suportado pelo provedor de SaaS. No entanto, com base nos limites de taxa de API mencionados na documentação, não hospedaremos o MCA no AWS Glue, pois isso poderá afetar outras workloads e potencialmente causar problemas de desempenho devido à contenção de recursos.

Criação de uma conta do Intercom e configuração da aplicação cliente

Criação de uma conta do Intercom

1. Escolha o URL do Intercom e escolha Iniciar avaliação gratuita no canto superior direito da página.
2. Escolha o botão Experimentar gratuitamente no canto superior direito da página.
3. Escolha o tipo de empresa necessário.
4. Insira todas as informações solicitadas na página.
5. Depois de inserir todas as informações, escolha Registrar.

Criação de uma aplicação de desenvolvedor do Intercom

Para obter o Id do cliente e o Segredo do cliente, crie uma conta de desenvolvedor.

1. Navegue até https://app.intercom.com/.
2. Digite o ID do e-mail e a Senha/Faça login usando o Google.
3. Selecione perfil do usuário no canto inferior esquerdo e escolha as configurações.
4. Escolha Aplicações e integração.
5. Escolha a guia Hub do desenvolvedor em Aplicações e integração.
6. Escolha Nova aplicação e crie a aplicação aqui.
7. Forneça o nome da aplicação e escolha Criar aplicação.
8. Dentro da aplicação, navegue até a seção Autenticação.
9. Escolha os URIs de edição e de adição de redirecionamento. Adicione o URL de redirecionamento específico da sua região, como `https://<aws-region>.console.aws.amazon.com/gluestudio/oauth`. Por exemplo, adicione `https://us-east-1.console.aws.amazon.com/gluestudio/oauth for the us-east-1 region`.
10. Obtenha o Id do cliente e o Segredo do cliente gerados na seção Informações básicas.

Conectando-se ao Jira Cloud

O Jira Cloud é uma plataforma desenvolvida pela Atlassian. A plataforma inclui produtos de rastreamento de problemas que ajudam as equipes a planejar e monitorar seus projetos ágeis.

Como usuário do Jira Cloud, sua conta contém dados sobre seus projetos, como problemas, fluxos de trabalho e eventos. Você pode usar AWS Glue para transferir seus dados do Jira Cloud para determinados AWS serviços ou outros aplicativos compatíveis.

Tópicos

- AWS Glue suporte para o Jira Cloud
- Políticas contendo as API operações para criar e usar conexões
- Configurando o Jira Cloud
- Configuração de conexões do Jira Cloud
- Leitura de entidades do Jira Cloud
- Opções de conexão do Jira Cloud
- Limitações e notas sobre o conector Jira Cloud

AWS Glue suporte para o Jira Cloud

AWS Glue suporta o Jira Cloud da seguinte forma:

Compatível como fonte?

Sim. Você pode usar AWS Glue ETL trabalhos para consultar dados do Jira Cloud.

Compatível como destino?

Não.

Versões compatíveis do Jira Cloud API

As seguintes API versões do Jira Cloud são suportadas:

- v2

Para suporte de entidades por versão específica, consulte Entidades suportadas para o Source.

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS IAM permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, use as seguintes IAM políticas gerenciadas:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configurando o Jira Cloud

Antes de usar AWS Glue para transferir dados do Jira Cloud para destinos compatíveis, você deve atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta Atlassian na qual usa o produto de software Jira no Jira Cloud. Para obter mais informações, consulte Criação de uma conta do Jira Cloud.
- Você deve ter uma AWS conta criada com o acesso ao serviço AWS Glue a.
- Este aplicativo fornece as credenciais do cliente que AWS Glue usa para acessar seus dados com segurança ao fazer chamadas autenticadas para sua conta. Para obter mais informações, consulte Habilitando OAuth 2.0 (3LO) na documentação do Atlassian Developer.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua conta do Jira Cloud.

Criação de uma conta do Jira Cloud

Para criar uma conta do Jira Cloud:

1. Navegue até a inscrição da Atlassian. URL
2. Insira seu e-mail e nome de trabalho e escolha Concordo. Você recebe um e-mail de verificação.
3. Depois de verificar seu e-mail, você pode criar uma senha e escolher Inscrever-se.
4. Insira o nome e a senha e escolha Inscrever-se.
5. Você é redirecionado para uma página na qual precisa entrar no seu site. Insira o nome do site e escolha Concordo.

Depois que seu site Atlassian Cloud for iniciado, você poderá configurar seu Jira respondendo a algumas perguntas de acordo com suas preferências de tipo de projeto.

Para fazer login em uma conta existente:

1. Navegue até o login da Atlassian URL e insira as credenciais.
2. Digite o e-mail e a senha e clique em Entrar. Você será redirecionado para o painel do Jira.

Criando um aplicativo em seu Jira Cloud

Para criar um aplicativo no Jira Cloud e obter o ID do cliente e o segredo do cliente do aplicativo cliente gerenciado:

1. Navegue até o Jira Cloud URL e insira as credenciais.
2. Escolha Criar e selecione a opção de integração OAuth 2.0.
3. Insira o nome do aplicativo, verifique os Termos e Condições e escolha Criar.

4. Navegue até a seção Distribuição no menu à esquerda e escolha Editar.
5. Na seção Editar controles de distribuição:
   a. Selecione DISTRIBUTIONSTATUScomo Compartilhamento.
   b. Insira o nome do fornecedor.
   c. Insira o URL para sua política de privacidade. Por exemplo, https://docs.aws.amazon.com/glue/latest/dg/security -iam-awsmanpol.html
   d. Insira os Termos URL de Serviço em seus Termos de Serviço (opcional).
   e. Insira o URL para seu contato de suporte ao cliente (opcional).
   f. Selecione Sim/Não em PERSONALDATADECLARATIONe escolha Salvar alterações.
6. Navegue até Permissões no menu esquerdo do respectivo aplicativo.
7. Para o Jira API, escolha Adicionar. Depois de adicionado, escolha a opção Configuração.
8. Na REST API seção Escopos clássicos > Plataforma Jira, escolha Editar escopos e marque todos os escopos. Clique em Salvar.
9. Em Escopos granulares, escolha Editar escopos e selecione os seguintes escopos:
10. Role para baixo e encontre escopos. Há dois tipos de escopos que você deve selecionar nos títulos "CRM" e “Padrão”.
11. Adicione os seguintes escopos:

```
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:jir
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 Navegue até Autenticação no menu à esquerda e escolha Adicionar.

13 Insira um retorno de chamada URL, como https://us-east-1.console.aws.amazon.com/gluestudio/oauth

14 Navegue até Configurações no menu à esquerda e role para baixo para ver os detalhes da autenticação. Anote o ID do cliente e o segredo.

Configuração de conexões do Jira Cloud

O Jira Cloud oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O console do AWS Glue redirecionará o usuário para o Jira Cloud, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Jira Cloud.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no Jira Cloud e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Jira Cloud para fazer login e autorizar o acesso do AWS Glue aos recursos.

- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Jira Cloud sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Habilitação do OAuth 2.0 (3LO).

Para configurar uma conexão com o Jira Cloud:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Observação: é necessário criar um segredo para a conexão no AWS Glue.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Jira Cloud.
   b. Forneça o ambiente do Jira Cloud.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Jira Cloud

Pré-requisito

Um objeto do Jira Cloud do qual você deseja ler. Você precisará do nome do objeto, como Registro de auditoria ou Problema. A tabela a seguir mostra as entidades compatíveis.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Registro de auditoria	Sim	Sim	Não	Sim	Sim
Problema	Sim	Sim	Não	Sim	Sim
Campo Problema	Não	Não	Não	Sim	Não
Configuração do campo Problema	Sim	Sim	Não	Sim	Sim
Tipo de link de problema	Não	Não	Não	Sim	Não
Esquema da notificação de problema	Sim	Sim	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Esquema de segurança de problemas	Não	Não	Não	Sim	Não
Esquema do tipo de problema	Sim	Sim	Sim	Sim	Sim
Esquema de tela do tipo de problema	Sim	Sim	Sim	Sim	Sim
Tipo de problema	Não	Não	Não	Sim	Não
Configuração do Jira	Sim	Não	Não	Sim	Não
Configuração avançada do Jira	Não	Não	Não	Sim	Não
Configuração global do Jira	Não	Não	Não	Sim	Não
Rótulo	Não	Não	Não	Sim	Sim
Eu mesmo(a)	Sim	Não	Não	Sim	Não
Permissão	Não	Não	Não	Sim	N.º
Projeto	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Categoria do projeto	Não	Não	Não	Sim	Não
Tipo de projeto	Não	Não	Não	Sim	Não
Informações do servidor	Não	Não	Não	Sim	Não
Usuários	Não	Não	N.º	Sim	Não
Fluxo de trabalho	Sim	Sim	Sim	Sim	Sim
Esquema do fluxo de trabalho	Não	Sim	Não	Sim	Sim
Associação de projetos do esquema do fluxo de trabalho	Sim	Não	Não	Sim	Não
Status do fluxo de trabalho	Não	Não	Não	Sim	Não
Categoria de status do fluxo de trabalho	Não	Não	Não	Sim	Não

Exemplo:

```
jiracloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="JiraCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "audit-record",
        "API_VERSION": "v2"
    }
```

Detalhes das entidades e dos campos do Jira Cloud:

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
Registro de auditoria	filtrar	String	"="
	from	DateTime	"="
	para	DateTime	"="
	id	Inteiro	N/D
	resumo	String	N/D
	remoteAddress	String	N/D
	authorAccountId	String	N/D
	created	String	N/D
	category	String	N/D
	eventSource	String	N/D
	description	String	N/D
	objectItem	struct	N/D
	changedValues	Listar	N/D
	associatedItems	Listar	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
Grupos	groupName	Listar	"="
	name	String	N/D
	groupId	String	"="
Problema	affectedVersion	String	"=, !="
	assignee	String	"=, !="
	category	String	"=, !="
	componente	String	"=, !="
	criador	String	"=, !="
	devido	DateTime	N/D
	epic_link	String	"=, !="
	filtrar	String	"=, !="
	fixVersion	String	"=, !="
	hierarchyLevel	Inteiro	"=, !="
	issueKey	String	"=, !=, >, <, >=, <="
	issueLink	String	"=, !="
	issueLinkType	String	"=, !="
	rótulos	String	"=, !="
	lastViewed	DateTime	“=, >, <, >=, <=, between”
	level	String	"=, !="

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	parent	String	"=, !="
	priority	String	"=, !="
	project	String	"=, !="
	projectType	String	"=, !="
	denunciante	String	"=, !="
	resolução	String	"=, !="
	resolvido	DateTime	“=, >, <, >=, <=, between”
	sprint	String	"=, !="
	status	String	"=, !="
	tipo	String	"=, !="
	updated	DateTime	“=, >, <, >=, <=, between”
	eleitor	String	"=, !="
	votos	Inteiro	“=, !=, <, >, <=, >=, between”
	observador	String	"=, !="
	observadores	Inteiro	“=, !=, <, >, <=, >=, between”
	workRatio	Inteiro	“=, !=, <, >, <=, >=, between”
	validateQuery	String	"="

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	expandir	String	"="
	fieldByKeys	Booleano	"="
	id	String	N/D
	self	String	N/D
	chave	String	N/D
	renderedFields	struct	N/D
	propriedades	Listar	"="
	nomes	struct	N/D
	Esquema	struct	N/D
	transições	Listar	N/D
	operações	struct	N/D
	editmeta	struct	N/D
	changelog	struct	N/D
	versionedRepresentations	struct	N/D
	fields	Listar	"="
	fieldsToInclude	struct	N/D
	warningMessages	Listar	N/D
	created	DateTime	N/D
	worklogDate	DateTime	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
IssueEvents	id	Inteiro	N/D
	name	String	N/D
Campos Problema	id	String	N/D
	chave	String	N/D
	name	String	N/D
	personalizado	Booleano	N/D
	orderable	Booleano	N/D
	navigable	Booleano	N/D
	pesquisável	Booleano	N/D
	clauseNames	Listar	N/D
	scope	struct	N/D
	Esquema	struct	N/D
Configurações do campo Problema	isDefault	Booleano	"="
	consulta	String	"="
	id	Inteiro	"="
	name	String	N/D
	description	String	N/D
Tipo de link de problema	id	String	N/D
	name	String	N/D
	interno	String	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	externo	String	N/D
	self	String	N/D
Esquemas de notificação de problemas	expandir	String	"="
	self	String	N/D
	id	Inteiro	N/D
	name	String	N/D
	description	String	N/D
	notificationSchemeEvents	Listar	N/D
	scope	struct	N/D
Prioridade do problema	self	String	N/D
	statusColor	String	N/D
	description	String	N/D
	iconUrl	String	N/D
	name	String	N/D
	id	String	N/D
	isDefault	Booleano	N/D
Resoluções do problema	self	String	N/D
	id	String	N/D
	description	String	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	name	String	N/D
Esquema de segurança de problemas	self	String	N/D
	id	Inteiro	N/D
	name	String	N/D
	description	String	N/D
	defaultSecurityLevelId	Inteiro	N/D
	níveis	Listar	N/D
Tipo de problema	self	String	N/D
	id	String	N/D
	description	String	N/D
	iconUrl	String	N/D
	name	String	N/D
	subtarefa	Booleano	N/D
	avatarId	Inteiro	N/D
	entityId	String	N/D
	hierarchyLevel	Inteiro	N/D
	scope	struct	N/D
Esquema do tipo de problema	orderBy	String	"="
	expandir	String	"="
	queryString	String	"="

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	id	String	N/D
	name	String	N/D
	description	String	N/D
	defaultIssueTypeId	String	N/D
	isDefault	Booleano	N/D
Esquema de tela do tipo de problema	queryString	String	"="
	orderBy	String	"="
	expandir	String	"="
	id	String	"="
	name	String	N/D
	description	String	N/D
Configurações do Jira	chave	String	N/D
	keyFilter	String	"="
	id	String	N/D
	valor	String	N/D
	name	String	N/D
	desc	String	N/D
	tipo	String	N/D
	defaultValue	String	N/D
	exemplo	String	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	allowedValues	Listar	N/D
Configurações avançadas do Jira	id	String	N/D
	chave	String	N/D
	valor	String	N/D
	name	String	N/D
	desc	String	N/D
	tipo	String	N/D
	defaultValue	String	N/D
	exemplo	String	N/D
	allowedValues	Listar	N/D
Configurações globais do Jira	votingEnabled	Booleano	N/D
	watchingEnabled	Booleano	N/D
	unassignedIssuesAllowed	Booleano	N/D
	subTasksEnabled	Booleano	N/D
	issueLinkingEnabled	Booleano	N/D
	timeTrackingEnabled	Booleano	N/D
	attachmentsEnabled	Booleano	N/D
	timeTrackingConfiguration	struct	N/D
Rótulo	values	Listar	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
Eu mesmo(a)	expandir	String	"="
	self	String	N/D
	accountId	String	N/D
	accountType	String	N/D
	emailAddress	String	N/D
	avatarUrls	String	N/D
	Nome de exibição	String	N/D
	active	Booleano	N/D
	timeZone	String	N/D
	locale	String	N/D
	groups	struct	N/D
	applicationRoles	struct	N/D
Permissão	id	String	N/D
	chave	String	N/D
	name	String	N/D
	tipo	String	N/D
	description	String	N/D
	havePermission	Booleano	N/D
	deprecatedKey	Booleano	N/D
Projeto	orderBy	String	"="

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	keys	Listar	"="
	consulta	String	"="
	typeKey	String	"="
	categoryId	Inteiro	"="
	ação	String	"="
	expandir	String	"="
	status	Listar	"="
	self	String	N/D
	id	Inteiro	"="
	chave	String	N/D
	description	String	N/D
	lead	struct	N/D
	Componentes	Listar	N/D
	issueTypes	Listar	N/D
	url	String	N/D
	email	String	N/D
	assigneeType	String	N/D
	versões	Listar	N/D
	name	String	N/D
	funções	struct	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	avatarUrls	struct	N/D
	projectCategory	struct	N/D
	projectTypeKey	String	N/D
	simplified	Booleano	N/D
	estilo	String	N/D
	favorito	Booleano	N/D
	isPrivate	Booleano	N/D
	issueTypeHierarchy	struct	N/D
	permissões	struct	N/D
	propriedades	Listar	"="
	uuid	String	N/D
	insight	struct	N/D
	deleted	Booleano	N/D
	retentionTillDate	String	N/D
	deletedDate	String	N/D
	deletedBy	struct	N/D
	archived	Booleano	N/D
	archivedDate	String	N/D
	archivedBy	struct	N/D
	landedPageInfo	struct	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
Categoria do projeto	self	String	N/D
	id	String	N/D
	name	String	N/D
	description	String	N/D
Tipo de projeto	chave	String	N/D
	formattedKey	String	N/D
	description	String	N/D
	descriptionI18nKey	String	N/D
	icon	String	N/D
	color	String	N/D
Informações do servidor	baseUrl	String	N/D
	versão	String	N/D
	versionNumbers	Listar	N/D
	deploymentType	String	N/D
	buildNumber	Inteiro	N/D
	buildDate	DateTime	N/D
	serverTime	DateTime	N/D
	scmInfo	String	N/D
	serverTitle	String	N/D
	healthChecks	Listar	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
Usuários	self	String	N/D
	accountId	String	N/D
	accountType	String	N/D
	emailAddress	String	N/D
	avatarUrls	struct	N/D
	Nome de exibição	String	N/D
	active	Booleano	N/D
	timeZone	String	N/D
	locale	String	N/D
	groups	struct	N/D
	applicationRoles	struct	N/D
	expandir	String	N/D
Fluxo de trabalho	workflowName	String	"="
	expandir	String	"="
	queryString	String	"="
	orderBy	String	"="
	isActive	Booleano	"="
	id	struct	N/D
	description	String	N/D
	transições	Listar	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	statuses	Listar	N/D
	isDefault	Booleano	N/D
	esquemas	Listar	N/D
	projetos	Listar	N/D
	hasDraftWorkflow	Booleano	N/D
	operações	struct	N/D
	created	String	N/D
	updated	String	N/D
Esquema do fluxo de trabalho	self	String	N/D
	id	Inteiro	N/D
	name	String	N/D
	description	String	N/D
	defaultWorkflow	String	N/D
	issueTypeMappings	struct	N/D
	originalDefaultWorkflow	String	N/D
	originalIssueTypeMappings	struct	N/D
	rascunho	Booleano	N/D
	lastModifiedUser	struct	N/D
	lastModified	String	N/D

Objeto	Campo	Tipo de dados	Operadores de filtro compatíveis
	updateDraftIfNeeded	Booleano	N/D
	issueTypes	struct	N/D
Associação de projetos do esquema do fluxo de trabalho	projectId	Inteiro	"="
	projectIds	Listar	N/D
	workflowScheme	struct	N/D
Status do fluxo de trabalho	self	String	N/D
	description	String	N/D
	iconUrl	String	N/D
	name	String	N/D
	id	String	N/D
	StatusCategory	struct	N/D
Categoria de status do fluxo de trabalho	self	String	N/D
	id	String	N/D
	chave	String	N/D
	colorName	String	N/D
	name	String	N/D

Consultas de particionamento

Você pode fornecer a opção adicional `NUM_PARTITIONS` do Spark se quiser utilizar a simultaneidade no Spark. Com esse parâmetro, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- NUM_PARTITIONS: o número de partições.

Exemplo:

```
jiraCloud_read = glueContext.create_dynamic_frame.from_options(
    connection_type="JiraCloud",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "issue",
        "API_VERSION": "v2",
        "NUM_PARTITIONS": "10"
    }
```

Opções de conexão do Jira Cloud

A seguir estão as opções de conexão para o Jira Cloud:

- ENTITY_NAME(String) - (Obrigatório) Usado para leitura. O nome do seu objeto no Jira Cloud.
- API_VERSION(String) - (Obrigatório) Usado para leitura. APIVersão do Jira Cloud Rest que você deseja usar. Por exemplo: v2.
- DOMAIN_URL(String) - (Obrigatório) O Jira Cloud ID que você deseja usar.
- SELECTED_FIELDS(Lista<String>) - Padrão: vazio (SELECT*). Usado para leitura. Colunas que deseja selecionar para o objeto.
- FILTER_PREDICATE(String): padrão: vazia. Usado para leitura. Ele deve estar no SQL formato Spark.
- QUERY(String): padrão: vazia. Usado para leitura. SQLConsulta completa do Spark.
- NUM_PARTITIONS(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações e notas sobre o conector Jira Cloud

A seguir estão as limitações ou notas do conector do Jira Cloud:

- O Contains operador não funciona com o resourceName campo, que é do tipo de dados String.

Conexão ao Kustomer

O Kustomer é uma poderosa plataforma de experiência do cliente que reúne tudo o que você precisa para atender melhor seus clientes em uma ferramenta fácil de usar.

Tópicos

- Suporte do AWS Glue para o Kustomer
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Kustomer
- Configuração de conexões do Kustomer
- Leitura de entidades do Kustomer
- Opções de conexão do Kustomer
- Limitações do Kustomer

Suporte do AWS Glue para o Kustomer

O AWS Glue oferece suporte ao Kustomer da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Kustomer.

Compatível como destino?

Não.

Versões compatíveis da API do Kustomer

Estas são as versões compatíveis da API do Kustomer:

- v1

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
```

```
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Kustomer

Antes de usar o AWS Glue para transferir dados do Kustomer aos destinos compatíveis, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta no Kustomer que contém os dados que deseja transferir.

- Nas configurações da sua conta, você criou uma chave de API. Para ter mais informações, consulte Criação de uma chave de API.
- Você fornece a chave de API para o AWS Glue ao criar a conexão.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Kustomer.

Criação de uma chave de API

Para criar uma chave de API que você usará para criar uma conexão com o conector do Kustomer no AWS Glue Studio:

1. Faça login no painel do Kustomer usando suas credenciais.
2. No menu à esquerda, escolha o ícone Settings.
3. Expanda o menu suspenso Security e selecione API Keys.
4. Na página de criação da chave de API, selecione Add an API Key no canto superior direito.
5. Preencha as entradas obrigatórias para a chave de API que está sendo criada.
   - Name: qualquer nome para sua chave de API.
   - Roles: a opção “org” deve ser selecionada para que as APIs do Kustomer funcionem.
   - Expires (in days): o número de dias durante o qual você deseja que a chave de API seja válida. Você pode manter como Never expires, se a opção de nunca expirar for adequada para o seu caso de uso.
6. Escolha Criar.
7. Armazene o valor da chave de API (token) para uso posterior na criação de uma conexão com o conector do Kustomer no AWS Glue Studio.

Configuração de conexões do Kustomer

Para configurar uma conexão do Kustomer:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave `apiKey`.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

a. Em Conexões, escolha Criar conexão.

b. Ao selecionar uma Fonte de dados, selecione o Kustomer.

c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Kustomer

Pré-requisito

Um objeto do Kustomer do qual você deseja ler. Você precisará do nome do objeto, como Marcas ou Cartões. A tabela a seguir mostra as entidades compatíveis.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Marcas	Não	Sim	Não	Sim	Não
Cartões	Não	Sim	Não	Sim	Não
Configura ções de chat	Não	Não	Não	Sim	Não
Empresas	Sim	Sim	Sim	Sim	Sim
Conversas	Sim	Sim	Sim	Sim	Sim
Clientes	Sim	Sim	Sim	Sim	Sim
Pesquisas de clientes fixadas	Não	Sim	Não	Sim	Não
Posição das pesquisas de clientes	Não	Não	Não	Sim	Não
Hooks de e-mail	Não	Sim	Não	Sim	Não
Webhooks	Não	Sim	Não	Sim	Não
Artigos da base de conhecime nto	Não	Sim	Não	Sim	Não
Categorias da base de	Não	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
conhecime nto					
Formulários da base de conhecime nto	Não	Sim	Não	Sim	Não
Rotas da base de conhecime nto	Não	Sim	Não	Sim	Não
Tags da base de conhecime nto	Não	Sim	Não	Sim	Não
Modelos da base de conhecime nto	Não	Sim	Não	Sim	Não
Temas da base de conhecime nto	Não	Sim	Não	Sim	Não
Klasses	Não	Sim	Não	Sim	Não
KViews	Não	Sim	Não	Sim	Não
Mensagens	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Observações	Sim	Sim	Sim	Sim	Sim
Notificações	Não	Sim	Não	Sim	Não

Exemplo:

```
Kustomer_read = glueContext.create_dynamic_frame.from_options(
    connection_type="kustomer",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "brands",
        "API_VERSION": "v1"
    }
```

Detalhes das entidades e dos campos do Kustomer

Para obter mais informações sobre os detalhes das entidades e dos campos, consulte:

- Marcas
- Cartões
- Configurações de chat
- Empresas
- Conversas
- Clientes
- Pesquisas de clientes fixadas
- Posições das pesquisas de clientes
- Hooks de e-mail
- Webhooks
- Artigos da base de conhecimento
- Categorias da base de conhecimento
- Formulários da base de conhecimento

- Rotas da base de conhecimento
- Tags da base de conhecimento
- Modelos da base de conhecimento
- Temas da base de conhecimento
- Klasses
- Kviews
- Mensagens
- Observações
- Notificações

API do Kustomer v1

Entidade	Campo	Tipo de dados	Operadores compatíveis
Marcas	id	String	N/D
	nome	String	N/D
	iconUrl	String	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	padrão	Booliano	N/D
Cartões	id	String	N/D
	nome	String	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	description	String	N/D
	url	String	N/D
	contexts	Lista	N/D
Configurações de chat	id	String	N/D
	settingsVersion	Inteiro	N/D
	widgetType	String	N/D
	version	Inteiro	N/D
	teamName	String	N/D
	greeting	String	N/D
	autoreply	String	N/D
	embedIconUrl	String	N/D
	embedIconColor	String	N/D
	fallbackEmailSubject	String	N/D
	fallbackEmailIntroduction	String	N/D
	enabled	Booliano	N/D
	outboundChatEnabled	Booliano	N/D
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	offhoursMessage	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	offhoursImageUrl	String	N/D
	closableChat	Booliano	N/D
	noHistory	Booliano	N/D
	disableAttachments	Booliano	N/D
	volumeControl	Struct	N/D
	singleSessonChat	Booliano	N/D
	showTypingIndicatorWeb	Booliano	N/D
Empresas	id	String	N/D
	nome	String	=, !=, CONTAINS
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	tags	Lista	N/D
	domínios	Lista	N/D
	emails	Lista	N/D
	phones	Lista	N/D
	whatsapps	Lista	N/D
	socials	Lista	N/D
	urls	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	locais	Lista	N/D
	roleGroupVersions	Lista	N/D
	rev	Inteiro	N/D
Conversas	id	String	N/D
	nome	String	=, !=, CONTAINS
	preview	String	N/D
	canais	Lista	N/D
	status	String	=, !=, CONTAINS
	messageCount	Inteiro	=, !=, >, >=, <, <=
	snoteCount	Inteiro	=, !=, >, >=, <, <=
	satisfaction	Inteiro	=, !=, >, >=, <, <=
	satisfactionLevel	Struct	N/D
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	lastActivityAt	DateTime	N/D
	spam	Booliano	N/D
	ended	Booliano	=, !=

Entidade	Campo	Tipo de dados	Operadores compatíveis
	endedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	endedReason	String	CONTAINS
	endedByType	String	N/D
	importedAt	String	N/D
	tags	Lista	N/D
	suggestedTags	Lista	N/D
	sentimento	String	N/D
	predições	Lista	N/D
	suggestedShortcuts	Lista	N/D
	firstMessageIn	Struct	N/D
	firstMessageOut	Struct	N/D
	lastMessageIn	Struct	N/D
	lastMessageOut	Struct	N/D
	lastMessageAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	lastMessageUnrespondedTo	Struct	N/D
	lastMessageUnrespondedToSinceLastDone	Struct	N/D
	assignedUsers	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	assignedTeams	Lista	N/D
	firstResponse	Struct	N/D
	firstResponseSince LastDone	Struct	N/D
	lastResponse	Struct	N/D
	firstDone	Struct	N/D
	lastDone	Struct	N/D
	direction	String	=, !=, CONTAINS
	lastMessageDirection	String	N/D
	outboundM essageCount	Inteiro	N/D
	inboundMe ssageCount	Inteiro	N/D
	rev	Inteiro	N/D
	priority	Inteiro	=, !=, >, >=, <, <=
	roleGroupVersions	Lista	N/D
	accessOverride	Lista	N/D
	assistente	Struct	N/D
	phase	String	N/D
	Habilidades	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	matchedTimeBasedRules	Lista	N/D
Clientes	id	String	N/D
	nome	String	=, !=, CONTAINS
	Nome de exibição	String	N/D
	displayColor	String	N/D
	displayIcon	String	N/D
	externalId	String	=, !=, CONTAINS
	externalIds	Lista	N/D
	sharedExternalIds	Lista	N/D
	emails	Lista	N/D
	sharedEmails	Lista	N/D
	phones	Lista	N/D
	sharedPhones	Lista	N/D
	whatsapps	Lista	N/D
	facebookIds	Lista	N/D
	instagramIds	Lista	N/D
	socials	Lista	N/D
	sharedSocials	Lista	N/D
	urls	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	locais	Lista	N/D
	activeUsers	Lista	N/D
	observadores	Lista	N/D
	recentLocation	Struct	N/D
	locale	String	=, !=, CONTAINS
	timeZone	String	N/D
	gender	String	=, !=, CONTAINS
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	lastActivityAt	DateTime	N/D
	deleted	Booliano	N/D
	lastConversation	Struct	N/D
	conversationCounts	Struct	N/D
	preview	Struct	N/D
	tags	Lista	N/D
	progressiveStatus	String	=, !=, CONTAINS
	verified	Booliano	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	rev	Inteiro	N/D
	recentItems	Lista	N/D
	defaultLang	String	=, !=, CONTAINS
	satisfactionLevel	Struct	N/D
	roleGroupVersions	Lista	N/D
	accessOverride	Lista	N/D
	companyName	String	N/D
	firstName	String	N/D
	lastName	String	N/D
Pesquisas de clientes fixadas	id	String	N/D
	pesquisar	String	N/D
	createdAt	DateTime	N/D
Posições das pesquisas de clientes	id	String	N/D
	posições	Lista	N/D
	children	Lista	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	rev	Inteiro	N/D
Hooks de e-mail	id	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	description	String	N/D
	depurar	Booliano	N/D
	email	String	N/D
	eventName	String	N/D
	título	String	N/D
	hash	String	N/D
	key	String	N/D
	createdAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	updatedAt	DateTime	N/D
Webhooks	id	String	N/D
	description	String	N/D
	eventName	String	N/D
	hash	String	N/D
	url	String	N/D
	createdAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	updatedAt	DateTime	N/D
	título	String	N/D
	version	Inteiro	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	depurar	Booliano	N/D
Artigos da base de conhecimento	id	String	N/D
	hash	String	N/D
	título	String	N/D
	origem	String	N/D
	status	String	N/D
	scope	String	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	deleted	Booliano	N/D
	deletedAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	publishedAt	DateTime	N/D
	tags	Lista	N/D
	categories	Lista	N/D
	knowledgeBases	Lista	N/D
	metaTitle	String	N/D
	metaDescription	String	N/D
	metaKeywords	Lista	N/D
	langVersions	Struct	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	latestLangs	Struct	N/D
Categorias da base de conhecimento	id	String	N/D
	hash	String	N/D
	createdAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	updatedAt	DateTime	N/D
	published	Booliano	N/D
	posições	Lista	N/D
	categoryPositions	Lista	N/D
	raiz	Booliano	N/D
	langs	Struct	N/D
Formulários da base de conhecimento	id	String	N/D
	nome	String	N/D
	slug	String	N/D
	hash	String	N/D
	body	String	N/D
	layout	Lista	N/D
	layoutV2	Lista	N/D
	componentsV2	Struct	N/D
	condições	Struct	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	advanced	Booliano	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	publishedAt	DateTime	N/D
	modifiedAt	String	N/D
	published	Booliano	N/D
	snippets	Lista	N/D
	recaptcha	Booliano	N/D
	klass	String	N/D
	channel	String	N/D
	deflection	Booliano	N/D
	formHookEnabled	Booliano	N/D
	replyFrom	String	N/D
	wcag	Booliano	N/D
Rotas da base de conhecimento	id	String	N/D
	url	String	N/D
	routableType	String	N/D
	routableId	String	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	modifiedAt	DateTime	N/D
Tags da base de conhecimento	id	String	N/D
	nome	String	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	N/D
Modelos da base de conhecimento	id	String	N/D
	título	String	N/D
	description	String	N/D
	beta	Booliano	N/D
	manifesto	Struct	N/D
	jsxSnippets	Lista	N/D
	imagens	Lista	N/D
	version	String	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
Temas da base de conhecimento	id	String	N/D
	nome	String	N/D
	active	Booliano	N/D
	padrão	Booliano	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	lastfileUpdatedAt	DateTime	N/D
	personalizado	Booliano	N/D
	status	String	N/D
	templateVersionId	String	N/D
	templateTitle	String	N/D
	templateVersion	String	N/D
	manifesto	Struct	N/D
	configSnippets	Lista	N/D
	jsxSnippets	Lista	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	rev	Inteiro	N/D
Klasses	id	String	N/D
	nome	String	N/D
	icon	String	N/D
	color	String	N/D
	appDisabled	Booliano	N/D
	status	String	N/D
	updatedAt	DateTime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	createdAt	DateTime	N/D
	s3DataUrl	String	N/D
KViews	id	String	N/D
	recurso	String	N/D
	modelo	String	N/D
	context	String	N/D
	meta	Struct	N/D
	appDisabled	Booliano	N/D
	enabled	Booliano	N/D
	advanced	Booliano	N/D
	layout	Lista	N/D
	Componentes	Struct	N/D
	condições	Struct	N/D
	rev	Inteiro	N/D
	createdAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	updatedAt	DateTime	N/D
Notificações	id	String	N/D
	nome	String	N/D
	status	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	event	Struct	N/D
	createdAt	DateTime	N/D
	updatedAt	DateTime	N/D
Mensagens	id	String	N/D
	externalId	String	N/D
	channel	String	=, !=, CONTAINS
	aplicação	String	N/D
	size	Inteiro	=, !=, >, >=, <, <=
	direction	String	=, !=, CONTAINS
	preview	String	N/D
	subject	String	N/D
	meta	Struct	N/D
	status	String	=, !=, CONTAINS
	directionType	String	=, !=, CONTAINS
	assignedTeams	Lista	N/D
	assignedUsers	Lista	N/D
	errorAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	auto	Booliano	=, !=
	sentAt	DateTime	=, !=, <, <=, >, >=, BETWEEN

Entidade	Campo	Tipo de dados	Operadores compatíveis
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	N/D
	modifiedAt	DateTime	N/D
	redacted	Booliano	N/D
	createdByTeams	Lista	N/D
	rev	Inteiro	N/D
	reações	Lista	N/D
	intentDetections	Lista	N/D
Observações	id	String	N/D
	body	String	CONTAINS
	createdAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	updatedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	modifiedAt	DateTime	=, !=, <, <=, >, >=, BETWEEN
	createdByTeams	Lista	N/D

Particionamento de consultas

Particionamento com base em campo

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses

parâmetros, a consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo DateTime, aceitamos o valor no formato ISO.

  Exemplo de valor válido:

  ```
  "2023-01-15T11:18:39.205Z"
  ```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na seguinte tabela:

Nome da entidade	Campos de particionamento	Tipo de dados
Empresas	modifiedAt	DateTime
Conversas	createdAt, updatedAt , modifiedAt, endedAt, lastMessageAt	DateTime
	messageCount, noteCount	BigInteger
	priority	Inteiro
Clientes	createdAt, updatedAt, modifiedAt	DateTime
Mensagens	errorAt, sentAt, createdAt	DateTime
	size	BigInteger
Observações	createdAt, updatedAt, modifiedAt	DateTime

Exemplo: .

```
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"
    }
```

Opções de conexão do Kustomer

Estas são as opções de conexão do Kustomer:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Kustomer.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Kustomer que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL` (String): (obrigatório) usado para leitura. URL de instância do Kustomer.

Limitações do Kustomer

Estas são as limitações ou observações do Kustomer:

- Não há suporte para a entidade `Customer Searches`, pois a documentação da API do Kustomer não declarou nenhum endpoint para ela.
- A entidade `Klasses` não oferece suporte à filtragem e à transferência incremental.
- O suporte ao recurso de ordenação está disponível para vários campos aplicáveis em uma única solicitação.

  No entanto, observou-se que essa funcionalidade de ordenação em vários campos apresenta um comportamento inconsistente por parte do SaaS para algumas combinações. Ele é imprevisível, uma vez que pode haver “n” combinações que talvez mostrem resultados de ordenação incorretos. Por exemplo:

  Para a entidade `Customers`, ordenar por `progressiveStatus desc, name asc` não produz o resultado ordenado correto. Ele classifica apenas com base na ordem `progressiveStatus`. Se esse comportamento for observado, você pode usar um único campo para fazer a ordenação.
- Apenas as entidades `Conversations` e `Messages` oferecem suporte à ordenação no campo “id” como um parâmetro de consulta. Por exemplo: https://api.kustomerapp.com/v1/conversations?sort=desc (classifica os resultados por “id” em ordem decrescente)

  Além disso, qualquer outro filtro ou ordenação em qualquer outro campo é traduzido em um corpo de solicitação POST com o endpoint da API como POST https://api.kustomerapp.com/v1/customers/search Para permitir o suporte à ordenação por “id” em `Conversations` e `Messages`, somente a ordenação por id deve estar presente ou qualquer outro filtro e/ou ordenação em outro campo aplicável.
- O Kustomer permite a busca de, no máximo, 10 mil registros, independentemente de a solicitação ser filtrada ou não filtrada. Devido a essa limitação, haverá uma perda de dados para qualquer entidade que tiver mais de 10 mil registros. Existem duas soluções alternativas possíveis que você pode executar para mitigar essa limitação parcialmente:
  - Aplique filtros para buscar um conjunto específico de registros.
  - Se houver mais de 10 mil registros com um filtro aplicado, aplique um valor de filtro sucessivo em uma nova solicitação subsequente ou aplique intervalos nos filtros. Por exemplo:

    filterExpression da 1.ª solicitação: `modifiedAt >= 2022-03-15T05:26:23.000Z and modifiedAt < 2023-03-15T05:26:23.000Z`

    Suponha que isso esgote o limite de 10 mil registros.

Outra solicitação pode ser acionada com filterExpression: `modifiedAt >= 2023-03-15T05:26:23.000Z`

- Como um comportamento de SaaS, o operador `CONTAINS` no Kustomer oferece suporte à correspondência somente para palavras completas, e não a correspondências parciais de uma palavra. Por exemplo: “body CONTAINS 'test record'” fará a correspondência a um registro que tenha “test” no campo “body”. No entanto, “body CONTAINS 'test'” não fará a correspondência a um registro que tenha “testAnotherRecord” no campo “body”.

Conexão com o LinkedIn

O LinkedIn é uma ferramenta de marketing paga que oferece acesso às redes sociais do LinkedIn por meio de várias postagens patrocinadas e outros métodos. O LinkedIn é uma poderosa ferramenta de marketing para empresas B2B gerarem leads, obterem reconhecimento online, compartilharem conteúdo e muito mais.

Tópicos

- Suporte do AWS Glue para o LinkedIn
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do LinkedIn
- Configuração de conexões do LinkedIn
- Leitura de entidades do LinkedIn
- Opções de conexão do LinkedIn
- Criação de uma conta do LinkedIn
- Limitações

Suporte do AWS Glue para o LinkedIn

O AWS Glue oferece suporte ao LinkedIn da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do LinkedIn.

Compatível como destino?

Nº

Versões da API do LinkedIn com suporte

202406 (junho de 2024)

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do LinkedIn

Antes de poder usar o AWS Glue para transferir dados do LinkedIn, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do LinkedIn. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do LinkedIn.
- A conta do LinkedIn precisa estar habilitada para acesso à API.
- Você criou uma integração com a `OAuth2 API` na sua conta do LinkedIn. Essa integração fornece as credenciais de cliente que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para ter mais informações, consulte the section called "Criação de uma conta do LinkedIn".

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do LinkedIn. Para conexões típicas, você não precisa fazer mais nada no LinkedIn.

Configuração de conexões do LinkedIn

O LinkedIn oferece suporte ao tipo de concessão `AUTHORIZATION_CODE` para OAuth2.

Esse tipo de concessão é considerado um `OAuth` de "três pernas", pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Os usuários podem optar por criar a própria aplicação conectada no LinkedIn e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o LinkedIn para fazer login e autorizar o acesso do AWS Glue aos seus recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso expira 60 dias após a criação. Um novo token de acesso pode ser obtido usando o token de atualização.

Para obter a documentação pública do LinkedIn sobre como criar uma aplicação conectada para o fluxo de `Authorization Code OAuth`, consulte Fluxo de código de autorização (OAuth de 3 pernas).

Configuração de uma conexão do LinkedIn

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

- Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
- Para uma aplicação conectada gerenciada pela AWS, um segredo vazio ou um segredo com algum valor temporário.

> **Note**
>
> É preciso criar um segredo por conexão em AWS Glue.

2. No AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

   1. Ao selecionar um Tipo de conexão, escolha LinkedIn.
   2. Forneça o ambiente do LinkedIn.
   3. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   4. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   5. Selecione as Opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do LinkedIn

Pré-requisitos

Um objeto do LinkedIn do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Contas de anúncios	Sim	Sim	Sim	Sim	Não
Campanhas	Sim	Sim	Sim	Sim	Não
Grupos de campanhas	Sim	Sim	Sim	Sim	Não
Criativos	Sim	Sim	Sim	Sim	Não
Análise de anúncios	Sim	Não	Não	Sim	Não
Análise de anúncios, todas as contas de anúncios	Sim	Não	Não	Sim	Não
Análise de anúncios,	Sim	Não	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
todas as campanhas					
Análise de anúncios, todos os grupos de campanhas	Sim	Não	Não	Sim	Não
Análise de anúncios, todos os criativos de anúncios	Sim	Não	Não	Sim	Não
Estatísticas de compartil hamentos	Sim	Não	Não	Sim	Não
Estatísticas de páginas	Sim	Não	Não	Sim	Não
Estatísticas de seguidore s	Sim	Não	Não	Sim	Não

Exemplo

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="linkedin",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "adaccounts",
        "API_VERSION": "202406"
```

```
    }
)
```

Detalhes de entidade e campo do LinkedIn

Tipos de dados de campo	Operadores de filtro com suporte
String	=
DateTime	BETWEEN, =
Numérico	=
Booleano	=

Opções de conexão do LinkedIn

Estas são as opções de conexão do LinkedIn:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no LinkedIn. Por exemplo, adAccounts.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do LinkedIn que você deseja usar. O valor será 202406, pois o LinkedIn atualmente só oferece suporte à versão 202406.
- `SELECTED_FIELDS`(lista<string>): padrão: vazio (SELECT *). Usado para leitura. Colunas que você deseja selecionar para a entidade selecionada.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

Criação de uma conta do LinkedIn

Criação de uma aplicação do LinkedIn e credenciais OAuth

1. Navegue até a página da Rede de desenvolvedores do LinkedIn e faça login com as credenciais da sua conta do LinkedIn.
2. Navegue até a página Minhas aplicações e escolha Criar aplicação para criar uma nova aplicação do LinkedIn.

3. Insira os detalhes a seguir no formulário de registro da aplicação:

   - Nome da empresa: selecione uma empresa existente ou crie uma nova empresa.
   - Nome: insira o nome da aplicação.
   - Descrição: insira a descrição da aplicação.
   - Logotipo da aplicação: selecione um arquivo de imagem como logotipo da aplicação.
   - Uso da aplicação: selecione o uso da sua aplicação.
   - URL do site: insira o URL do site que contém informações detalhadas sobre sua aplicação.
   - E-mail comercial: insira seu endereço de e-mail comercial.
   - Telefone comercial: insira seu número de telefone comercial.
   - Termos de uso da API do LinkedIn: leia e concorde.
4. Após preencher o formulário de registro da aplicação, escolha Enviar.

   Você será redirecionado para a página de Autenticação, onde as Chaves de autenticação (ID do cliente e segredo do cliente) e outros detalhes relevantes serão exibidos.
5. Se sua aplicação da Web exigir acesso ao endereço de e-mail do usuário em sua conta do LinkedIn, selecione a permissão `r_emailaddress`. Além disso, é possível especificar URLs de redirecionamento autorizados para sua aplicação do LinkedIn.

Criação de uma página na conta do LinkedIn

1. Navegue até Produtos para desenvolvedores do LinkedIn.
2. No canto superior direito da página Produtos de desenvolvedores do LinkedIn, selecione Minhas aplicações.
3. No canto superior direito da página Minhas aplicações, selecione Criar aplicação.
4. Na página Criar uma aplicação, insira o nome da sua aplicação no campo Nome da aplicação.
5. No campo Página do LinkedIn, insira o nome ou URL da página da sua empresa.

   > **Note**
   >
   > Se você não tiver uma página do LinkedIn, poderá criar uma selecionando Criar um novo LinkedIn.
6. No campo URL da política de privacidade, insira o URL da sua política de privacidade.

7. Escolha Carregar um logotipo para fazer upload de uma imagem que será exibida aos usuários quando eles autorizarem sua aplicação.
8. Na seção Contrato legal, selecione Eu li e concordei com estes termos.
9. Escolha Criar aplicação.

   Sua nova aplicação será criada e estará disponível na guia Minhas aplicações.

Publicação de anúncios de campanha no LinkedIn

1. Faça login no Gerenciador de campanhas.
2. Selecione um Grupo de campanha existente, ou escolha Criar para criar um novo.
3. Selecione seu objetivo.
4. Selecione seu grupo, orçamento e cronograma.
5. Crie seu público-alvo.
6. Selecione o formato do seu anúncio.
7. Selecione seu orçamento e cronograma.
8. Configure seu(s) anúncio(s).
9. Analise e execute

Limitações

Para os campos do Analytics `ad_analytics_all_adAccounts`, `ad_analytics_all_campaigns`, `ad_analytics_all_campaign_groups` e `ad_analytics_all_adCreatives`, um filtro é obrigatório para recuperar os registros.

Conexão ao Mailchimp

O Mailchimp é uma plataforma de marketing completa que ajuda você a gerenciar e conversar com seus clientes e outras partes interessadas. Sua abordagem ao marketing se concentra em práticas íntegras para o gerenciamento de contatos, e-mails bem projetados, fluxos de trabalho automatizados exclusivos e uma análise avançada dos dados. Se você usa o Mailchimp, pode conectar o AWS Glue à conta do Mailchimp. Em seguida, será possível usar o Mailchimp como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Mailchimp e serviços da AWS ou outras aplicações compatíveis.

Tópicos

- Suporte do AWS Glue para o Mailchimp
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Mailchimp
- Configuração de conexões do Mailchimp
- Leitura de entidades do Mailchimp
- Opções de conexão do Mailchimp
- Criação de uma conta do Mailchimp
- Limitações

Suporte do AWS Glue para o Mailchimp

O AWS Glue oferece suporte ao Mailchimp da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Mailchimp.

Compatível como destino?

Não.

Versões compatíveis da API do Mailchimp

3.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
```

```
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Mailchimp

Antes de usar o AWS Glue para transferir do Mailchimp, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Mailchimp com e-mail e senha. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Mailchimp.
- Você deve ter uma conta da AWS criada com acesso de serviço ao AWS Glue.
- Certifique-se de ter criado um dos recursos a seguir. Esses recursos fornecem as credenciais que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta.
  - Uma aplicação de desenvolvedor que ofereça suporte à autenticação OAuth 2.0. Para obter mais informações sobre como criar uma aplicação de desenvolvedor, consulte Criação de uma conta do Mailchimp.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Mailchimp. Para conexões típicas, você não precisa fazer mais nada no Mailchimp.

Configuração de conexões do Mailchimp

O Mailchimp oferece suporte aos dois tipos seguintes de mecanismo de autenticação:

- O Mailchimp oferece suporte ao tipo de concessão `AUTHORIZATION_CODE`.
  - Esse tipo de concessão é considerado um `OAuth` de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O usuário que está criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao AWS Glue, na qual ele não precisa fornecer quaisquer informações relacionadas ao `OAuth`, exceto o ID e segredo do cliente do Mailchimp. O Console do AWS Glue redirecionará o usuário para o Mailchimp, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Mailchimp.
  - Os usuários ainda podem optar por criar sua própria aplicação conectada no Mailchimp e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Mailchimp para fazer login e autorizar o acesso do AWS Glue aos recursos.
  - Para obter a documentação pública do Mailchimp sobre como criar uma aplicação conectada para o fluxo `AUTHORIZATION_CODE OAuth`, consulte Access Data on Behalf of Other Users with OAuth 2.
- Autenticação personalizada: para obter a documentação pública do Mailchimp sobre como gerar as chaves de API necessárias para a autorização personalizada, consulte About API Keys.

Para configurar uma conexão do Mailchimp:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   - Autenticação`OAuth`: para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   - Autenticação personalizada: para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave “api_key”.

> **Note**
>
> É preciso criar um segredo por conexão em AWS Glue.

2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Em Conexões, selecione Criar conexão.
   b. Ao selecionar uma Fonte de dados, selecione o Mailchimp.
   c. Forneça o `instanceUrl` do Mailchimp.
   d. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
    "Version": "2012-10-17",
        "Statement": [
            {
                "Effect": "Allow",
                "Action": [
                    "secretsmanager:DescribeSecret",
                    "secretsmanager:GetSecretValue",
                    "secretsmanager:PutSecretValue",
                    "ec2:CreateNetworkInterface",
                    "ec2:DescribeNetworkInterface",
                    "ec2:DeleteNetworkInterface",
                ],
                "Resource": "*"
            }
        ]
    }
```

   e. Selecione o tipo de autenticação para se conectar ao Mailchimp:
      - Para a autenticação `0Auth`: forneça o URL do token e o ClientId da aplicação cliente gerenciada pelo usuário do Mailchimp ao qual deseja se conectar.
      - Para a autenticação personalizada: selecione o tipo de autenticação PERSONALIZADA para se conectar ao Mailchimp.
   f. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   g. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma conexão de rede adicional.

Leitura de entidades do Mailchimp

Pré-requisitos

Um objeto do Mailchimp do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

- Relatórios de abuso
- Automação
- Campanhas
- Detalhes de cliques
- Listas
- Membros
- Detalhes de abertura
- Segmentos
- Lojas
- Cancelamentos de assinaturas

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Automação	Sim	Sim	Sim	Sim	Sim
Campanhas	Não	Não	Não	Não	Não
Listas	Sim	Sim	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Relatórios de abusos	Não	Sim	Não	Sim	Sim
Relatórios de aberturas	Não	Sim	Não	Sim	Sim
Relatórios de cliques	Sim	Sim	Não	Sim	Sim
Relatórios de cancelame ntos de assinaturas	Não	Sim	Não	Sim	Sim
Segment	Não	Sim	Não	Sim	Sim
Membros do segmento	Sim	Sim	Não	Sim	Não
Lojas	Sim	Sim	Sim	Sim	Não

Exemplo

```
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"
               })
```

Detalhes das entidades e dos campos do Mailchimp

- Relatórios de abuso
- Automação
- Campanhas
- Detalhes de cliques
- Listas
- Membros
- Detalhes de abertura
- Segmentos
- Lojas
- Cancelamentos de assinaturas

Consultas de particionamento

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo DateTime, aceitamos o valor no formato ISO.

  Exemplo de valor válido:

  ```
  "2024-07-01T00:00:00.000Z"
  ```

- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: o número de partições.

A tabela a seguir descreve os detalhes do suporte do campo de particionamento da entidade:

Nome da entidade	Campos de particionamento	Tipo de dados

Exemplo: .

```
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"
    }
```

Opções de conexão do Mailchimp

Estas são as opções de conexão do Mailchimp:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Mailchimp.
- `INSTANCE_URL`(string): (obrigatório) um URL de instância válida do Mailchimp.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Mailchimp Engage que você deseja usar. Por exemplo: 3.0.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.

- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Criação de uma conta do Mailchimp

1. Navegue até a página de login do Mailchimp, insira seu ID de e-mail e senha e escolha Sign up.
2. Abra o e-mail de confirmação do Mailchimp e escolha o link de confirmação para verificar sua conta.

   > **Note**
   >
   > O tempo necessário para receber o e-mail de ativação pode variar. Se você não recebeu o e-mail de ativação, verifique sua pasta de spam e leia nossas dicas para a solução de problemas do e-mail de ativação. O Mailchimp bloqueia inscrições de endereços de e-mail baseados em perfis, como admin@pottedplanter.com ou security@example.com.

   Na primeira vez que você fizer login na sua conta, o Mailchimp solicitará as informações necessárias. O Mailchimp usa essas informações para ajudar a garantir que sua conta esteja em conformidade com os Termos de uso e para fornecer orientações relevantes a você, de acordo com as necessidades da sua empresa.
3. Insira suas informações, siga as instruções para concluir o processo de ativação e comece a usar sua nova conta do Mailchimp.

Registro de uma aplicação **`OAuth2.0`**

1. Navegue até a página de login do Mailchimp, insira seu ID de e-mail e senha e escolha Log in.
2. Selecione o ícone User no canto superior direito e escolha Account and billing no menu suspenso.
3. Selecione Extras e escolha Registered apps no menu suspenso.
4. Localize e escolha Register An App.
5. Insira os detalhes a seguir:

- App name: o nome da aplicação.
- Company/Organization: o nome da sua empresa ou organização.
- App website: o site da aplicação.
- Redirect URI: um padrão de URI de redirecionamento é um caminho de URI (ou uma lista de caminhos separados por vírgula) para o qual o Mailchimp pode redirecionar (se solicitado) quando o fluxo de login for concluído. Por exemplo, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`

6. Escolha Criar.
7. O ID do cliente e o Segredo do cliente agora estarão visíveis. Copie e salve-os em um lugar seguro. Escolha Concluído.

> **Note**
>
> Suas strings de ID do cliente e Segredo do cliente são credenciais usadas para estabelecer uma conexão com esse conector ao usar o AppFlow ou o AWS Glue.

Geração de uma chave de API

1. Navegue até a página de login do Mailchimp, insira seu ID de e-mail e senha e escolha Log in.
2. Selecione o ícone User no canto superior direito e escolha Account and billing no menu suspenso.
3. Selecione Extras e escolha API keys no menu suspenso.
4. Escolha Create A Key.
5. Insira um nome e escolha Generate Key.

   A próxima página exibe a chave de API gerada.
6. Copie sua chave, guarde-a com segurança e escolha Done.

Limitações

Estas são as limitações do conector do Mailchimp:

- Apenas as entidades `Campaigns`, `Automations`, `Lists`, `Open Details`, `Members` e `Segments` oferecem suporte à filtragem.

- Ao usar um filtro no campo de tipo de dados `DateTime`, você deve passar valores neste formato: `yyyy-mm-ddThh:MM:ssZ`

Conexão ao Microsoft Teams

O Microsoft Teams é um espaço de trabalho colaborativo no Microsoft 365 que atua como um hub central para conversas no local de trabalho, colaboração entre as equipes, chats por vídeo e compartilhamento de documentos, tudo projetado para melhorar a produtividade dos funcionários com um conjunto unificado de ferramentas.

Tópicos

- Suporte do AWS Glue para o Microsoft Teams
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Microsoft Teams
- Configuração de conexões do Microsoft Teams
- Leitura de entidades do Microsoft Teams
- Referência de opções de conexão do Microsoft Teams
- Limitações
- Crie uma nova conta do Microsoft Teams:

Suporte do AWS Glue para o Microsoft Teams

O AWS Glue oferece suporte ao Microsoft Teams da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Microsoft Teams.

Compatível como destino?

Não.

Versões compatíveis da API do Microsoft Teams

v1. Para conferir o suporte de entidades por versão específica, consulte Entidades compatíveis para a fonte.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Microsoft Teams

Antes de usar o AWS Glue para transferir dados do Microsoft Teams, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta de desenvolvedor do Microsoft Teams com e-mail e senha. Para ter mais informações, consulte Crie uma nova conta do Microsoft Teams:.
- Você deve ter uma aplicação OAuth2 configurada na sua conta Microsoft que forneça o ID do cliente e as credenciais secretas que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para ter mais informações, consulte Crie uma nova conta do Microsoft Teams:.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Microsoft Teams. Para conexões típicas, você não precisa fazer mais nada no Microsoft Teams.

Configuração de conexões do Microsoft Teams

O Microsoft Teams oferece suporte aos dois tipos seguintes de mecanismo de autenticação:

1. Autenticação OAuth: o Microsoft Teams oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2.
   - Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O usuário que está criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao AWS Glue, na qual ele não precisa fornecer quaisquer informações relacionadas ao OAuth, exceto o instanceurl do Microsoft Teams. O Console do AWS Glue redirecionará o usuário para o Microsoft Teams, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Microsoft Teams.
   - Os usuários podem optar por criar sua própria aplicação conectada no Microsoft Teams e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Microsoft Teams para fazer login e autorizar o acesso do AWS Glue aos recursos.
   - Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso ficará ativo por uma hora e poderá ser atualizado automaticamente sem a interação do usuário por meio do token de atualização.
   - Para obter a documentação pública do Microsoft Teams sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte, no Microsoft Learn, Register an application with the Microsoft identity platform - Microsoft Graph.

Para configurar uma conexão do Microsoft Teams:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para a autenticação OAuth:
      - Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET.
2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Em Conexões de dados, escolha Criar conexão.
   b. Ao selecionar uma Fonte de dados, selecione o Microsoft Teams.
   c. Forneça seu ID do locatário do Microsoft Teams.
   d. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   e. Forneça o ClientId da aplicação cliente gerenciada pelo usuário da aplicação Microsoft Teams.
   f. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   g. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`. Escolha Próximo.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Microsoft Teams

Pré-requisitos

- Um objeto do Microsoft Teams do qual você deseja ler. Você precisará do nome do objeto, como equipe ou mensagem do canal. A tabela a seguir mostra as entidades compatíveis.

Entidades compatíveis para a fonte

Todas as entidades são compatíveis com a versão 1.0 da API.

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Equipes	Não	Não	Não	Sim	Não
Membros da equipe	Sim	Sim	Não	Sim	Sim
Grupos	Sim	Sim	Sim	Sim	Sim
Membros do grupo	Sim	Sim	Não	Sim	Não
Canais	Sim	Não	Não	Sim	Sim
Mensagens do canal	Não	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Respostas de mensagens do canal	Não	Sim	Não	Sim	Não
Guias do canal	Sim	Não	Não	Sim	Não
Chats	Sim	Sim	Sim	Sim	Sim
Eventos de calendário	Sim	Sim	Sim	Sim	Sim

Exemplo

```
MicrosoftTeams_read = glueContext.create_dynamic_frame.from_options(
    connection_type="MicrosoftTeams",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "company",
        "API_VERSION": "v1.0"
    }
```

Detalhes das entidades e dos campos do Microsoft Teams

Lista de entidades:

- Equipe: https://docs.microsoft.com/en-us/graph/api/user-list-joinedteams?view=graph-rest-1.0
- Membro da equipe: https://docs.microsoft.com/en-us/graph/api/team-list-members?view=graph-rest-1.0
- Grupo: https://docs.microsoft.com/en-us/graph/api/group-list?view=graph-rest-1.0
- Membro do grupo: https://docs.microsoft.com/en-us/graph/api/group-list-members?view=graph-rest-1.0
- Canal: https://docs.microsoft.com/en-us/graph/api/channel-list?view=graph-rest-1.0

- Mensagem do canal: https://docs.microsoft.com/en-us/graph/api/channel-list-messages?view=graph-rest-1.0
- Resposta da mensagem do canal: https://docs.microsoft.com/en-us/graph/api/chatmessage-list-replies?view=graph-rest-1.0
- Guia do canal: 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
- Evento do calendário: https://docs.microsoft.com/en-us/graph/api/group-list-events?view=graph-rest-1.0

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na tabela abaixo:

Entity Name	Campos de particionamento	Tipo de dado
Membros da equipe	visibleHistoryStartDateTime	DateTime
Grupos	createdDateTime	DateTime
Canais	createdDateTime	DateTime

Entity Name	Campos de particionamento	Tipo de dado
Chats	createdDateTime, lastModifiedDateTime	DateTime
Eventos de calendário	createdDateTime, lastModifiedDateTime, originalStart	DateTime

Exemplo

```
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"
    }
```

Referência de opções de conexão do Microsoft Teams

Estas são as opções de conexão do Microsoft Teams:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Microsoft Teams.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Microsoft Teams que você deseja usar. Exemplo: v1.0.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.

- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações

Estas são as limitações do conector do Microsoft Teams:

- A API do Microsoft Teams retorna um número menor de registros do que o especificado para entidades de Chat e Membro da equipe. Esse problema foi relatado ao Suporte do Microsoft Teams e está sob investigação.

Crie uma nova conta do Microsoft Teams:

1. Navegue até a página inicial do Microsoft Teams, https://account.microsoft.com/account/ e escolha Entrar.
2. Escolha Crie uma!.
3. Insira as informações necessárias para a criação da conta e crie uma nova conta.
4. Navegue até o site do Microsoft Teams em https://www.microsoft.com/pt-br/microsoft-teams/log-in.
5. Inscreva-se usando a conta Microsoft que você acabou de criar.
6. Depois de se inscrever com êxito no Teams, navegue até https://account.microsoft.com/services.
7. Escolha Experimentar o Microsoft 365.
8. Ative uma das assinaturas do Microsoft 365 ou do Microsoft Teams abaixo para acessar todos os recursos necessários do conector do Microsoft Teams:
    - Microsoft Teams Essentials
    - Microsoft 365 Business
    - Microsoft 365 Business Basic
    - Microsoft 365 Business Standard
    - Microsoft 365 Business Premium

Criar uma aplicação cliente gerenciada:

1. Para criar uma aplicação gerenciada, você precisa registrar uma nova aplicação OAuth no Microsoft Entra (anteriormente Azure Active Directory):
2. Faça login no centro de administração do Microsoft Entra.
3. Se você tiver acesso a vários locatários, use o ícone Configurações no menu superior para alternar para o locatário no qual deseja registrar a aplicação no menu Diretórios + assinaturas.
4. Navegue até Identidade > Aplicativos > Registros de aplicativo e selecione Novo registro.
5. Insira um nome de exibição para sua aplicação.
6. Especifique quem pode usar a aplicação na seção Tipos de conta compatíveis. Para tornar essa aplicação global, selecione “Contas em qualquer diretório organizacional” ou “Contas em qualquer diretório organizacional e contas pessoais da Microsoft”.
7. Insira o URI de redirecionamento `https://{region}.console.aws.amazon.com/appflow/oauth`. Por exemplo, para `us-west-2 region`, adicione `https://us-west-2.console.aws.amazon.com/appflow/oauth`. Você pode adicionar vários URLs para as diferentes regiões que deseja usar.
8. Registre a aplicação.
9. Anote o ID do cliente para uso futuro.
10. Escolha Adicionar um certificado ou segredo na seção Essentials.
11. Escolha Novo segredo do cliente.
12. Insira uma descrição e a duração da expiração.
13. Copie e salve o segredo do cliente para uso futuro.
14. Na lista do menu à esquerda, selecione Permissões de API.
15. Escolha Adicionar uma permissão.
16. Selecione “Microsoft Graph”.
17. Selecione “Permissões delegadas”.
18. Marque todas as seguintes permissões:

    - User.Read
    - Offline_access
    - User.Read.All
    - User.ReadWrite.All
    - TeamsTab.ReadWriteForTeam

- TeamsTab.ReadWriteForChat
- TeamsTab.ReadWrite.All
- TeamsTab.Read.All
- TeamSettings.ReadWrite.All
- TeamSettings.Read.All
- TeamMember.ReadWrite.All
- TeamMember.Read.All
- Team.ReadBasic.All
- GroupMember.ReadWrite.All
- GroupMember.Read.All
- Group.ReadWrite.All
- Group.Read.All
- Directory.ReadWrite.All
- Directory.Read.All
- Directory.AccessAsUser.All
- Chat.ReadWrite
- Chat.ReadBasic
- Chat.Read
- ChannelSettings.ReadWrite.All
- ChannelSettings.Read.All
- ChannelMessage.Read.All
- Channel.ReadBasic.All

19. Escolha Adicionar permissões. Sua aplicação agora foi configurada com êxito. Você pode usar o ID e o segredo do cliente para criar uma nova conexão. Para obter mais informações, consulte https://learn.microsoft.com/en-us/graph/auth-register-app-v2.

Conexão com o Mixpanel

O Mixpanel é uma poderosa plataforma de análise em tempo real que ajuda as empresas a medir e otimizar o engajamento do usuário. O Mixpanel é uma aplicação usada para rastrear o comportamento do cliente. Ele permite que você acompanhe como os usuários interagem com seu produto e analise esses dados com relatórios interativos que permitem consultar e visualizar os

resultados com apenas alguns cliques. Como usuário do Mixpanel, é possível conectar o AWS Glue à sua conta do Mixpanel. Em seguida, será possível usar o Slack como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Mixpanel e serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para Mixpanel
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Mixpanel
- Configuração de conexões do Mixpanel
- Leitura de entidades do Mixpanel
- Opções de conexão do Mixpanel
- Criação de uma conta do Mixpanel e configuração da aplicação cliente
- Limitações

Suporte do AWS Glue para Mixpanel

O AWS Glue oferece suporte ao Mixpanel da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do Mixpanel.

Compatível como destino?

Nº

Versões da API do Mixpanel com suporte

2.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
```

```
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Mixpanel

Antes de poder usar o AWS Glue para transferir dados do Mixpanel, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Mixpanel. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Mixpanel.

- Sua conta do Mixpanel precisa estar habilitada para acesso à API. O acesso à API estar ativado por padrão para as edições Enterprise, Unlimited, Developer e Performance.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Mixpanel. Para conexões típicas, você não precisa fazer mais nada no Mixpanel.

Configuração de conexões do Mixpanel

O Mixpanel oferece suporte a nome de usuário e senha para `BasicAuth`. A autenticação básica é um método de autenticação simples em que os clientes fornecem credenciais diretamente para acessar recursos protegidos. O AWS Glue é capaz de usar o nome de usuário e a senha para autenticar as APIs do Mixpanel.

Para obter a documentação pública do Mixpanel sobre o fluxo de `BasicAuth`, consulte Contas de serviço do Mixpanel.

Para configurar uma conexão do Mixpanel:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   - Para a autenticação básica, o segredo deve conter o segredo do consumidor da aplicação conectada com `USERNAME` e `PASSWORD` como chave.

     > **Note**
     >
     > É preciso criar um segredo por conexão em AWS Glue.

2. No AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Mixpanel.
   b. Forneça o `INSTANCE_URL` do Mixpanel ao qual você deseja se conectar.
   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
```

```
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione Opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Mixpanel

Pré-requisitos

Você deve ter um objeto do Mixpanel, como `Funnels`, `Retention` ou `Retention Funnels`, do qual gostaria de ler dados. Além disso, você precisará saber o nome do objeto.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Funis	Sim	Não	Não	Sim	Não
Retenção	Sim	Não	Não	Sim	Não
Segmentação	Sim	Não	Não	Sim	Não
Soma da segmentação	Sim	Não	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Média de segmentação	Sim	Não	Não	Sim	Não
Cohorts	Sim	Não	Não	Sim	Não
Engage	Não	Sim	Não	Sim	Não
Eventos	Sim	Não	Não	Sim	Não
Eventos principais	Sim	Não	Não	Sim	Não
Nome dos eventos	Sim	Não	Não	Sim	Não
Propriedades dos eventos	Sim	Não	Não	Sim	Não
Propriedades dos eventos principais	Sim	Não	Não	Sim	Não
Valores das propriedades dos eventos	Sim	Não	Não	Sim	Não
Anotações	Sim	Não	Não	Sim	Não
Atividade de evento do perfil	Sim	Não	Não	Sim	Não

Exemplo

```
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"
    }
```

Detalhes das entidades e dos campos do Mixpanel

Entidade	Campo	Tipo de dado	Operadores com suporte
Funil	funnel_id	Inteiro	'='
	workspace_id	Inteiro	'='
	from_date	Data	'='
	to_date	Data	'=’
	length	Inteiro	'='
	length_unit	String	'='
	intervalo	Inteiro	'='
	unidade	String	'='
	limite	Inteiro	'='
	dados	Struct	
	meta	Struct	
Retenção	workspace_id	Inteiro	'='
	unidade	String	'='
	addiction_unit	String	'='

Entidade	Campo	Tipo de dado	Operadores com suporte
	from_date	Data	'='
	to_date	Data	'='
	event	String	'='
	limite	Inteiro	'='
	dados	Struct	
Segmentação	workspace_id	Inteiro	'='
	event	String	'='
	from_date	Data	'='
	to_date	Data	'='
	unidade	String	'='
	intervalo	Inteiro	'='
	limite	Inteiro	'='
	type	String	'='
	série	Lista	
	values	Struct	
	dados	Struct	
Segmentação numérica	workspace_id	Inteiro	'='
	event	String	'='
	ativado	String	'='
	from_date	Data	'='

Entidade	Campo	Tipo de dado	Operadores com suporte
	to_date	Data	'='
	unidade	String	'='
	type	String	'='
	série	Lista	
	values	Struct	
Soma da segmentação	workspace_id	Inteiro	'='
	event	String	'='
	ativado	String	'='
	from_date	Data	'='
	to_date	Data	'='
	unidade	String	'='
	metadados	Struct	
	resultados	Struct	
Média de segmentação	workspace_id	Inteiro	'='
	event	String	'='
	ativado	String	'='
	from_date	Data	'='
	to_date	Data	'='
	unidade	String	'='
	metadados	Struct	

Entidade	Campo	Tipo de dado	Operadores com suporte
	resultados	Struct	
Cohorts	contagem	Inteiro	
	is_visible	Inteiro	
	description	String	
	created	DateTime	
	project_id	Inteiro	
	id	BigInteger	
	nome	String	
	data_group_id	String	
Engage	distinct_id	String	
		propriedades	Struct
Event	espaço de trabalho	Inteiro	'='
	event	String	'='
	type	String	'='
	unidade	String	'='
	intervalo	Inteiro	'='
	from_date	Data	'='
	to_date	Data	'='
	série	Lista	
	values	Struct	

Entidade	Campo	Tipo de dado	Operadores com suporte
Eventos principais	type	String	'='
	workspace_id	Inteiro	'='
	limite	Inteiro	'='
	valor	Inteiro	
	event	String	
	percent_change	Float	
Nome do evento	dados	Lista	
	workspace_id	Inteiro	'='
	type	String	'='
	limite	Inteiro	'='
Propriedades do evento	workspace_id	Inteiro	'='
	event	String	'='
	nome	String	'='
	type	String	'='
	unidade	String	'='
	intervalo	Inteiro	'='
	from_date	Data	'='
	to_date	Data	'='
	limite	Inteiro	'='
	dados	Struct	

Entidade	Campo	Tipo de dado	Operadores com suporte
	série	Lista	
	values	Struct	
Propriedades dos eventos principais	workspace_id	Inteiro	'='
	event	String	'='
	limite	Inteiro	'='
	dados	Struct	
Valor das proprieda des dos eventos	workspace_id	Inteiro	'='
	event	String	'='
	limite	Inteiro	'='
	nome	String	'='
	dados	Lista	
Anotação	workspace_id	Inteiro	
	date	DateTime	
	project_id	Inteiro	
	id	BigInteger	
	description	String	
	from_date	Data	BETWEEN
Atividade de evento do perfil	workspace_id	Inteiro	'='
	distinct_ids	String	'='
	from_date	Data	'='

Entidade	Campo	Tipo de dado	Operadores com suporte
	to_date	Data	'='
	event	String	
	propriedades	Struct	

Opções de conexão do Mixpanel

Estas são as opções de conexão do Mixpanel:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Mixpanel.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Mixpanel que você deseja usar. Por exemplo, v2.0.
- `SELECTED_FIELDS`(lista<string>): padrão: vazio (SELECT *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

Criação de uma conta do Mixpanel e configuração da aplicação cliente

Criação de uma conta do Mixpanel

1. Navegue até a página inicial do Mixpanel.
2. Na página inicial do Mixpanel, escolha Cadastrar-se no canto superior direito da página.
3. Na página Vamos começar, conclua as seguintes ações:
   - Insira seu endereço de e-mail no campo designado.
   - Marque a caixa de seleção obrigatória para concordar com os termos.
   - Escolha Começar para prosseguir.

     Após a conclusão com êxito, você receberá um e-mail de verificação.

4. Verifique sua caixa de entrada de e-mail em busca de uma mensagem de verificação, abra o e-mail e siga as instruções para verificar seu endereço de e-mail.
5. Na página de verificação, escolha Verificar e-mail para concluir a verificação do seu e-mail.
6. Na página Nomeie sua organização, insira o nome da sua organização e escolha Avançar.
7. Na página Seu primeiro projeto, insira os detalhes do seu projeto e escolha Criar.
8. Na próxima página, escolha Vamos começar para concluir a criação da sua conta.

Login em uma conta do Mixpanel

1. Navegue até a página de login do Mixpanel.
2. Insira seu endereço de e-mail e escolha Continuar.
3. Verifique sua caixa de entrada de e-mail em busca de uma mensagem de verificação, abra o e-mail e siga as instruções para verificar seu endereço de e-mail.
4. Na próxima página, escolha o botão Login para fazer login na sua conta.

Aquisição de um plano do Mixpanel

1. Na página do Mixpanel, selecione o ícone Configurações localizado no canto superior direito da página.
2. Na lista de opções, selecione Detalhes e cobrança do plano.
3. Na página Detalhes e cobrança do plano, selecione Atualizar ou modificar.
4. Na próxima página, selecione o plano que você deseja comprar.

   Isso conclui o processo de criação da conta e aquisição do plano.

Criação de um nome de usuário e segredo do cliente (para registrar sua aplicação)

1. Na página do Mixpanel, selecione o ícone Configurações localizado no canto superior direito da página.
2. Na lista de opções, selecione Configurações do projeto.
3. Na página Configurações do projeto, selecione Contas de serviço e, em seguida, selecione Adicionar conta de serviço.
4. Na lista suspensa Conta de serviço, selecione a conta de serviço ou insira o nome para criar, adicione o Perfil do projeto, especifique a expiração e selecione Adicionar.

> **Important**
>
> Após concluir a etapa anterior, a página a seguir exibe a chave secreta da conta de serviço. Certifique-se de salvar a chave secreta da conta de serviço. Você não poderá acessá-lo novamente após este ponto.

Limitações

Estas são as limitações do conector do Mixpanel:

- Para a entidade `Segmentation Numeric`, a API do Mixpanel gera um erro `400 (Bad Request)` se nenhum dado numérico for encontrado para os filtros obrigatórios. Estamos tratando isso como uma resposta `OK` para evitar falhas no fluxo.
- O campo consultável `limit` foi removido das entidades com suporte porque:
  - Estava causando erros por ser interpretado como o atributo de limite do SDK
  - O filtro não servia a nenhum propósito prático
  - A funcionalidade equivalente agora é coberta pela implementação do atributo de limite
- Não pode gaver suporte para o particionamento baseado em campo devido à ausência dos operadores necessários (`>=`, `<=`, `<`, `>`, `between`) para particionamento na plataforma SaaS. Embora ela ofereça suporte ao operador `between`, os campos para os quais ela oferece suporte a esse operador não são recuperáveis. Portanto, os critérios para particionamento baseado em campo não são atendidos.
- Como não há provisão para obter um valor de 'offset' para entidades que suportam paginação, não é possível oferecer suporte ao particionamento baseado em registros para o Mixpanel.
- A entidade `Cohorts` oferece suporte apenas ao campo `CreatedDate/Time`, e não há nenhum campo para identificar `UpdatedDate/Time`. Como resultado, `DML_Status` não pode ser identificado. Além disso, não há endpoints para identificar registros excluídos. Portanto, não pode haver suporte para o CDC.
- Para executar um trabalho de AWS Glue para as entidades mencionadas abaixo, filtros obrigatórios são necessários. Consulte a tabela abaixo para conferir os nomes de entidades e seus filtros obrigatórios.

Nome da entidade e filtros obrigatórios

Nome da entidade	Filtros obrigatórios
Anotações	from_date, to_date
Cohorts	Nenhum
Engage	Nenhum
Event	event, type, unit, from_date, to_date, on
Nome dos eventos	type
Propriedades dos eventos	event, name, type, unit, from_date, to_date
Propriedades dos eventos principais	event
Valores das propriedades dos eventos	event, name
Eventos principais	type
Funis	funnel_id, from_date, to_date
Atividade de evento do perfil	distinct_ids, from_date, to_date
Retenção	from_date, to_date, unit, addiction_unit
Segmentação	event, from_date, to_date
Média de segmentação	event, from_date, to_date, on
Segmentação numérica	event, from_date, to_date, on
Soma da segmentação	event, from_date, to_date, on

Conexão ao Monday

O Monday.com é um sistema operacional de trabalho versátil que simplifica o gerenciamento de projetos e a colaboração em equipe. Ele apresenta fluxos de trabalho personalizáveis, painéis

visuais e ferramentas de automação para aumentar a produtividade. Os usuários podem rastrear tarefas, gerenciar recursos e se comunicar de forma eficaz em uma plataforma integrada.

Tópicos

- Suporte do AWS Glue para o Monday
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Monday
- Configuração de conexões do Monday
- Leitura de entidades do Monday
- Referência de opções de conexão do Monday
- Limitações
- Criar uma nova conta do Monday:

Suporte do AWS Glue para o Monday

O AWS Glue oferece suporte ao Monday da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Monday.

Compatível como destino?

Não.

Versões compatíveis da API do Monday

v2.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
```

```
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Monday

Antes de usar o AWS Glue para transferir dados do Monday, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta de desenvolvedor do Monday com e-mail e senha. Para ter mais informações, consulte Criar uma nova conta do Monday:.
- Sua conta de desenvolvedor do Monday está habilitada para acesso à API. Todo o uso das APIs do Monday está disponível sem custo adicional durante o período de avaliação. Quando o período de avaliação terminar, você precisará comprar uma assinatura para criar e acessar os dados. Para obter mais informações, consulte a página de licenciamento do Monday para mais detalhes.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Monday. Para conexões típicas, você não precisa fazer mais nada no Monday.

Configuração de conexões do Monday

O Monday oferece suporte aos dois tipos seguintes de mecanismo de autenticação:

1. Autenticação OAuth: o Monday oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2.
   - Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O usuário que está criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao AWS Glue, na qual ele não precisa fornecer quaisquer informações relacionadas ao OAuth, exceto o instanceurl do Monday. O Console do AWS Glue redirecionará o usuário para o Monday, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Monday.
   - Os usuários devem optar por criar sua própria aplicação conectada no Monday e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Monday para fazer login e autorizar o acesso do AWS Glue aos recursos.
   - Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso ficará ativo por uma hora e poderá ser atualizado automaticamente sem a interação do usuário por meio do token de atualização.
   - Para obter mais informações, consulte a documentação sobre como criar uma aplicação conectada para o fluxo AUTHORIZATION_CODE do OAuth.
2. Autenticação personalizada:
   - Para obter a documentação pública do Monday sobre como gerar as chaves de API necessárias para a autorização personalizada, consulte https://developer.monday.com/api-reference/docs/authentication#api-token-permissions.

Para configurar uma conexão do Monday:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para a autenticação OAuth:

- Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET.

b. Para a autenticação personalizada:

- Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave `personalAccessToken`.

2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

a. Em Conexões de dados, escolha Criar conexão.

b. Ao selecionar uma Fonte de dados, selecione o Monday.

c. Forneça o instanceURL do Monday.

d. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

e. Selecione o tipo de autenticação para se conectar ao Monday

- Para a autenticação OAuth: forneça o URL do Token e o ClientId da aplicação cliente gerenciada pelo usuário do Monday ao qual deseja se conectar.
- Para a autenticação personalizada: selecione o tipo de autenticação PERSONALIZADA para se conectar ao Monday.

f. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

g. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`. Escolha Próximo.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Monday

Pré-requisitos

- Um objeto do Monday do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis para a fonte

Lista de entidades:

- Conta: https://developer.monday.com/api-reference/docs/account#queries
- Mural: https://developer.monday.com/api-reference/docs/boards#queries
- Coluna: https://developer.monday.com/api-reference/docs/columns#queries
- Documentos: https://developer.monday.com/api-reference/docs/docs#queries
- Bloco de documento: https://developer.monday.com/api-reference/docs/blocks#queries
- Arquivos: https://developer.monday.com/api-reference/docs/files#queries
- Pastas: https://developer.monday.com/api-reference/docs/folders#queries
- Grupos: https://developer.monday.com/api-reference/docs/groups#queries
- Item: https://developer.monday.com/api-reference/docs/items#queries
- Subitens: https://developer.monday.com/api-reference/docs/subitems#queries
- Tags: https://developer.monday.com/api-reference/docs/tags-queries#queries
- Equipes: https://developer.monday.com/api-reference/docs/teams#queries
- Atualizações: https://developer.monday.com/api-reference/docs/updates#queries
- Usuários: https://developer.monday.com/api-reference/docs/users#queries
- Espaços de trabalho: https://developer.monday.com/api-reference/docs/workspaces#queries

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Conta	Não	Não	Não	Sim	Não
Murais	Sim	Sim	Não	Sim	Não
Columns	Não	Não	Não	Sim	Não
Documentos	Sim	Sim	Não	Sim	Não
Blocos de documentos	Não	Sim	Não	Sim	Não
Arquivos	Sim	Não	Não	Sim	Não
Grupos	Não	Não	Não	Sim	Não
Item	Sim	Sim	Não	Sim	Não
Subitens	Não	Não	Não	Sim	Não
Tags	Sim	Não	Não	Sim	Sim
Equipes	Sim	Não	Não	Sim	Não
Atualizações	Não	Sim	Não	Sim	Não
Usuários	Sim	Sim	Não	Sim	Não
Workspaces	Sim	Sim	Não	Sim	Não
Pastas	Sim	Sim	Não	Sim	Não

Exemplo

```
monday_read = glueContext.create_dynamic_frame.from_options(
     connection_type="monday",
```

```
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "account",
        "API_VERSION": "v2"
    }
```

Referência de opções de conexão do Monday

Estas são as opções de conexão do Monday:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Monday.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. A versão da API Rest do Monday que você deseja usar. Exemplo: v2.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.

Limitações

Estas são as limitações do conector do Monday:

- A resposta dinâmica de metadados apresenta alguns conflitos com a documentação, conforme mencionado abaixo:
  - A entidade Grupo, Coluna oferece suporte a operações de filtro, mas não está presente no endpoint dinâmico de metadados, portanto, é mantida como uma entidade não filtrável.
  - O endpoint dinâmico consiste em cerca de mais de 15 mil linhas e retorna metadados de todas as entidades em uma única resposta. Por isso, os campos demoram, em média, dez segundos para carregar, o que pode exigir mais tempo durante a execução de um trabalho.
  - Consulte na tabela abaixo os limites de taxa do Monday. O tamanho significativo dos dados de respostas da entidade dinâmica causa um atraso perceptível, com os campos exigindo, em média, dez segundos para carregar.

Limite de complexidade	5 milhões (5M) de pontos de complexidade
Limite diário de chamadas	10 mil para o plano Profissional
Limite por minuto	500 consultas por minuto
Limite de simultaneidade	100 solicitações simultâneas, no máximo, para o plano Profissional

Criar uma nova conta do Monday:

1. Navegue até a página inicial do Monday, https://monday.com/ e escolha Iniciar sessão.
2. Você será redirecionado para a página de login. Na parte inferior da página, escolha Sign up.
3. Insira seu endereço de e-mail e escolha Continuar. Como alternativa, você pode fazer login com o Google.
4. Insira as informações necessárias e escolha Continue.
5. Responda às perguntas da pesquisa e siga as etapas para concluir o processo de criação da conta.

Registrar uma aplicação OAuth:

1. Faça login na sua conta do monday.com. Clique no seu avatar (ícone de imagem) no canto inferior esquerdo da tela.
2. Escolha Developer.
3. Escolha Criar aplicação.
4. Preencha os campos obrigatórios para um nome e descrição.
5. Navegue até a seção “OAuth” no lado direito, adicione os escopos e escolha “Save Feature”.
6. Navegue até a guia “Redirect URLs” ao lado do escopo, adicione o URL de redirecionamento e escolha “Save Feature”.
7. Na guia Redirect URLs, informe o URL da sua aplicação. Esse URL deve ser https://{código-da-região}.console.aws.amazon.com/appflow/oauth. Por exemplo, se estiver usando `us-east-1` , você pode adicionar `https://us-east-1.console.aws.amazon.com/appflow/oauth`.

8. Agora a aplicação está pronta para uso. Você pode encontrar suas credenciais na seção “Basic Information”. Anote as strings do seu ID e segredo do cliente. Essas strings são usadas para fazer uma conexão com essa aplicação usando um conector do AppFlow.

Gerar token de acesso pessoal:

Atualmente, a monday.com oferece apenas nossos tokens de API V2, que são todos tokens pessoais. Para acessar seus tokens de API, é possível usar dois métodos, dependendo do nível do usuário. Os usuários administradores podem utilizar os dois métodos para adquirir os tokens de API. Os usuários membros podem acessar os tokens de API nas guias de desenvolvedor.

Administradores: se você for um usuário administrador na sua conta do monday.com, poderá acessar os tokens de API na guia “Admin” seguindo estas etapas:

1. Faça login na sua conta do monday.com. Clique no seu avatar (ícone de imagem) no canto inferior esquerdo da tela.
2. Selecione “Administration” no menu exibido (isso requer que você tenha permissões de administrador).
3. Navegue até a seção “API” e gere um “API V2 Token”. Você pode copiar seu token e usá-lo.

Desenvolvedores: se você for um usuário membro na sua conta do monday.com, poderá acessar os tokens de API na guia “Developer” seguindo estas etapas:

1. Faça login na sua conta do monday.com. Clique no seu avatar (ícone de imagem) no canto inferior esquerdo da tela.
2. Selecione “Developers” no menu exibido.
3. No menu superior, escolha o menu suspenso “Developer”. Selecione a primeira opção no menu suspenso chamada “My Access Tokens”.

Conectar ao MongoDB no AWS Glue Studio

O AWS Glue oferece suporte integrado ao Mongo DB. O AWS Glue Studio fornece uma interface visual para conectar ao Mongo DB, criar trabalhos de integração de dados e executá-los no runtime Spark do AWS Glue Studio sem servidor.

Tópicos

• Criar uma conexão do MongoDB

- Criar um nó de origem do MongoDB
- Criar um nó de destino do MongoDB
- Opções avançadas

Criar uma conexão do MongoDB

Pré-requisitos:

- Se a sua instância do MongoDB estiver em uma Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com a instância do MongoDB sem que o tráfego passe pela Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre sua instância do MongoDB e esse local. Com base no layout da rede, isso pode exigir alterações em regras do grupo de segurança, ACLs de rede, gateways de NAT e conexões de emparelhamento.

Para configurar uma conexão com o MongoDB:

1. Opcionalmente, no AWS Secrets Manager, crie um segredo usando suas credenciais do MongoDB. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.

   - Ao selecionar Pares chave/valor, crie um par para a chave `username` com o valor *`mongodbUser`*.

     Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *`mongodbPass`*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *`connectionName`*, para uso futuro em AWS Glue.

   - Ao selecionar um Tipo de conexão, selecione MongoDB ou MongoDB Atlas.
   - Ao selecionar o URL do MongoDB ou o URL do MongoDB Atlas, forneça o nome de host da sua instância do MongoDB.

Um URL do MongoDB é fornecido no formato `mongodb://mongoHost:mongoPort/mongoDBname`.

Um URL do MongoDB Atlas é fornecido no formato `mongodb+srv://mongoHost:mongoPort/mongoDBname`.

Fornecer o banco de dados padrão *mongoDBname* para a conexão é opcional.

- Se você optar por criar um segredo do Secrets Manager, escolha o Tipo de credencial do AWS Secrets Manager.

  Em seguida, em Segredo do AWS, forneça o *secretName*.

- *Se você optar por fornecer* ***Nome de usuário e senha****, forneça também o mongodbUser e o mongodbPass*.

3. Nas seguintes situações, configurações adicionais podem ser necessárias:

   - Para instâncias do MongoDB hospedadas na AWS em uma Amazon VPC
     - Será necessário fornecer informações de conexão da Amazon VPC à conexão do AWS Glue que define suas credenciais de segurança do MongoDB. Ao criar ou atualizar sua conexão, defina VPC, Sub-rede e Grupos de segurança em Opções de rede.

Depois de criar uma conexão AWS Glue MongoDB, siga estas etapas antes de executar seu trabalho do AWS Glue:

- Ao trabalhar com trabalhos do AWS Glue no editor visual, é necessário fornecer informações de conexão da Amazon VPC para que seu trabalho se conecte ao MongoDB. Identifique um local adequado na Amazon VPC e forneça-o à sua conexão AWS Glue MongoDB.
- Se você optar por criar um segredo do Secrets Manager, conceda ao perfil do IAM associado ao seu trabalho do AWS Glue permissão para ler *secretName*.

Criar um nó de origem do MongoDB

Pré-requisitos necessários

- Uma conexão AWS Glue MongoDB, conforme descrito na seção anterior, the section called “Criar uma conexão do MongoDB”.

- Se você optar por criar um segredo do Secrets Manager, permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma coleção do MongoDB da qual você gostaria de ler. Você precisará de informações de identificação para a coleção.

  Uma coleção do MongoDB é identificada por um nome de banco de dados e um nome de coleção, *`mongodbName`* e *`mongodbCollection`*.

Adicionar uma fonte de dados do MongoDB

Para adicionar um nó de Fonte de dados – MongoDB:

1. Escolha a conexão para sua fonte de dados do MongoDB. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o MongoDB. Para mais informações, consulte a seção the section called “Criar uma conexão do MongoDB” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Escolha um Banco de dados. Insira o *`mongodbName`*.
3. Escolha uma Coleção. Insira *`mongodbCollection`*.
4. Escolha seu Particionador, o Tamanho da partição (MB) e a Chave da partição. Para obter mais informações sobre parâmetros de partições, consulte the section called ““connectionType”: “mongodb” como fonte”.
5. Em Propriedades personalizadas do MongoDB, insira parâmetros e valores conforme necessário.

Criar um nó de destino do MongoDB

Pré-requisitos necessários

- Uma conexão AWS Glue MongoDB configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão do MongoDB”.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do MongoDB na qual você gostaria de escrever, *`tableName`*.

Adicionar um destino de dados do MongoDB

Para adicionar um nó de Destino de dados – MongoDB:

1. Escolha a conexão para sua fonte de dados do MongoDB. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o MongoDB. Para mais informações, consulte a seção the section called “Criar uma conexão do MongoDB” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Escolha um Banco de dados. Insira o *`mongodbName`*.
3. Escolha uma Coleção. Insira *`mongodbCollection`*.
4. Escolha seu Particionador, o Tamanho da partição (MB) e a Chave da partição. Para obter mais informações sobre parâmetros de partições, consulte the section called ““connectionType”: “mongodb” como fonte”.
5. Escolha Repetir operações de escrever, se desejar.
6. Em Propriedades personalizadas do MongoDB, insira parâmetros e valores conforme necessário.

Opções avançadas

Você pode fornecer opções avançadas ao criar um nó do Mongo DB. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexão do MongoDB”.

Conectando-se ao Oracle NetSuite

NetSuite A Oracle é uma solução de gerenciamento de negócios em all-in-one nuvem que ajuda as organizações a operar com mais eficiência automatizando os principais processos e fornecendo visibilidade em tempo real do desempenho operacional e financeiro. Com um pacote único e integrado de aplicativos para gerenciamento de contabilidade, processamento de pedidos, gerenciamento de inventário, produção, cadeia de suprimentos e operações de armazém, a Oracle NetSuite oferece às empresas uma visibilidade clara de seus dados e um controle mais rígido sobre seus negócios.

Tópicos

- AWS Glue suporte para Oracle NetSuite
- Políticas contendo as API operações para criar e usar conexões
- Configurando o Oracle NetSuite
- Configuração de conexões do Oracle NetSuite
- Leitura de entidades do Oracle NetSuite
- Opções de NetSuite conexão Oracle
- Limitações e notas para o NetSuite conector Oracle

AWS Glue suporte para Oracle NetSuite

AWS Glue oferece suporte ao Oracle da NetSuite seguinte forma:

Compatível como fonte?

Sim. Você pode usar AWS Glue ETL trabalhos para consultar dados da Oracle NetSuite.

Compatível como destino?

Não.

NetSuite APIVersões Oracle suportadas

As seguintes NetSuite API versões do Oracle são suportadas:

- v1

Para suporte de entidades por versão específica, consulte Entidades suportadas para o Source.

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS IAM permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
```

```
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, use as seguintes IAM políticas gerenciadas:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configurando o Oracle NetSuite

Antes de poder usar AWS Glue para transferir dados da Oracle NetSuite, você deve atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma NetSuite conta Oracle. Para obter mais informações, consulte Criando uma NetSuite conta Oracle.
- Sua NetSuite conta Oracle está habilitada para API acesso.

- Você criou uma API integração OAuth 2.0 em sua conta de NetSuite desenvolvedor Oracle. Essa integração fornece as credenciais do cliente que você AWS Glue usa para acessar seus dados com segurança ao fazer chamadas autenticadas para sua conta. Para obter mais informações, consulte Criação de um aplicativo NetSuite cliente Oracle e credenciais OAuth 2.0.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua NetSuite conta Oracle.

Criando uma NetSuite conta Oracle

Navegue até Oracle NetSuite e escolha Free Product Tour. Preencha os detalhes necessários para obter um tour gratuito do produto, por meio do qual você pode entrar em contato com um fornecedor. O processo de aquisição de uma conta é o seguinte:

- A aquisição de uma NetSuite conta é feita por meio de um fornecedor, que fornece um formulário/cotação que deve ser revisado legalmente.
- A conta a ser adquirida para o NetSuite conector Oracle é do Standard Cloud Service.
- Essa conta é criada pelo fornecedor e as credenciais temporárias são compartilhadas por ele. Você receberá um e-mail de boas-vindas NetSuite < billing@notification.netsuite.com > < system@sent-via.netsuite.com > com detalhes como seu nome de usuário e um link para definir sua senha.
- Use o link Defina sua senha para definir a senha do nome de usuário fornecido pelo fornecedor.

Criação de um aplicativo NetSuite cliente Oracle e credenciais OAuth 2.0

Para obter o ID do cliente e o segredo do cliente, você cria um aplicativo NetSuite cliente Oracle:

1. Faça login na sua NetSuite conta por meio do login NetSuite do cliente.
2. Escolha Configuração > Empresa > Ativar recursos.
3. Navegue até a SuiteCloudseção e marque a RESTWEBSERVICEScaixa de seleção em SuiteTalk (Serviços da Web).
4. Marque a caixa de seleção OAUTH2.0 em Gerenciar autenticação. Clique em Salvar.
5. Vá para Configuração > Integração > Gerenciar integrações e escolha Novo para criar um aplicativo OAuth2 .0.
6. Insira um nome de sua escolha e mantenha o STATEcomo Ativado.

7. Se marcada, desmarque as BASED AUTHENTICATION caixas de seleção TBA: AUTHORIZATION FLOW e TOKEN- exibidas em Autenticação baseada em token.
8. Marque as PUBLICCLIENTcaixas de seleção AUTHORIZATIONCODEGRANTe em OAuth2.0.
9. Em Auth, anote o ID do cliente e o segredo do cliente.
10. Insira um REDIRECTURI. Por exemplo, https://us-east-1.console.aws.amazon.com/gluestudio/oauth
11. Marque a RESTWEBSERVICEScaixa de seleção abaixo SCOPE.
12. Marque a USERCREDENTIALScaixa de seleção em Credenciais do usuário. Escolha Salvar.
13. Observe o CONSUMER KEY/CLIENT ID and CONSUMER SECRET/CLIENT SECRET item Credenciais do cliente. Esses valores são exibidos somente uma vez.
14. Crie uma ADMINISTRATOR função, se necessário, navegando até Usuário/Funções > Gerenciar Funções > Novo.
15. Ao criar uma função personalizada, adicione acesso total na guia Permissões às seguintes entidades/funcionalidades:
    - “Depósito”, “Itens”, “Atendimento do item”, “Fazer registro no diário”, “Pedido de compra”, “Subsidiárias”, “Fornecedores”, “Faturas”, “Autorização de devolução do fornecedor”, “Tempo de rastreamento”, “Pagamento do cliente”, “Entradas de registro personalizadas”, “Tipos de registros personalizados”, “Serviços REST Web”, “Gerenciamento de aplicativos autorizados OAuth 2.0”, “Campos de entidade personalizados”, “Faça login usando tokens de acesso OAuth 2.0”.

Para obter mais informações, consulte OAuth2.0 na documentação do NetSuite Applications Suite.

Configuração de conexões do Oracle NetSuite

O Oracle NetSuite oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2. O tipo de concessão determina como o AWS Glue se comunica com o Oracle NetSuite para solicitar acesso aos seus dados.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O usuário que estiver criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao AWS Glue (aplicação cliente gerenciada pelo AWS Glue), na qual ele não precisa fornecer quaisquer informações relacionadas ao OAuth, exceto o URL da instância do Oracle NetSuite. O

console do AWS Glue redirecionará o usuário ao Oracle NetSuite para que o usuário pode fazer login e autorizar que as permissões solicitadas pelo AWS Glue acessem sua instância do Oracle NetSuite.

- Os usuários ainda podem optar por criar sua própria aplicação conectada no Oracle NetSuite e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados ao Oracle NetSuite para iniciar sessão e autorizar o acesso do AWS Glue a seus recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Oracle NetSuite sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Aplicações públicas.

Para configurar uma conexão do Oracle NetSuite:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Observação: é necessário criar um segredo para sua conexão no AWS Glue.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Oracle NetSuite.
   b. Forneça o ambiente do Oracle NetSuite.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
```

```
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Oracle NetSuite

Pré-requisito

Um objeto do Oracle do qual você deseja ler. Você precisará do nome do objeto, como `deposit` ou `timebill`. A tabela a seguir mostra as entidades compatíveis.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a Ordenar por	Oferece suporte a limite	Oferece suporte a SELECIONAR *	Oferece suporte a particionamento
Depósito	Sim	Não	Sim	Sim	Sim
Item de descrição	Sim	Não	Sim	Sim	Sim
Item de inventário	Sim	Não	Sim	Sim	Sim
Atendimento do item	Sim	Não	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a Ordenar por	Oferece suporte a limite	Oferece suporte a SELECIONAR *	Oferece suporte a particionamento
Grupo de itens	Sim	Não	Sim	Sim	Sim
Lançamento no diário	Sim	Não	Sim	Sim	Sim
Item de compra que não é de estoque	Sim	Não	Sim	Sim	Sim
Item de revenda que não é de estoque	Sim	Não	Sim	Sim	Sim
Item de venda que não é de estoque	Sim	Não	Sim	Sim	Sim
Ordem de compra	Sim	Não	Sim	Sim	Sim
Subsidiária	Sim	Não	Sim	Sim	Sim
Vendor	Sim	Não	Sim	Sim	Sim
Fatura do fornecedor	Sim	Não	Sim	Sim	Sim
Autorização de devolução ao fornecedor	Sim	Não	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a Ordenar por	Oferece suporte a limite	Oferece suporte a SELECIONAR *	Oferece suporte a particionamento
Faturamento com prazo	Sim	Não	Sim	Sim	Sim
Pagamento do cliente	Sim	Não	Sim	Sim	Sim
Solicitação de atendimento	Sim	Não	Sim	Sim	Sim

Exemplo:

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="netsuiteerp",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "deposit",
        "API_VERSION": "v1"
    }
)
```

Detalhes das entidades e dos campos do Oracle NetSuite:

O Oracle NetSuite carrega dinamicamente os campos disponíveis na entidade selecionada. Dependendo do tipo de dados de campo, ele é compatível com os operadores de filtro a seguir.

Tipos de dados de campo	Operadores de filtro compatíveis
String	LIKE, =, !=
Data	BETWEEN, =, <, <=, >, >=
DateTime	BETWEEN, <, <=, >, >=

Tipos de dados de campo	Operadores de filtro compatíveis
Numérico	=, !=, <, <=, >, >=
Booleano	=, !=

Consultas de particionamento

Particionamento com base em campo

O conector do Oracle NetSuite tem metadados dinâmicos para que os campos compatíveis com particionamento com base em campo sejam escolhidos dinamicamente. O particionamento baseado em campo é compatível nos campos com o tipo de dados Integer, BigInteger, Date ou DateTime.

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo de carimbo de data e hora, aceitamos o formato de carimbo de data e hora do Spark usado nas consultas SQL do Spark.

  Exemplos de valores válidos:

  ```
  "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`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: o número de partições.

Exemplo:

```
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"
    }
```

Particionamento com base em registros

Você pode fornecer a opção adicional NUM_PARTITIONS do Spark se quiser utilizar a simultaneidade no Spark. Com esse parâmetro, a consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

No particionamento com base em registros, o número total de registros presentes é consultado na API do Oracle NetSuite e dividido pelo número de NUM_PARTITIONS fornecido. O número resultante de registros, em seguida, é obtido simultaneamente por cada subconsulta.

- NUM_PARTITIONS: o número de partições.

Exemplo:

```
netsuiteerp_read = glueContext.create_dynamic_frame.from_options(
    connection_type="netsuiteerp",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "deposit",
        "API_VERSION": "v1",
        "NUM_PARTITIONS": "3"
    }
```

Opções de NetSuite conexão Oracle

A seguir estão as opções de conexão para o Oracle NetSuite:

- ENTITY_NAME(String) - (Obrigatório) Usado para leitura. O nome da NetSuite entidade Oracle. Exemplo: depósito.

- `API_VERSION`(String) - (Obrigatório) Usado para leitura. APIVersão do Oracle NetSuite Rest que você deseja usar. O valor será v1, já que a Oracle NetSuite atualmente oferece suporte somente à versão v1.
- `SELECTED_FIELDS`(Lista<String>) - Padrão: vazio (SELECT*). Usado para leitura. Lista de colunas separadas por vírgulas que você deseja selecionar para a entidade selecionada.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Ele deve estar no SQL formato Spark.
- `QUERY`(String): padrão: vazia. Usado para leitura. SQLConsulta completa do Spark.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta (particionamento baseado em campo).
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido, usado no particionamento baseado em campo.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido, usado no particionamento baseado em campo.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura. Usado em particionamento baseado em campo e registro.
- `INSTANCEE_URL`(String) - Uma NetSuite instância válida URL com formato https://{account-id}.suitetalk.api.netsuite.com.

Limitações e notas para o NetSuite conector Oracle

A seguir estão as limitações ou observações do NetSuite conector Oracle:

- Os valores dos parâmetros access_token e refresh_token estão no formato JSON Web Token (). JWT O token de acesso é válido por 60 minutos, enquanto o refresh_token é válido por sete dias.
- Durante a geração do ID do cliente e do segredo do cliente, se você selecionar PUBLIC CLIENT "" junto com "AUTHORIZATIONCODEGRANT“, o token de atualização só será válido por três horas e será usado apenas uma vez.
- Você pode buscar no máximo 1.000.000 de registros usando o conector.
- As partições são criadas de forma que cada partição busque registros em múltiplos de 1000, exceto possivelmente a última que buscará os registros restantes.

Conectar ao OpenSearch Service no AWS Glue Studio

O AWS Glue oferece suporte integrado ao Amazon OpenSearch Service. O AWS Glue Studio fornece uma interface visual para conectar ao Amazon OpenSearch Service, criar trabalhos de integração de dados e executá-los no runtime Spark do AWS Glue Studio sem servidor. Esse recurso não é compatível com o OpenSearch Service com tecnologia sem servidor.

O AWS Glue Studio cria uma conexão unificada para o Amazon OpenSearch Service. Para ter mais informações, consulte Considerações.

Tópicos

- Criar uma conexão com o OpenSearch Service
- Criar um nó de origem do OpenSearch Service
- Criar um nó de destino do OpenSearch Service
- Opções avançadas

Criar uma conexão com o OpenSearch Service

Pré-requisitos:

- Identifique o endpoint do domínio, *aosEndpoint* e porta, *aosPort* do qual gostaria de ler, ou crie o recurso seguindo as instruções na documentação do Amazon OpenSearch Service. Para obter mais informações sobre a criação de domínios, consulte Criar e gerenciar domínios do Amazon OpenSearch Service na documentação do Amazon OpenSearch Service.

  Um endpoint de domínio do Amazon OpenSearch Service terá o seguinte formato padrão, https://search-*domainName*-*unstructuredIdContent*.*region*.es.amazonaws.com. Para obter mais informações sobre a identificação do endpoint do domínio, consulte Criar e gerenciar domínios do Amazon OpenSearch Service na documentação do Amazon OpenSearch Service.

  Identifique ou gere credenciais de autenticação básica HTTP, *aosUser* e *aosPassword* para seu domínio.

Para configurar uma conexão com o OpenSearch Service:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do OpenSearch Service. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets

Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

- Ao selecionar Pares chave/valor, crie um par para a chave USERNAME com o valor *aosUser*.
- Ao selecionar Pares chave/valor, crie um par para a chave PASSWORD com o valor *aosPassword*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para uso futuro em AWS Glue.

   - Ao selecionar um Tipo de conexão, escolha OpenSearch Service.
   - Ao selecionar um endpoint de domínio, forneça *aosEndpoint*.
   - Ao selecionar uma porta, forneça *aosPort*.
   - Ao selecionar um Segredo da AWS, forneça o *secretName*.

Criar um nó de origem do OpenSearch Service

Pré-requisitos necessários

- Uma conexão do AWS Glue OpenSearch Service, configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called "Criar uma conexão com o OpenSearch Service".
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Um índice do OpenSearch Service do qual você gostaria de ler, *aosIndex*.

Adicionar uma fonte de dados do OpenSearch Service

Para adicionar um nó de Fonte de dados – OpenSearch Service:

1. Escolha a conexão para sua fonte de dados do OpenSearch Service. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o OpenSearch Service. Para mais informações, consulte a seção the section called "Criar uma conexão com o OpenSearch Service" anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.

2. Forneça o Índice que você gostaria de ler.
3. Opcionalmente, forneça Consulta, uma consulta do OpenSearch para fornecer resultados mais específicos. Para obter mais informações sobre como escrever consultas do OpenSearch, consulte the section called “Ler do OpenSearch Service”.
4. Em Propriedades personalizadas do OpenSearch Service, insira parâmetros e valores conforme o necessário.

Criar um nó de destino do OpenSearch Service

Pré-requisitos necessários

- Uma conexão do AWS Glue OpenSearch Service, configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão com o OpenSearch Service”.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Um índice do OpenSearch Service em que você gostaria de escrever, `aosIndex`.

Adicionar um destino de dados do OpenSearch Service

Para adicionar um nó de Destino de dados – OpenSearch Service:

1. Escolha a conexão para sua fonte de dados do OpenSearch Service. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o OpenSearch Service. Para mais informações, consulte a seção the section called “Criar uma conexão com o OpenSearch Service” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Forneça o Índice que você gostaria de ler.
3. Em Propriedades personalizadas do OpenSearch Service, insira parâmetros e valores conforme o necessário.

Opções avançadas

É possível fornecer opções avançadas ao criar um nó do OpenSearch Service. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexões do OpenSearch Service”.

Conexão ao Okta

A API do Okta é a interface programática do Okta, usada para gerenciar contas e campanhas grandes ou complexas do Okta. Se você usa o Okta, pode conectar o AWS Glue à conta do Okta. Em seguida, será possível usar o Okta como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Okta e serviços da AWS ou outras aplicações compatíveis.

Tópicos

- Suporte do AWS Glue para o Okta
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Okta
- Configuração de conexões do Okta
- Leitura de entidades do Okta
- Referência de opções de conexão do Okta
- Etapas para a criação de uma nova conta e aplicação de desenvolvedor do Okta
- Limitações

Suporte do AWS Glue para o Okta

O AWS Glue oferece suporte ao Okta da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Okta.

Compatível como destino?

Não.

Versões compatíveis da API do Okta

v1.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Okta

Antes de usar o AWS Glue para transferir dados de ou para o Okta, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Okta. Para obter mais informações sobre como criar uma conta, consulte Etapas para a criação de uma nova conta e aplicação de desenvolvedor do Okta.
- Sua conta do Okta está habilitada para acesso à API.
- Você criou uma integração com a OAuth2 API na sua conta do Okta. Essa integração fornece as credenciais de cliente que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para obter mais informações, consulte as etapas para criar uma aplicação cliente e credenciais do OAuth2.0: Etapas para a criação de uma nova conta e aplicação de desenvolvedor do Okta
- Você tem uma conta do Okta com um OktaApiToken. Consulte a documentação do Okta.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Okta. Para conexões típicas, você não precisa fazer mais nada no Okta.

Configuração de conexões do Okta

O Okta oferece suporte a dois tipos de mecanismos de autenticação:

- Autenticação OAuth: o Okta oferece suporte ao tipo de concessão `AUTHORIZATION_CODE`.
  - Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O Console do AWS Glue redirecionará o usuário para o Okta, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Okta.
  - Os usuários podem optar por criar sua própria aplicação conectada no Okta e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Okta para fazer login e autorizar o acesso do AWS Glue aos recursos.
  - Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
  - Para obter mais informações, consulte a documentação pública do Okta sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth.
- Autenticação personalizada:

- Para obter a documentação pública do Okta sobre como gerar as chaves de API necessárias para a autorização personalizada, consulte a documentação do Okta.

Para configurar uma conexão do Okta:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para a autenticação OAuth:
      - Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Para a autenticação personalizada:
      - Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave `OktaApiToken`.
2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Em Conexões, escolha Criar conexão.
   b. Ao selecionar uma Fonte de dados, selecione o Okta.
   c. Forneça seu subdomínio do Okta.
   d. Selecione o URL do domínio do Okta da sua conta do Okta.
   e. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
```

```
    ]
}
```

f. Selecione o tipo de autenticação para se conectar à fonte de dados.

g. Para o tipo de autenticação OAuth2, forneça o ClientId da aplicação cliente gerenciada pelo usuário da aplicação Okta.

h. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

i. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Okta

Pré-requisitos

- Um objeto do Okta do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Aplicações	Sim	Sim	Não	Sim	Não
Dispositivos	Sim	Sim	Não	Sim	Sim
Grupos	Sim	Sim	Sim	Sim	Sim
Usuários	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Tipos de usuário	Não	Não	Não	Sim	Não

Exemplo

```
okta_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Okta",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "applications",
        "API_VERSION": "v1"
    }
```

Detalhes das entidades e dos campos do Okta

Lista de entidades:

- Aplicação: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Application/
- Dispositivo: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Device/
- Grupo: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/Group/
- Usuário: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/User/
- Tipo de usuário: https://developer.okta.com/docs/api/openapi/okta-management/management/tag/UserType/

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valores válidos: "2024-02-06".
- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: número de partições.

Exemplo

```
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"
    }
```

Referência de opções de conexão do Okta

Estas são as opções de conexão do Okta:

- ENTITY_NAME(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Okta.
- API_VERSION(string): (obrigatório) usado para leitura/gravação. A versão da API Rest do Okta que você deseja usar. Exemplo: v1.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- FILTER_PREDICATE(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- PARTITION_FIELD(string): usado para leitura. Campo a ser usado para particionar a consulta.
- LOWER_BOUND(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.

- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Etapas para a criação de uma nova conta e aplicação de desenvolvedor do Okta

Crie uma conta de desenvolvedor no Okta para ter acesso à API do Okta. Uma conta de desenvolvedor gratuita do Okta dá acesso à maioria dos principais recursos de desenvolvedor necessários para acessar a API do Okta.

Para criar uma conta de desenvolvedor no Okta

1. Navegue até https://developer.okta.com/signup/.
2. Insira as informações da conta: e-mail, nome, sobrenome e país/região. Escolha I'm not a robot e, em seguida, Signup.
3. Um e-mail de verificação é enviado para o seu ID de e-mail registrado. Você receberá um link em seu e-mail para ativar sua conta de desenvolvedor do Okta. Selecione Ativar.
4. Você será redirecionado para a página de redefinição de senha. Digite a nova senha duas vezes e escolha Reset password.
5. Você será redirecionado para o painel da sua conta de desenvolvedor do Okta.

Para criar uma aplicação cliente e credenciais do OAuth 2.0

1. No painel do desenvolvedor, escolha Create App Integration.

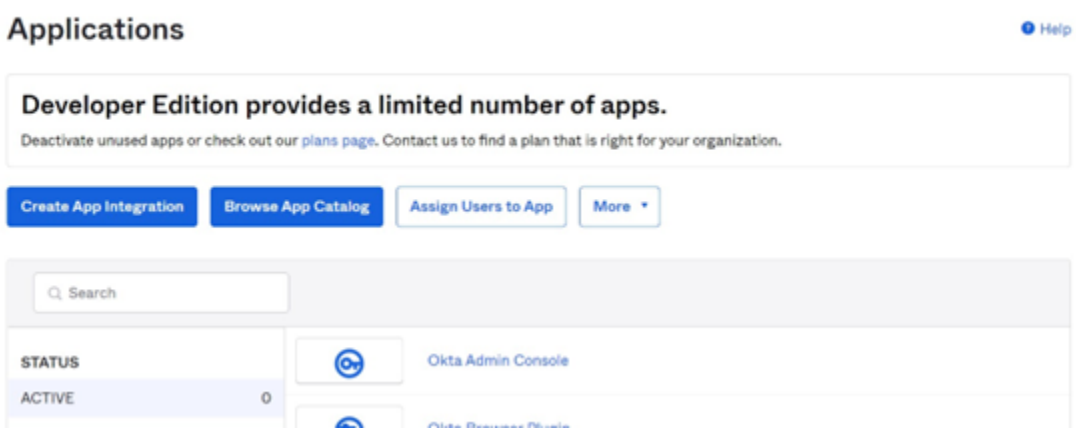

2. A janela Create a new app Integration será exibida e apresentará vários métodos de login. Selecione OIDC –OpenID Connect.
3. Rola para baixo até a seção Application type. Selecione a opção Web Application e escolha Next.
4. Na tela “New Web App Integration”, preencha as seguintes informações:
   - App integration name: insira o nome da aplicação.
   - Grant type: escolha Authorization Code e Refresh Token na lista.
   - Sign-in redirect URIs: escolha Add URI e adicione `https://{regioncode}.console.aws.amazon.com/appflow/oauth`. Por exemplo, se estiver usando `us-west-2 (Oregon)`, você pode adicionar `https://us-east-1.console.aws.amazon.com/appflow/oauth`.
   - Controlled Access: atribua a aplicação aos seus grupos de usuários conforme necessário e escolha Save.
5. Seu ID e segredo do cliente são gerados.

Limitações

Estas são as limitações do conector do Okta:

- Para a entidade “Aplicações”, somente um filtro pode ser aplicado. Se mais de um filtro for aplicado, será retornado um erro 400 Bad Request com o resumo do erro: “Critérios de pesquisa inválidos”.
- O suporte ao recurso de ordenação está disponível apenas para consultas de pesquisa. Por exemplo, `http://dev-15940405.okta.com/api/v1/groups?search=type e.q. "OKTA_GROUP"&sortBy=lastUpdated&sortOrder=asc`

Conexão com o PayPal

O PayPal é um sistema de pagamentos que facilita transferências de dinheiro online entre partes, como transferências entre clientes e fornecedores online. Se você for usuário do PayPal, sua conta contém dados sobre suas transações, como pagadores, datas e status. É possível usar o AWS Glue para transferir dados do PayPal para determinados serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para PayPal
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do PayPal
- Configuração de conexões do PayPal
- Leitura de entidades do PayPal
- Opções de conexão do PayPal
- Limitações e notas do conector do PayPal

Suporte do AWS Glue para PayPal

O AWS Glue oferece suporte ao PayPal da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do PayPal.

Compatível como destino?

Nº

Versões da API do PayPal com suporte

Versões da API do PayPal com suporte:

- v1

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
```

```
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do PayPal

Antes de poder usar o AWS Glue para transferir dados do PayPal, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do PayPal com credenciais de cliente.
- Sua conta do PayPal tem acesso à API com uma licença válida.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do PayPal. Para conexões típicas, você não precisa fazer mais nada no PayPal.

Configuração de conexões do PayPal

O PayPal oferece suporte ao tipo de concessão CLIENT CREDENTIALS para OAuth2.

- Esse tipo de concessão é considerado OAuth 2.0 de 2 pernas, pois é usado pelos clientes para obter um token de acesso fora do contexto de um usuário. O AWS Glue é capaz de usar o ID do cliente e o segredo do cliente para autenticar as APIs do PayPal que são fornecidas pelos serviços personalizados que você define.
- Cada serviço personalizado é de propriedade de um usuário somente de API que tem um conjunto de perfis e permissões que autorizam o serviço a realizar ações específicas. Um token de acesso é associado a um único serviço personalizado.
- Esse tipo de concessão resulta em um token de acesso de curta duração, que pode ser renovado com uma chamada ao endpoint `/v2/oauth2/token` novamente.
- Para obter a documentação pública do PayPal para OAuth 2.0 com credenciais de cliente, consulte Autenticação.

Para configurar uma conexão do PayPal:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha PayPal.
   b. Forneça o `INSTANCE_URL` da instância do PayPal à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
```

```
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Obtenção de credenciais do Outh 2.0

Para chamar a API REST, você precisará trocar seu ID do cliente e segredo do cliente por um token de acesso. Para obter mais informações, consulte Conceitos básicos das APIs REST do PayPal.

Leitura de entidades do PayPal

Pré-requisito

Um objeto do PayPal do qual você deseja ler. Você precisará do nome do objeto, `transaction`.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
transaction	Sim	Sim	Não	Sim	Sim

Exemplo:

```
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"
    }
```

Detalhes de entidade e campo do PayPal:

Entidades com metadados estáticos:

Entidade	Campo	Tipo de dados	Operadores compatíveis
transaction	transaction_initiation_date	DateTime	Entre
	last_refreshed_datetime	String	N/D
	payment_instrument_type	String	=
	balance_affecting_records_only	String	=
	store_id	String	=
	terminal_id	String	=
	transaction_currency	String	=
	transaction_id	String	N/D
	transaction_status	String	N/D
	transaction_type	String	N/D
	transaction_info	Struct	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	payer_info	Struct	N/D
	shipping_info	Struct	N/D
	cart_info	Struct	N/D
	store_info	Struct	N/D
	auction_info	Struct	N/D
	incentive_info	Struct	N/D

Consultas de particionamento

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo Datetime, aceitamos o valor no formato ISO.

  Exemplos de valores válidos:

  ```
  "2024-07-01T00:00:00.000Z"
  ```

- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: o número de partições.

Há suporte para o campo a seguir para particionamento por entidade:

Nome da entidade	Campos de particionamento	Tipo de dados
transaction	transaction_initiation_date	DateTime

Exemplo: .

```
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"
    }
```

Opções de conexão do PayPal

Estas são as opções de conexão do PayPal:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no PayPal.
- `API_VERSION`(string): (obrigatório) usado para leitura. Versão da API Rest do PayPal que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações e notas do conector do PayPal

Estas são as limitações ou notas do conector do PayPal:

- A documentação de transações do PayPal menciona que são necessárias no máximo três horas para que as transações executadas apareçam na chamada de listagem de transações. No entanto, observou-se que leva mais tempo do que isso, dependendo da `last_refreshed_datetime`. Aqui, `last_refreshed_datetime` é o tempo até o qual você tem dados disponíveis nas APIs.
- Se a `last_refreshed_datetime` for menor que a `end_date` solicitada, então a `end_date` torna-se igual à `last_refreshed_datetime`, pois só temos dados até aquele ponto.
- O campo `transaction_initiation_date` é um filtro obrigatório a ser fornecido para a entidade `transaction` e o intervalo de datas máximo suportado para esse campo é de 31 dias.
- Quando você chama a solicitação de API da entidade `transaction` com filtros (parâmetros de consulta) diferentes do campo `transaction_initiation_date`, espera-se que o valor do campo `ending_balance` não seja obtido na resposta.

Conexão ao Pendo

O Pendo fornece um armazenamento de dados avançado para dados de interação do usuário. Os clientes transferirão esses dados para a AWS para que possam combiná-los a outros dados do produto, realizar análises adicionais, criar painéis e definir alertas, se quiserem.

Tópicos

- Suporte do AWS Glue para o Pendo
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Pendo
- Configuração de conexões do Pendo
- Leitura de entidades do Pendo
- Opções de conexão do Pendo
- Limitações

Suporte do AWS Glue para o Pendo

O AWS Glue oferece suporte ao Pendo da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Pendo.

Compatível como destino?

Não.

Versões compatíveis da API do Pendo

v1

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.

- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Pendo

Antes de usar o AWS Glue para transferir do Pendo, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Pendo com uma `apiKey` habilitada com `write access`.
- Sua conta do Pendo tem acesso à API com uma licença válida.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Pendo. Para conexões típicas, você não precisa fazer mais nada no Pendo.

Configuração de conexões do Pendo

O Pendo oferece suporte à autenticação personalizada.

Para obter a documentação pública do Pendo sobre como gerar as chaves de API necessárias para a autorização personalizada, consulte Autenticação – Documentação da API REST do Pendo.

Para configurar uma conexão do Pendo:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   - Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave `apiKey`.

   > **Note**
   >
   > É preciso criar um segredo por conexão em AWS Glue.

2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar uma Fonte de dados, selecione o Pendo.
   b. Forneça o `instanceUrl` da instância do Pendo à qual você deseja se conectar.

c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
    "Version": "2012-10-17",
        "Statement": [
            {
                "Effect": "Allow",
                "Action": [
                    "secretsmanager:DescribeSecret",
                    "secretsmanager:GetSecretValue",
                    "secretsmanager:PutSecretValue",
                    "ec2:CreateNetworkInterface",
                    "ec2:DescribeNetworkInterface",
                    "ec2:DeleteNetworkInterface",
                ],
                "Resource": "*"
            }
        ]
    }
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma conexão de rede adicional.

Leitura de entidades do Pendo

Pré-requisitos

Um objeto do Pendo do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

- Atributo
- Guia

- Página
- Relatório
- Dados de relatório
- Visitante
- Conta
- Evento
- Evento do recurso
- Evento do guia
- Evento da página
- Evento de enquete
- Evento de rastreamento

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Atributo	Não	Não	Não	Sim	Não
Guia	Não	Não	Não	Sim	Não
Página	Não	Não	Não	Sim	Não
Relatório	Não	Não	Não	Sim	Não
Dados de relatório	Não	Não	Não	Sim	Não
Visitante (API de agregação)	Sim	Não	Sim	Sim	Não
Conta (API de agregação)	Sim	Não	Sim	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Evento (API de agregação)	Sim	Não	Sim	Sim	Não
Evento do recurso (API de agregação)	Sim	Não	Sim	Sim	Sim
Evento do guia (API de agregação)	Sim	Não	Sim	Sim	Sim
Conta (API de agregação)	Sim	Não	Sim	Sim	Sim
Evento da página (API de agregação)	Sim	Não	Sim	Sim	Sim
Evento de enquete (API de agregação)	Sim	Não	Sim	Sim	Sim
Evento de rastreamento (API de agregação)	Sim	Não	Sim	Sim	Sim

Exemplo

```
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"
    }
```

Consultas de particionamento

É possível fornecer as opções adicionais do Spark PARTITION_FIELD, LOWER_BOUND, UPPER_BOUND e NUM_PARTITIONS se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- PARTITION_FIELD: o nome do campo a ser usado para particionar a consulta.
- LOWER_BOUND: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo DateTime, aceitamos o valor no formato ISO.

  Exemplo de valor válido:

  ```
  "2024-07-01T00:00:00.000Z"
  ```
- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

A tabela a seguir descreve os detalhes do suporte do campo de particionamento da entidade:

Nome da entidade
Event
Evento do recurso
Evento do guia
Evento da página

Nome da entidade
Evento de enquete
Evento de rastreamento

Exemplo: .

```
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"
    }
```

Opções de conexão do Pendo

Estas são as opções de conexão do Pendo:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Pendo.
- `INSTANCE_URL`(string): (obrigatório) um URL de instância válida do Pendo com os valores permitidos a seguir.
  - Padrão
  - Europa
  - US1
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Pendo Engage que você deseja usar. Por exemplo: 3.0.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.

- PARTITION_FIELD(string): usado para leitura. Campo a ser usado para particionar a consulta.
- LOWER_BOUND(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- UPPER_BOUND(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações

Estas são as limitações do conector do Pendo:

- Não há suporte à paginação no Pendo.
- Somente os objetos da API de agregação (`Account`, `Event`, `Feature Event`, `Guide Events`, `Page Event`, `Poll Event`, `Track Event` e `Visitor`) oferecem suporte à filtragem
- DateTimeRange é um parâmetro de filtro obrigatório para objetos da API de agregação (`Event`, `Feature Event`, `Guide Events`, `Page Event`, `Poll Event,`, `Track Event`)
- O período dayRange será arredondado para baixo até o início do período no fuso horário. Por exemplo, se o filtro fornecido for `2023-01-12T07:55:27.065Z`, esse período será arredondado para o início do período, que é `2023-01-12T00:00:00Z`.

Conexão ao Pipedrive

O Pipedrive é um CRM de pipeline de vendas projetado para ajudar pequenas empresas a gerenciar leads, rastrear atividades de vendas e fechar mais negócios. O Pipedrive permite que as equipes de vendas em pequenas empresas simplifiquem processos e consolidem dados de vendas em uma ferramenta unificada de CRM de vendas. Se você usa o Pipedrive, pode conectar o AWS Glue à conta do Pipedrive. Em seguida, será possível usar o Pipedrive como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Pipedrive e serviços da AWS ou outras aplicações compatíveis.

Tópicos

- Suporte do AWS Glue para o Pipedrive
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Pipedrive

- Configuração de conexões do Pipedrive
- Leitura de entidades do Pipedrive
- Referência de opções de conexão do Pipedrive
- Limitações

Suporte do AWS Glue para o Pipedrive

O AWS Glue oferece suporte ao Pipedrive da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Pipedrive.

Compatível como destino?

Não.

Versões compatíveis da API do Pipedrive

v1.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
```

```
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Pipedrive

Antes de usar o AWS Glue para transferir dados do Pipedrive, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Pipedrive.
- Sua conta do Pipedrive está habilitada para acesso à API.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Pipedrive. Para conexões típicas, você não precisa fazer mais nada no Pipedrive.

Configuração de conexões do Pipedrive

O Pipedrive oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O usuário que está criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao

AWS Glue, na qual ele não precisa fornecer quaisquer informações relacionadas ao OAuth, exceto o instanceurl do Pipedrive. O Console do AWS Glue redirecionará o usuário para o Pipedrive, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Pipedrive.

- Os usuários devem optar por criar sua própria aplicação conectada no Pipedrive e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Pipedrive para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso ficará ativo por uma hora e poderá ser atualizado automaticamente sem a interação do usuário por meio do token de atualização.
- Para obter mais informações, consulte a documentação sobre como criar uma aplicação conectada para o fluxo AUTHORIZATION_CODE do OAuth.

Para configurar uma conexão do Pipedrive:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET.
2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Em Conexões de dados, escolha Criar conexão.
   b. Ao selecionar uma Fonte de dados, selecione o Pipedrive.
   c. Forneça o instanceURL do Pipedrive.
   d. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
```

```
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

e. Forneça o ClientId da aplicação cliente gerenciada pelo usuário do Pipedrive ao qual deseja se conectar.

f. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

g. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`. Escolha Próximo.
4. Forneça o connectionName e escolha Próximo.
5. Na página seguinte, escolha Criar conexão. Você precisará fazer login no Pipedrive. Forneça seu nome de usuário e senha e selecione Fazer login.
6. Depois de fazer login, escolha Continuar para a aplicação. Agora sua conexão está pronta para ser usada.
7. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Pipedrive

Pré-requisitos

- Um objeto do Pipedrive do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Atividades	Sim	Sim	Não	Sim	Sim
Tipo de atividade	Não	Não	Não	Sim	Não
Logs de chamadas	Não	Não	Não	Sim	Não
Moedas	Sim	Sim	Não	Sim	Não
Ofertas	Sim	Sim	Sim	Sim	Sim
Leads	Sim	Sim	Sim	Sim	Não
Fontes de leads	Não	Sim	Não	Sim	Não
Rótulos de leads	Não	Não	Não	Não	Não
Observações	Sim	Sim	Sim	Sim	Sim
Organização	Sim	Sim	Não	Sim	Sim
Conjuntos de permissões	Sim	Não	Não	Sim	Não
Pessoas	Sim	Sim	Sim	Sim	Sim
Pipelines	Não	Sim	Não	Sim	Não
Produtos	Sim	Sim	Não	Sim	Sim
Perfis	Não	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Estágios	Sim	Sim	Não	Sim	Não
Usuários	Não	Não	Não	Sim	Não

Exemplo

```
pipedrive_read= glueContext.create_dynamic_frame.from_options(
    connection_type="PIPEDRIVE",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "activites",
        "API_VERSION": "v1"
    }
```

Detalhes das entidades e dos campos do Pipedrive

Lista de entidades:

- Atividades: https://developers.pipedrive.com/docs/api/v1/Activities
- Tipo de atividade: https://developers.pipedrive.com/docs/api/v1/ActivityTypes
- Logs de chamadas: https://developers.pipedrive.com/docs/api/v1/CallLogs
- Moedas: https://developers.pipedrive.com/docs/api/v1/Currencies
- Ofertas: https://developers.pipedrive.com/docs/api/v1/Deals
- Leads: https://developers.pipedrive.com/docs/api/v1/Leads
- Fontes de leads: https://developers.pipedrive.com/docs/api/v1/LeadSources
- Rótulos de leads: https://developers.pipedrive.com/docs/api/v1/LeadLabels
- Observações: https://developers.pipedrive.com/docs/api/v1/Notes
- Organizações: https://developers.pipedrive.com/docs/api/v1/Organizations
- Conjuntos de permissões: https://developers.pipedrive.com/docs/api/v1/PermissionSets
- Pessoas: https://developers.pipedrive.com/docs/api/v1/Persons
- Pipelines: https://developers.pipedrive.com/docs/api/v1/Pipelines

- Produtos: https://developers.pipedrive.com/docs/api/v1/Products
- Perfis: https://developers.pipedrive.com/docs/api/v1/Roles
- Estágios: https://developers.pipedrive.com/docs/api/v1/Stages
- Usuários: https://developers.pipedrive.com/docs/api/v1/Users

Entidade	Tipo de dado	Operadores com suporte
Atividades, Ofertas, Observações, Organização, Pessoas e Produtos.	Data	'='
	Inteiro	'='
	String	'='
	Booliano	'='

Particionamento de consultas

No Pipedrive, apenas um campo (due_date) da entidade Atividades oferece suporte ao particionamento baseado em campos, que é um campo de Data.

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: número de partições.

Exemplo

```
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"
    }
```

Referência de opções de conexão do Pipedrive

Estas são as opções de conexão do Pipedrive:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Pipedrive.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. A versão da API Rest do Pipedrive que você deseja usar. Exemplo: v1.
- `INSTANCE_URL`(string): (obrigatório) o URL da instância em que o usuário deseja executar as operações. Exemplo: v1.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações

Estas são as limitações do conector do Pipedrive:

- O Pipedrive oferece suporte ao particionamento baseado em campos para apenas uma entidade (Atividades).
- O Pipedrive oferece suporte ao particionamento baseado em registros para as entidades Atividades, Ofertas, Observações, Pessoas, Organizações e Produtos.
- Na entidade Ofertas, o campo de status como filtro retornará todos os registros se um valor de filtro inválido for usado.
- Na entidade Ofertas, não há suporte para a ordenação com vários campos.
- Para obter dados de performance, utilizamos uma conta local da AWS. No entanto, devido à limitação de atualizar o token de acesso localmente, o trabalho do AWS Glue para processar 1 GB de dados está falhando. Consequentemente, otimizamos o teste de performance com 179 MB de dados, e os resultados acima são baseados nessa otimização. Ainda assim, observamos que, com um número cada vez maior de partições, o endpoint SaaS está levando mais tempo, em comparação ao processamento com uma única partição. Consultamos a equipe de suporte do Pipedrive sobre esse comportamento e eles nos informaram que o Pipedrive está silenciosamente limitando as solicitações e atrasando a resposta. Portanto, executar o trabalho do AWS Glue com grandes conjuntos de dados ou chamar o mesmo endpoint de API várias vezes pode resultar em um problema de tempo limite devido à implementação da API do Pipedrive. Porém, os tempos de resposta do conector e do shim estão diminuindo conforme o esperado com o aumento do número de partições.

Conexão ao Productboard

O Productboard é o sistema de gerenciamento de produtos que ajuda as equipes a colocar os produtos certos no mercado com mais rapidez. Mais de 3 mil empresas modernas orientadas por produto, como a Zendesk, a UiPath e a Microsoft, usam o Productboard para entender do que os usuários realmente precisam, priorizar o próximo projeto a ser criado e reunir toda a equipe em torno do seu roteiro.

Tópicos

- Suporte do AWS Glue para o Productboard
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Productboard
- Configuração de conexões do Productboard
- Leitura de entidades do Productboard
- Opções de conexão do Productboard

- Criação de uma conta do Productboard
- Limitações

Suporte do AWS Glue para o Productboard

O AWS Glue oferece suporte ao Productboard da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Productboard.

Compatível como destino?

Não.

Versões compatíveis da API do Productboard

v1

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Productboard

Antes de usar o AWS Glue para transferir do Productboard, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Productboard com e-mail e senha. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Productboard.
- Você deve ter uma conta da AWS criada com acesso de serviço ao AWS Glue.
- Você tem os detalhes de autenticação de uma conta do Productboard: o token JWT, se quiser usar a autenticação personalizada, ou o ID e segredo do cliente, se quiser usar o OAuth2.0.
- Se o usuário quiser usar o `OAuth2.0`, registre sua aplicação no Productboard e configure a aplicação seguindo as instruções em How to integrate with Productboard via OAuth2 - developer documentation.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Productboard. Para conexões típicas, você não precisa fazer mais nada no Productboard.

Configuração de conexões do Productboard

O Productboard oferece suporte à autenticação personalizada e `OAuth2.0`. Para `OAuth2.0`, o Productboard oferece suporte ao tipo de concessão `AUTHORIZATION_CODE`.

- Esse tipo de concessão é considerado um `OAuth` de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O usuário que está criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao AWS Glue, na qual ele não precisa fornecer quaisquer informações relacionadas ao `OAuth`, exceto o ID e segredo do cliente do Productboard. O Console do AWS Glue redirecionará o usuário para o Productboard, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Productboard.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no Productboard e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Productboard para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Productboard sobre como criar uma aplicação conectado para o fluxo `AUTHORIZATION_CODE OAuth`, consulte How to integrate with Productboard via OAuth2 - developer documentation.

Para configurar uma conexão do Productboard:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   - Para a autenticação `OAuth`: para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   - Para `Custom auth`: para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada `JWT token` com a chave `access_token`.

   > **Note**
   >
   > É preciso criar um segredo por conexão em AWS Glue.

2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar uma Fonte de dados, selecione o Productboard.

b. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

c. Selecione o tipo de autenticação para se conectar à fonte de dados:

- Para a autenticação `OAuth`: forneça o `Token URL` e o `User Managed Client Application ClientId` da aplicação Productboard.

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma conexão de rede adicional.

Leitura de entidades do Productboard

Pré-requisitos

Um objeto do Productboard do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

- Relatórios de abuso
- Automação
- Campanhas
- Detalhes de cliques
- Listas
- Membros
- Detalhes de abertura
- Segmentos
- Lojas
- Cancelamentos de assinaturas

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Atributos	Sim	Sim	Não	Sim	Sim
Component es	Não	Sim	Não	Sim	Não
Produtos	Não	Sim	Não	Sim	Não
Status de recursos	Não	Sim	Não	Sim	Sim
Definições de campos personali zados	Não	Sim	Não	Sim	Não
Valores de campos	Sim	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
personali zados					

Exemplo

```
Productboard_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Productboard",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "feature",
        "API_VERSION": "1"
    }
```

Detalhes das entidades e dos campos do Productboard

- Atributos
- Componentes
- Status de recursos
- Produtos
- Definições de campos personalizados
- Valores de campos personalizados

Opções de conexão do Productboard

Estas são as opções de conexão do Productboard:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Productboard.
- `API_VERSION`(string): (obrigatório) usado para leitura. A versão da API Rest do Productboard Engage que você deseja usar. Por exemplo: 3.0.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.

- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.

Criação de uma conta do Productboard

1. Navegue até a página de inscrição do Productboard, insira seu ID de e-mail e senha e escolha Log me in.
2. No campo Account Name, insira o nome da sua conta do Productboard e marque a caixa de seleção I agree to the Privacy Policy check.
3. Na página Now create your workspace, no campo Workspace URL, insira o URL do seu novo espaço de trabalho. Em seguida, escolha Continue para prosseguir para a próxima página e fornecer os detalhes que faltam.

   Sua conta de teste foi criada. A conta de teste é gratuita por 15 dias. Após o período de avaliação expirar, você poderá adquirir um plano pago. Anote o endereço de e-mail, a senha e o URL do espaço de trabalho. Você precisará dessas informações para acessar sua conta no futuro.

Registro de uma aplicação **`OAuth2.0`**

1. Navegue até a página de login do Productboard, insira seu ID de e-mail e senha e escolha Log in.
2. Selecione o ícone User no canto superior direito e escolha Account and billing no menu suspenso.
3. Selecione Extras e escolha Registered apps no menu suspenso.
4. Localize e escolha Register An App.
5. Insira os detalhes a seguir:

   - App name: o nome da aplicação.
   - Company/Organization: o nome da sua empresa ou organização.
   - App website: o site da aplicação.
   - Redirect URI: um padrão de URI de redirecionamento é um caminho de URI (ou uma lista de caminhos separados por vírgula) para o qual o Productboard pode redirecionar (se solicitado) quando o fluxo de login for concluído. Por exemplo, `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`

6. Escolha Criar.
7. O ID do cliente e o Segredo do cliente agora estarão visíveis. Copie e salve-os em um lugar seguro. Escolha Concluído.

> **Note**
>
> Suas strings de ID do cliente e Segredo do cliente são credenciais usadas para estabelecer uma conexão com esse conector ao usar o AppFlow ou o AWS Glue.

Recuperação das credenciais de CustomAuth

1. Navegue até a página de login do Productboard, insira seu ID de e-mail e senha e escolha Log me in.

   Você será redirecionado para a página inicial.
2. Na página inicial, navegue até Workspace Settings > Integrations > Public APIs > Access Token.

> **Note**
>
> Se a seção Public APIs não estiver visível, é possível que sua conta tenha o plano Essentials. O acesso aos tokens da API requer pelo menos um plano Pro. Os recursos e os nomes dos planos estão sujeitos a alterações. Para obter mais informações sobre os pacotes, consulte os preços do Productboard.

3. Escolha + para gerar um novo token e certifique-se de guardá-lo com segurança para referência futura.

Criação de credenciais do **`OAuth2.0`**

Para utilizar a autenticação `OAuth2.0` com o conector do Productboard, você precisa registrar sua aplicação na plataforma do Productboard e gerar um `Client ID` e um `Client Secret`.

1. Navegue até a página de login do Productboard, insira seu ID de e-mail e senha e escolha Log me in.
2. Para registrar uma nova aplicação OAuth2 com sua conta do Productboard, navegue até a página do Productboard.

3. Preencha os campos obrigatórios e selecione os escopos necessários para cada entidade que você deseja acessar.

   > **Note**
   >
   > Você escolheu os quatro escopos a seguir, que são necessários para as seis entidades com suporte.

4. O URL de redirecionamento deve ter o seguinte formato: `https://ap-southeast-2\\.console\\.aws\\.amazon\\.com`

   > **Note**
   >
   > Os URLs de redirecionamento do Appflow estão sujeitos a alterações. Quando estiverem disponíveis, atualize os URLs de redirecionamento para a plataforma do AWS Glue.

5. O ID do cliente e o Segredo do cliente agora estarão visíveis. Copie e salve-os em um lugar seguro.
6. Você pode configurar e verificar o `OAuth2` seguindo as etapas na documentação do desenvolvedor How to Integrate with Productboard via OAuth2.

Limitações

Estas são as limitações do conector do Productboard:

- O Productboard não oferece suporte ao particionamento baseado em campos ou em registros.

Conexão com o QuickBooks

O QuickBooks é uma aplicação de contabilidade líder para pequenas e médias empresas. As aplicações de contabilidade do QuickBooks datam da década de 1980 como um dos primeiros produtos da Intuit e, consequentemente, eram originalmente um software de desktop. Hoje, o QuickBooks oferece várias aplicações contábeis e financeiras empresariais como software instalável e software SaaS baseado em nuvem. Como usuário do QuickBooks, é possível conectar o AWS Glue à sua conta do QuickBooks. Em seguida, será possível usar o QuickBooks como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o QuickBooks e serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para QuickBooks
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do QuickBooks
- Configuração de conexões do QuickBooks
- Leitura de entidades do QuickBooks
- Opções de conexão do QuickBooks
- Limitações e notas do conector do QuickBooks

Suporte do AWS Glue para QuickBooks

O AWS Glue oferece suporte ao QuickBooks da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do QuickBooks.

Compatível como destino?

Nº

Versões da API do QuickBooks com suporte

Versões da API do QuickBooks com suporte:

- v3

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
```

```
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do QuickBooks

Antes de poder usar o AWS Glue para transferir dados do QuickBooks, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do QuickBooks.
- Sua conta do QuickBooks precisa estar habilitada para acesso à API.

Para obter mais informações, consulte os seguintes tópicos na documentação do QuickBooks:

- Criar uma conta do Intuit
- Criar e começar a desenvolver sua aplicação

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do QuickBooks. Para conexões típicas, você não precisa fazer mais nada no QuickBooks.

Configuração de conexões do QuickBooks

O QuickBooks oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2. O tipo de concessão determina como o AWS Glue se comunica com o QuickBooks para solicitar acesso aos seus dados.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no QuickBooks e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o QuickBooks para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do QuickBooks sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Configuração do OAuth 2.0.

Para configurar uma conexão do QuickBooks:

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha QuickBooks.
   b. Forneça o URL da instância e o ID da instância do QuickBooks com a qual deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
```

```
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do QuickBooks

Pré-requisito

Um objeto do QuickBooks do qual você deseja ler.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Conta	Sim	Sim	Sim	Sim	Sim
Cobrança	Sim	Sim	Sim	Sim	Sim
Informações da empresa	Não	Não	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Cliente	Sim	Sim	Sim	Sim	Sim
Funcionário	Sim	Sim	Sim	Sim	Sim
Estimativa	Sim	Sim	Sim	Sim	Sim
Fatura	Sim	Sim	Sim	Sim	Sim
Item	Sim	Sim	Sim	Sim	Sim
Pagamento	Sim	Sim	Sim	Sim	Sim
Preferências	Não	Não	Não	Sim	Não
Lucros e perdas	Sim	Não	Não	Sim	Não
Agência tributária	Sim	Sim	Sim	Sim	Sim
Fornecedores	Sim	Sim	Sim	Sim	Sim

Exemplo:

```
QuickBooks_read = glueContext.create_dynamic_frame.from_options(
    connection_type="quickbooks",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v3"
    }
```

Detalhes de entidade e campo do QuickBooks:

Para obter mais informações sobre os detalhes das entidades e dos campos, consulte:

- Conta
- Cobrança
- CompanyInfo
- Cliente
- Funcionário
- Estimativa
- Fatura
- Item
- Pagamento
- Preferências
- ProfitAndLoss
- TaxAgency
- Fornecedor

Particionamento de consultas

Particionamento com base em campo:

No QuickBooks, os campos de tipo de dados Integer e DateTime oferecem suporte a particionamento com base em campos.

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Datetime, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

  Exemplos de valores válidos:

```
"2024-05-07T02:03:00.00Z"
```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

Exemplo: .

```
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"
    }
```

Particionamento com base em registros:

A consulta original é dividida em NUM_PARTITIONS subconsultas que podem ser executadas pelas tarefas do Spark simultaneamente:

- NUM_PARTITIONS: o número de partições.

Exemplo: .

```
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"
    }
```

Opções de conexão do QuickBooks

Estas são as opções de conexão do QuickBooks:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no QuickBooks.
- `INSTANCE_URL`(string): (obrigatório) um URL de instância válida do QuickBooks.
- `API_VERSION`(string): (obrigatório) usado para leitura. Versão da API Rest do QuickBooks que você deseja usar.
- `REALM_ID`(string): um ID que identifica uma empresa individual do QuickBooks Online para a qual você envia solicitações.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações e notas do conector do QuickBooks

Estas são as limitações ou notas do conector do QuickBooks:

- Na API `taxAgency`, a ordenação por filtragem não está funcionando conforme o esperado.

Conectar ao Salesforce

O Salesforce fornece software de gerenciamento de relacionamento com o cliente (CRM) que ajuda nas atividades de vendas, atendimento ao cliente, comércio eletrônico e muito mais. Se você usa o Salesforce, pode conectar o AWS Glue à sua conta do Salesforce. Em seguida, você pode usar o Salesforce como fonte de dados ou destino em seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre os serviços do Salesforce e do AWS ou de outros aplicativos compatíveis.

Tópicos

- Compatibilidade do AWS Glue com o Salesforce
- Políticas que contêm as operações de API para criar e usar conexões

- Configurar o Salesforce
- Aplicar perfil de administrador do sistema
- Configurar conexões do Salesforce
- Ler do Salesforce
- Gravação no Salesforce
- Opções de conexão do Salesforce
- Limitações do conector do Salesforce
- Configurar o fluxo do código de autorização para Salesforce
- Configurar o fluxo OAuth do portador JWT para Salesforce

Compatibilidade do AWS Glue com o Salesforce

O AWS Glue é compatível com o Salesforce da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do Salesforce.

Compatível como destino?

Sim. É possível usar trabalhos de ETL do AWS Glue para gravar registros no Salesforce.

Versões compatíveis da API do Salesforce

As seguintes versões da API do Salesforce são compatíveis

- v58.0
- v59.0
- v60.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política do IAM a seguir descreve as permissões necessárias para criar, gerenciar e usar conexões do Salesforce com trabalhos de ETL do AWS Glue. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"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": "*"
        }
    ]
}
```

É possível usar as seguintes políticas do IAM para permitir acesso:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Se você fornecer opções de rede ao criar uma conexão com o Salesforce, as seguintes ações também deverão ser incluídas no perfil do IAM:

```
{
    "Version": "2012-10-17",
    "Statement": [
```

```
        {
            "Effect": "Allow",
            "Action": [
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

Para obter informações sobre conexões de ETL zero do Salesforce, consulte Pré-requisitos de ETL zero.

Para obter informações sobre conexões de ETL zero do Salesforce, consulte Pré-requisitos de ETL zero.

Configurar o Salesforce

Antes de usar o AWS Glue para transferir dados para ou do Salesforce, é preciso atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Ter uma conta do Salesforce.
- A conta do Salesforce estar habilitada para acesso à API. O acesso à API estar ativado por padrão para as edições Enterprise, Unlimited, Developer e Performance.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Salesforce. O AWS Glue trata dos requisitos restantes com a aplicação conectada gerenciada pela AWS.

A aplicação conectada gerenciada pela AWS para o Salesforce

A aplicação conectada gerenciada pela AWS ajuda a criar uma conexão com o Salesforce em menos etapas. No Salesforce, uma aplicação conectada é uma estrutura que autoriza aplicações externas, como o AWS Glue, a acessar seus dados do Salesforce usando OAuth 2.0. Para usar a aplicação conectada gerenciada pela AWS, crie uma conexão com o Salesforce usando o console do AWS

Glue. Ao configurar a conexão, defina o tipo de concessão do OAuth como Código de autorização e mantenha a caixa Usar aplicação cliente gerenciada pela AWS marcada.

Ao salvar a conexão, você será redirecionado ao Salesforce para iniciar sessão e aprovar o acesso do AWS Glue a sua conta do Salesforce.

Aplicar perfil de administrador do sistema

No Salesforce, siga as etapas para aplicar o perfil de administrador do sistema:

1. No Salesforce, navegue até Configurações > Aplicações conectadas > Uso do OAuth por aplicações conectados.
2. Na lista de aplicações conectadas, localize AWS Glue e escolha Instalar. Se necessário, escolha Desbloquear.
3. Navegue até Configurações > Gerenciar aplicações conectadas e depois escolha AWS Glue. Em Políticas do OAuth, escolha Usuários aprovados pelo administrador são pré-autorizados e selecione o perfil Administrador do sistema. Essa ação restringe o acesso ao AWS Glue somente aos usuários com o perfil de administrador do sistema.

Aplicar perfil de administrador do sistema

No Salesforce, siga as etapas para aplicar o perfil de administrador do sistema:

1. No Salesforce, navegue até Configurações > Aplicações conectadas > Uso do OAuth por aplicações conectados.
2. Na lista de aplicações conectadas, localize AWS Glue e escolha Instalar. Se necessário, escolha Desbloquear.
3. Navegue até Configurações > Gerenciar aplicações conectadas e depois escolha AWS Glue. Em Políticas do OAuth, escolha Usuários aprovados pelo administrador são pré-autorizados e selecione o perfil Administrador do sistema. Essa ação restringe o acesso ao AWS Glue somente aos usuários com o perfil de administrador do sistema.

Configurar conexões do Salesforce

Para configurar uma conexão do Salesforce:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

a. Para o tipo de concessão JWT_TOKEN, o segredo deve conter a chave JWT_TOKEN com seu valor.

b. Para o tipo de concessão AuthorizationCode:

   i. Para uma aplicação conectada gerenciada pela AWS, é necessário fornecer um segredo vazio ou um segredo com algum valor temporário.

   ii. Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada `Consumer Secret` com `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como a chave.

c. Observação: é necessário criar um segredo para sua conexão no AWS Glue.

2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

   a. Ao selecionar um Tipo de conexão, escolha Salesforce.

   b. Forneça o INSTANCE_URL da instância do Salesforce à qual você deseja se conectar.

   c. Forneça o ambiente do Salesforce.

   d. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   e. Selecione o tipo de concessão do OAuth2 que deseja usar para as conexões. O tipo de concessão determina como o AWS Glue se comunica com o Salesforce para solicitar acesso aos seus dados. A escolha afeta os requisitos que você deve atender antes de criar a conexão. Escolha um destes tipos:

- Tipo de concessão JWT_BEARER: funciona bem para cenários de automação, pois permite que um token Web JSON (JWT) seja criado antecipadamente com as permissões de um usuário específico na instância do Salesforce. O criador tem controle sobre por quanto tempo o JWT é válido. O AWS Glue é capaz de usar o JWT para obter um token de acesso, que é usado para chamar as APIs do Salesforce.

  Esse fluxo exige que o usuário tenha criado uma aplicação conectada em sua instância do Salesforce, o que permite a emissão de tokens de acesso baseados em JWT para os usuários.

  Para obter informações sobre como criar uma aplicação conectada para o fluxo OAuth do portador JWT, consulte Fluxo do portador JWT do OAuth 2.0 para integração de servidor a servidor. Para configurar o fluxo do portador JWT com a aplicação conectada do Salesforce, consulte Configurar o fluxo OAuth do portador JWT para Salesforce.
- Tipo de concessão AUTHORIZATION_CODE: é considerado um OAuth de "três pernas", pois depende do redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O usuário que está criando uma conexão pode, por padrão, confiar em uma aplicação do AWS Glue conectada (aplicação cliente gerenciada pelo AWS Glue), na qual não precisa fornecer nenhuma informação relacionada ao OAuth, exceto o URL da instância do Salesforce. O console do AWS Glue redirecionará o usuário ao Salesforce para iniciar sessão e autorizar que as permissões solicitadas pelo AWS Glue acessem sua instância do Salesforce.

  Os usuários ainda podem optar por criar a própria aplicação conectada no Salesforce e fornecer ID e segredo do cliente próprios ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados ao Salesforce para iniciar sessão e autorizar o acesso do AWS Glue a seus recursos.

  Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

  Para obter mais informações sobre como criar uma aplicação conectada para o fluxo de código de autorização OAuth, consulte the section called “Configurar o fluxo do código de autorização para Salesforce”.

f. Selecione o `secretName` que deseja usar para essa conexão no AWS Glue para armazenar os tokens OAuth 2.0.

g. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
4. Ao fornecer opções de rede, conceda também ao perfil do IAM as seguintes permissões:

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

Configurar conexões do Salesforce com a AWS CLI

É possível criar conexões do Salesforce usando a 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
```

Ler do Salesforce

Pré-requisito

Um sObject do Salesforce do qual você deseja ler. Você precisará do nome do objeto, como `Account`, `Case` ou `Opportunity`.

Exemplo:

```
salesforce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="salesforce",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v60.0"
    }
```

Consultas de particionamento

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Para os campos Data e Timestamp, o conector aceita o formato de timestamp do Spark usado nas consultas SQL do Spark.

  Exemplos de valores válidos:

  ```
  "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`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: o número de partições.
- `TRANSFER_MODE`: aceita dois modos: `SYNC` e `ASYNC`. O padrão é `SYNC`. Quando definido como `ASYNC`, o Bulk API 2.0 Query será usado para processamento.

Exemplo:

```
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"
    }
```

Gravação no Salesforce

Pré-requisitos

Um sObject do Salesforce no qual você deseja escrever. Você precisará do nome do objeto, como `Account`, `Case` ou `Opportunity`.

O conector do Salesforce é compatível com quatro operações de gravação:

- INSERT
- UPSERT
- UPDATE
- DELETE

Ao usar a operação de gravação `UPSERT`, a opção `ID_FIELD_NAMES` deverá ser fornecida para especificar o campo de ID externo para os registros.

Você também pode adicionar opções de conexão:

- `TRANSFER_MODE`: aceita dois modos: `SYNC` e `ASYNC`. O padrão é `SYNC`. Quando definido como `ASYNC`, o Bulk API 2.0 Ingest será usado para processamento.
- `FAIL_ON_FIRST_ERROR`: o valor padrão é `FALSE`, o que significa que o trabalho AWS Glue continuará processando todos os dados, mesmo que haja alguns registros de gravação com falha. Quando definido como `TRUE`, o trabalho AWS Glue falhará se houver algum registro de gravação com falha e não continuará o processamento.

Exemplo

```
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"
    }
```

Opções de conexão do Salesforce

As seguintes opções de conexão são aceitas pelo conector do Salesforce:

- `ENTITY_NAME`(String): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Salesforce.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Salesforce que deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.

  Ao fornecer um predicado de filtro, apenas o operador `AND` é compatível. Outros operadores, como `OR` e `IN`, ainda não são compatíveis.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `IMPORT_DELETED_RECORDS`(string): (padrão): FALSE. Usado para leitura. Para obter os registros excluídos durante a consulta.

- `WRITE_OPERATION`(string): padrão: INSERT. Usado para gravação. O valor deve ser INSERT, UPDATE, UPSERT, DELETE.
- `ID_FIELD_NAMES`(string): padrão: null. Necessário para UPDATE e UPSERT.

Limitações do conector do Salesforce

Estas são as limitações do conector do Salesforce:

- Só oferecemos suporte ao Spark SQL. Não há suporte para o Salesforce SOQL.
- Marcadores de trabalho não são compatíveis.
- Todos os nomes de campos do Salesforce diferenciam maiúsculas de minúsculas. Ao gravar no Salesforce, os dados devem corresponder às maiúsculas e minúsculas dos campos definidos no Salesforce.

Configurar o fluxo do código de autorização para Salesforce

Consulte a documentação pública do Salesforce para habilitar o fluxo do código de autorização do OAuth 2.0.

Para configurar uma aplicação conectada:

1. Ative a caixa de seleção Habilitar configurações de OAuth.
2. No campo de texto URL de retorno de chamada, insira um ou mais URLs de redirecionamento para o AWS Glue.

   Os URLs de redirecionamento têm o seguinte formato:

   https://*region*.console.aws.amazon.com/gluestudio/oauth

   Nesse URL, region é o código da região da AWS em que você usa o AWS Glue para transferir dados do Salesforce. Por exemplo, o código para a região Leste dos EUA (Norte da Virgínia) é `us-east-1`. Para essa região, o URL é:

   https://us-east-1.console.aws.amazon.com/gluestudio/oauth

   Para obter uma lista das regiões da AWS com as quais o AWS Glue é compatível, consulte Endpoints e cotas do AWS Glue na Referência geral da AWS.
3. Ative a caixa de seleção Exigir segredo para o fluxo do servidor Web.

4. Na lista Escopos OAuth disponíveis, adicione os seguintes escopos:
   - Gerenciar dados do usuário via APIs (api)
   - Acessar permissões personalizadas (custom_permissions)
   - Acessar o serviço de URL de identidade (ID, perfil, e-mail, endereço, telefone)
   - Acessar identificadores de usuário exclusivos (openid)
   - Executar solicitações a qualquer momento (refresh_token, offline_access)
5. Defina a política de token de atualização para a aplicação conectada como O token de atualização é válido até ser revogado. Caso contrário, seus trabalhos falharão quando seu token de atualização expirar. Para obter mais informações sobre como verificar e editar a política de token de atualização, consulte Gerenciar políticas de acesso OAuth para uma aplicação conectada na documentação do Salesforce.

Configurar o fluxo OAuth do portador JWT para Salesforce

Consulte a documentação pública do Salesforce para habilitar a integração de servidor a servidor com os Tokens Web JSON do OAuth 2.0.

Após criar um JWT e configurar a aplicação conectada adequadamente no Salesforce, você poderá criar uma nova conexão do Salesforce com a chave `JWT_TOKEN` definida em seu segredo do Secrets Manager. Defina o tipo de concessão OAuth como Token do portador JWT ao criar a conexão.

Conexão com o Salesforce Marketing Cloud

O Salesforce Marketing Cloud é um fornecedor de software de automação e analytics de marketing para e-mail, dispositivos móveis, redes sociais e marketing on-line. Ele também oferece serviços de consultoria e implementação. Caso seja um usuário do Salesforce Marketing Cloud, você poderá conectar o AWS Glue à sua conta do Salesforce Marketing Cloud. Depois, você poderá usar o Salesforce Marketing Cloud como uma fonte de dados ou um destino em seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre os serviços do Salesforce Marketing Cloud e da AWS ou de outras aplicações compatíveis.

Tópicos

- AWS Glue suporte para Salesforce Marketing Cloud
- Políticas contendo as API operações para criar e usar conexões
- Configuração do Salesforce Marketing Cloud

- Configuração de conexões do Salesforce Marketing Cloud
- Leitura de entidades do Salesforce Marketing Cloud
- Gravação em entidades do Salesforce Marketing Cloud
- Opções de conexão do Salesforce Marketing Cloud
- Limitações e observações do conector do Salesforce Marketing Cloud

AWS Glue suporte para Salesforce Marketing Cloud

AWS Glue oferece suporte ao Salesforce Marketing Cloud da seguinte forma:

Compatível como fonte?

Sim. Você pode usar AWS Glue ETL trabalhos para consultar dados do Salesforce Marketing Cloud.

Compatível como destino?

Não.

Versões compatíveis do Salesforce Marketing Cloud API

As seguintes API versões do Salesforce Marketing Cloud são suportadas:

- v1

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS IAM permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
```

```
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, use as seguintes IAM políticas gerenciadas:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configuração do Salesforce Marketing Cloud

Antes de poder usar o AWS Glue para transferir dados do Salesforce Marketing Cloud, você precisa atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Ter uma conta do Salesforce Marketing Cloud. Para ter mais informações, consulte Criação de uma conta do Salesforce Marketing Cloud.
- A conta do Salesforce Marketing Cloud estar habilitada para acesso à API. O acesso à API estar ativado por padrão para as edições Enterprise, Unlimited, Developer e Performance.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Salesforce Marketing Cloud. Para conexões típicas, você não precisa fazer mais nada no Salesforce Marketing Cloud.

Criação de uma conta do Salesforce Marketing Cloud

Para o Salesforce Marketing Cloud, você precisa entrar em contato com o fornecedor para criar uma conta. Se você ou sua empresa tiver uma associação com a Salesforce, entre em contato com o gerente de contas da Salesforce para solicitar uma licença do Salesforce Marketing Cloud. Caso contrário, você pode solicitar o contato de um representante da Salesforce da seguinte maneira:

1. Acesse https://www.salesforce.com/in/products/marketing-cloud/overview/ e escolha Cadastrar-se.
2. Selecione o link Entre em contato conosco no canto superior direito da página.
3. Insira as informações necessárias e escolha Entre em contato comigo.

Um representante da Salesforce entrará em contato com você para discutir suas necessidades.

Criação de um projeto e de credenciais do OAuth 2.0

Para obter um projeto e credenciais do OAuth 2.0:

1. Faça login na instância do Salesforce Marketing Cloud com seu nome de usuário e senha e autentique-se usando seu número de celular registrado.
2. Clique no seu perfil no canto superior direito e depois acesse Configuração.
3. Em Ferramentas dr plataforma, escolha Aplicações e, em seguida, escolha Pacotes instalados.

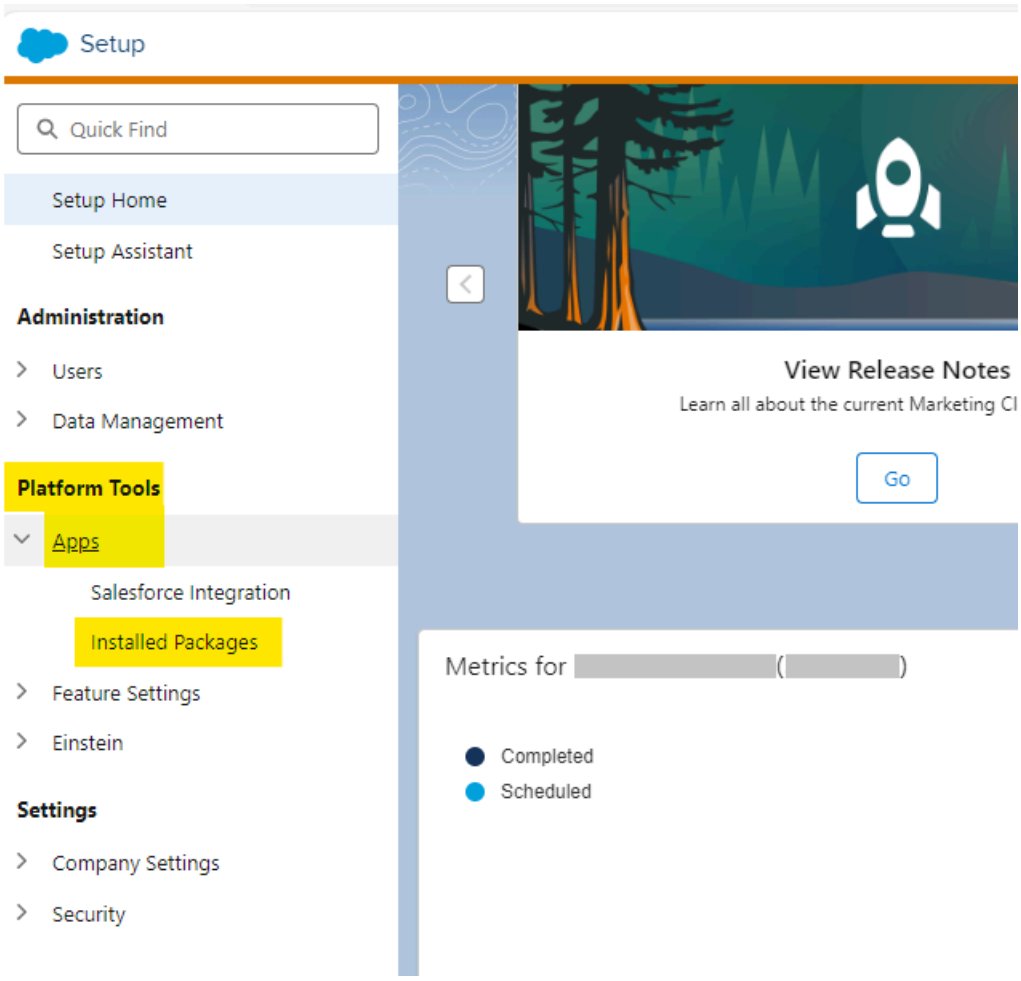

4. Na página Pacotes instalados, clique em Novo no canto superior direito. Forneça o nome e a descrição do pacote.

   Salve o pacote. Depois que o pacote for salvo, você poderá visualizar os detalhes dele.

5. Na página Detalhes do pacote, na seção Componente, escolha Adicionar componente.

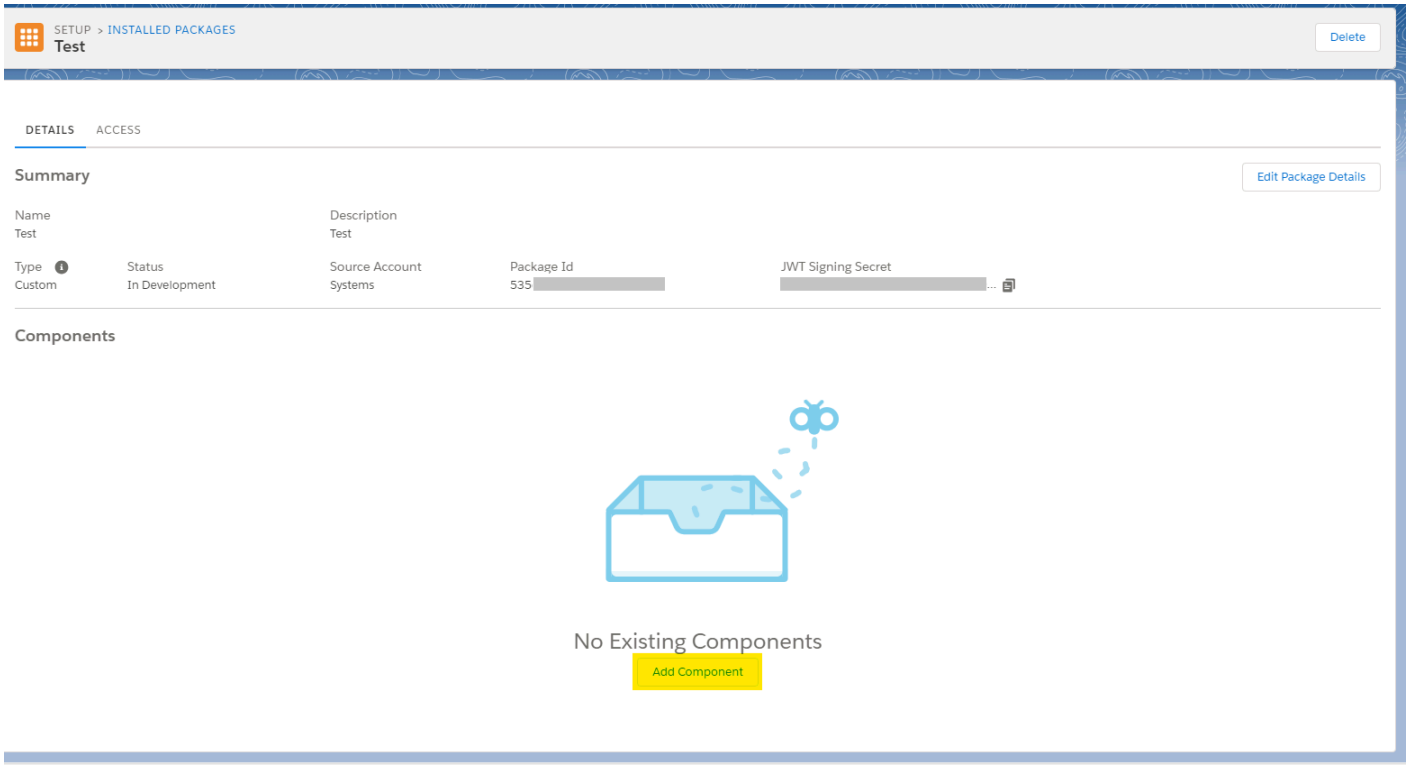

6. Selecione o Tipo de componente “Integração de API” e clique em Avançar.
7. Selecione o Tipo de integração “Servidor a servidor” (que tem o tipo de concessão de credenciais do cliente do OAuth) e clique em Avançar.
8. Adicione os escopos com base nos seus requisitos e clique em Salvar.

Configuração de conexões do Salesforce Marketing Cloud

O Salesforce Marketing Cloud oferece suporte ao tipo de concessão CLIENT CREDENTIALS para OAuth2.

- Esse tipo de concessão é considerado OAuth 2.0 de 2 pernas, pois é usado pelos clientes para obter um token de acesso fora do contexto de um usuário. AWS Glue é capaz de usar o ID do cliente e o segredo do cliente para autenticar as APIs do Salesforce Marketing Cloud que são fornecidas pelos serviços personalizados que você define.
- Cada serviço personalizado é de propriedade de um usuário somente de API que tem um conjunto de perfis e permissões que autorizam o serviço a realizar ações específicas. Um token de acesso é associado a um único serviço personalizado.
- Esse tipo de concessão resulta em um token de acesso de curta duração, que pode ser renovado com uma chamada a um endpoint de identidade.

- Para obter a documentação pública do Salesforce Marketing Cloud para OAuth 2.0 com credenciais de cliente, consulte Configuração do seu ambiente de desenvolvimento para pacotes aprimorados.

Para configurar uma conexão do Salesforce Marketing Cloud:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Salesforce Marketing Cloud.
   b. Forneça o `Subdomain Endpoint` da Salesforce Marketing Cloud à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Salesforce Marketing Cloud

Pré-requisito

Um objeto do Salesforce Marketing Cloud do qual você deseja ler. Você precisará do nome do objeto, como `Activity` ou `Campaigns`. A tabela a seguir mostra as entidades compatíveis.

Entidades compatíveis quanto à origem:

Entidade	Interface	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a SELECIONAR *	Oferece suporte a particionamento
Retorno de chamada de notificação de eventos	REST	Não	Não	Não	Sim	Não
Seed-List	REST	Não	Sim	Não	Sim	Não
Configuração	REST	Sim	Sim	Não	Sim	Não
Verificação de domínio	REST	Sim	Sim	Sim	Sim	Não
Etiquetas de objeto aninhadas	REST	Sim	Não	Não	Sim	Não
Contato	REST	Não	Sim	Não	Sim	Não

Entidade	Interface	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a SELECIONAR *	Oferece suporte a particionamento
Assinatura de notificação de eventos	REST	Não	Não	Não	Sim	Não
Sistema de mensagens	REST	Não	Sim	Não	Sim	Não
Atividade	SOAP	Não	Não	Não	Sim	Sim
Evento de devolução	SOAP	Não	Não	Não	Sim	Sim
Evento de clique	SOAP	Não	Não	Não	Sim	Sim
Área de conteúdo	SOAP	Não	Não	Não	Sim	Sim
Extensão de dados	SOAP	Não	Sim	Não	Sim	Sim
E-mail	SOAP	Não	Sim	Não	Sim	Sim
Evento de e-mail encaminhado	SOAP	Não	Sim	Não	Sim	Sim
OptinEvent de e-mail encaminhado	SOAP	Não	Sim	Não	Sim	Sim

Entidade	Interface	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a SELECIONAR *	Oferece suporte a particionamento
Link	SOAP	Não	Sim	Não	Sim	Sim
Envio do link	SOAP	Não	Sim	Não	Sim	Sim
Lista	SOAP	Não	Sim	Não	Sim	Sim
Listar assinante	SOAP	Não	Sim	Não	Sim	Sim
Evento não enviado	SOAP	Não	Sim	Não	Sim	Sim
Evento aberto	SOAP	Não	Sim	Não	Sim	Sim
Enviar	SOAP	Não	Sim	Não	Sim	Sim
Evento enviado	SOAP	Não	Sim	Não	Sim	Sim
Assinante	SOAP	Não	Sim	Não	Sim	Sim
Evento de pesquisa	SOAP	Não	Sim	Não	Sim	Sim
Evento cancelamento de assinatura	SOAP	Não	Sim	Não	Sim	Sim
Eventos de auditoria	REST	Não	Sim	Sim	Sim	Não
Campanhas	REST	Não	Sim	Sim	Sim	Não

Entidade	Interface	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a SELECIONAR *	Oferece suporte a particionamento
Interações	REST	Não	Sim	Sim	Sim	Não
Ativos de conteúdo	REST	Não	Sim	Sim	Sim	Não

Exemplo de 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"
    }
```

Exemplo de 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"
    }
```

Detalhes das entidades e dos campos do Salesforce Marketing Cloud:

As tabelas a seguir descrevem as entidades do Salesforce Marketing Cloud. Há entidades REST com metadados estáticos e entidades SOAP com metadados dinâmicos.

Entidades REST com metadados estáticos:

Entidade	Campo	Tipo de dados	Operadores compatíveis
Retorno de chamada de notificação de eventos	callbackId	String	
	callbackName	String	
	url	String	
	maxBatchSize	Inteiro	
	status	String	
	statusReason	String	
Seed-List	id	String	
	nome	String	
	description	String	
	activeSeedCount	Inteiro	
Configuração	customerKey	String	
	nome	String	
	description	String	
	locationType	String	'='
	awsFileTransferLocation	Struct	
Verificação de domínio	enterpriseId	Inteiro	
	status	String	'='
	domainType	String	'='
	memberId	Inteiro	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	emailSendTime	DateTime	
	domínio	String	
	isSendable	Booleano	
Etiquetas de objeto aninhadas	id	Inteiro	
	modifiedDate	DateTime	
	tags	Lista	
	nome	String	
	description	String	
	parentId	Inteiro	
Contato	values	Lista	
Assinatura de notificação de eventos	subscriptionName	String	
	callbackId	String	
	callbackName	String	
	eventCategoryTypes	Lista	
	filtros	Lista	
	url	String	
	maxBatchSize	Inteiro	
	subscriptionId	String	
	status	String	
	statusReason	String	

Entidade	Campo	Tipo de dados	Operadores compatíveis
Sistema de mensagens	deliveryTime	DateTime	
	id	String	
	messageId	String	
	status	String	
	com	Struct	
Interações	status	String	'='
	id	String	
	key	String	
	nome	String	
	lastPublishedDate	DateTime	
	description	String	
	version	Inteiro	
	workflowApiVersion	Inteiro	
	createdDate	DateTime	
	modifiedDate	DateTime	
	metas	Struct	
	stats	Struct	
	entryMode	String	
	defaults	Struct	
	executionMode	Struct	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	definitionId	String	
Ativos de conteúdo	id	Inteiro	
	customerKey	String	
	objectId	String	
	contentType	String	
	assetType	Struct	
	nome	String	
	description	String	
	proprietário	Struct	
	createdDate	DateTime	
	createdBy	Struct	
	modifiedDate	DateTime	
	modifiedBy	Struct	
	miniatura	Struct	
	categoria	Struct	
	meta	Struct	
	visualizações	Struct	
	availableViews	Struct	
	dados	Struct	
	legacyData	Struct	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	modelVersion	Inteiro	
	Versão	Inteiro	
	Locked (Bloqueada)	Booleano	
	FileProperties	Struct	
	Tags	Lista	
	Conteúdo	String	
	Projeto	String	
	SuperContent	String	
	CustomFields	Struct	
	Blocos	Struct	
	MinBlocks	Inteiro	
	MaxBlocks	Inteiro	
	Canais	Struct	
	AllowedBlocks	Lista	
	Slots	Struct	
	BusinessUnitAvailability	Struct	
	sharingProperties	Struct	
	sharingProperties.sharedWith	Struct	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	sharingProperties.sharingType	String	
	Modelo	Struct	
	Arquivo	String	
	GenerateFrom	String	
Eventos de auditoria	id	Inteiro	
	createdDate	DateTime	
	memberId	Inteiro	
	enterpriseId	Inteiro	
	funcionário	Struct	
	objectType	Struct	
	operação	Struct	
	objeto	Struct	
	transactionId	String	
Campanhas	id	Inteiro	
	createdDate	DateTime	
	modifiedDate	DateTime	
	nome	String	
	description	String	
	campaignCode	String	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	color	String	
	favorito	Booleano	

Entidades SOAP com metadados dinâmicos:

Entidade	Tipo de dados	Operadores compatíveis
Atividade	String	LIKE,!=,=
	Struct	
	Inteiro	!=,=,>=,<=,<,>
	Duplo	!=,=,>=,<=,<,>
	Booleano	!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
Evento de devolução	Inteiro	!=,=,>=,<=,<,>
	DateTime	>=,<=,<,>,=,BETWEEN
	String	LIKE,!=,=
	Struct	
Evento de clique	Inteiro	!=,=,>=,<=,<,>
	DateTime	>=,<=,<,>,=,BETWEEN
	String	LIKE,!=,=
	Struct	
Área de conteúdo	Struct	

Entidade	Tipo de dados	Operadores compatíveis
	String	LIKE,!=,=
	Inteiro	!=,=,>=,<=,<,>
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=
Extensão de dados	DateTime	>=,<=,<,>,=,BETWEEN
	String	LIKE,!=,=
E-mail	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=
	Struct	
Evento de e-mail encaminhado	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
OptinEvent de e-mail encaminhado	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Link	Inteiro	!=,=,>=,<=,<,>

Entidade	Tipo de dados	Operadores compatíveis
Envio do link	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	Duplo	!=,=,>=,<=,<,>
Lista	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Listar assinante	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento não enviado	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento aberto	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Enviar	Inteiro	!=,=,>=,<=,<,>

Entidade	Tipo de dados	Operadores compatíveis
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=
	Struct	
Evento enviado	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Assinante	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento de pesquisa	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Struct	
Evento cancelamento de assinatura	Inteiro	!=,=,>=,<=,<,>
	String	LIKE,!=,=
	DateTime	>=,<=,<,>,=,BETWEEN
	Booleano	!=,=

Entidade	Tipo de dados	Operadores compatíveis
	Struct	

Particionamento de consultas

No Salesforce Marketing Cloud, os campos de tipo de dados Integer e DateTime oferecem suporte a particionamento com base em campo.

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Para o campo de carimbo de data e hora, aceitamos o formato de carimbo de data e hora do Spark usado nas consultas SQL do Spark.

  Exemplos de valores válidos:

  ```
  “2024-05-07T02:03:00.00Z"
  ```
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: o número de partições.

Exemplo:

```
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"
```

```
    }
```

Gravação em entidades do Salesforce Marketing Cloud

Pré-requisitos

- Um objeto do Salesforce Marketing no qual você deseja gravar. Você precisará especificar o nome do objeto, como `List` ou `Campaigns`, ou qualquer outra entidade descrita na tabela abaixo.
- O conector do Salesforce Marketing Cloud é compatível com três operações de gravação:
  - INSERT
  - UPSERT
  - UPDATE

  Ao usar as operações de gravação `UPDATE` e `UPSERT`, você deverá fornecer opção `ID_FIELD_NAMES` para especificar o campo de ID externo para os registros.

Entidades compatíveis para destino:

Entidade	Prioridade	Interface (REST, SOAP etc.)	Pode ser inserido	Pode ser atualizado	Pode ser upserted
Campanhas	P0	REST	S- Único	S- Único	N
Ativos de conteúdo	P0	REST	S- Único, em massa	S- Único	N
Contato	P1	REST	S- Único	S- Único	N
Verificação de domínio	P1	REST	S- Único	S- Único, em massa	N
Retorno de chamada de notificação de eventos	P1	REST	S- Único	S- Único	N

Entidade	Prioridade	Interface (REST, SOAP etc.)	Pode ser inserido	Pode ser atualizado	Pode ser upserted
Assinatura de notificação de eventos	P1	REST	S- Único	S- Único	N
Sistema de mensagens	P1	REST	S- Único	N	N
Tags de objetos aninhados	P2	REST	S- Único	S- Único	N
Seed-List	P1	REST	S- Único	S- Único	N
Configuração	P1	REST	S- Único	S- Único	N
Extensão de dados	P0	SOAP	S- Único	S- Único	S- Único
E-mail	P0	SOAP	S- Único	S- Único	N
Lista	P0	SOAP	S- Único	S- Único	N
Enviar	P0	SOAP	S- Único	N	N
Assinante	P0	SOAP	S- Único	S- Único	N

Exemplo de operação INSERT para 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"
```

```
    }
```

Exemplo de operação INSERT para 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"
    }
```

Exemplo de operação UPDATE para 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"
    }
```

Exemplo de operação UPDATE para 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"
    }
```

Exemplo de operação UPSERT para 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"
    }
```

Opções de conexão do Salesforce Marketing Cloud

Confira abaixo as opções de conexão do Salesforce Marketing Cloud:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do objeto no Salesforce Marketing Cloud.
- `API_VERSION`(string): (obrigatório) usado para leitura. Versão da API SOAP e REST do Salesforce Marketing Cloud que você deseja usar.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `WRITE_OPERATION`(string): padrão: INSERT. Usado para gravação. O valor deve ser INSERT, UPDATE e UPSERT.
- `ID_FIELD_NAMES` (String), Padrão: null. Necessário para UPDATE e UPSERT.

Limitações e observações do conector do Salesforce Marketing Cloud

Confira abaixo as limitações ou as observações do conector do Salesforce Commerce Cloud:

- Ao usar o filtro no campo de tipo de dados DateTime, você precisa passar o valor no formato “yyyy-mm-ddThh:MM:ssZ”.
- Na Pré-visualização de dados, o valor boleano do tipo de dados aparece em branco.
- Para entidades SOAP, você pode definir no máximo dois filtros, e para entidades REST, você pode definir somente um filtro, o que restringe o teste de particionamento com filtros.
- Vários comportamentos inesperados foram observados do lado do SaaS: o campo `Link.Alias` na entidade “linksend” não é compatível com o operador CONTAINS (por exemplo, `Link.Alias CONTAINS "ViewPrivacyPolicy"`), e os operadores de filtro para entidades de extensão de dados (como EQUALS e GREATER THAN) não retornam os resultados esperados.
- A API SOAP de ClickEvent do SFMC tem um atraso em refletir os registros recém-criados, portanto, os registros criados recentemente podem não estar imediatamente disponíveis na resposta da API.

  Exemplo: se você criar cinco novos registros de ClickEvent em 2025-01-10T14:30:00 e buscá-los imediatamente usando a API SOAP, a resposta poderá não incluir todos os cinco registros. Pode levar até cinco minutos para que os registros recém-criados apareçam na resposta da API. Esse atraso também pode afetar a recuperação de dados e as execuções programadas.
- Dois formatos DateTime diferentes: 2025-03-11T04:46:00 (sem milissegundos) e 2025-03-11T04:46:00.000Z são compatíveis ao realizar operações de gravação no AWS Glue (com milissegundos).
- Para a entidade Event Notification Subscription, uma assinatura só pode ser criada para um URL de retorno de chamada verificado, e você pode ter até 200 assinaturas por retorno de chamada.
- Para a entidade Event Notification Callback, um máximo de cinquenta registros pode ser criado por conta.

Conexão ao Salesforce Commerce Cloud

A API B2C Commerce é um conjunto de APIs RESTful para interagir com instâncias do B2C Commerce. Ela é conhecida por alguns nomes diferentes: Salesforce Commerce API, o acrônimo SCAPI ou apenas Commerce API.

A API permite aos desenvolvedores criar uma ampla variedade de aplicações, como lojas completas ou ferramentas comerciais personalizadas, para aprimorar o Business Manager. Para todos os clientes do B2C Commerce, a API está disponível sem custo adicional.

A API é dividida em dois grupos principais: APIs de compradores e APIs de administradores. Dentro de cada grupo, elas também são divididas em famílias de APIs e em grupos menores focados em funcionalidades relacionadas.

Tópicos

- Suporte do AWS Glue para o Salesforce Commerce Cloud
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Salesforce Commerce Cloud
- Configuração de conexões do Salesforce Commerce Cloud
- Leitura de entidades do Salesforce Commerce Cloud
- Referência de opções de conexão do Salesforce Commerce Cloud
- Limitações

Suporte do AWS Glue para o Salesforce Commerce Cloud

O AWS Glue oferece suporte ao Salesforce Commerce Cloud da seguinte forma:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Salesforce Commerce Cloud.

Compatível como destino?

Não.

Versões compatíveis da API do Salesforce Commerce Cloud

v1.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
```

```
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Salesforce Commerce Cloud

Antes de usar o AWS Glue para transferir dados do Salesforce Commerce Cloud, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma aplicação cliente do Salesforce Commerce Cloud com clientId e clientSecret.
- Sua conta do Salesforce Commerce Cloud está habilitada para acesso à API.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Salesforce Commerce Cloud. Para conexões típicas, você não precisa fazer mais nada no Salesforce Commerce Cloud.

Configuração de conexões do Salesforce Commerce Cloud

O Salesforce Commerce Cloud oferece suporte ao tipo de concessão CLIENT CREDENTIALS para OAuth2.

- Esse tipo de concessão é considerado um OAuth 2.0 de “duas pernas”, pois é usado pelos clientes para obter um token de acesso fora do contexto de um usuário. O AWS Glue é capaz de usar o ID e o segredo do cliente para autenticar as APIs do Salesforce Commerce Cloud fornecidas pelos serviços personalizados que você definir.
- Cada serviço personalizado é de propriedade de um usuário somente de API que tem um conjunto de perfis e permissões que autorizam o serviço a realizar ações específicas. Um token de acesso é associado a um único serviço personalizado.
- Esse tipo de concessão resulta em um token de acesso de curta duração, que pode ser renovado com uma chamada a um endpoint de identidade.
- Para obter mais informações sobre a documentação do Salesforce Commerce Cloud referente à geração das credenciais do cliente, consulte a documentação do Salesforce.

Para configurar uma conexão do Salesforce Commerce Cloud:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET.
2. Em AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Em Conexões de dados, escolha Criar conexão.
   b. Ao selecionar uma Fonte de dados, selecione o Salesforce Commerce Cloud.
   c. Forneça seu Código curto, ID da organização e ID do site do Salesforce Commerce Cloud.
   d. Selecione o URL do domínio do Salesforce Commerce Cloud da sua conta do Salesforce Commerce Cloud.
   e. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
```

```
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

f. Forneça os escopos OAuth: opcional, o ClientId da aplicação cliente gerenciada pelo usuário do Salesforce Commerce Cloud ao qual deseja se conectar.

g. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

h. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
4. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Salesforce Commerce Cloud

Pré-requisitos

- Um objeto do Salesforce Commerce Cloud do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Atribuições	Sim	Sim	Sim	Sim	Sim
Campanhas	Sim	Sim	Sim	Sim	Sim
Catálogos	Sim	Sim	Sim	Sim	Sim
Categorias	Sim	Sim	Sim	Sim	Sim
Cupons	Sim	Sim	Sim	Sim	Sim
Certificados de presente	Sim	Sim	Sim	Sim	Sim
Produtos	Sim	Sim	Sim	Sim	Sim
Promoções	Sim	Sim	Sim	Sim	Sim
Grupos de código-fonte	Sim	Sim	Sim	Sim	Sim

Exemplo

```
salesforce_commerce_cloud_read = glueContext.create_dynamic_frame.from_options(
     connection_type="SalesforceCommerceCloud",
     connection_options={
         "connectionName": "connectionName",
         "ENTITY_NAME": "campaign",
         "API_VERSION": "v1"
     }
```

Detalhes das entidades e dos campos do Salesforce Commerce Cloud

Lista de entidades:

- Atribuições: https://developer.salesforce.com/docs/commerce/commerce-api/references/assignments
- Campanhas: https://developer.salesforce.com/docs/commerce/commerce-api/references/campaigns
- Catálogos: https://developer.salesforce.com/docs/commerce/commerce-api/references/catalogs
- Categorias: https://developer.salesforce.com/docs/commerce/commerce-api/references/catalogs?meta=searchCategories
- Certificados de presente: https://developer.salesforce.com/docs/commerce/commerce-api/references/gift-certificates
- Produtos: https://developer.salesforce.com/docs/commerce/commerce-api/references/products
- Promoções: https://developer.salesforce.com/docs/commerce/commerce-api/references/promotions
- Grupos de código-fonte: https://developer.salesforce.com/docs/commerce/commerce-api/references/source-code-groups

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valores válidos: `"2024-02-06"`.
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na tabela abaixo:

Entidade	Campo de particionamento	DataType
Campanhas	lastModified	DateTime
Campanhas	startDate	DateTime
Campanhas	endDate	DateTime
Catálogos	creationDate	DateTime
Categorias	creationDate	DateTime
Certificados de presente	merchantId	String
Certificados de presente	creationDate	DateTime
Produtos	creationDate	DateTime
Produtos	lastModified	DateTime
Grupos de código-fonte	creationDate	DateTime
Grupos de código-fonte	startTime	DateTime
Grupos de código-fonte	endTime	DateTime

Exemplo

```
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"
    }
```

Referência de opções de conexão do Salesforce Commerce Cloud

Estas são as opções de conexão do Salesforce Commerce Cloud:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no Salesforce Commerce Cloud.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. A versão da API Rest do Salesforce Commerce Cloud que você deseja usar. Exemplo: v1.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações

Estas são as limitações do conector do Salesforce Commerce Cloud:

- O filtro Contém não está funcionando conforme o esperado durante o particionamento.
- A entidade das zonas de CDN não oferece suporte a instâncias de sandbox e oferece suporte somente aos tipos de instância de desenvolvimento e produção. Para obter mais informações, consulte https://help.salesforce.com/s/articleView?id=cc.b2c_embedded_cdn_overview.htm.
- No Salesforce Commerce Cloud, não há um endpoint de API para buscar metadados dinâmicos. Como resultado, não há uma provisão para oferecer suporte aos campos personalizados nas entidades Produto e Categoria.
- O ID do site é um parâmetro de consulta obrigatório. Você deve passar o valor do ID do site por meio da configuração de conector personalizado. Para obter mais informações, consulte Base URL and Request Formation.

- Você pode aplicar filtros em, no máximo, dois campos (exceto em níveis, se presentes) em uma única solicitação de API com a combinação de diferentes operadores, conforme mencionado na tabela abaixo:

Critérios de filtro	Tem suporte?
Um campo com o operador CONTAINS em uma única solicitação de API.	Sim
Um campo com o operador Equals em uma única solicitação de API.	Sim
Um campo com o operador BETWEEN em uma única solicitação de API.	Sim
Dois ou mais campos com o operador CONTAINS em uma única solicitação de API.	Não
Dois ou mais campos com o operador Equals em uma única solicitação de API.	Não
Dois ou mais campos com o operador BETWEEN em uma única solicitação de API.	Não
Um campo com o operador Equals e um campo com CONTAINS em uma única solicitação de API.	Sim
Um campo com o operador BETWEEN e um campo com CONTAINS em uma única solicitação de API.	Sim
Um campo com o operador BETWEEN e um campo com Equals em uma única solicitação de API.	Sim
Um campo com o operador Equals, um campo com CONTAINS e um campo com BETWEEN em uma única solicitação de API.	Não

Critérios de filtro	Tem suporte?
Um campo com o operador Equals quando a INCREMENTAL PULL é aplicada em uma única solicitação de API.	Sim
Um campo com o operador CONTAINS quando a INCREMENTAL PULL é aplicada em uma única solicitação de API.	Sim
Um campo com o operador BETWEEN quando a INCREMENTAL PULL é aplicada em uma única solicitação de API.	Não
Um operador Equals e um CONTAINS quando a INCREMENTAL PULL é aplicada em uma única solicitação de API.	Não

- Em algumas entidades, o tipo de dados dos campos durante a recuperação é diferente de quando é usado como campos pesquisáveis. Como resultado, não há uma provisão para o recurso de filtro nesses campos. A tabela a seguir fornece detalhes sobre esses campos.

N.º de série	Entity Name	Nome do campo pesquisável	Tipo de dados como pesquisável	Tipo de dados como recuperável
1	Catálogo	nome	String	Struct
2	Catálogo	description	String	Struct
3	Categoria	nome	String	Struct
4	Categoria	description	String	Struct
5	Produto	nome	String	Struct
6	Produto	pesquisável	Booliano	Struct
7	Produto	validFrom	DateTime	Struct

N.º de série	Entity Name	Nome do campo pesquisável	Tipo de dados como pesquisável	Tipo de dados como recuperável
8	Produto	validTo	DateTime	Struct
9	Produto	type	String	Struct
10	Produto	onlineFlag	Booliano	Struct
11	Promotion	nome	String	Struct

Conexão com o Salesforce Marketing Cloud Account Engagement

O Salesforce Marketing Cloud Account Engagement é uma solução de automação de marketing que ajuda as empresas a criar conexões significativas, gerar mais pipeline e potencializar as vendas para fechar mais negócios. Se você é usuário do Salesforce Marketing Cloud Account Engagement, pode conectar o AWS Glue à sua conta do Salesforce Marketing Cloud Account Engagement. Você pode usar o Salesforce Marketing Cloud Account Engagement como fonte de dados em trabalhos de ETL. Execute esses trabalhos para transferir dados do Salesforce Marketing Cloud Account Engagement para serviços da AWS ou outras aplicações compatíveis.

Tópicos

- Suporte do AWS Glue para o Salesforce Marketing Cloud Account Engagement
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Salesforce Marketing Cloud Account Engagement
- Configuração das conexões com o Salesforce Marketing Cloud Account Engagement
- Leitura de entidades do Salesforce Marketing Cloud Account Engagement
- Opções de conexão do Salesforce Marketing Cloud Account Engagement
- Limitações e notas do conector do Salesforce Marketing Cloud Account Engagement

Suporte do AWS Glue para o Salesforce Marketing Cloud Account Engagement

O AWS Glue oferece suporte para o Salesforce Marketing Cloud Account Engagement da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Salesforce Marketing Cloud Account Engagement no modo ASYNC ou SYNC.

Compatível como destino?

N.º

Versões compatíveis da API do Salesforce Marketing Cloud Account Engagement

As seguintes versões da API do Salesforce Marketing Cloud Account Engagement API são compatíveis:

- v5

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Salesforce Marketing Cloud Account Engagement

Antes de poder usar o AWS Glue para transferir dados do Salesforce Marketing Cloud Account Engagement, você precisa atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Ter uma conta de marketing do Salesforce.
- Ter um plano do Account Engagement licenciado para a conta do Salesforce.
- Ter sincronizado o usuário do Salesforce com o usuário do Account Engagement.
- Ter criado uma aplicação conectada no Gerenciador de aplicações para obter as credenciais do OAuth.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Salesforce Marketing Cloud Account Engagement.

Configuração das conexões com o Salesforce Marketing Cloud Account Engagement

O tipo de concessão determina como o AWS Glue se comunica com o Salesforce Marketing Cloud Account Engagement para solicitar acesso aos seus dados. A escolha afeta os requisitos que você deve atender antes de criar a conexão. O Salesforce Marketing Cloud Account Engagement só é compatível com o tipo de concessão AUTHORIZATION_CODE para OAuth 2.0.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no Salesforce Marketing Cloud Account Engagement e fornecer os próprios ID e segredo de cliente quando criarem conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Salesforce Marketing Cloud Account Engagement para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Salesforce Marketing Cloud Account Engagement sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Authentication.

Para configurar uma conexão do Salesforce Marketing Cloud Account Engagement:

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Salesforce Marketing Cloud Account Engagement.
   b. Forneça o `INSTANCE_URL` da instância do Salesforce Marketing Cloud Account Engagement à qual você deseja se conectar.
   c. Forneça o `PARDOT_BUSINESS_UNIT_ID` da instância do Salesforce Marketing Cloud Account Engagement à qual você deseja se conectar.
   d. Selecione o URL do código de autorização apropriado no menu suspenso.
   e. Selecione o URL do token apropriado no menu suspenso.
   f. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
```

```
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

g. Forneça o ID do cliente da aplicação cliente gerenciada pelo usuário (o ID do cliente da aplicação conectada).

h. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens. O segredo selecionado precisa ter uma chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` com o valor sendo o segredo do cliente da aplicação conectada.

i. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
3. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Salesforce Marketing Cloud Account Engagement

Pré-requisito

Um objeto do Salesforce Marketing Cloud Account Engagement do qual você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis com a fonte de Sync:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Campaign	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Dynamic Content	Sim	Sim	Sim	Sim	Sim
E-mail	Sim	Sim	Sim	Sim	Sim
Modelo de e-mail	Sim	Sim	Sim	Sim	Sim
Engagemen t Studio Program	Sim	Sim	Sim	Sim	Sim
Conteúdo da pasta	Sim	Sim	Sim	Sim	Sim
Página de destino	Sim	Sim	Sim	Sim	Sim
Histórico do ciclo de vida	Sim	Sim	Sim	Sim	Sim
Estágio do ciclo de vida	Sim	Sim	Sim	Sim	Sim
Lista	Sim	Sim	Sim	Sim	Sim
Listar e-mail	Sim	Sim	Sim	Sim	Sim
Listar associação	Sim	Sim	Sim	Sim	Sim
Oportunidade	Sim	Sim	Sim	Sim	Sim
Cliente potencial	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Conta de cliente potencial	Sim	Sim	Sim	Sim	Sim
Usuário	Sim	Sim	Sim	Sim	Sim

Exemplo:

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforcePardot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v5"
    }
   )
```

Entidades compatíveis com a fonte de ASYNC:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Campaign	Sim	Não	Não	Sim	Não
Dynamic Content	Sim	Não	Não	Sim	Não
Modelo de e-mail	Sim	Não	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Página de destino	Sim	Não	Não	Sim	Não
Histórico do ciclo de vida	Sim	Não	Não	Sim	Não
Estágio do ciclo de vida	Sim	Não	Não	Sim	Não
Lista	Sim	Não	Não	Sim	Não
Listar e-mail	Sim	Não	Não	Sim	Não
Listar associação	Sim	Não	Não	Sim	Não
Oportunidade	Sim	Não	Não	Sim	Não
Cliente potencial	Sim	Não	Não	Sim	Não
Conta de cliente potencial	Sim	Não	Não	Sim	Não
Usuário	Sim	Não	Não	Sim	Não

Exemplo:

```
salesforcepardot_read = glueContext.create_dynamic_frame.from_options(
    connection_type="SalesforcePardot",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v5",
```

```
        "TRANSFER_MODE": "ASYNC"
    }
)
```

Detalhes dos campos e das entidades do Salesforce Marketing Cloud Account Engagement:

Para visualizar os detalhes dos campos das entidades a seguir, navegue até API do Salesforce Marketing Cloud Account Engagement, escolha Guias, role para baixo até Wrappers de APIs de código aberto, expanda Documentos da versão 5 no menu e escolha uma entidade.

Lista de entidades:

- Campaign
- Dynamic Content
- E-mail
- Modelo de e-mail
- Engagement Studio Program
- Conteúdo da pasta
- Página de destino
- Histórico do ciclo de vida
- Estágio do ciclo de vida
- Lista
- Listar e-mail
- Listar associação
- Oportunidade
- Cliente potencial
- Conta de cliente potencial
- Usuário

Além dos campos mencionados acima, o modo ASYNC é compatível com campos filtráveis específicos para cada entidade, conforme mostrado na tabela abaixo.

Entidade	Campos filtráveis adicionais compatíveis no modo ASYNC
Campaign	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Dynamic Content	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Modelo de e-mail	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Engagement Studio Program	-
Página de destino	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Histórico do ciclo de vida	`createdAfter` , `createdBefore`
Estágio do ciclo de vida	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Lista	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Listar e-mail	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Listar associação	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`

Entidade	Campos filtráveis adicionais compatíveis no modo ASYNC
Oportunidade	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Cliente potencial	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`
Conta de cliente potencial	`createdAfter` , `createdBefore` , `deleted`
Usuário	`createdAfter` , `createdBefore` , `deleted`, `updatedAfter` , `updatedBefore`

Para obter mais informações sobre os campos adicionais, consulte Salesforce Export API

Observe as seguintes considerações sobre o conector:

- O valor do campo `delete` nas entidades pode ser `false` (padrão), `true` ou `all`.

Particionamento de consultas

Particionamento baseado em filtro:

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Data e hora, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

Exemplos de valores válidos:

```
"2022-01-01T01:01:01.000Z"
```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.
- PARTITION_BY: o tipo de particionamento a ser executado. “FIELD” deve ser passado no caso de particionamento com base em campo.

Exemplo:

```
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"
    }
   )
```

Opções de conexão do Salesforce Marketing Cloud Account Engagement

Estas são as opções de conexão do Salesforce Marketing Cloud Account Engagement:

- ENTITY_NAME(string): (obrigatório) usado para leitura. O nome do objeto no Salesforce Marketing Cloud Account Engagement.
- PARDOT_BUSINESS_UNIT_ID: (Obrigatório) Usado para criar uma conexão. Forneça o ID da unidade de negócios da instância do Salesforce Marketing Cloud Account Engagement à qual você deseja se conectar.
- API_VERSION(string): (obrigatório) usado para leitura. Versão da API Rest do Salesforce Marketing Cloud Account Engagement que você deseja usar.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.

- `FILTER_PREDICATE` (String):
  - No modo SYNC, Padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
  - No modo ASYNC, Padrão: valor `DateTime` atual (de acordo com o fuso horário do usuário) - 1 ano. Usado para leitura.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL` (String): (obrigatório) usado para leitura. Um URL válido da instância do Salesforce Marketing Cloud Account Engagement.
- `PARTITION_BY` (String): (obrigatório) usado para leitura. O tipo de particionamento a ser executado. “FIELD” deve ser passado no caso de particionamento com base em campo.
- `TRANSFER_MODE` (String): (opcional) valor a ser usado para executar um trabalho no modo ASYNC. Se esta opção não for fornecida, o trabalho será executado no modo SYNC.

Limitações e notas do conector do Salesforce Marketing Cloud Account Engagement

As seguintes notas e limitações são aplicáveis:

- Quando um limite e um particionamento são aplicados, o limite tem precedência sobre o particionamento.
- De acordo com a documentação da API, `SalesforceMarketingCloudEngagement` aplica um RateLimit nas solicitações diárias e simultâneas. Para obter mais informações, consulte Limites de taxa.
- A API Export está sujeita ao limite diário de chamadas de API do Account Engagement e ao limite simultâneo de chamadas de API do Account Engagement para sua conta.
- Semelhante a uma fila, as chamadas de API Export/Async são executadas sequencialmente para cada conta. As exportações mais antigas são processadas antes das exportações mais recentes.
- A partição não é compatível no modo ASYNC.
- O número de campos selecionados especificados nas chamadas de API Export/Async não pode exceder 150.

- A entidade Prospect suporta mais de 150 campos, mas apenas 150 campos podem ser selecionados por vez. Se `Select All` for escolhido, alguns campos serão excluídos. Para recuperar dados desses campos excluídos, você precisa incluí-los na opção `Selected Fields`.

  Confira abaixo a lista de campos excluídos em `SELECT_ALL`: `updatedBy.firstName`, `updatedBy.lastName`, `updatedBy.jobTitle`, `updatedBy.roleName`, `updatedBy.salesforceId`, `updatedBy.createdAt`, `updatedBy.updatedAt`, `updatedBy.isDeleted`, `updatedBy.createdById`, `updatedBy.updatedById`, `updatedBy.tagReplacementLanguage`
- Os campos de coleta não podem ser exportados para ASYNC. Por exemplo, em lista de e-mails, os campos `senderOptions` e `replyToOptions` não são compatíveis.
- Para todas as entidades, o filtro é obrigatório. Se nenhum filtro for fornecido, o predicado padrão do filtro será definido para o campo `Created After` com um valor da data e hora atual (ajustado ao seu fuso horário), menos um ano.
- De acordo com as limitações do Salesforce Marketing Cloud Account Engagement, no Async, o intervalo máximo para buscar dados é de um ano. Se uma consulta for fornecida por mais de um ano, o trabalho vai gerar um erro.
- Atualmente, há um bug no Salesforce Pardot. Quando o trabalho inclui apenas um único campo que não tem dados, o valor do campo não está retornando o resultado correto e, em vez disso, o nome do campo está sendo retornado várias vezes. A equipe do Salesforce Pardot está ciente do problema e está trabalhando ativamente em uma solução.

Conectar ao SAP HANA no AWS Glue Studio

O AWS Glue oferece suporte integrado ao SAP HANA. O AWS Glue Studio fornece uma interface visual para conectar ao SAP HANA, criar trabalhos de integração de dados e executá-los no runtime Spark do AWS Glue Studio sem servidor.

O AWS Glue Studio cria uma conexão unificada para o SAP HANA. Para ter mais informações, consulte Considerações.

Tópicos

- Criar uma conexão SAP HANA
- Criar um nó de origem do SAP HANA
- Criar um nó de destino do SAP HANA
- Opções avançadas

Criar uma conexão SAP HANA

Para se conectar ao SAP HANA via AWS Glue, será necessário criar e armazenar suas credenciais do SAP HANA em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão ao AWS Glue do SAP HANA. Você precisará configurar a conectividade de rede entre seu serviço SAP HANA e o AWS Glue.

Pré-requisitos:

- Se o seu serviço SAP HANA estiver em uma Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com o serviço SAP HANA sem que o tráfego passe pela Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre seu endpoint SAP HANA e esse local. Seu trabalho precisará estabelecer uma conexão TCP com a porta JDBC do SAP HANA. Para obter mais informações sobre as portas do SAP HANA, consulte a Documentação do SAP HANA. Com base no layout da rede, isso pode exigir alterações em regras do grupo de segurança, ACLs de rede, gateways de NAT e conexões de emparelhamento.

Para configurar uma conexão com o SAP HANA:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do SAP HANA. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.

   - Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *`saphanaUsername`*.
   - Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *`saphanaPassword`*.
2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *`connectionName`*, para uso futuro em AWS Glue.

   - Ao selecionar um Tipo de conexão, selecione SAP HANA.
   - Ao fornecer o URL do SAP HANA, forneça o URL da sua instância.

Os URLs JDBC do SAP HANA estão no formato `jdbc:sap://saphanaHostname:saphanaPort/?databaseName=saphanaDBname,Paramete`

O AWS Glue requer os seguintes parâmetros de URL do JDBC:

- `databaseName`: um banco de dados padrão no SAP HANA ao qual se conectar.

- Ao selecionar um Segredo da AWS, forneça o *`secretName`*.

Depois de criar uma conexão AWS Glue SAP HANA, siga estas etapas antes de executar seu trabalho do AWS Glue:

- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *`secretName`*.

Criar um nó de origem do SAP HANA

Pré-requisitos necessários

- Uma conexão AWS Glue SAP HANA configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão SAP HANA”.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do SAP HANA da qual você gostaria de ler, *`tableName`*, ou consultar *`targetQuery`*.

  Uma tabela pode ser especificada com um nome de tabela e um nome de esquema do SAP HANA, no formulário *`schemaName`*`.`*`tableName`*. O nome do esquema e o separador "." não serão necessários se a tabela estiver no esquema padrão, "público". Chame isso de *`tableIdentifier`*. Observe que o banco de dados é fornecido como um parâmetro de URL do JDBC em `connectionName`.

Adicionar uma fonte de dados do SAP HANA

Para adicionar um nó de Fonte de dados – SAP HANA:

1. Escolha a conexão para sua fonte de dados do SAP HANA. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o SAP HANA. Para mais informações, consulte a seção the section called “Criar uma conexão SAP HANA” anterior.

Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.

2. Escolha uma opção de Fonte do SAP HANA:

   - Escolher uma única tabela: acesse todos os dados de uma única tabela.
   - Inserir consulta personalizada: acesse um conjunto de dados de várias tabelas com base em sua consulta personalizada.

3. Se você escolheu uma única tabela, insira *`tableName`*.

   Se você escolheu Inserir consulta personalizada, insira uma consulta SQL SELECT.

4. Em Propriedades personalizadas do SAP HANA, insira parâmetros e valores conforme necessário.

Criar um nó de destino do SAP HANA

Pré-requisitos necessários

- Uma conexão AWS Glue SAP HANA configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão SAP HANA”.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do SAP HANA na qual você gostaria de escrever, *`tableName`*.

  Uma tabela pode ser especificada com um nome de tabela e um nome de esquema do SAP HANA, no formulário *`schemaName`*`.`*`tableName`*. O nome do esquema e o separador "." não serão necessários se a tabela estiver no esquema padrão, "público". Chame isso de *`tableIdentifier`*. Observe que o banco de dados é fornecido como um parâmetro de URL do JDBC em `connectionName`.

Adicionar um destino de dados do SAP HANA

Para adicionar um nó de Destino de dados – SAP HANA:

1. Escolha a conexão para sua fonte de dados do SAP HANA. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o SAP HANA. Para mais informações, consulte a seção the section called “Criar uma conexão SAP HANA” anterior.

Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.

2. Configure o nome da tabela fornecendo o *tableName*.
3. Em Propriedades personalizadas do Teradata, insira parâmetros e valores conforme necessário.

Opções avançadas

É possível fornecer opções avançadas ao criar um nó do SAP HANA. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexões do SAP HANA”.

Conexão com o SAP OData

O SAP OData é um protocolo padrão da Web usado para consultar e atualizar dados presentes no SAP usando ABAP (Advanced Business Application Programming), aplicando e desenvolvendo tecnologias da Web, como HTTP, para fornecer acesso a informações de uma variedade de aplicações, plataformas e dispositivos externos. Com o produto, você pode acessar tudo de que precisa para ajudar na integração perfeita com o sistema, a aplicação ou dados SAP.

Tópicos

- Suporte do AWS Glue para SAP OData
- Criar conexões
- Criar um trabalho OData no SAP
- Uso do script de gerenciamento de estado do SAP OData
- Particionamento para entidades não de ODP
- Opções de conexão do SAP OData
- Detalhes de entidades e campos OData do SAP

Suporte do AWS Glue para SAP OData

O AWS Glue oferece suporte ao SAP OData da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do SAP OData.

Versões compatíveis da API do SAP OData

As seguintes versões da API do SAP OData são compatíveis:

- 2.0

Fontes compatíveis

As seguintes fontes são compatíveis:

- Fontes de ODP (Operational Data Provisioning):
  - Extratores BW (DataSources)
  - Visualizações do CDS
  - SLT
- Fontes não de ODP, por exemplo:
  - Serviços de visualização do CDS
  - Serviços baseados em RFC
  - Serviços personalizados ABAP

Componentes compatíveis do SAP

Estes são os requisitos mínimos:

- Você deve habilitar o serviço de catálogo para descoberta de serviços.
  - Configure fontes de dados de provisionamento de dados operacionais (ODP) para extração no SAP Gateway do seu sistema SAP.
  - OData V2.0: habilite os serviços de catálogo OData V2.0 no Gateway do SAP por meio da transação `/IWFND/MAINT_SERVICE`.
  - Habilite os serviços OData V2.0 no seu SAP Gateway por meio da transação `/IWFND/MAINT_SERVICE`.
  - O serviço SAP OData deve oferecer suporte às opções de paginação/consulta do lado do cliente, como `$top` e `$skip`. Ele também deve oferecer suporte à opção `$count` de consulta do sistema.
  - Você deve fornecer a autorização necessária para que o usuário no SAP descubra os serviços e extraia dados usando os serviços OData do SAP. Consulte a documentação de segurança fornecida pela SAP.

- Se quiser usar o OAuth 2.0 como mecanismo de autorização, você deverá habilitar o OAuth 2.0 para o serviço OData e registrar o cliente OAuth de acordo com a documentação do SAP.
- Para gerar um serviço OData com base em fontes de dados de ODP, o SAP Gateway Foundation deve ser instalado localmente em sua pilha de ERP/BW ou em uma configuração de hub.
  - Para as aplicações de ERP/BW, a pilha do NetWeaver AS ABAP do SAP deve ser da versão 7.50 SP02 ou superior.
  - Para o sistema de hub (SAP Gateway), o NetWeaver AS ABAP do SAP do sistema de hub deve ser da versão 7.50 SP01 ou superior para configuração de hub remoto.
- Para fontes não de ODP, a versão da pilha do NetWeaver do SAP deve ser da versão 7.40 SP02 ou acima.

Métodos de autenticação compatíveis

Os seguintes métodos de autenticação são compatíveis:

- Autenticação básica
- OAuth 2.0

Pré-requisitos

Antes de iniciar um trabalho do AWS Glue de extração de dados OData do SAP usando a conexão OData do SAP, atenda aos seguintes pré-requisitos:

- O serviço OData relevante do SAP deve ser ativado no sistema SAP, garantindo que a fonte de dados esteja disponível para consumo. Se o serviço OData não estiver ativado, o trabalho do Glue não poderá acessar nem extrair dados do SAP.
- Os mecanismos de autenticação apropriados, como autenticação básica (personalizada) ou o OAuth 2.0, devem ser configurados no SAP para garantir que o trabalho do AWS Glue possa estabelecer com sucesso uma conexão com o serviço OData do SAP.
- Configure as políticas do IAM para conceder ao trabalho do AWS as permissões apropriadas para acessar o SAP, o Secrets Manager e outros recursos da AWS Glue envolvidos no processo.
- Se o sistema SAP estiver hospedado em uma rede privada, a conectividade da VPC deverá ser configurada para garantir que o trabalho do AWS Glue possa se comunicar com o SAP de modo seguro, sem expor dados confidenciais pela internet pública.

O AWS Secrets Manager pode ser usado para armazenar de modo seguro informações confidenciais, como credenciais do SAP, que o trabalho do AWS Gluepode recuperar dinamicamente durante o runtime. Essa abordagem elimina a necessidade de codificar credenciais, aumentando a segurança e a flexibilidade.

Os pré-requisitos a seguir fornecem orientação passo a passo sobre como configurar cada componente para uma integração perfeita entre o AWS Glue e o OData do SAP.

Tópicos

- Ativação do OData do SAP
- Políticas do IAM
- Conectividade/conexão de VPC
- Autenticação do SAP
- AWS Secrets Manager para armazenar o segredo de autenticação

Ativação do OData do SAP

Conclua as seguintes etapas para essa conexão OData do SAP:

Fontes de ODP

Para transferir dados de um provedor ODP, é necessário atender aos seguintes requisitos:

- Você tem uma instância do NetWeaver AS ABAP do SAP.
- Sua instância do NetWeaver do SAP contém um provedor ODP do qual você deseja transferir dados. Os provedores ODP incluem:
  - DataSources do SAP (código de transação RSO2)
  - Visualizações dos CDS ABAP do ABAP Core Data Services
  - Sistemas BW ou BW/4HANA do SAP (InfoObject, DataStore Object)
  - Replicação em tempo real de tabelas e visualizações de BD do SAP Source System via SAP Landscape Replication Server (SAP SLT)
  - Visualizações de informações de HANA do SAP em fontes baseadas em ABAP do SAP
- Sua instância do NetWeaver do SAP tem o componente SAP Gateway Foundation.
- Você criou um serviço OData que extrai dados do seu provedor ODP. Para criar o serviço OData, você usa o desenvolvedor de serviço de gateway do SAP. Para acessar os dados do ODP, o Amazon AppFlow chama esse serviço usando a API OData. Para obter mais informações, consulte

Generating a Service for Extracting ODP Data via OData na documentação de BW/4HANA do SAP.

- Para gerar um serviço OData com base em fontes de dados de ODP, o SAP Gateway Foundation deve ser instalado localmente em sua pilha de ERP/BW ou em uma configuração de hub.
  - Para as aplicações de ERP/BW, a pilha do NetWeaver AS ABAP do SAP deve ser da versão 7.50 SP02 ou superior.
  - Para o sistema de hub (SAP Gateway), o NetWeaver AS ABAP do SAP do sistema de hub deve ser da versão 7.50 SP01 ou superior para configuração de hub remoto.

Fontes não de ODP

- A versão da pilha do SAP NetWeaver deve ser 7.40 SP02 ou superior.
- Você deve habilitar o serviço de catálogo para descoberta de serviços.
  - OData V2.0: Os serviços de catálogo OData V2.0 podem ser habilitados no Gateway do SAP por meio da transação `/IWFND/MAINT_SERVICE`
- O serviço SAP OData deve oferecer suporte às opções de paginação/consulta do lado do cliente, como `$top` e `$skip`. Ele também deve oferecer suporte à opção `$count` de consulta do sistema.
- Para o OAuth 2.0, vVocê deve habilitar o OAuth 2.0 para o serviço OData e registrar o cliente de OAuth de acordo com a documentação do SAP, e definir a URL de redirecionamento autorizada da seguinte maneira:
  - `https://<region>.console.aws.amazon.com/gluestudio/oauth`, substituindo `<region>` pela região em que o AWS Glue está sendo executado, por exemplo: us-east-1.
  - Você deve habilitar a configuração segura para conexão por HTTPS.
- Você deve fornecer a autorização necessária para que o usuário no SAP descubra os serviços e extraia dados usando os serviços OData do SAP. Consulte a documentação de segurança fornecida pela SAP.

Políticas do IAM

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
```

```
"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": "*"
         }
    ]
}
```

O perfil deve conceder acesso a todos os recursos usados pelo trabalho, por exemplo, o Amazon S3. Se você não quiser usar o método acima, como alternativa use as seguintes políticas gerenciadas do IAM.

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

- SecretsManagerReadWrite: fornece acesso de leitura/gravação ao AWS Secrets Manager pelo Console de Gerenciamento da AWS. Observação: isso exclui ações do IAM. Portanto, combine com o `IAMFullAccess` se for necessária configuração de rotação.

Políticas/permissões do IAM necessárias para configurar a VPC

As seguintes permissões do IAM são necessárias ao usar a conexão de VPC para criar a conexão do AWS Glue. Para obter mais detalhes, consulte Criar uma política do IAM para o AWS Glue.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "ec2:CreateNetworkInterface",
                "ec2:DeleteNetworkInterface",
                "ec2:DescribeNetworkInterfaces",
            ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Conectividade/conexão de VPC

Etapas para a conexão de VPC:

1. Use a conexão de VPC existente ou crie uma nova conexão seguindo a documentação da Amazon VPC.
2. Certifique-se de ter um gateway NAT que direcione o tráfego para a Internet.
3. Escolha o endpoint da VPC como o gateway do Amazon S3 para criar uma conexão.
4. Habilite a resolução do DNS e o nome do host do DNS para usar os serviços de DNS fornecidos pela AWS.
5. Acesse a VPC criada e adicione os endpoints necessários para os diferentes serviços, como STS, AWS Glue, Secret Managers.

   a. Escolha Criar Endpoint.

b. Em Categoria do serviço, selecione Serviços da AWS.
c. Em Nome do serviço, escolha o serviço ao qual você está se conectando.
d. Escolha a VPC e Habilitar nome do DNS.
e. Endpoints da VPC necessários para a conexão da VPC:
   i. STS
   ii. AWS Glue
   iii. Secrets Manager

Configuração do security group

O grupo de segurança deve permitir tráfego da VPC do AWS Glue para a porta de escuta para que o AWS Glue possa se conectar a ela. É uma prática recomendada restringir o intervalo de endereços IP de origem o máximo possível.

O AWS Glue exige um grupo de segurança especial que permite todo o tráfego de entrada originado nele mesmo. Você pode criar uma regra autorreferenciada que permita todo o tráfego originado no grupo de segurança. Você pode modificar um grupo de segurança existente e especificá-lo como origem.

Abra a comunicação das portas HTTPS do endpoint da URL (instância NLB ou SAP).

Opções de conectividade

- Conexão HTTPS com NLB interno e externo, certificado SSL da autoridade de certificação (CA), certificado SSL não autoassinado
- Conexão HTTPS com instância do SAP, certificado SSL de autoridade certificadora (CA), certificado SSL não auto-assinado

Autenticação do SAP

O conector do SAP é compatível com os métodos de autenticação CUSTOM (essa é a autenticação BASIC do SAP) e OAUTH.

Autenticação personalizada

O AWS Glue é compatível com Custom (autenticação básica) como um método para estabelecer conexões com os sistemas SAP, permitindo o uso de um nome de usuário e senha para acesso

seguro. Esse tipo de autorização: funciona bem em cenários de automação, pois permite o uso do nome de usuário e senha antecipadamente com as permissões de um usuário específico na instância OData do SAP. O AWS Glue pode usar o nome de usuário e senha para autenticar as APIs OData do SAP. No AWS Glue, a autorização básica é implementada como autorização personalizada.

Para obter a documentação pública do SAP OData para o fluxo de autenticação básica, consulte HTTP Basic Authentication.

Autenticação OAuth 2.0

O AWS Glue também é compatível com o OAuth 2.0 como um mecanismo de autenticação seguro para estabelecer conexões com seus sistemas SAP. Isso permite uma integração perfeita, garantindo a conformidade com os padrões modernos de autenticação e aprimorando a segurança do acesso aos dados.

Tipo de concessão AUTHORIZATION_CODE

O tipo de concessão determina como o AWS Glue se comunica com o SAP OData para solicitar acesso aos seus dados. O SAP OData só oferece suporte ao tipo de concessão `AUTHORIZATION_CODE`. Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue.

Os usuários ainda podem optar por criar a própria aplicação conectada no SAP OData e fornecer ID e segredo do cliente próprios ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o SAP OData para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter documentação pública do SAP OData sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Autenticação usando o OAuth 2.0.

AWS Secrets Manager para armazenar o segredo de autenticação

Você precisará armazenar os segredos da conexão OData do SAP no AWSSecrets Manager, configurar as permissões necessárias para recuperação conforme especificado na seção Políticas do IAM e usá-las ao criar uma conexão.

Use o AWS Management Console do AWS Secrets Manager para criar um segredo para a sua fonte no SAP. Para obter mais informações, consulte Create an AWS Secrets Manager secret. Os detalhes do AWS Secrets Manager devem incluir os elementos de código a seguir.

Serviço de autenticação personalizada

Você precisará inserir o nome de usuário do sistema SAP no lugar de <your SAP username> e sua senha no lugar de <your SAP username password> e True ou False. Nesse contexto, configurar `basicAuthDisableSSO` como `true` desabilita a autenticação única (SSO) para solicitações de Autenticação Básica, exigindo credenciais de usuário explícitas para cada solicitação. Por outro lado, configurar esse valor como `false` permite o uso de sessões de SSO existentes, se disponíveis.

```
{
   "basicAuthUsername": "<your SAP username>",
   "basicAuthPassword": "<your SAP username password>",
   "basicAuthDisableSSO": "<True/False>",
   "customAuthenticationType": "CustomBasicAuth"
}
```

Segredo do OAuth 2.0

Caso você esteja usando o OAuth 2.0 como mecanismo de autenticação, o segredo no AWS Secrets Manager deve ter o ClientId da aplicação cliente gerenciado pelo usuário no formato a seguir. Você precisará inserir o segredo do cliente SAP no lugar de <your client secret>.

```
{"USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET": "<your client secret>"
}
```

Criar conexões

Para configurar uma conexão OData no SAP:

1. Faça login no Console de gerenciamento da AWS e abra o console do AWS Glue. No AWS Glue Studio, crie uma conexão seguindo as etapas abaixo:
   a. Clique em Conexões de dados no painel esquerdo.
   b. Clique em Criar conexão.
   c. Selecione OData do SAP em Escolher fonte de dados

d. Forneça o URL do host da aplicação da instância do SAP OData à qual você deseja se conectar. Essa URL do host da aplicação deve pode ser acessada pela Internet pública para conexões que não sejam de VPC.

e. Forneça o Caminho do serviço da aplicação da instância do SAP OData à qual você deseja se conectar. Esse é o mesmo caminho do serviço de catálogo. Por exemplo: `/sap/opu/odata/iwfnd/catalogservice;v=2`. O AWS Glue não aceita um caminho de objeto específico.

f. Forneça o Número do cliente da instância do SAP OData à qual você deseja se conectar. Os valores aceitáveis são [001 a 999]. Exemplo: 010

g. Forneça o Número da porta da instância do SAP OData à qual você deseja se conectar. Exemplo: 443

h. Forneça o Idioma de logon da instância do SAP OData à qual você deseja se conectar. Exemplo: PT_BR

i. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões, conforme descrito na seção Políticas do IAM.

j. Selecione o Tipo de autenticação que você deseja usar para essa conexão no AWS Glue, na lista suspensa OAUTH2 ou CUSTOM

   i. CUSTOM: selecione o segredo que você criou conforme especificado na seção AWS Secrets Manager para armazenar o segredo de autenticação.

   ii. OAUTH 2.0: insira as seguintes entradas apenas no caso do OAuth 2.0:

      A. Em ClientId da aplicação cliente gerenciado pelo usuário, insira o ID do cliente.

      B. `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` (o segredo do cliente) no AWS Secrets Manager que você criou na seção AWS Secrets Manager para armazenar o segredo de autenticação.

      C. Em URL do código de autorização, insira a URL do código de autorização.

      D. Em URL dos tokens de autorização, insira a URL dos tokens de autorização.

      E. Em Escopos do OAuth, insira os escopos do OAuth separados por espaços. Example: `/IWFND/SG_MED_CATALOG_0002 ZAPI_SALES_ORDER_SRV_0001`

k. Selecione as opções de rede se quiser usar sua rede. Consulte mais detalhes em Conectividade/conexão de VPC.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`. Para obter mais detalhes, consulte Políticas do IAM.

3. Escolha Testar conexão e teste sua conexão. Se o teste de conexão for bem-sucedido, clique em Avançar, insira o nome da conexão e salve-a. A funcionalidade de teste de conexão não está disponível se você tiver escolhido Opções de rede (VPC).

Criar um trabalho OData no SAP

Consulte Criar trabalhos de ETL visuais com o AWS Glue Studio

Fontes de Provisionamento de Dados Operacionais (ODP)

O Provisionamento de Dados Operacionais (ODP) oferece uma infraestrutura técnica que você pode usar para dar suporte à extração e à replicação de dados para várias aplicações de destino e que é compatível com mecanismos delta nesses cenários. No caso de um procedimento delta, os dados de uma fonte (Provedor ODP) são automaticamente gravados em uma fila delta (Fila Delta Operacional, ODQ) usando um processo de atualização ou passados para a fila delta usando uma interface de extração. Um provedor ODP pode ser um DataSource (extratores), visualizações do ABAP Core Data Services (Visualizações do ABAP CDS), SAP BW ou SAP BW/4HANA, SAP Landscape Transformation Replication Server (SLT) e SAP HANA Information Views (visualizações de cálculo). As aplicações de destino (chamados de "assinantes" de ODQ ou, mais geralmente, "Consumidores de ODP") recuperam os dados da fila delta e continuam processando esses dados.

Carga total

No contexto das entidades OData e ODP do SAP, uma carga total se refere ao processo de extrair todos os dados disponíveis de uma entidade ODP em uma única operação. Essa operação recupera todo o conjunto de dados do sistema de origem, garantindo que o sistema de destino tenha uma cópia abrangente e atualizada dos dados da entidade. As cargas totais geralmente são usadas para fontes que não são compatíveis com cargas incrementais ou quando é necessária uma atualização do sistema de destino.

Exemplo

Você pode definir explicitamente o sinalizador `ENABLE_CDC` como false ao criar o DynamicFrame. Observação: `ENABLE_CDC` é false por padrão. Se você não quiser inicializar a fila delta, não precisará enviar esse sinalizador nem defini-lo como true. Não definir esse sinalizador como true resultará na extração da carga total.

```
sapodata_df = glueContext.create_dynamic_frame.from_options(
```

```
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "ENABLE_CDC": "false"
    }, transformation_ctx=key)
```

Carga incremental

Uma carga incremental no contexto das entidades ODP (Operational Data Provisioning) envolve a extração somente dos dados novos ou alterados (deltas) do sistema de origem desde a última extração de dados, evitando o pré-processamento dos registros já processados. Essa abordagem melhora significativamente a eficiência, reduz os volumes de transferência de dados, melhora a performanda, garante a sincronização entre os sistemas e minimiza o tempo de processamento, especialmente para grandes conjuntos de dados que mudam com frequência.

Transferências incrementais baseadas no token delta

Para habilitar a transferência incremental usando Change Data Capture (CDC) para entidades habilitadas para ODP compatíveis, siga estas etapas:

1. Crie a tarefa de transferência incremental no modo de script.
2. Ao criar o DataFrame ou o DynamicFrame do Glue, você precisa passar a opção `"ENABLE_CDC": "True"`. Essa opção garante que você receberá um token delta da SAP, que poderá ser usado para subsequente recuperação dos dados alterados.

O token delta poderá ser encontrado na última linha do dataframe, na coluna DELTA_TOKEN. Você poderá usar esse token como uma opção de conector em chamadas subsequentes para recuperar o próximo conjunto de dados incrementalmente.

Exemplo

- Definimos o sinalizador `ENABLE_CDC` como `true`, ao criar o DynamicFrame. Observação: `ENABLE_CDC` será `false` por padrão, se você não quiser inicializar a fila delta, não precisará enviar esse sinalizador nem defini-lo como true. Não definir esse sinalizador como true resultará na extração da carga total.

```
sapodata_df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
```

```
    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
```

- O token delta extraído pode ser passado como uma opção para recuperar novos eventos.

```
sapodata_df_2 = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    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)
```

Observe que o último registro, no qual o `DELTA_TOKEN` está presente, não é um registro transacional da fonte e existe apenas com a finalidade de passar o valor do token delta.

Além do `DELTA_TOKEN`, os campos a seguir são retornados em cada linha do dataframe.

- GLUE_FETCH_SQ: esse é um campo sequencial, gerado a partir do timestamp EPOC na ordem de recebimento dos registros e é exclusivo para cada registro. Isso pode ser usado se você precisar conhecer ou estabelecer a ordem das alterações no sistema de origem. Esse campo estará presente apenas para entidades habilitadas para ODP.
- DML_STATUS: isso exibirá `UPDATED` para todos os registros recém-inseridos e atualizados a partir da fonte e `DELETED` para os registros que foram excluídos da fonte.

Para obter mais detalhes sobre como gerenciar estado e reutilizar o token delta para recuperar registros alterados por meio de um exemplo, consulte a seção Uso do script de gerenciamento de estado do SAP OData.

Invalidação do token delta

Um token delta é associado ao conjunto de serviços e a um usuário. Se uma extração inicial com `“ENABLE_CDC” : “true”` for iniciada para o mesmo conjunto de serviços e usuário, todos os tokens delta anteriores emitidos como resultado de uma inicialização anterior serão invalidados pelo serviço OData do SAP. Invocar o conector com um token delta expirado gerará uma exceção:

```
Could not open data access via extraction API RODPS_REPL_ODP_OPEN
```

Serviços OData (fontes não ODP)

Carga total

Para sistemas não ODP (Operational Data Provisioning), uma carga total envolve extrair todo o conjunto de dados do sistema de origem e carregá-lo no sistema de destino. Como os sistemas não ODP não são inerantemente compatíveis com mecanismos avançados de extração de dados como deltas, o processo é simples, mas pode consumir muitos recursos, dependendo do tamanho dos dados.

Carga incremental

Para sistemas ou entidades que não são compatíveis com ODP (Operational Data Provisioning), a transferência incremental de dados pode ser gerenciada manualmente por meio da implementação de um mecanismo baseado em timestamp para rastrear e extrair as alterações.

Transferências incrementais baseadas em timestamp

Para entidades não habilitadas para ODP (ou para entidades habilitadas para ODP que não usam o sinalizador ENABLE_CDC), você pode usar uma opção `filteringExpression` no conector para indicar o intervalo de `datetime` para o qual queremos recuperar dados. Esse método depende de um campo de timestamp nos dados, que mostra quando cada registro foi criado/modificado a última vez.

Exemplo

Recuperação de registros que foram alterados após 2024-01-01T00:00:00.000

```
sapodata_df = glueContext.create_dynamic_frame.from_options(
    connection_type="SAPOData",
    connection_options={
        "connectionName": "connectionName",
```

```
        "ENTITY_NAME": "entityName",
        "filteringExpression": "LastChangeDateTime >= 2024-01-01T00:00:00.000"
    }, transformation_ctx=key)
```

Nesse exemplo, `LastChangeDateTime` é o campo que representa quando cada registro foi modificado a última vez. O nome real do campo pode variar, dependendo da entidade específica do SAP OData.

Para obter um novo subconjunto de dados em execuções subsequentes, você pode atualizar o `filteringExpression` com um novo carimbo de data e hora. Normalmente, esse seria o valor máximo do carimbo de data e hora dos dados recuperados anteriormente.

Exemplo

```
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
```

Na próxima seção, forneceremos uma abordagem automatizada para gerenciar essas transferências incrementais com base em carimbo de data e hora, eliminando a necessidade de atualizar manualmente a expressão de filtragem entre as execuções.

Uso do script de gerenciamento de estado do SAP OData

Para usar o script de gerenciamento de estado OData do SAP no trabalho do AWS Glue, siga estas etapas:

- Faça o download do script de gerenciamento de estado do bucket público do Amazon S3.
- Carregue o script em um bucket do Amazon S3 que seu trabalho do AWS Glue tenha permissões para acessar.
- Referencie o script no ttrabalho do AWS Glue: quando criar ou atualizar o trabalho do AWS Glue, passe a opção `'--extra-py-files'` referenciando o caminho do script no bucket do Amazon S3. Por exemplo: `--extra-py-files s3://your-bucket/path/to/sap_odata_state_management.py`
- Importe e use a biblioteca de gerenciamento de estado nos scripts do trabalho do AWS Glue.

Exemplo de transferência incremental baseada no token delta

Veja um exemplo de como usar o script de gerenciamento de estado para transferências incrementais com base em tokens 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 = "SAPODataNode"
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="SAPOData",
    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())
```

Exemplo de transferência incremental baseada no timestamp

Veja um exemplo de como usar o script de gerenciamento de estado para transferências incrementais com base em tokens 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 = "SAPODataNode"
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="SAPOData",
    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())
```

Nos dois exemplos, o script de gerenciamento de estado lida com as complexidades de armazenar o estado (token delta ou carimbo de data e hora) entre as execuções do trabalho. Ele recupera automaticamente o último estado conhecido ao obter as opções do conector e atualiza o estado após o processamento, garantindo que cada execução de trabalho só processe dados novos ou alterados.

Particionamento para entidades não de ODP

No Apache Spark, particionamento se refere ao modo como os dados são divididos e distribuídos entre os nós de trabalho de um cluster para processamento paralelo. Cada partição é um bloco lógico de dados que pode ser processado de modo independente por uma tarefa. Particionamento é um conceito fundamental no Spark que afeta diretamente a performance, a escalabilidade e

a utilização de recursos. Os trabalhos do AWS Glue usam o mecanismo de particionamento do Spark para dividir o conjunto de dados em partes menores (partições) que podem ser processadas paralelamente nos nós de trabalho do cluster. Observe que o particionamento não é aplicável a entidades de ODP.

Para obter mais detalhes, consulte AWS Glue Spark and PySpark jobs.

Pré-requisitos

Um objeto OData do SAP que você deseja ler. Você precisará do nome do objeto/EntitySet, por exemplo, `/sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder` .

Exemplo

```
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)
```

Particionamento de consultas

Particionamento baseado no campo

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente. Os campos Integer, Date e DateTime oferecem suporte ao particionamento com base em campo no conector do SAP OData.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Em qualquer campo com dados do tipo DataTime, o formato de timestamp do Spark usado nas consultas em SQL do Spark é aceito.

  Exemplos de valores válidos: `"2000-01-01T00:00:00.000Z"`
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: número de partições.

- PARTITION_BY: o tipo de particionamento a ser realizado, FIELD a ser passado no caso de particionamento baseado em campo.

Exemplo

```
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)
```

Particionamento baseado em registro

A consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

O particionamento com base em registros só é compatível para entidades não ODP, pois a paginação em entidades ODP é compatível por meio do próximo token/ignorar token.

- PARTITION_BY: o tipo de particionamento a ser executado. COUNT deve ser passado no caso de particionamento baseado em registro.

Exemplo

```
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)
```

Limitações/legendas

- As entidades de ODP não são compatíveis com particionamento baseado em registro, pois a paginação é feita usando o token skip/token delta. Assim sendo, para o particionamento baseados em registros, o valor padrão de maxConcurrency é definido como “null”, independentemente da entrada do usuário.
- Quando tanto limite quanto partição são aplicados, o limite tem precedência sobre a partição.

Opções de conexão do SAP OData

Estas são as opções de conexão do SAP OData:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no SAP OData.

  Por exemplo: /sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder
- `API_VERSION` (String): (Opcional) usado para leitura. Versão da API Rest do SAP OData que você deseja usar. Exemplo: 2.0.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.

  Por exemplo: SalesOrder
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.

  Por exemplo: `SalesOrder = "10"`
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

  Por exemplo: `SELECT * FROM /sap/opu/odata/sap/API_SALES_ORDER_SRV/A_SalesOrder`
- `PARTITION_FIELD`(string): usado para leitura. Campo a ser usado para particionar a consulta.

  Por exemplo: `ValidStartDate`
- `LOWER_BOUND`(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.

  Por exemplo: `"2000-01-01T00:00:00.000Z"`
- `UPPER_BOUND`(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.

Por exemplo: `"2024-01-01T00:00:00.000Z"`

- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL` (String): o URL do host da aplicação da instância do SAP.

  Por exemplo: `https://example-externaldata.sierra.aws.dev`
- `SERVICE_PATH` (String): o caminho do serviço da aplicação da instância do SAP.

  Por exemplo: `/sap/opu/odata/iwfnd/catalogservice;v=2`
- `CLIENT_NUMBER` (String): o número do cliente da aplicação da instância do SAP.

  Por exemplo: 100
- `PORT_NUMBER` (String): padrão: o número da porta da aplicação da instância do SAP.

  Por exemplo: 443
- `LOGON_LANGUAGE` (String): o idioma de logon da aplicação da instância do SAP.

  Por exemplo: `EN`
- `ENABLE_CDC` (String): define se deve ser executado um trabalho com a captura de dados de alteração (CDC) habilitada, ou seja, com alterações de faixa.

  Por exemplo: `True/False`
- `DELTA_TOKEN` (String): executa uma extração de dados incremental com base no token Delta válido fornecido.

  Por exemplo: `D20241107043437_000463000`
- `PAGE_SIZE` (inteiro): define o tamanho da página para consultar os registros. O tamanho de página padrão é 50.000. Quando um tamanho de página é especificado, o SAP retorna apenas o número definido de registros por chamada de API, em vez de todo o conjunto de dados. O conector fornecerá também o número total de registros e processará a paginação usando o tamanho de página especificado. Se você precisar de um tamanho de página maior, poderá escolher qualquer valor até 500.000, que é o máximo permitido. Qualquer tamanho de página especificado que exceda 500.000 será ignorado. Em vez disso, o sistema usará o tamanho máximo de página permitido. Você pode especificar o tamanho da página na interface de usuário do AWS Glue Studioadicionando uma opção de conexão `PAGE_SIZE` com o valor desejado.

  Por exemplo: `20000`

Detalhes de entidades e campos OData do SAP

Entidade	Tipo de dados	Operadores compatíveis
Tabelas (entidades dinâmicas)	String	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Inteiro	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Longo	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Duplo	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Data	=, !=, >, >=, <, <=, BETWEEN, LIKE
	DateTime	=, !=, >, >=, <, <=, BETWEEN, LIKE
	Booliano	=, !=
	Struct	=, !=, >, >=, <, <=, BETWEEN, LIKE

Conexão com o SendGrid

O SendGrid é uma plataforma de comunicação com clientes para e-mails transacionais e de marketing.

- O conector do SendGrid ajuda na criação e gerenciamento de listas de contatos e na criação de campanhas de marketing por e-mail.
- O SendGrid permite que empresas online, organizações sem fins lucrativos e outras entidades online criem e enviem e-mails de marketing para grandes públicos e monitorem o engajamento com esses e-mails.

Tópicos

- Suporte do AWS Glue para SendGrid
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do SendGrid
- Configuração de conexões do SendGrid
- Leitura de entidades do SendGrid
- Opções de conexão do SendGrid
- Limitações do SendGrid

Suporte do AWS Glue para SendGrid

O AWS Glue oferece suporte ao SendGrid da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do SendGrid.

Compatível como destino?

Nº

Versões da API do SendGrid com suporte

Versões da API do SendGrid com suporte:

- v3

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
```

```
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do SendGrid

Antes de poder usar o AWS Glue para transferir dados do SendGrid, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do SendGrid com uma chave de API.
- Sua conta do SendGrid tem acesso à API com uma licença válida.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do SendGrid. Para conexões típicas, você não precisa fazer mais nada no SendGrid.

Configuração de conexões do SendGrid

O SendGrid oferece suporte a autenticação personalizada.

Para obter a documentação pública do SendGrid sobre a geração das chaves de API necessárias para autenticação personalizada, consulte Autenticação.

Para configurar uma conexão do SendGrid:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave *`api_key`*.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha SendGrid.
   b. Forneça o `INSTANCE_URL` da instância do SendGrid à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do SendGrid

Pré-requisito

Um objeto do SendGrid do qual você deseja ler. Você precisará do nome do objeto, como `lists`, `singlesends` ou `segments`.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Listas	Não	Sim	Não	Sim	Não
Envios únicos	Sim	Sim	Não	Sim	Não
Estatísti cas de campanhas de marketing, Automações	Sim	Sim	Não	Sim	Não
Estatísti cas de campanhas de marketing, Envios únicos	Sim	Sim	Não	Sim	Não
Segmentos	Sim	Não	Não	Sim	Não
Contatos	Sim	Não	Não	Sim	Não
Categoria	Não	Não	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Estatísticas	Sim	Não	Não	Sim	Não
Cancelar inscrição em grupos	Sim	Não	Não	Sim	Não

Exemplo:

```
sendgrid_read = glueContext.create_dynamic_frame.from_options(
    connection_type="sendgrid",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "lists",
        "API_VERSION": "v3",
        "INSTANCE_URL": "instanceUrl"
    }
```

Detalhes de entidade e campo do SendGrid:

Entidades com metadados estáticos:

Entidade	Campo	Tipo de dados	Operadores compatíveis	
Listas	id	String	N/D	
	nome	String	N/D	
	contact_count	Inteiro	N/D	
	_metadata	Struct	N/D	
Envios únicos	id	String	N/D	

Entidade	Campo	Tipo de dados	Operadores compatíveis	
	nome	String	EQUAL_TO	
	abtest	Struct	N/D	
	status	String	EQUAL_TO	
	categories	Lista	EQUAL_TO	
	send_at	String	N/D	
	is_abtest	Booleano	N/D	
	updated_at	String	N/D	
	created_at	String	N/D	
	canais	Lista	N/D	
Estatísticas de campanhas de marketing, Automações	id	String	N/D	
	agregação	String	N/D	
	step_id	String	N/D	
	stats	Struct	N/D	
	automation_ids	Lista	EQUAL_TO	
Estatísticas de campanhas de marketing, Envios únicos	id	String	N/D	
	ab_variation	String	N/D	
	ab_phase	String	N/D	
	agregação	String	N/D	
	stats	Struct	N/D	
	singlesend_ids	Lista	EQUAL_TO	

Entidade	Campo	Tipo de dados	Operadores compatíveis	
Segmentos	id	String	N/D	
	nome	String	N/D	
	query_version	String	N/D	
	contacts_count	Inteiro	N/D	
	sample_updated_at	String	N/D	
	next_sample_update	String	N/D	
	created_at	String	N/D	
	updated_at	String	N/D	
	parent_list_id	String	N/D	
	status	Struct	N/D	
	parent_list_ids	String	EQUAL_TO	
	no_parent_list_id	Booleano	EQUAL_TO	
Contatos	id	String	N/D	
	first_name	String	N/D	
	last_name	String	N/D	
	unique_name	String	N/D	
	email	String	N/D	
	alternate_emails	Lista	N/D	
	address_line_1	String	N/D	

Entidade	Campo	Tipo de dados	Operadores compatíveis	
	address_line_2	String	N/D	
	city	String	N/D	
	state_province_region	String	N/D	
	country	String	N/D	
	postal_code	String	N/D	
	phone_number	String	N/D	
	whatsapp	String	N/D	
	linha	String	N/D	
	facebook	String	N/D	
	list_ids	Lista	N/D	
	custom_fields	Struct	N/D	
	created_at	String	N/D	
	updated_at	String	N/D	
	_metadata	Struct	N/D	
	event_timestamp	DateTime	BETWEEN	
Categoria	categories	Lista	N/D	
Estatísticas	date	String	N/D	
	stats	Lista	N/D	
	start_date	DateTime	EQUAL_TO, BETWEEN	

Entidade	Campo	Tipo de dados	Operadores compatíveis
	aggregated_by	String	EQUAL_TO
Cancelar inscrição em grupos	id	Inteiro	EQUAL_TO
	nome	String	N/D
	description	String	N/D
	last_email_sent_at	Inteiro	N/D
	is_default	Booleano	N/D
	cancela assinatura	Inteiro	N/D

> **Note**
>
> Os tipos de dados Struct e List são convertidos no tipo de dados String, e o tipo de dados DateTime é convertido em Timestamp na resposta dos conectores.

Particionamento de consultas

O SendGrid não oferece suporte ao particionamento baseado em filtros ou ao particionamento baseado em registros.

Opções de conexão do SendGrid

Estas são as opções de conexão do SendGrid:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome do seu objeto no SendGrid.
- `API_VERSION`(string): (obrigatório) usado para leitura. Versão da API Rest do SendGrid que você deseja usar.
- `INSTANCE_URL`(string): (obrigatório) usado para leitura. Um URL válido da instância do SendGrid.

- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

Limitações do SendGrid

A seguir estão as limitações ou notas do SendGrid:

- Só há suporte para a extração incremental na entidade Estatísticas no campo `start_date`, e na entidade Contato no campo `event_timestamp`.
- Só há suporte para paginação nas entidades Estatísticas da campanha de marketing (automações), Estatísticas da campanha de marketing (envios únicos), Envios únicos e Listas.
- Para a entidade Estatísticas, `start_date` é um parâmetro de filtro obrigatório.
- Uma chave de API com acesso restrito não pode oferecer suporte ao acesso de leitura para as entidades API de e-mail e Estatísticas. Use uma chave de API com acesso total. Para obter mais informações, consulte a Visão geral da API.

Conectando-se a ServiceNow

ServiceNow é uma plataforma SaaS baseada em nuvem para automatizar fluxos de trabalho de gerenciamento de TI. A ServiceNow plataforma se integra facilmente a outras ferramentas, permitindo que os usuários gerenciem projetos, equipes e interações com clientes usando uma variedade de aplicativos e plug-ins. Como ServiceNow usuário, você pode se conectar AWS Glue à sua ServiceNow conta. Em seguida, você pode usar ServiceNow como fonte de dados em seus ETL trabalhos. Execute essas tarefas para transferir dados ServiceNow entre AWS serviços ou outros aplicativos compatíveis.

Tópicos

- AWS Glue suporte para ServiceNow
- Políticas contendo as API operações para criar e usar conexões
- Configurando ServiceNow
- Configuração de conexões do ServiceNow
- Leitura de entidades do ServiceNow
- ServiceNow opções de conexão

- Limitações e notas do conector do ServiceNow

AWS Glue suporte para ServiceNow

AWS Glue suporta da ServiceNow seguinte forma:

Compatível como fonte?

Sim. Você pode usar AWS Glue ETL trabalhos para consultar dados ServiceNow.

Compatível como destino?

Não.

ServiceNow APIVersões suportadas

As seguintes ServiceNow API versões são suportadas:

- v2

Para suporte de entidades por versão específica, consulte Entidades suportadas para o Source.

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS IAM permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
```

```
}
```

Se você não quiser usar o método acima, use as seguintes IAM políticas gerenciadas:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configurando ServiceNow

Antes de usar AWS Glue para transferir dados de ServiceNow, você deve atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma ServiceNow conta com e-mail e senha. Para obter mais informações, consulte Criando uma ServiceNow conta.
- Sua ServiceNow conta está habilitada para API acesso. Todo o uso do ServiceNow API está disponível sem custo adicional.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua ServiceNow conta.

Criando uma ServiceNow conta

Para criar uma ServiceNow conta:

1. Navegue até a página de inscrição em servicenow.com, insira seus dados e clique em Continuar.

2. Ao receber um código de verificação em seu e-mail registrado, insira esse código e escolha Verificar.
3. Configure a autenticação multifatorial ou deixe de fazer isso.

Sua conta é criada e ServiceNow exibe seu perfil.

Criação de uma instância de ServiceNow desenvolvedor

Solicite uma instância de desenvolvedor depois de fazer login em ServiceNow.

1. Na página de ServiceNow login, insira as credenciais da sua conta.
2. Escolha o Programa para ServiceNow Desenvolvedores.

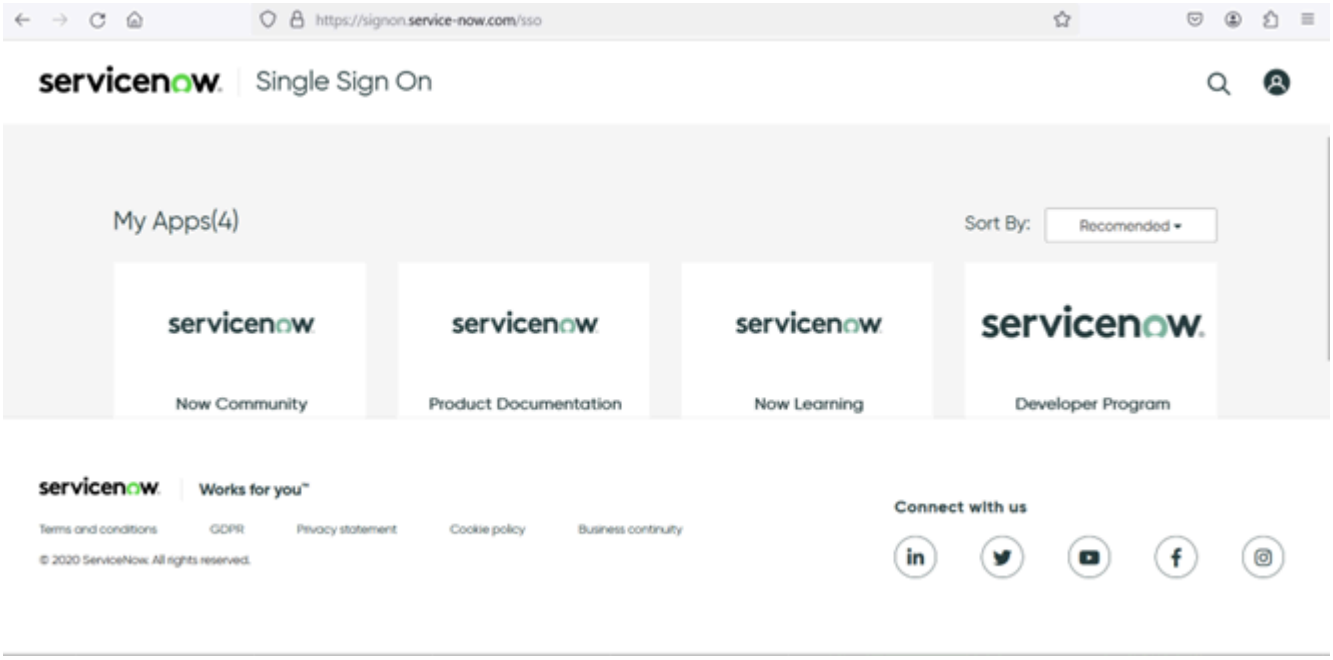

3. Escolha Solicitar instância no canto superior direito.
4. Insira suas responsabilidades profissionais. Indique sua concordância com os termos de uso e escolha Concluir configuração.
5. Depois que a instância for criada, anote sua instância URL e suas credenciais.

Recuperando credenciais BasicAuth

Para recuperar as credenciais do Basic Auth para uma conta gratuita:

1. Na página de ServiceNow login, insira as credenciais da sua conta.

2. Na página inicial, escolha a seção de edição do perfil (canto superior direito) e escolha Gerenciar senha da instância.
3. Recupere as credenciais de login, como nome de usuário, senha e instância. URL

> **Note**
>
> <username><password>Se MFA estiver habilitado para a conta, anexe o MFA token ao final da senha do usuário na autenticação básica:: < Token> MFA

Para obter mais informações, consulte Criação de aplicativos na ServiceNow documentação.

Criação de credenciais OAuth 2.0

Para usar OAuth2 .0 no ServiceNow conector, você precisa criar um (cliente) de entrada para gerar o ID do cliente e o segredo do cliente:

1. Na página de ServiceNow login, insira as credenciais da sua conta.
2. Na página inicial, escolha Começar a criar.
3. Na página do App Engine Studio, pesquise por Registro de aplicativos.
4. Escolha Novo no canto superior direito.
5. Escolha a opção Criar um OAuth API endpoint para clientes externos.
6. Faça as alterações necessárias na OAuth configuração e escolha Atualizar.

   Exemplo de redirecionamentoURL: oauth https://us-east-1.console.aws.amazon.com/gluestudio/
7. Selecione o aplicativo OAuth cliente recém-criado para recuperar o ID do cliente e o segredo do cliente.
8. Armazene o ID do cliente e o segredo do cliente para processamento adicional.

Para configurar OAuth em uma conta de desenvolvedor que não seja de produção:

1. Crie um perfil de autenticação usando o tópico Criar um perfil de autenticação na ServiceNow documentação.
2. No Perfil de Autenticação paraOAuth, selecione Tipo como OAuth e selecione o cliente de entrada criado acima para definir a Entidade. OAuth

3. Se houver vários clientes, você precisará criar vários perfis de autenticação para definir a OAuth entidade necessária no perfil de autenticação.
4. Se não estiver configurado, crie uma política de REST API acesso para dar acesso ao TABLEAPI. Consulte Criar política de REST API acesso.

Configuração de conexões do ServiceNow

O tipo de concessão determina como o AWS Glue se comunica com o ServiceNow para solicitar acesso aos seus dados. A escolha afeta os requisitos que você deve atender antes de criar a conexão. O ServiceNow só oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth 2.0.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O console do AWS Glue redirecionará o usuário para o ServiceNow, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do ServiceNow.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no ServiceNow e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o ServiceNow para fazer login e autorizar o acesso do AWS Glue aos seus recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do ServiceNow sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Configuração do OAuth.

Para configurar uma conexão do ServiceNow:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para autenticação básica, o segredo deve conter o segredo do consumidor da aplicação conectada com `USERNAME` e `PASSWORD` como chave.
   b. Para um tipo de concessão de código de autorização, o segredo deve conter o segredo do consumidor da aplicação conectada com `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET` como chave.

c. Nota: é preciso criar um segredo por conexão em AWS Glue.

2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha ServiceNow.
   b. Forneça o INSTANCE_URL da instância do ServiceNow à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Selecione o Tipo de autenticação que você deseja usar para essa conexão no AWS Glue.
      i. Autorização básica: esse tipo de autorização funciona bem para cenários de automação, pois permite o uso do nome de usuário e da senha antecipadamente com as permissões de um usuário específico na instância do ServiceNow. O AWS Glue pode usar o nome de usuário e a senha para autenticar APIs do ServiceNow. Insira as entradas a seguir somente no caso de autenticação básica: `Username` e `Password`.
      ii. OAuth2: insira as entradas a seguir somente no caso de OAuth2: `ClientId`, `ClientSecret`, `Authorization URL`, `Authorization Token URL`.
   e. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   f. Selecione as opções de rede se quiser usar sua rede.
3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do ServiceNow

Pré-requisito

Um objeto de tabelas do ServiceNow do qual você deseja ler. Você precisará do nome do objeto, como pa_bucket ou incidente.

Exemplo:

```
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"
    }
)
```

Detalhes das entidades e dos campos do ServiceNow:

Para as entidades a seguir, o ServiceNow fornece endpoints para buscar metadados dinamicamente, para que o suporte do operador seja capturado no nível do tipo de dados de cada entidade.

Entidade	Tipo de dados	Operadores compatíveis
Tabelas (entidades dinâmicas)	Inteiro	=, !=, <, <=, >, >=, BETWEEN
	BigDecimal	=, !=, <, <=, >, >=, BETWEEN
	Float	=, !=, <, <=, >, >=, BETWEEN
	Longo	=, !=, <, <=, >, >=, BETWEEN
	Data	=, !=, <, <=, >, >=, BETWEEN
	DateTime	=, !=, <, <=, >, >=, BETWEEN
	Booliano	=, !=
	String	=, !=, <, <=, >, >=, BETWEEN, LIKE

Entidade	Tipo de dados	Operadores compatíveis
	Struct	N/D

> **Note**
>
> O tipo de dados Struct é convertido no tipo de dados String na resposta do conector.

> **Note**
>
> `DML_STATUS` é um atributo adicional definido pelo usuário usado para rastrear registros CREATED/UPDATED.

Particionamento de consultas

Particionamento com base em campo:

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

Nome da entidade	Campos de particionamento	Tipo de dados
Entidade dinâmica	sys_mod_count	Inteiro
	sys_created_on, sys_updated_on	DateTime

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Data e hora, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

Exemplos de valores válidos:

```
"2024-01-30T06:47:51.000Z"
```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

A tabela a seguir descreve os detalhes do suporte do campo de particionamento da entidade:

Exemplo: .

```
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"
    }
```

Particionamento com base em registros:

Você pode fornecer a opção adicional NUM_PARTITIONS do Spark se quiser utilizar a simultaneidade no Spark. Com esse parâmetro, a consulta original é dividida em NUM_PARTITIONS subconsultas, que podem ser executadas pelas tarefas do Spark simultaneamente.

No particionamento com base em registros, o número total de registros presentes é consultado na API do ServiceNow e dividido pelo número NUM_PARTITIONS fornecido. O número resultante de registros é então buscado simultaneamente por cada subconsulta.

- NUM_PARTITIONS: o número de partições.

Exemplo: .

```
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 opções de conexão

A seguir estão as opções de conexão para ServiceNow:

- `ENTITY_NAME`(String) - (Obrigatório) Usado para leitura. O nome do seu objeto em ServiceNow.
- `API_VERSION`(String) - (Obrigatório) Usado para leitura. ServiceNow APIVersão REST que você deseja usar. Por exemplo: v1, v2, v3, v4.
- `SELECTED_FIELDS`(Lista<String>) - Padrão: vazio (SELECT*). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Ele deve estar no SQL formato Spark.
- `QUERY`(String): padrão: vazia. Usado para leitura. SQLConsulta completa do Spark.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido. Por exemplo: 2024-01-30T 06:47:51.000 Z.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido. Por exemplo: 2024-06-30T 06:47:51.000 Z.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura. Por exemplo: 10.
- `INSTANCE_URL`(String) - (Obrigatório) Uma ServiceNow instância válida URL com formato https://<instance-name>.service-now.com.

Limitações e notas do conector do ServiceNow

Estas são as limitações ou notas do conector do ServiceNow:

- De acordo com a documentação do SaaS, `sys_created_on`, `sys_updated_on` e `sys_mod_count` são campos gerados pelo sistema. O conector depende de APIs SaaS para fornecer esses campos no corpo da resposta.

  - Se o SaaS não gerar esses campos para nenhuma entidade, o particionamento baseado em filtros não poderá ser suportado.
- Se as APIs SaaS não retornarem os campos `sys_created_on` e `sys_updated_on` na resposta, `DML_STATUS` não poderá ser calculado.

Conexão com o Slack no AWS Glue Studio

O Slack é um aplicativo de comunicação empresarial que permite aos usuários enviar mensagens e anexos por meio de vários canais públicos e privados. Se você usa o Slack, pode conectar o AWS Glue à conta do Slack. Em seguida, você pode usar o Slack como fonte de dados nos trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Slack e serviços da AWS ou outras aplicações compatíveis.

Tópicos

- Suporte do AWS Glue para o Slack
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Slack
- Configuração de conexões do Slack
- Leitura de entidades do Slack
- Opções de conexão do Slack
- Limitações
- Criação de uma conta do Slack e configuração da aplicação cliente

Suporte do AWS Glue para o Slack

O AWS Glue oferece suporte ao Slack da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Slack.

Compatível como destino?

N.º

Versões compatíveis da API do Slack

API do Slack v2.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Slack

Antes de poder usar o AWS Glue para transferir dados de ou para o Slack, você precisa atender aos seguintes requisitos:

Requisitos mínimos

- Você deve ter uma conta do Slack. Para ter mais informações, consulte Criação de uma conta do Slack e configuração da aplicação cliente.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Slack.

Configuração de conexões do Slack

O Slack é compatível com o tipo de concessão `AUTHORIZATION_CODE` para OAuth 2.

Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O Console do AWS Glue redirecionará o usuário para o Slack, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Slack.

Os usuários ainda podem optar por criar sua própria aplicação conectada no Slack e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Slack para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso expira uma hora após a criação. Um novo token de acesso pode ser obtido usando o token de atualização.

Para obter mais informações sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte a API do Slack.

Para configurar uma conexão do Slack:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para a conexão no AWS Glue.

a. Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:

   a. Ao selecionar um Tipo de conexão, escolha Slack.

   b. Forneça o ambiente do Slack.

   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

   e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Slack

Pré-requisitos

- Um objeto do Slack do qual você deseja ler.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
conversas	Sim	Sim	Não	Sim	Sim

Exemplo

```
slack_read = glueContext.create_dynamic_frame.from_options(
    connection_type="slack",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "conversations/C058W38R5J8"
    }
)
```

Detalhes das entidades e dos campos do Slack

Entidade	Campo	Tipo de dado	Operadores compatíveis
conversas	attachments	Listar	N/D
conversas	bot_id	String	N/D
conversas	blocks	Listar	N/D
conversas	client_msg_id	String	N/D
conversas	is_starred	Booleano	N/D
conversas	last_read	String	N/D
conversas	latest_reply	String	N/D
conversas	reações	Listar	N/D

Entidade	Campo	Tipo de dado	Operadores compatíveis
conversas	responde	Listar	N/D
conversas	reply_count	Inteiro	N/D
conversas	reply_users	Listar	N/D
conversas	reply_users_count	Inteiro	N/D
conversas	inscrito	Booleano	N/D
conversas	subtipo	String	N/D
conversas	text	String	N/D
conversas	team	String	N/D
conversas	thread_ts	String	N/D
conversas	ts	String	EQUAL_TO, BETWEEN, LESS_THAN , LESS_THAN _OR_EQUAL_TO, GREATER_T HAN, GREATER_T HAN_OR_EQUAL_TO
conversas	tipo	String	N/D
conversas	usuário	String	N/D
conversas	anfitrião	String	N/D
conversas	raiz	struct	N/D
conversas	is_locked	Booleano	N/D
conversas	files	Listar	N/D

Entidade	Campo	Tipo de dado	Operadores compatíveis
conversas	sala	struct	N/D
conversas	carregar	Booleano	N/D
conversas	display_as_bot	Booleano	N/D
conversas	channel	String	N/D
conversas	no_notifications	Booleano	N/D
conversas	permalink	String	N/D
conversas	pinned_to	Listar	N/D
conversas	pinned_info	struct	N/D
conversas	editado	struct	N/D
conversas	app_id	String	N/D
conversas	bot_profile	struct	N/D
conversas	metadata	struct	N/D

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valor válido: `"2024-07-01T00:00:00.000Z"`.
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.

- NUM_PARTITIONS: número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na tabela a seguir.

Entity Name	Campo de particionamento	Tipo de dado
conversas	ts	String

Exemplo

```
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"
    }
)
```

Opções de conexão do Slack

Estas são as opções de conexão do Slack:

- ENTITY_NAME (String): (obrigatório) usado para leitura. Nome da entidade compatível. Exemplo: conversations/C058W38R5J8.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que você deseja selecionar para o objeto.
- FILTER_PREDICATE(String): padrão: vazia. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- NUM_PARTITIONS(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações

Estas são as limitações do conector do Slack:

- O particionamento com base em registros não é compatível, pois o conector não fornece um meio de buscar o número total de registros (mensagens) disponíveis em uma determinada conversa.

Criação de uma conta do Slack e configuração da aplicação cliente

Criação de uma conta do Slack

1. Abra a página inicial do Slack para cadastrar-se em uma conta.
2. Escolha CADASTRAR-SE COM ENDEREÇO DE E-MAIL. Insira seu ID de email e escolha Continuar.
3. Insira o código de seis caracteres enviado ao seu endereço de e-mail. Ele redirecionará você para criar um espaço de trabalho ou ingressar em um espaço de trabalho existente.
4. Escolha Criar um espaço de trabalho para criar um espaço de trabalho. Isso redirecionará você para responder a algumas perguntas como parte do processo de configuração.
   - Nome da empresa
   - Seu nome
   - Para adicionar colegas por e-mail
   - Em que sua equipe está trabalhando? (Esse será o nome do canal)
5. Preencha os campos de entrada para essas perguntas e continue. Sua conta agora está pronta para ser usada.

Criação de uma aplicação para desenvolvedores do Slack

1. Entre na sua conta do Slack e faça login no espaço de trabalho do Slack.
2. No menu do espaço de trabalho, selecione Ferramentas e configurações e, em seguida, selecione Gerenciar aplicações.
3. No menu Diretório de aplicações do Slack, selecione Criar.
4. Na página Suas aplicações, selecione Criar uma aplicação.
5. Na página Criar uma aplicação, selecione Do zero.

6. Na caixa de diálogo Nomear aplicação e escolher espaço de trabalho que se abre, adicione um nome de aplicação e Escolha um espaço de trabalho para implantar a aplicação. Em seguida, selecione Criar aplicação.
7. Anotar seu Id de cliente e o segredo exibidos nas credenciais da aplicação
8. Na barra lateral do OAuth e permissões, acesse Escopos e escolha Adicionar um escopo do OAuth. Você pode adicionar os URLs de redirecionamento à aplicação para configuração da geração automática do botão “Adicionar ao Slack” ou para distribuir a aplicação. Role para cima até a seção URLs de redirecionamento, escolha Adicionar novo URL de redirecionamento e salve.
9. Em seguida, role até a seção Tokens OAuth na seção do espaço de trabalho e escolha Instalar no espaço de trabalho.
10. Na caixa de diálogo que se abre informando que a aplicação que você criou está solicitando permissão para acessar o espaço de trabalho do Slack ao qual você deseja conectá-lo, selecione Permitir.
11. Após a conclusão bem-sucedida, o console exibirá uma tela Tokens OAuth para seu espaço de trabalho..
12. Na tela Tokens OAuth para seu espaço de trabalho, copie e salve o token OAuth que você usará para se conectar ao AWS Glue
13. Em seguida, recupere o ID da sua equipe do Slack. No menu do espaço de trabalho do Slack, selecione Ferramentas e configurações e, em seguida, selecione Gerenciar aplicações. Você encontrará o ID da sua equipe no URL da página que se abre.
14. Para distribuir publicamente a aplicação, você pode ativá-la acessando o botão Gerenciar distribuição na barra lateral. Role para baixo até a seção Compartilhar sua aplicação com outros espaços de trabalho e escolha Remover informações com codificação rígida. Forneça consentimento e escolha Distribuição pública ativa.
15. Agora, a aplicação está distribuída publicamente. Para acessar as APIs da entidade, a aplicação precisa ser adicionada a cada canal do espaço de trabalho de onde o usuário deseja acessar.
16. Faça login na sua conta do Slack e abra o espaço de trabalho cujo canal precisa ser acessado.
17. No espaço de trabalho, abra o canal que a aplicação deseja acessar e escolha o título do canal. Selecione a guia Integrações no pop-up e adicione a aplicação. Dessa forma, a aplicação é integrada ao canal para ter acesso à API.

    O ID do cliente do OAuth 2.0 deve ter um ou mais URLs de redirecionamento autorizados. Os URLs de redirecionamento têm o seguinte formato:

> **Note**
>
> Os URLs de redirecionamento do Appflow estarão sujeitos a alterações depois que os URLs de redirecionamento da plataforma do AWS Glue estiverem disponíveis. O ID do cliente e o segredo do cliente são originários das configurações do ID do cliente do OAuth 2.0.

O URL de redirecionamento pode ser um dos mostrados a seguir	
URL de redirecionamento para ambiente 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	

O URL de redirecionamento pode ser um dos mostrados a seguir	
URL de redirecionamento para ambiente Gamma	
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	
https://eu-west-2.console.aws.amazon.com/appflow/oauth	
https://eu-west-3.console.aws.amazon.com/appflow/oauth	
https://sa-east-1.console.aws.amazon.com/appflow/oauth	
https://us-west-2.awsc-integ.aws.amazon.com/appflow/oauth	
https://af-south-1.console.aws.amazon.com/appflow/oauth	

Conectar ao Smartsheet

O Smartsheet é um produto SaaS de gerenciamento de trabalho e colaboração. Fundamentalmente, o Smartsheet permite que os usuários usem objetos semelhantes a planilhas para criar, armazenar e utilizar dados de negócios.

Tópicos

- Suporte do AWS Glue para Smartsheet

- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Smartsheet
- Configuração de conexões do Smartsheet
- Leitura de entidades do Smartsheet
- Opções de conexão do Smartsheet
- Criação de uma conta do Smartsheet
- Limitações

Suporte do AWS Glue para Smartsheet

O AWS Glue oferece suporte ao Smartsheet da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar dados do Smartsheet.

Compatível como destino?

Nº

Versões da API do Smartsheet com suporte

v2.0

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
```

```
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se não quiser usar o método anterior, uma alternativa será usar as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Smartsheet

Antes de poder usar o AWS Glue para transferir dados do Smartsheet, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

- Você tem uma conta do Smartsheet com e-mail e senha. Para obter mais informações sobre como criar uma conta, consulte Criação de uma conta do Smartsheet.
- Sua conta do Smartsheet tem acesso à API com uma licença válida.
- Sua conta do Smartsheet tem um plano de preços Pro para a entidade `Sheets` e um plano de preços Enterprise com o complemento Event Reporting para a entidade `Events`.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Smartsheet. Para conexões típicas, você não precisa fazer mais nada no Smartsheet.

Configuração de conexões do Smartsheet

O Smartsheet oferece suporte ao tipo de concessão `AUTHORIZATION_CODE` para OAuth2.

Esse tipo de concessão é considerado um `OAuth` de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Os usuários ainda podem optar por criar sua própria aplicação conectada no Smartsheet e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Smartsheet para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.

Para obter a documentação pública do Smartsheet sobre a criação de uma aplicação conectada para o fluxo OAuth AUTHORIZATION_CODE, consulte APIs do Smartsheet.

Para configurar uma conexão do Smartsheet:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

   Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.

   > **Note**
   >
   > É preciso criar um segredo por conexão em AWS Glue.

2. No AWS Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Smartsheet.
   b. Forneça o `instanceUrl` do Smartsheet ao qual deseja se conectar.
   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
```

```
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Smartsheet

Pré-requisitos

Um objeto do `Smartsheet` do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Listar planilha	Sim	Sim	Não	Sim	Não
Metadados de linha	Sim	Sim	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Metadados da planilha	Não	Não	Não	Sim	Não
Dados da planilha	Sim	Sim	Sim	Sim	Não
Event	Sim	Sim	Não	Sim	Não

Exemplo

```
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"
    })
```

Detalhes de entidade e campo do Smartsheet

Entidade	Campo	Tipo de dado	Operadores com suporte
Listar planilhas	id	Longo	NA
	accessLevel	String	NA
	createdAt	DateTime	NA
	modifiedAt	DateTime	NA
	nome	String	NA

Entidade	Campo	Tipo de dado	Operadores com suporte
	permalink	String	NA
	modifiedSince	DateTime	>=
	version	Inteiro	NA
	origem	Struct	NA
Metadados de linha	id	Longo	NA
	sheetId	Longo	NA
	accessLevel	String	NA
	anexos	Lista	NA
	colunas	Lista	NA
	conditionalFormat	String	NA
	createdAt	DateTime	NA
	createdBy	Struct	NA
	discussions	Lista	NA
	proofs	Struct	NA
	expanded	Booleano	NA
	filteredOut	Booleano	NA
	formato	String	NA
	inCriticalPath	Booleano	NA
	locked	Booleano	NA
	lockedForUser	Booleano	NA

Entidade	Campo	Tipo de dado	Operadores com suporte
	modifiedAt	DateTime	NA
	modifiedBy	Struct	NA
	permalink	String	NA
	rowNumber	Inteiro	NA
	version	Inteiro	NA
	totalRowCount	Inteiro	NA
	rowsModifiedSince	DateTime	>
	filterId	Longo	“="
	siblingId	Longo	NA
	parentId	Longo	NA
Metadados da planilha	id	Longo	NA
	fromId	Longo	NA
	ownerId	Longo	NA
	accessLevel	String	NA
	anexos	Lista	NA
	colunas	Lista	NA
	createdAt	DateTime	NA
	crossSheetReferences	Lista	NA
	dependenciesEnabled	Booleano	NA

Entidade	Campo	Tipo de dado	Operadores com suporte
	discussions	Lista	NA
	effectiveAttachmentOptions	Lista	NA
	favorito	Booleano	NA
	ganttEnabled	Booleano	NA
	hasSummaryFields	Booleano	NA
	modifiedAt	DateTime	NA
	nome	String	NA
	proprietário	String	NA
	permalink	String	NA
	projectSettings	Struct	NA
	readOnly	Booleano	NA
	resourceManagementEnabled	Booleano	NA
	showParentRowsForFilters	Booleano	NA
	origem	Struct	NA
	resumo	Struct	NA
	totalRowCount	Inteiro	NA
	userPermissions	Struct	NA
	userSettings	Struct	NA

Entidade	Campo	Tipo de dado	Operadores com suporte
	version	Inteiro	NA
	espaço de trabalho	Struct	NA
	filtros	Lista	NA
	ganttConfig	Struct	NA
	resourceManagementType	String	NA
	cellImageUploadEnabled	Booleano	NA
	isMultiPicklistEnabled	Booleano	NA
Eventos	eventId	String	NA
	objectType	String	NA
	action	String	NA
	objectId	Longo	NA
	eventTimestamp	DateTime	NA
	userId	Longo	NA
	requestUserId	Longo	NA
	accessTokenName	String	NA
	origem	String	NA
	additionalDetails	Struct	NA
	since	DateTime	>=

Entidades com metadados dinâmicos:

Para a entidade a seguir, o Smartsheet fornece um endpoint para buscar metadados dinamicamente, para que o suporte do operador seja capturado no nível do tipo de dados.

Entidade	Tipo de dado	Operadores compatíveis
Dados da planilha	String	NA
Dados da planilha	Longo	"="
Dados da planilha	Inteiro	NA
Dados da planilha	DateTime	>

Exemplo

```
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"
    }
```

Opções de conexão do Smartsheet

Estas são as opções de conexão do Smartsheet:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Smartsheet.
- `API_VERSION`(string): (obrigatório) usado para leitura/gravação. Versão da API Rest do Smartsheet que você deseja usar. Por exemplo, v2.0.
- `INSTANCE_URL`(string): (obrigatório) usado para leitura. URL da instância do Smartsheet.
- `SELECTED_FIELDS`(lista<string>): padrão: vazio (SELECT *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.

- QUERY(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

Criação de uma conta do Smartsheet

1. Cadastre-se para obter uma conta do Smartsheet acessando a página de inscrição do Smartsheet.
2. Escolha Criar uma para criar uma nova conta ou faça login usando sua conta registrada do Google, Microsoft ou Apple.
3.
4.
5. Abra o e-mail de confirmação do Smartsheet e escolha o link de confirmação para verificar sua conta.

   Você será inscrito no Plano de teste por padrão.
6. No canto inferior esquerdo, escolha o ícone Conta e escolha Adicionar licenças/Atualizar para atualizar seu plano de preços.

   > **Note**
   >
   > Isso é necessário para acessar o Relatório de eventos, que é um complemento do plano Enterprise.
7. No plano Enterprise, escolha Fale conosco para solicitar uma atualização de conta à equipe de suporte.
8. No formulário de solicitação de suporte, forneça os detalhes necessários e seus requisitos para atualizar o plano.

   Isso conclui a atualização para o plano Enterprise.

Criação de credenciais do **OAuth2.0**

1. Depois de atualizar o plano de preços da sua conta para ter acesso às Ferramentas do desenvolvedor, acesse Desenvolvedores do Smartsheet.

   Você receberá um e-mail de ativação.

2. Abra o e-mail de ativação do Smartsheet e escolha o link de ativação para ativar as ferramentas do desenvolvedor em sua conta.

   As ferramentas de desenvolvedor permitem que você crie a aplicação.
3. Abra a página inicial da sua conta do Smartsheet e escolha Conta para verificar o acesso.
4. Escolha Ferramentas do desenvolvedor na lista de serviços e insira os detalhes do Perfil do desenvolvedor.
5. Selecione Criar nova aplicação.
6. Insira os detalhes a seguir no formulário de registro da aplicação:

   - Nome: o nome da aplicação.
   - Descrição: a descrição da aplicação.
   - URL: URL que permite que você inicie sua aplicação ou o URL da página de destino.
   - Contato/suporte: informações de contato da equipe de suporte.
   - URL de redirecionamento: URL (também conhecida como URL de retorno de chamada) dentro da sua aplicação que receberá as credenciais do OAuth 2.0.
7. Escolha Salvar.

   O Smartsheet atribui um ID do cliente e um segredo do cliente à sua aplicação. Registre esses valores para as próximas etapas. Você também pode procurá-los novamente mais tarde na seção Ferramentas do desenvolvedor.

Limitações

O Smartsheet não oferece suporte ao particionamento baseado em campos ou baseado em registros.

Conexão com o Snapchat Ads no AWS Glue Studio

O Snapchat é uma aplicação e um serviço de mensagens instantâneas multimídia desenvolvido pela Snap Inc., originalmente Snapchat Inc. Um dos principais recursos do Snapchat é que as imagens e mensagens geralmente só ficam disponíveis por um breve período antes de se tornarem inacessíveis para os destinatários. O Snapchat Marketing consiste em publicações pelas quais as empresas podem pagar para servir aos usuários do Snapchat.

Tópicos

- Suporte do AWS Glue ao Snapchat Ads
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Snapchat Ads
- Configuração de conexões do Snapchat Ads
- Leitura de entidades do Snapchat Ads
- Opções de conexão do Snapchat Ads
- Criação de uma conta do Snapchat Ads e configuração da aplicação cliente
- Criação de uma aplicação na conta do Snapchat Ads

Suporte do AWS Glue ao Snapchat Ads

O AWS Glue oferece suporte ao Snapchat Ads da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Snapchat Ads.

Compatível como destino?

N.º

Versões compatíveis da API do Snapchat Ads

v1.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões da AWS necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
```

```
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Snapchat Ads

Antes de poder usar o AWS Glue para transferir dados do Snapchat Ads, você precisa atender aos seguintes requisitos:

Requisitos mínimos

- Ter uma conta do Snapchat Ads. Para obter mais informações sobre a criação de uma conta, consulte Criação de uma conta do Snapchat Ads e configuração da aplicação cliente .
- Ter criado uma aplicação OAuth2 na conta do Snapchat Ads. Essa integração fornece as credenciais que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para ter mais informações, consulte Criação de uma aplicação na conta do Snapchat Ads .

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Snapchat Ads. No Snapchat Ads, uma aplicação conectada é uma estrutura que autoriza aplicações externas, como o AWS Glue, a acessar os dados do Snapchat Ads.

Configuração de conexões do Snapchat Ads

O Snapchat Ads só oferece suporte ao tipo de concessão `AUTHORIZATION_CODE`.

Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para o servidor de autorização de terceiros para autenticar o usuário. Ele é usado na criação de conexões por meio do Console do AWS Glue. O usuário que está criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao AWS Glue (aplicação cliente gerenciada pelo AWS Glue), na qual ele não precisa fornecer quaisquer informações relacionadas ao OAuth, exceto o URL da instância do Snapchat Ads. O Console do AWS Glue redirecionará o usuário para o Snapchat Ads, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Snapchat Ads.

Os usuários ainda podem optar por criar sua própria aplicação conectada no Snapchat Ads e fornecer os próprios ID e segredo de cliente quando criarem conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Snapchat Ads para fazer login e autorizar o acesso do AWS Glue aos recursos.

Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso expira uma hora após a criação. Um novo token de acesso pode ser obtido usando o token de atualização.

Para obter mais informações sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte a API do Amazon Ads.

Para configurar uma conexão com o Snapchat Ads:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Snapchat Ads.
   b. Forneça o ambiente do Snapchat Ads.
   c. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Snapchat Ads

Pré-requisitos

- Um objeto do Snapchat Ads do qual você deseja ler. Consulte a tabela de entidades compatíveis abaixo para verificar as entidades disponíveis.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Organização	Não	Não	Não	Sim	Não
Conta de anúncios	Não	Não	Não	Sim	Não
Criativa	Não	Não	Não	Sim	Não
Mídia	Não	Não	Não	Sim	Não
Campaign	Sim	Não	Não	Sim	Não
Anúncio em conta de anúncio	Sim	Não	Não	Sim	Não
Anúncio em campanha	Não	Não	Não	Sim	Não
Esquadrão de anúncios	Sim	Não	Não	Sim	Não
Segment	Não	Não	Não	Sim	Não

Exemplo

```
snapchatads_read = glueContext.create_dynamic_frame.from_options(
    connection_type="snapchatAds",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "organization",
        "API_VERSION": "v1"
    }
)
```

Detalhes das entidades e dos campos do Snapchat Ads

O Snapchat Ads carrega dinamicamente os campos disponíveis na entidade selecionada. Dependendo do tipo de dados de campo, ele é compatível com os operadores de filtro a seguir.

Tipos de dados de campo	Operadores de filtro compatíveis
Booleano	=

Particionamento de consultas

- Particionamento baseado em campo: não compatível.
- Particionamento baseado em registro: não compatível.

Opções de conexão do Snapchat Ads

Estas são as opções de conexão do Snapchat Ads:

- `ENTITY_NAME` (String): (obrigatório) usado para leitura. O nome da entidade do Snapchat Ads. Exemplo: `campaign` .
- `API_VERSION` (String): (obrigatório) usado para leitura. Versão da API Rest do Snapchat Ads que você deseja usar. O valor será v1, pois o Snapchat Ads atualmente só é compatível com a versão v1.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Lista de colunas separadas por vírgula que você deseja selecionar para a entidade selecionada.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.

Criação de uma conta do Snapchat Ads e configuração da aplicação cliente

Tópicos

- Cadastrar-se no Snapchat Ads
- Etapas para criar uma conta do Snapchat Ads

Cadastrar-se no Snapchat Ads

Para se cadastrar no Snapchat Ads:

1. Navegue até o Gerenciador do Snapchat Ads. Escolha Cadastrar-se ao lado de Começando no Snapchat?.
2. Na tela Criar conta, siga os prompts para inserir o nome da empresa, e-mail, senha etc. Escolha Próximo.
3. Na tela Criar seu perfil, insira valores para Nome de usuário, Site (opcional) e escolha Criar conta. Isso dará a você a opção de adicionar uma foto do perfil e dados biométricos na tela Editar seu perfil. Escolha Confirmar.
4. Na tela Informações da empresa, preencha os campos obrigatórios, como País, Moeda, Número de telefone, GSTIN etc. e conclua o processo de criação da conta escolhendo Avançar.

Etapas para criar uma conta do Snapchat Ads

Para criar uma conta do Snapchat Ads:

1. Faça login no Gerenciador de anúncios. Em seguida, clique na navegação no canto superior e selecione Contas de anúncios.
2. Escolha + Nova conta de anúncios. Insira os detalhes do anunciante:
   - Selecione se você é ou não uma agência que compra anúncios em nome de um anunciante. Se você selecionar “Sim”, seu anúncio poderá ser rejeitado se usar parâmetros de segmentação que podem incluir segmentação por idade, gênero ou nível de código postal. A segmentação por idade mínima pode ser aplicada até 21 anos.
   - Selecione se sua conta de anúncios exibirá ou não anúncios imobiliários, de crédito ou de emprego. Se você selecionar “Sim”, seu anúncio poderá ser rejeitado se usar parâmetros de segmentação que podem incluir segmentação por idade, gênero ou nível de código postal. A segmentação por idade mínima pode ser aplicada até 21 anos.
   - Selecione se você usará a conta de anúncios para anúncios políticos. Se você estiver veiculando um anúncio político, insira a organização política patrocinadora ou o grupo de apoio que está pagando pelo anúncio. Se você não inserir a organização política com exatidão, seus anúncios poderão ser rejeitados. Você também precisará preencher o “Formulário de análise de anúncios políticos” obrigatório vinculado antes de enviar anúncios.
3. Escolha Detalhes da conta e preencha as informações da conta de anúncios:

Campo	Descrição
Nome	O nome da conta de anúncios.
Tipo de conta	Selecione o tipo de conta, se não for preenchido automaticamente.
Tipo de faturamento	Se você quiser ter acesso contínuo à sua fonte de financiamento, escolha “Rotativo”. Isso permite que você reabasteça sua linha de crédito e, muitas vezes, ela é escolhida para veicular anúncios no Gerenciador de anúncios. Se você preferir veicular uma campanha avulsa com um limite de gastos, poderá escolher Pedido de inserção. Se você criar uma conta com um Pedido de inserção, mas quiser definir um limite de gastos posteriormente, poderá deixar o limite de gastos como USD 0. Dessa forma, a conta terá um limite de gastos de USD 0, mas você poderá aplicar um posteriormente.
Empresa de publicidade	A empresa que compra anúncios.
Central de faturamento	Escolha a central de faturamento da qual você deseja receber faturas. Você pode usar a que foi criada automaticamente quando solicitou sua empresa pela primeira vez ou adicionar outra central de faturamento seguindo as etapas na Central de ajuda empresarial.
Moeda	Escolha sua moeda.

Campo	Descrição
Limite de gastos	Se você tiver escolhido “Pedido de inserção” como tipo de faturamento, insira o orçamento para a conta de anúncios.
Fuso horário	Selecione seu fuso horário.

4. Escolha Criar conta. A conta de anúncios será criada e você poderá encontrá-la na parte Contas de anúncios do Gerenciador de anúncios. Para começar a lançar anúncios, você deverá inserir um método de pagamento. Você também pode adicionar membros à sua conta de anúncios.
5. Selecione se deseja usar um método de pagamento existente ou criar um. Em seguida, escolha Salvar método de pagamento.
6. Selecione todos os membros que você convidou para sua empresa para adicionar à conta de anúncios. Para obter mais informações sobre os perfis e permissões que podem ser atribuídos, consulte Visão geral de perfis e permissões. Os membros adicionados poderão fazer login no Gerenciador de anúncios e acessar a conta de anúncios. Quando concluir, salve os membros.

Para obter mais informações sobre contas de anúncios, consulte https://businesshelp.snapchat.com/s/article/roles-permissions?language=en_US https://businesshelp.snapchat.com/s/article/roles-permissions?language=en_US

Criação de uma aplicação na conta do Snapchat Ads

Para ativar o acesso à API de marketing do Snapchat, certifique-se de ter uma conta comercial configurada. Em seguida, siga as etapas mostradas abaixo.

1. Faça login no Gerenciador de anúncios. Em seguida, escolha o menu no canto superior esquerdo, selecione Painel empresarial e selecione Detalhes empresariais.
2. Escolha Aplicação +OAuth.
3. Insira o Nome da aplicação e adicione o URL `https://<aws-region>.console.aws.amazon.com/gluestudio/oauth` como URI de redirecionamento do Snap. Por exemplo, se estiver sendo usada a região us-west-1, o URL será `https://us-west-1.console.aws.amazon.com/gluestudio/oauth) and choose` **`Create OAuth App`**. Escolha Criar aplicação OAuth.
4. As credenciais da aplicação (ID do cliente e Segredo do cliente) serão exibidas. Salve-as, pois elas serão necessárias para criar uma conexão.

Conectar ao Snowflake no AWS Glue Studio

> **Note**
>
> É possível usar o AWS Glue para Spark para ler e gravar em tabelas no Snowflake no AWS Glue 4.0 e versões posteriores. Para configurar uma conexão Snowflake com trabalhos AWS Glue programaticamente, consulte Conexões do Redshift.

O AWS Glue fornece suporte integrado para o Snowflake. O AWS Glue Studio fornece uma interface visual para conectar ao Snowflake, criar trabalhos de integração de dados e executá-los no runtime do AWS Glue Studio Spark sem servidor.

O AWS Glue Studio cria uma conexão unificada para o Snowflake. Para ter mais informações, consulte Considerações.

Tópicos

- Criar uma conexão com o Snowflake
- Criar um nó de origem do Snowflake
- Criar um nó de destino do Snowflake
- Opções avançadas

Criar uma conexão com o Snowflake

> **Note**
>
> As conexões unificadas (conexão v2) padronizam todas as conexões para usar chaves `USERNAME`, `PASSWORD` para credenciais de autenticação básica. Você ainda pode criar uma conexão v1 via API com segredos contendo `sfUser`, `sfPassword`.

Ao adicionar um nó Fonte de dados – SnowflakeAWS Glue Studio, é possível escolher uma conexão existente do AWS Glue Snowflake ou criar uma nova conexão. Você deve escolher um tipo de conexão do `SNOWFLAKE` e não um tipo de conexão `JDBC` configurada para se conectar ao Snowflake. Faça o seguinte procedimento para criar uma conexão com o AWS Glue Snowflake:

Criar uma conexão com o Snowflake

1. No Snowflake, gere um usuário, *SnowflakeUser* e senha, *snowflakePassword*.
2. *Determine com qual armazém do Snowflake esse usuário interagirá, SnowflakeWarehouse*. Defina-o como o DEFAULT_WAREHOUSE para *SnowFlakeUser* no Snowflake ou lembre-se dele para a próxima etapa.
3. No AWS Secrets Manager, crie um segredo usando suas credenciais do Snowflake. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criação de um segredo do AWS Secrets Manager na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.
   - Ao selecionar pares de chave/valor, crie um par para *snowflakeUser* com a chave `sfUser`.
   - Ao selecionar pares de chave/valor, crie um par para *snowflakePassword* com a chave `sfPassword`.
   - Ao selecionar pares de chave/valor, crie um par para *snowflakeWarehouse* com a chave `sfWarehouse`. Isso não é necessário se for definido um padrão no Snowflake.
4. No catálogo de dados do AWS Glue, crie uma conexão seguindo as etapas em Adicionar uma conexão do AWS Glue. Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para a próxima etapa.
   - Ao selecionar um Tipo de conexão, selecione Snowflake.
   - Ao selecionar o URL do Snowflake, forneça o URL da sua instância do Snowflake. O URL usará um nome de host no formulário *account_identifier*`.snowflakecomputing.com`.
   - Ao selecionar um Segredo da AWS, forneça o *secretName*.

Criar um nó de origem do Snowflake

Permissões necessárias

Trabalhos do AWS Glue Studio usando fontes de dados do Snowflake exigem permissões adicionais. Para obter mais informações sobre como adicionar permissões a trabalhos de ETL, consulte Review IAM permissions needed for ETL jobs.

As conexões AWS Glue do `SNOWFLAKE` usam um segredo do AWS Secrets Manager para fornecer informações de credenciais. Os perfis de pré-visualização de trabalhos e dados no AWS Glue Studio devem ter permissão para ler esse segredo.

Adicionar uma fonte de dados do Snowflake

Pré-requisitos:

- Um segredo do AWS Secrets Manager para suas credenciais do Snowflake
- Uma conexão de catálogo de dados do AWS Glue do tipo Snowflake

Para adicionar um nó fonte de dados: Snowflake:

1. Escolha a conexão para sua fonte de dados do Snowflake. Isso pressupõe que a conexão já exista e que você possa selecionar entre as conexões existentes. Se precisar criar uma conexão, escolha Criar conexão com o Snowflake. Para obter mais informações, consulte Visão geral do uso de conectores e conexões.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades. As informações sobre a conexão estão visíveis, incluindo URL, grupos de segurança, sub-rede, zona de disponibilidade, descrição e timestamps de criação (UTC) e última atualização (UTC).
2. Escolha uma opção de fonte do Snowflake:

   - Escolher uma única tabela: essa é a tabela que contém os dados que você deseja acessar de uma única tabela do Snowflake.
   - Inserir consulta personalizada: permite que você acesse um conjunto de dados de várias tabelas do Snowflake com base na sua consulta personalizada.
3. Se você escolheu uma única tabela, insira o nome de um esquema do Snowflake.

   Ou escolha Inserir consulta personalizada. Escolha essa opção para acessar um conjunto de dados personalizado de várias tabelas do Snowflake. Ao escolher essa opção, insira a consulta do Snowflake.
4. Nas opções de Desempenho e segurança (opcional),

   - Ative o envio de consultas: escolha se você deseja transferir o trabalho para a instância do Snowflake.
5. Em Propriedades personalizadas do Snowflake (opcional), insira parâmetros e valores conforme necessário.

Criar um nó de destino do Snowflake

Permissões necessárias

Trabalhos do AWS Glue Studio usando fontes de dados do Snowflake exigem permissões adicionais. Para obter mais informações sobre como adicionar permissões a trabalhos de ETL, consulte Review IAM permissions needed for ETL jobs.

As conexões AWS Glue do `SNOWFLAKE` usam um segredo do AWS Secrets Manager para fornecer informações de credenciais. Os perfis de pré-visualização de trabalhos e dados no AWS Glue Studio devem ter permissão para ler esse segredo.

Adicionar um destino de dados do Snowflake

Para criar um nó de destino do Snowflake:

1. Escolha uma tabela existente do Snowflake como destino ou insira um novo nome de tabela.
2. Ao usar o nó de destino Nó de destino: Snowflake, você pode escolher entre as seguintes opções:

   - APPEND: se uma tabela já existir, despejar todos os novos dados na tabela como uma inserção. Se a tabela não existir, criar e inserir todos os novos dados.
   - MERGE: o AWS Glue atualizará ou anexará dados à sua tabela de destino com base nas condições que você especificar.

     Escolha as opções:

     - Escolher chaves e ações simples: escolha as colunas a serem usadas como chaves de correspondência entre os dados de origem e seu conjunto de dados de destino.

       Especifique as seguintes opções quando correspondidas:

       - Atualizar o registro em seu conjunto de dados de destino com os dados da fonte.
       - Excluir o registro em seu conjunto de dados de destino.

       Especifique as seguintes opções quando não correspondidas:

       - Inserir os dados de origem como uma nova linha em seu conjunto de dados de destino.
       - Não executar nenhuma ação.
     - Inserir declaração MERGE personalizada: você pode então escolher Validar declaração de Merge para verificar se a declaração é válida ou inválida.

- TRUNCATE: se uma tabela já existir, truncar os dados da tabela limpando primeiro o conteúdo da tabela de destino. Se o truncamento for bem-sucedido, inserir todos os dados. Se a tabela não existir, criar a tabela e inserir todos os novos dados. Se o truncamento não tiver sucesso, a operação falhará.
- DROP: se uma tabela já existir, excluir os metadados e os dados da tabela. Se a exclusão for bem-sucedida, inserir todos os dados. Se a tabela não existir, criar a tabela e inserir todos os novos dados. Se o drop não tiver sucesso, a operação falhará.

Opções avançadas

Consulte as Snowflake connections no guia do desenvolvedor do AWS Glue.

Conexão com o Stripe no AWS Glue Studio

O Stripe é uma plataforma online de processamento de pagamentos e de cartões de crédito para empresas. A plataforma Stripe permite que as empresas aceitem pagamentos online, criem assinaturas (faturamento recorrente) para comércio eletrônico e configurem uma conta bancária para receber pagamentos. O Stripe também oferece suporte a pagamentos de várias partes, permitindo que as empresas configurem seu mercado e recebam pagamentos e, em seguida, paguem a vendedores ou a prestadores de serviços por meio de uma conta “conectada”.

Tópicos

- Suporte do AWS Glue para o Stripe
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Stripe
- Configuração de conexões do Stripe
- Leitura de entidades do Stripe
- Opções de conexão do Stripe
- Limitações
- Criação de uma conta do Stripe e configuração da aplicação cliente

Suporte do AWS Glue para o Stripe

O AWS Glue oferece suporte ao Stripe da seguinte maneira:

Compatível como fonte?

Sim. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Stripe.

Compatível como destino?

N.º

Versões compatíveis da API do Slack

v1.

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

É possível usar as seguintes políticas gerenciadas do IAM para permitir acesso:

- AWSGlueServiceRole: concede acesso a recursos que vários processos do AWS Glue exigem para serem executados em seu nome. Esses recursos incluem AWS Glue, Amazon S3, IAM, Amazon CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você

seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Stripe

Antes de poder usar o AWS Glue para transferir dados do Stripe, você precisa atender aos seguintes requisitos:

Requisitos mínimos

- Você deve uma conta do Stripe com e-mail e senha. Para ter mais informações, consulte Criação de uma conta do Stripe e configuração da aplicação cliente.
- A conta do Stripe precisa estar habilitada para acesso à API. Todo o uso da API do Stripe está disponível sem custo adicional.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do Stripe.

Configuração de conexões do Stripe

O Stripe oferece suporte à autenticação personalizada. Para obter mais informações sobre a geração das chaves de API necessárias para autorização personalizada, consulte a Documentação da STRIPE REST API.

Para configurar uma conexão do Stripe:

1. No AWS Secrets Manager, crie um segredo com os detalhes a seguir. É necessário criar um segredo para cada conexão no AWS Glue.
   a. Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Stripe.
   b. Selecione o perfil do IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
```

```
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

c. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

d. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Stripe

Pré-requisitos

- Um objeto do Stripe do qual você deseja ler.

Entidades compatíveis

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Equilibrar	Não	Não	Não	Sim	Não
Equilibrar transações	Sim	Sim	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Cobranças	Sim	Sim	Não	Sim	Sim
Disputas	Sim	Sim	Não	Sim	Sim
Links de arquivos	Sim	Sim	Não	Sim	Sim
PaymentIn tents	Sim	Sim	Não	Sim	Sim
SetupIntents	Sim	Sim	Não	Sim	Sim
Pagamentos	Sim	Sim	Não	Sim	Sim
Reembolsos	Sim	Sim	Não	Sim	Sim
Produtos	Sim	Sim	Não	Sim	Sim
Preços	Sim	Sim	Não	Sim	Sim
Cupons	Sim	Sim	Não	Sim	Sim
Códigos de promoção	Sim	Sim	Não	Sim	Sim
Códigos tributários	Não	Sim	Não	Sim	Não
Alíquotas	Sim	Sim	Não	Sim	Sim
Taxas de envio	Sim	Sim	Não	Sim	Sim
Sessões	Sim	Sim	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Notas de crédito	Sim	Sim	Não	Sim	Sim
Cliente	Sim	Sim	Não	Sim	Sim
Faturas	Sim	Sim	Não	Sim	Sim
Itens da fatura	Sim	Sim	Não	Sim	Não
Planos	Sim	Sim	Não	Sim	Sim
Cotações	Sim	Sim	Não	Sim	Não
Assinaturas	Sim	Sim	Não	Sim	
Itens de assinatura	Não	Sim	Não	Sim	Não
Programa da assinatura	Sim	Sim	Não	Sim	Sim
Contas	Não	Sim	Não	Sim	Sim
Taxas de inscrição	Sim	Sim	Não	Sim	Sim
Especific ações do país	Não	Sim	Não	Sim	Não
Transferê ncias	Sim	Sim	Não	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Avisos aantecipados de fraude	Sim	Sim	Não	Sim	Sim
Tipos de relatórios	Não	Não	Não	Sim	Não

Exemplo

```
stripe_read = glueContext.create_dynamic_frame.from_options(
    connection_type="stripe",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "coupons",
        "API_VERSION": "v1"
    }
)
```

Detalhes das entidades e dos campos do Stripe

Entidade	Campo	Tipo de dado	Operadores compatíveis
Equilibrar			
	available	Listar	
	connect_reserved	Listar	
	pendentes	Listar	
	livemode	Booleano	
	objeto	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	instant_available	Listar	
	emissão	struct	
Equilibrar transações			
	id	String	
	objeto	String	
	valor	Inteiro	
	available_on	DateTime	=, >=, <=,<,>
	created	DateTime	=, >=, <=,<,>
	currency	String	
	description	String	
	exchange_rate	BigDecimal	
	taxa	Inteiro	
	fee_details	Listar	
	net	Inteiro	
	reporting_category	String	
	origem	String	=
	status	String	
	tipo	String	=
	cross_border_classification	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
Cobranças			
	id	String	
	objeto	String	
	valor	Inteiro	=, <, >
	amount_captured	Inteiro	
	amount_refunded	Inteiro	
	aplicação	String	
	application_fee	String	
	application_fee_amount	Inteiro	
	balance_transaction	String	
	billing_details	struct	
	calculated_statement_descriptor	String	
	capturado	Booleano	
	created	DateTime	=, >=, <=,<,>
	currency	String	
	customer	String	=
	description	String	
	destination	String	
	disputa	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	disputado	Booleano	=
	failure_balance_transaction	String	
	failure_code	String	
	failure_message	String	
	fraud_details	struct	
	fatura	String	
	livemode	Booleano	
	metadata	struct	
	on_behalf_of	String	
	ordem	String	
	outcome	struct	
	pago	Booleano	
	payment_intent	String	=
	payment_method	String	
	payment_method_details	struct	
	receipt_email	String	
	receipt_number	String	
	receipt_url	String	
	reembolsado	Booleano	=

Entidade	Campo	Tipo de dado	Operadores compatíveis
	reembolsos	struct	
	analisar	String	
	envio	struct	
	origem	struct	
	source_transfer	String	
	statement_descriptor	String	
	statement_descriptor_suffix	String	
	status	String	
	transferência	String	
	transfer_data	struct	
	transfer_group	String	=
Disputas			
	id	String	
	objeto	String	
	valor	Inteiro	=, <, >
	balance_transaction	String	
	balance_transactions	Listar	
	cobrança	String	=
	created	DateTime	=, >=, <=,<,>

Entidade	Campo	Tipo de dado	Operadores compatíveis
	currency	String	
	evidência	struct	
	evidence_details	struct	
	is_charge_refundable	Booleano	
	livemode	Booleano	
	metadata	struct	
	payment_intent	String	=
	razão	String	=
	status	String	
	payment_method_details	struct	
Links de arquivos			
	id	String	
	objeto	String	
	created	DateTime	=, >=, <=,<,>
	expirado	Booleano	=
	expires_at	DateTime	
	file	String	=
	livemode	Booleano	
	metadata	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	url	String	
PaymentIntents			
	id	String	
	objeto	String	
	valor	Inteiro	
	amount_capturable	Inteiro	
	amount_details	struct	
	amount_received	Inteiro	
	aplicação	String	
	application_fee_amount	Inteiro	
	automatic_payment_methods	struct	
	canceled_at	DateTime	
	cancellation_reason	String	
	capture_method	String	
	client_secret	String	
	confirmation_method	String	
	created	DateTime	=, >=, <=,<,>
	currency	String	
	customer	String	=

Entidade	Campo	Tipo de dado	Operadores compatíveis
	description	String	
	fatura	String	
	last_payment_error	struct	
	latest_charge	String	
	livemode	Booleano	
	metadata	struct	
	next_action	struct	
	on_behalf_of	String	
	payment_method	String	
	payment_method_options	struct	
	payment_method_types	Listar	
	payment_method_configuration_details	struct	
	processamento	struct	
	receipt_email	String	
	analisar	String	
	setup_future_usage	String	
	envio	struct	
	origem	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	statement_descriptor	String	
	statement_descriptor_suffix	String	
	status	String	
	transfer_data	struct	
	transfer_group	String	
SetupIntents			
	id	String	
	objeto	String	
	aplicação	String	
	cancellation_reason	String	
	client_secret	String	
	created	DateTime	=, >=, <=,<,>
	customer	String	=
	description	String	
	flow_directions	Listar	
	last_setup_error	struct	
	latest_attempt	String	
	livemode	Booleano	
	mandato	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	metadata	struct	
	next_action	struct	
	on_behalf_of	String	
	payment_method	String	
	payment_method_options	struct	
	payment_method_types	Listar	
	single_use_mandate	String	
	status	String	
	uso	String	
	automatic_payment_methods	struct	
Pagamentos			
	id	String	
	objeto	String	
	valor	Inteiro	=, <, >
	arrival_date	DateTime	=, >=, <=,<,>
	automatic	Booleano	
	balance_transaction	String	
	created	DateTime	=, >=, <=,<,>

Entidade	Campo	Tipo de dado	Operadores compatíveis
	currency	String	
	description	String	=
	destination	String	
	failure_balance_transaction	String	
	failure_code	String	
	failure_message	String	
	livemode	Booleano	
	metadata	struct	
	method	String	
	original_payout	String	
	reversed_by	String	
	reconciliation_status	String	
	source_type	String	
	statement_descriptor	String	
	status	String	
	tipo	String	
	application_fee	String	
	application_fee_amount	Inteiro	
Reembolsos			

Entidade	Campo	Tipo de dado	Operadores compatíveis
	id	String	
	objeto	String	
	valor	Inteiro	
	balance_transaction	String	
	cobrança	String	=
	created	DateTime	=, >=, <=,<,>
	currency	String	
	metadata	struct	
	destination_details	struct	
	payment_intent	String	=
	razão	String	
	receipt_number	String	
	source_transfer_reversal	String	
	status	String	
	transfer_reversal	String	
Produtos			
	id	String	
	objeto	String	
	active	Booleano	=

Entidade	Campo	Tipo de dado	Operadores compatíveis
	attributes	Listar	
	created	DateTime	=, >=, <=,<,>
	default_price	String	
	description	String	
	imagens	Listar	
	livemode	Booleano	
	metadata	struct	
	name	String	
	package_dimensions	struct	
	enviável	Booleano	
	statement_descriptor	String	
	tax_code	String	
	tipo	String	=
	unit_label	String	
	updated	DateTime	
	url	String	
	recursos	Listar	
Preços			
	id	String	
	objeto	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	active	Booleano	=
	billing_scheme	String	
	created	DateTime	=, >=, <=,<,>
	currency	String	=
	custom_unit_amount	struct	
	livemode	Booleano	
	lookup_key	String	
	metadata	struct	
	nickname	String	
	product	String	=
	recorrente	struct	
	tax_behavior	String	
	tiers_mode	String	
	transform_quantity	struct	
	tipo	String	=
	unit_amount	Inteiro	
	quantidade_unitária decimal	String	
Cupons			
	Id	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	objeto	String	
	amount_off	Inteiro	
	created	DateTime	=, >=, <=,<,>
	currency	String	=
	duration	String	=
	duration_in_months	Inteiro	=,<,>
	livemode	Booleano	
	max_redemptions	Inteiro	=, <, >
	metadata	struct	
	name	String	
	percent_off	Double	=
	redeem_by	DateTime	=, >=, <=, <, >
	times_redeemed	Inteiro	
	valid	Booleano	
Códigos de promoção			
	Id	String	
	objeto	String	
	active	Booleano	=
	Código	String	=
	cupon	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	created	DateTime	=,>=,<=,<,>
	customer	String	
	expires_at	DateTime	
	livemode	Booleano	
	max_redemptions	Inteiro	
	metadata	struct	
	restrições	struct	
	times_redeemed	Inteiro	
Códigos tributários			
	Id	String	
	objeto	String	
	description	String	
	name	String	
Alíquotas			
	Id	String	
	objeto	String	
	active	Booleano	=
	country	String	
	created	DateTime	=, >=, <=, <, >
	description	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	display_name	String	
	inclusive	Booleano	=
	jurisdição	String	
	jurisdiction_level	String	
	livemode	Booleano	
	metadata	struct	
	percentage	Double	
	effective_percentage	Double	
	estado	String	
	tax_type	String	
Taxas de envio			
	Id	String	
	objeto	String	
	active	Booleano	=
	created	DateTime	=, >=, <=, <, >
	delivery_estimate	struct	
	display_name	String	
	fixed_amount	struct	
	livemode	Booleano	
	metadata	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	tax_behavior	String	
	tax_code	String	
	tipo	String	
Sessões			
	id	String	
	objeto	String	
	after_expiration	struct	
	allow_promotion_codes	Booleano	
	amount_subtotal	Inteiro	
	amount_total	Inteiro	
	automatic_tax	struct	
	billing_address_collection	String	
	cancel_url	String	
	client_reference_id	String	
	consentimento	struct	
	consent_collection	struct	
	created	DateTime	=, >=, <=, <, >
	currency	String	
	custom_text	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	customer	String	
	customer_creation	String	
	customer_details	struct	
	customer_email	String	
	expires_at	DateTime	
	fatura	String	
	invoice_creation	struct	
	livemode	Booleano	
	locale	String	
	metadata	struct	
	modo	String	
	payment_intent	String	=
	payment_link	String	
	payment_method_collection	String	
	payment_method_options	struct	
	payment_method_types	Listar	
	payment_status	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	phone_number_collection	struct	
	recovered_from	String	
	setup_intent	String	
	shipping_address_collection	struct	
	shipping_cost	struct	
	shipping_details	struct	
	shipping_options	Listar	
	status	String	
	submit_type	String	
	Assinatura	String	
	success_url	String	
	tax_id_collection	struct	
	total_details	struct	
	url	String	
	ui_mode	String	
Notas de crédito			
	id	String	
	objeto	String	
	valor	Inteiro	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	created	DateTime	=, >=, <=, <, >
	currency	String	
	customer	String	=
	customer_balance_transaction	String	
	discount_amount	Inteiro	
	discount_amounts	Listar	
	fatura	String	=
	lines	struct	
	livemode	Booleano	
	memo	String	
	metadata	struct	
	número	String	
	out_of_band_amount	Inteiro	
	pdf	String	
	razão	String	
	reembolso	String	
	status	String	
	subtotal	Inteiro	
	subtotal_excluding_tax	Inteiro	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	tax_amounts	Listar	
	total	Inteiro	
	total_excluding_tax	Inteiro	
	tipo	String	
	voided_at	DateTime	
	amount_shipping	Inteiro	
	effective_at	DateTime	
	shipping_cost	struct	
Cliente			
	id	String	
	objeto	String	
	address	struct	
	balance	Inteiro	
	created	DateTime	
	currency	String	=, >=, <=, <, >
	default_source	String	
	delinquente	Booleano	=
	description	String	
	discount	struct	
	email	String	=

Entidade	Campo	Tipo de dado	Operadores compatíveis
	invoice_prefix	String	
	invoice_settings	struct	
	livemode	Booleano	
	metadata	struct	
	name	String	
	next_invoice_sequence	Inteiro	
	phone	String	
	preferred_locales	Listar	
	envio	struct	
	tax_exempt	String	
	test_clock	String	
Faturas			
	id	String	
	objeto	String	
	account_country	String	
	account_name	String	
	account_tax_ids	Listar	
	amount_due	Inteiro	
	amount_paid	Inteiro	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	amount_remaining	Inteiro	
	aplicação	String	
	application_fee_amount	Inteiro	
	attempt_count	Inteiro	
	tentado	Booleano	=
	auto_advance	Booleano	=
	automatic_tax	struct	
	billing_reason	String	
	cobrança	String	
	collection_method	String	=
	created	DateTime	=, >=, <=, <, >
	currency	String	
	custom_fields	Listar	
	customer	String	=
	customer_address	struct	
	customer_email	String	
	customer_name	String	
	customer_phone	String	
	customer_shipping	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	customer_tax_exempt	String	
	customer_tax_ids	Listar	
	default_payment_method	String	
	default_source	String	
	default_tax_rates	Listar	
	description	String	
	discount	struct	
	descontos	Listar	
	due_date	DateTime	=, >=, <=, <, >
	ending_balance	Inteiro	
	rodapé	String	
	from_invoice	struct	
	hosted_invoice_url	String	
	invoice_pdf	String	
	last_finalization_error	struct	
	latest_revision	String	
	lines	struct	
	livemode	Booleano	
	metadata	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	next_payment_attempt	DateTime	
	número	String	
	on_behalf_of	String	
	pago	Booleano	=
	paid_out_of_band	Booleano	
	payment_intent	String	
	payment_settings	struct	
	period_end	DateTime	=, >=, <=, <, >
	period_start	DateTime	=, >=, <=, <, >
	post_payment_credit_notes_amount	Inteiro	
	pre_payment_credit_notes_amount	Inteiro	
	cotação	String	
	receipt_number	String	
	renderização	struct	
	rendering_options	struct	
	starting_balance	Inteiro	
	statement_descriptor	String	
	status	String	=

Entidade	Campo	Tipo de dado	Operadores compatíveis
	status_transitions	struct	
	Assinatura	String	
	subscription_details	struct	
	subtotal	Inteiro	=, <, >
	subtotal_excluding_tax	Inteiro	
	tax	Inteiro	
	test_clock	String	
	total	Inteiro	=, <, >
	total_discount_amounts	Listar	
	total_excluding_tax	Inteiro	
	total_tax_amounts	Listar	
	transfer_data	struct	
	webhooks_delivered_at	DateTime	
	automatically_finalizes_at	DateTime	
	effective_at	DateTime	
	issuer (emissor)	struct	
Itens da fatura			

Entidade	Campo	Tipo de dado	Operadores compatíveis
	id	String	
	objeto	String	
	valor	Inteiro	=, <, >
	currency	String	
	customer	String	=
	date	DateTime	
	description	String	
	descontável	Booleano	
	descontos	Listar	
	fatura	String	=
	livemode	Booleano	
	metadata	struct	
	período	struct	
	planejamento	struct	
	preço	struct	
	rateio	Booleano	=
	quantity	Inteiro	
	Assinatura	String	
	subscription_item	String	
	tax_rates	Listar	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	test_clock	String	
	unit_amount	Inteiro	
	quantidade_unitária decimal	String	
Planos			
	id	String	
	objeto	String	
	active	Booleano	=
	aggregate_usage	String	
	valor	Inteiro	
	amount_decimal	String	
	billing_scheme	String	
	created	DateTime	=, >=, <=, <, >
	currency	String	=
	intervalo	String	=
	interval_count	Inteiro	
	livemode	Booleano	
	metadata	struct	
	nickname	String	
	product	String	=

Entidade	Campo	Tipo de dado	Operadores compatíveis
	tiers_mode	String	
	transform_usage	struct	
	trial_period_days	Inteiro	=, <, >
	usage_type	String	
	medida	String	
Cotações			
	id	String	
	objeto	String	
	amount_subtotal	Inteiro	
	amount_total	Inteiro	
	aplicação	String	
	application_fee_amount	Inteiro	
	application_fee_percent	Double	
	automatic_tax	struct	
	collection_method	String	
	computado	struct	
	created	DateTime	
	currency	String	
	customer	String	=

Entidade	Campo	Tipo de dado	Operadores compatíveis
	default_tax_rates	Listar	
	description	String	
	descontos	Listar	
	expires_at	DateTime	
	rodapé	String	
	from_quote	struct	
	cabeçalho	String	
	fatura	String	
	invoice_settings	struct	
	livemode	Booleano	
	metadata	struct	
	número	String	
	on_behalf_of	String	
	status	String	=
	status_transitions	struct	
	Assinatura	String	
	subscription_data	struct	
	subscription_schedule	String	
	test_clock	String	
	total_details	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	transfer_data	struct	
Assinaturas			
	id	String	
	objeto	String	
	aplicação	String	
	application_fee_percent	Double	
	automatic_tax	struct	
	billing_cycle_anchor	DateTime	
	billing_thresholds	struct	
	cancel_at	DateTime	
	cancel_at_period_end	Booleano	
	canceled_at	DateTime	
	collection_method	String	=
	created	DateTime	=, >=, <=,<,>
	currency	String	
	current_period_end	DateTime	=, >=, <=
	current_period_start	DateTime	=, >=, <=
	customer	String	=
	days_until_due	Inteiro	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	default_payment_method	String	
	default_source	String	
	default_tax_rates	Listar	
	description	String	
	discount	struct	
	ended_at	DateTime	
	itens	struct	
	latest_invoice	String	
	livemode	Booleano	
	metadata	struct	
	next_pending_invoice_item_invoice	DateTime	
	pause_collection	struct	
	payment_settings	struct	
	pending_invoice_item_interval	struct	
	pending_setup_intent	String	
	pending_update	struct	
	planejamento	struct	
	quantity	Inteiro	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	schedule	String	
	start_date	DateTime	
	status	String	=
	test_clock	String	
	transfer_data	struct	
	trial_end	DateTime	
	trial_start	DateTime	
Itens de assinatura			
	Id	String	
	objeto	String	
	billing_thresholds	struct	
	created	DateTime	=, >=, <=, <, >
	metadata	struct	
	planejamento	struct	
	preço	struct	
	Assinatura	String	
	tax_rates	Listar	
	descontos	Listar	
Programa da assinatura			

Entidade	Campo	Tipo de dado	Operadores compatíveis
	objeto	String	
	aplicação	String	
	canceled_at	DateTime	
	completed_at	DateTime	
	created	DateTime	
	current_phase	struct	
	customer	String	=
	default_settings	struct	
	end_behavior	String	
	livemode	Booleano	
	metadata	struct	
	phases	Listar	
	released_at	DateTime	
	released_subscription	String	
	renewal_interval	String	
	status	String	
	Assinatura	String	
	test_clock	String	
Contas			
	details_submitted	Booleano	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	tos_acceptance	struct	
	tipo	String	
	metadata	struct	
	id	String	
	objeto	String	
	default_currency	String	
	Capacidades	struct	
	charges_enabled	Booleano	
	configurações	struct	
	requisitos	struct	
	payouts_enabled	Booleano	
	future_requirements	struct	
	external_accounts	struct	
	controlador	struct	
	country	String	
	email	String	
	created	DateTime	=, >=, <=, <, >
	business_profile	struct	
	business_type	String	
	company	struct	

Entidade	Campo	Tipo de dado	Operadores compatíveis
Taxas de inscrição			
	id	String	
	objeto	String	
	conta	String	
	valor	Inteiro	=, <, >
	amount_refunded	Inteiro	=, <, >
	aplicação	String	
	balance_transaction	String	
	cobrança	String	=
	created	DateTime	
	currency	String	
	livemode	Booleano	
	originating_transaction	String	
	reembolsado	Booleano	=
	reembolsos	struct	
	fee_source	struct	
Especificações do país			
	id	String	
	objeto	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	default_currency	String	
	supported_bank_account_currencies	struct	
	supported_payment_currencies	Listar	
	supported_payment_methods	Listar	
	supported_transfer_countries	Listar	
	verification_fields	struct	
Transferências			
	id	String	
	objeto	String	
	valor	Inteiro	=, <, >
	amount_reversed	Inteiro	
	balance_transaction	String	
	created	DateTime	=, >=, <=, <, >
	currency	String	=
	description	String	
	destination	String	=
	destination_payment	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	livemode	Booleano	
	metadata	struct	
	reversões	struct	
	revertido	Booleano	
	source_transaction	String	
	source_type	String	
	transfer_group	String	=
Avisos aantecipados de fraude			
	id	String	
	objeto	String	
	acionável	Booleano	
	cobrança	String	=
	created	DateTime	=, >=, <=, <, >
	fraud_type	String	
	livemode	Booleano	
	payment_intent	String	=
Tipos de relatórios			
	id	String	
	objeto	String	

Entidade	Campo	Tipo de dado	Operadores compatíveis
	data_available_end	DateTime	
	data_available_start	DateTime	
	default_columns	Listar	
	livemode	Booleano	
	name	String	
	updated	DateTime	
	versão	Inteiro	

Particionamento de consultas

Podem ser fornecidas as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se você quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  Na data, aceitamos o formato de data do Spark usado em consultas SQL do Spark. Exemplo de valor válido: `"2024-07-01T00:00:00.000Z"`.
- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`: número de partições.

Os detalhes do suporte do campo de particionamento relativo às entidades são capturados na tabela a seguir.

Entity Name	Campo de particionamento	Tipo de dado
Equilibrar transações	created	DateTime

Entity Name	Campo de particionamento	Tipo de dado
Cobranças	created	DateTime
Disputas	created	DateTime
Links de arquivos	created	DateTime
PaymentIntents	created	DateTime
SetupIntents	created	DateTime
Pagamentos	created	DateTime
Reembolsos	created	DateTime
Produtos	created	DateTime
Preços	created	DateTime
Cupons	created	DateTime
Códigos de promoção	created	DateTime
Alíquotas	created	DateTime
Taxas de envio	created	DateTime
Sessões	created	DateTime
Notas de crédito	created	DateTime
Cliente	created	DateTime
Faturas	created	DateTime
Planos	created	DateTime
Assinaturas	created	DateTime
Programa da assinatura	created	DateTime

Entity Name	Campo de particionamento	Tipo de dado
Contas	created	DateTime
Taxas de inscrição	created	DateTime
Transferências	created	DateTime
Avisos aantecipados de fraude	created	DateTime

Exemplo

```
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"
    }
)
```

Opções de conexão do Stripe

Estas são as opções de conexão do Stripe:

- `ENTITY_NAME`(String): (obrigatório) usado para leitura/gravação. O nome do seu objeto no Stripe.
- `API_VERSION`(String): (obrigatório) usado para leitura/gravação. Versão da API Rest do Stripe que você deseja usar. Exemplo: v1.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta.

- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Limitações

Estas são as limitações do conector do Stripe:

- Somente o particionamento com base em campos é compatível com o conector.
- O particionamento com base em registros não compatível com o conector e não há provisão para a recuperação da contagem total de registros.
- O tipo de dados da chave primária é String. Portanto, o particionamento com base em Id não é compatível com o conector.

Criação de uma conta do Stripe e configuração da aplicação cliente

Criação de uma conta do Stripe

1. Clique no link https://dashboard.stripe.com/register.
2. Digite seu e-mail, nome completo, senha e escolha Criar conta.
3. Depois de fazer login na conta, verifique a conta escolhendo Abrir o Gmail.
4. Verifique a conta clicando no link de verificação recebido por e-mail.
5. Depois de clicar em verificar endereço de e-mail, você será redirecionado para outra página
6. Depois de clicar em Ativar pagamentos para ativar a conta, ela será redirecionada para a página Ativar pagamentos (https://dashboard.stripe.com/welcome) e certifique-se de preencher todos os detalhes válidos. Depois disso, clique no botão Continuar.

Criação de uma aplicação para desenvolvedores do Slack

1. Faça login no Stripe.
2. Escolha Desenvolvedores, conforme exibido na parte superior da imagem abaixo.
3. Escolha chaves de API em Desenvolvedores.

4. Escolha Revelar chave de teste para obter as chaves de API.

Conectar ao Teradata Vantage no AWS Glue Studio

O AWS Glue oferece suporte integrado ao Teradata Vantage. O AWS Glue Studio fornece uma interface visual para conectar ao Teradata, criar trabalhos de integração de dados e executá-los no runtime Spark do AWS Glue Studio sem servidor.

O AWS Glue Studio cria uma conexão unificada para o Teradata Vantage. Para ter mais informações, consulte Considerações.

Tópicos

- Criar uma conexão Teradata Vantage
- Criar um nó de origem do Teradata
- Criar um nó de destino do Teradata
- Opções avançadas

Criar uma conexão Teradata Vantage

Para se conectar ao Teradata Vantage via AWS Glue, será necessário criar e armazenar suas credenciais do Teradata em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão ao AWS Glue do Teradata.

Pré-requisitos:

- Se você estiver acessando seu ambiente Teradata via Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com o ambiente Teradata. Recomendamos não acessar o ambiente Teradata via Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre sua instância do Teradata e esse local. Seu trabalho precisará estabelecer uma conexão TCP com a porta cliente do Teradata. Para obter mais informações sobre portas do Teradata, consulte a Documentação do Teradata.

  Com base no layout da sua rede, a conectividade segura da VPC pode exigir alterações na Amazon VPC e em outros serviços de rede. Para obter mais informações sobre conectividade com a AWS, consulte Opções de conectividade da AWS na documentação da Teradata.

Para configurar uma conexão AWS Glue Teradata:

1. Em sua configuração do Teradata, identifique ou crie um usuário e a senha com os quais o AWS Glue se conectará, *teradataUser* e *teradataPassword*. Para obter mais informações, consulte Visão geral da segurança do Vantage na documentação do Teradata.
2. No AWS Secrets Manager, crie um segredo usando suas credenciais do Teradata. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

   - Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *teradataUsername*.
   - Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *teradataPassword*.
3. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para a próxima etapa.

   - Ao selecionar um Tipo de conexão, selecione Teradata.
   - Ao fornecer o URL do JDBC, forneça o URL da sua instância. Você também pode codificar certos parâmetros de conexão separados por vírgula no URL do JDBC. O URL deve estar de acordo com o seguinte formato: `jdbc:teradata://`*teradataHostname*`/`*ParameterName*`=`*ParameterValue*`,`*ParameterName*

     Os parâmetros de URL compatíveis incluem:

     - `DATABASE`: o nome do banco de dados no host a ser acessado por padrão.
     - `DBS_PORT`: a porta do banco de dados usada para execução em uma porta não padrão.
   - Ao selecionar um Tipo de credencial, selecione AWS Secrets Manager e defina Segredo da AWS como *secretName*.
4. Nas seguintes situações, configurações adicionais podem ser necessárias:

   - Para instâncias do Teradata hospedadas na AWS em uma Amazon VPC
     - Será necessário fornecer informações de conexão da Amazon VPC à conexão do AWS Glue que define suas credenciais de segurança do Teradata. Ao criar ou atualizar sua conexão, defina VPC, Sub-rede e Grupos de segurança em Opções de rede.

Criar um nó de origem do Teradata

Pré-requisitos necessários

- Uma conexão AWS Glue Teradata Vantage configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão Teradata Vantage”.
- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do Teradata da qual você gostaria de ler, *`tableName`*, ou consultar *`targetQuery`*.

Adicionar uma fonte de dados do Teradata

Para adicionar um nó de Fonte de dados – Teradata:

1. Escolha a conexão para sua fonte de dados do Teradata. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão. Para mais informações, consulte a seção the section called “Criar uma conexão Teradata Vantage” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Escolha uma opção de Fonte de dados teradata:

   - Escolher uma única tabela: acesse todos os dados de uma única tabela.
   - Inserir consulta personalizada: acesse um conjunto de dados de várias tabelas com base em sua consulta personalizada.
3. Se você escolheu uma única tabela, insira *`tableName`*.

   Se você escolheu Inserir consulta personalizada, insira uma consulta SQL SELECT.
4. Em Propriedades personalizadas do Teradata, insira parâmetros e valores conforme necessário.

Criar um nó de destino do Teradata

Pré-requisitos necessários

- Uma conexão AWS Glue Teradata Vantage configurada com um segredo do AWS Secrets Manager, conforme descrito na seção anterior, the section called “Criar uma conexão Teradata Vantage”.

- Permissões apropriadas em seu trabalho para ler o segredo usado pela conexão.
- Uma tabela do Teradata na qual você gostaria de escrever, *`tableName`*.

Adicionar um destino de dados do Teradata

Para adicionar um nó de Destino de dados – Teradata:

1. Escolha a conexão para sua fonte de dados do Teradata. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão com o Teradata. Para obter mais informações, consulte Visão geral do uso de conectores e conexões.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Configure o nome da tabela fornecendo o *`tableName`*.
3. Em Propriedades personalizadas do Teradata, insira parâmetros e valores conforme necessário.

Opções avançadas

É possível fornecer opções avançadas ao criar um nó do Teradata. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexões do Teradata Vantage”.

Conexão com o Twilio

O Twilio fornece ferramentas de comunicação programáveis para fazer e receber chamadas telefônicas, enviar e receber mensagens de texto e realizar outras funções de comunicação usando suas APIs de serviços da Web. As APIs do Twilio alimentam sua plataforma de comunicações. Por trás dessas APIs há uma camada de software conectando e otimizando redes de comunicação em todo o mundo para permitir que seus usuários liguem e enviem mensagens para qualquer pessoa, globalmente. Como usuário do Twilio, é possível conectar o AWS Glue à sua conta do Twilio. Em seguida, será possível usar o Twilio como fonte de dados nos seus trabalhos de ETL. Execute esses trabalhos para transferir dados entre o Twilio e serviços da AWS ou outras aplicações com suporte.

Tópicos

- Suporte do AWS Glue para o Twilio
- Políticas que contêm as operações de API para criar e usar conexões

- Configuração do Twilio
- Configuração de conexões do Twilio
- Leitura de entidades do Twilio
- Opções de conexão do Twilio
- Limitações e notas do conector do Twilio

Suporte do AWS Glue para o Twilio

O AWS Glue oferece suporte ao Twilio da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do Twilio.

Compatível como destino?

Nº

Versões da API do Twilio com suporte

Há suporte para as seguintes versões da API do Twilio:

- v1
- 2010-04-01

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
```

```
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Twilio

Antes de poder usar o AWS Glue para transferir dados do Twilio, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Twilio com nome de usuário e senha.
- Sua conta do Twilio está habilitada para acesso à API.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Twilio. Para conexões típicas, você não precisa fazer mais nada no Twilio.

Configuração de conexões do Twilio

O Twilio oferece suporte a nome de usuário e senha para autenticação básica. A autenticação básica é um método de autenticação simples em que os clientes fornecem credenciais diretamente para acessar recursos protegidos. O AWS Glue é capaz de usar o nome de usuário (SID da conta) e a senha (token de autenticação) para autenticar as APIs do Twilio.

Para obter a documentação pública do Twilio para o fluxo de autenticação básica, consulte Autenticação básica | Twilio.

Para configurar uma conexão do Twilio:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   - Para a autenticação básica: o segredo deve conter o segredo do consumidor da aplicação conectada com o SID da conta (nome de usuário) e o Token de autenticação (senha).

   > **Note**
   >
   > É necessário criar um segredo para a sua conexão no AWS Glue.

2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Twilio.
   b. Forneça o `Edge_Location` da instância do Twilio à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
```

```
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Twilio

Pré-requisito

Um objeto do Twilio do qual você deseja ler. Você precisará do nome do objeto, como `SMS-Message` ou `SMS-CountryPricing`.

Entidades compatíveis quanto à origem:

Entidade	Interface	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particionamento
SMS-Message	REST	Sim	Sim	Não	Sim	Sim
SMS-CountryPricing	REST	Não	Não	Não	Sim	Não
Voice-Call	REST	Sim	Sim	Não	Sim	Não
Voice-Application	REST	Sim	Sim	Não	Sim	Não
Voice-OutgoingCallerID	REST	Sim	Sim	Não	Sim	Não

Entidade	Interface	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particionamento
Voice-Queue	REST	Sim	Sim	Não	Sim	Não
Conversations-Conversation	REST	Sim	Sim	Não	Sim	Não
Conversations-User	REST	Não	Sim	Não	Sim	Não
Conversas-Função	REST	Não	Sim	Não	Sim	Não
Conversations-Configuration	REST	Não	Não	Não	Sim	Não
Conversations-AddressConfiguration	REST	Sim	Sim	Não	Sim	Não
Conversations-WebhookConfiguration	REST	Não	Não	Não	Sim	Não
Conversations-ParticipantConversation	REST	Não	Não	Não	Sim	Não

Entidade	Interface	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Conversations-Credential	REST	Não	Sim	Não	Sim	Não
Conversations-ConversationService	REST	Não	Sim	Não	Sim	Não

Exemplo:

```
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"
    }
```

Detalhes de entidade e campo do Twilio:

Entidade	Campo	Tipo de dados	Operadores compatíveis
SMS-Message	account_sid	String	N/D
	api_version	String	N/D
	body	String	N/D
	date_created	Datetime	N/D
	date_sent	Datetime	>=, <=, =

Entidade	Campo	Tipo de dados	Operadores compatíveis
	date_updated	Datetime	N/D
	direction	String	N/D
	error_code	Inteiro	N/D
	error_message	String	N/D
	from	Inteiro	=
	messaging_service_sid	String	N/D
	num_media	String	N/D
	num_segments	String	N/D
	preço	String	N/D
	price_unit	Struct	N/D
	sid	Inteiro	N/D
	status	String	N/D
	subresource_uris	Mapa	N/D
	com	Inteiro	=
	uri	Datetime	N/D
SMS-CountryPricing	country	String	N/D
	iso_country	String	N/D
	url	String	N/D
	outbound_sms_prices	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	inbound_sms_prices	Lista	N/D
	price_unit	String	N/D
Voice-Call	account_sid	String	N/D
	anotação	String	N/D
	answered_by	String	N/D
	api_version	String	N/D
	caller_name	String	N/D
	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	direction	String	N/D
	duration	String	N/D
	end_time	Datetime	>=, <=, =
	forwarded_from	String	N/D
	from	String	=
	from_formatted	String	N/D
	group_sid	String	N/D
	parent_call_sid	String	N/D
	phone_number_sid	String	N/D
	preço	String	N/D
	price_unit	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	sid	String	N/D
	start_time	Datetime	>=, <=, =
	status	String	=
	subresource_uris	String	N/D
	com	String	=
	to_formatted	String	N/D
	trunk_sid	String	N/D
	uri	String	N/D
	queue_time	String	N/D
Voice-Application	account_sid	String	N/D
	api_version	String	N/D
	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	friendly_name	String	=
	message_status_callback	String	N/D
	sid	String	N/D
	sms_fallback_method	String	N/D
	sms_fallback_url	String	N/D
	sms_method	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	sms_status_callback	String	N/D
	sms_url	String	N/D
	status_callback	String	N/D
	status_callback_method	String	N/D
	uri	String	N/D
	voice_caller_id_lookup	Booleano	N/D
	voice_fallback_method	String	N/D
	voice_fallback_url	String	N/D
	método_voz	String	N/D
	voice_url	String	N/D
public_application_connect_enabled	Booleano	N/D	
Voice-OutgoingCallerID	sid	String	N/D
	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	account_sid	String	N/D
	friendly_name	String	=
	phone_number	String	=
	uri	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
Voice-Queue	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	current_size	Inteiro	N/D
	friendly_name	String	N/D
	uri	String	N/D
	account_sid	String	N/D
	average_wait_time	Inteiro	N/D
	sid	String	N/D
	max_size	Inteiro	N/D
Conversations-Conversation	account_sid	String	N/D
	chat_service_sid	String	N/D
	messaging_service_sid	String	N/D
	sid	String	N/D
	friendly_name	String	N/D
	unique_name	String	N/D
	attributes	String	N/D
	estado	String	=
	date_created	Datetime	N/D
	date_updated	Datetime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	timers	Struct	N/D
	url	String	N/D
	links	Struct	N/D
	bindings	Struct	N/D
	start_date	Datetime	=
	end_date	Datetime	=
	Timers.DateInactive	String	N/D
	Timers.DateClosed	String	N/D
Conversations-User	sid	String	N/D
	account_sid	String	N/D
	chat_service_sid	String	N/D
	role_sid	String	N/D
	identidade	String	N/D
	friendly_name	String	N/D
	attributes	String	N/D
	is_online	Booleano	N/D
	is_notifiable	Booleano	N/D
	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	url	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	links	Struct	N/D
Conversations-Role	sid	String	N/D
	account_sid	String	N/D
	chat_service_sid	String	N/D
	friendly_name	String	N/D
	type	String	N/D
	permissões	String	N/D
	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	url	String	N/D
Conversations-Configuration	account_sid	Longo	N/D
	default_chat_service_sid	String	N/D
	default_messaging_service_sid	String	N/D
	default_inactive_timer	String	N/D
	default_closed_timer	String	N/D
	url	String	N/D
	links	Mapa	N/D
Conversations-AddressConfiguration	sid	String	N/D
	account_sid	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	type	String	N/D
	address	String	N/D
	friendly_name	String	N/D
	auto_creation	Struct	N/D
	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	url	String	N/D
	address_country	String	N/D
	AutoCreation.Enabled	Booleano	N/D
	AutoCreation.Type	String	N/D
	AutoCreation.ConversationServiceSid	String	N/D
	AutoCreation.WebhookUrl	String	N/D
	AutoCreation.WebhookMethod	String	N/D
	AutoCreation.WebhookFilters	Lista	N/D
	AutoCreation.StudioFlowSid	String	N/D
	AutoCreation.StudioRetryCount	Inteiro	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
Conversations-WebhookConfiguration	account_sid	String	N/D
	method	String	N/D
	filtros	Lista	N/D
	pre_webhook_url	String	N/D
	post_webhook_url	String	N/D
	target	String	N/D
	url	String	N/D
Converations-ParticipantConversation	account_sid	String	N/D
	chat_service_sid	String	N/D
	participant_sid	String	N/D
	participant_user_sid	String	N/D
	participant_identity	String	N/D
	participant_messaging_binding	Struct	N/D
	Conversation_sid	String	N/D
	conversation_unique_name	String	N/D
	conversation_friendly_name	String	N/D
	conversation_attributes	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	conversation_date_created	Datetime	N/D
	conversation_date_updated	Datetime	N/D
	conversation_created_by	String	N/D
	conversation_state	String	N/D
	conversation_timers	Struct	N/D
	links	Mapa	N/D
	address	String	=
	identidade	String	=
Conversation-Credentials	sid	String	N/D
	account_sid	String	N/D
	friendly_name	String	N/D
	type	String	N/D
	sandbox	String	N/D
	date_created	Datetime	N/D
	dated_updated	Datetime	N/D
	url	String	N/D
	certificado	String	N/D
	private_key	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	api_key	String	N/D
	secret	String	N/D
Conversations-ConversationService	sid	String	N/D
	account_sid	String	N/D
	friendly_name	String	N/D
	date_created	Datetime	N/D
	date_updated	Datetime	N/D
	url	String	N/D
	links	Mapa	N/D

Particionamento de consultas

Campos com suporte a particionamento:

No Twilio, os campos de tipo de dados DateTime oferecem suporte ao particionamento baseado em campos.

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Datetime, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

  Exemplos de valores válidos:

```
"2024-05-01T20:55:02.000Z"
```

- UPPER_BOUND: um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS: o número de partições.

Exemplo: .

```
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"
    }
```

Opções de conexão do Twilio

Estas são as opções de conexão do Twilio:

- ENTITY_NAME(string): (obrigatório) usado para leitura. O nome do seu objeto no Twilio.
- EDGE_LOCATION(string): (obrigatório) um local da borda válido do Twilio.
- API_VERSION(string): (obrigatório) usado para leitura. Versão da API Rest do Twilio que você deseja usar. O Twilio oferece suporte a duas versões de API: 'v1' e '2010-04-01'.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- FILTER_PREDICATE(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- PARTITION_FIELD(string): usado para leitura. Campo a ser usado para particionar a consulta.
- LOWER_BOUND(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- UPPER_BOUND(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.

- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- `INSTANCE_URL`(string): (obrigatório) usado para leitura. Um URL válido da instância do Twilio.

Limitações e notas do conector do Twilio

Estas são as limitações ou notas do conector do Twilio:

- Não há suporte para o particionamento com base em registros, e não há provisão para a recuperação da contagem total de registros do Twilio.
- Os campos `date_sent`, `start_time` e `end_time` são do tipo de dados Datetime, mas, na filtragem, eles só oferecem suporte a valores de data (os componentes de hora não são considerados).
- A filtragem dos campos "de" ou "para" funciona somente se os valores não incluírem nenhum prefixo (por exemplo, um protocolo ou rótulo). Se houver um prefixo, a filtragem do respectivo campo não funcionará. Por exemplo, se você passar "para": "whatsapp:+14xxxxxxxxxx" como filtro, o Twilio não retornará uma resposta. Você precisa passá-lo como "para": "+14xxxxxxxx", e então ele retornará os registros, se existirem.
- O filtro de campo "identidade" é obrigatório ao consultar a entidade `conversation-participant-conversation`.

Conectar ao Vertica no AWS Glue Studio

O AWS Glue oferece suporte integrado ao Vertica. O AWS Glue Studio fornece uma interface visual para conectar ao Vertica, criar trabalhos de integração de dados e executá-los no runtime Spark do AWS Glue Studio sem servidor.

O AWS Glue Studio cria uma conexão unificada para o Vertica. Para ter mais informações, consulte Considerações.

Tópicos

- Criar uma conexão Vertica
- Criar um nó de origem do Vertica
- Criar um nó de destino do Vertica
- Opções avançadas

Criar uma conexão Vertica

Pré-requisitos:

- Um bucket ou uma pasta do Amazon S3 para usar como armazenamento temporário ao ler e escrever no banco de dados, referido por *tempS3Path*.

> **Note**
>
> Quando o Vertica é usado em pré-visualizações de dados de trabalhos do AWS Glue, os arquivos temporários podem não ser removidos automaticamente de *tempS3Path*. Para garantir a remoção de arquivos temporários, encerre diretamente a sessão de visualização de dados escolhendo Encerrar sessão no painel Visualização de dados.
> Se não for possível garantir que a sessão de visualização de dados seja encerrada diretamente, considere definir a configuração do ciclo de vida do Amazon S3 para remover dados antigos. Recomendamos remover dados com mais de 49 horas com base no runtime máximo do trabalho somado a uma margem. Para obter mais informações sobre a configuração do Amazon S3, consulte Gerenciar o ciclo de vida do armazenamento na documentação do Amazon S3.

- Uma política do IAM com permissões apropriadas para seu caminho do Amazon S3 que você pode associar ao seu perfil de trabalho do AWS Glue.
- Se a sua instância do Vertica estiver em uma Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com a instância do Vertica sem que o tráfego passe pela Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre sua instância do Vertica e esse local. Seu trabalho precisará estabelecer uma conexão TCP com a porta cliente do Vertica (por padrão, 5433). Com base no layout da rede, isso pode exigir alterações em regras do grupo de segurança, ACLs de rede, gateways de NAT e conexões de emparelhamento.

Para configurar uma conexão com o Vertica:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do Vertica, *verticaUsername* e *verticaPassword*. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS

Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

- Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *verticaUsername*.
- Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *verticaPassword*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para a próxima etapa.

   - Ao selecionar um Tipo de conexão, selecione Vertica.
   - Ao selecionar Host do Vertica, forneça o URL da sua instalação do Vertica.
   - Ao selecionar Porta do Vertica, a porta pela qual sua instalação do Vertica está disponível.
   - Ao selecionar um Segredo da AWS, forneça o *secretName*.

3. Nas seguintes situações, configurações adicionais podem ser necessárias:

   - Para instâncias do Teradata hospedadas na AWS em uma Amazon VPC
     - Forneça informações de conexão da Amazon VPC à conexão do AWS Glue que define suas credenciais de segurança do Vertica. Ao criar ou atualizar sua conexão, defina VPC, Sub-rede e Grupos de segurança em Opções de rede.

Será necessário realizar as seguintes etapas antes de executar seu trabalho do AWS Glue:

- Conceda ao perfil do IAM associado ao seu trabalho do AWS Glue permissão para *tempS3Path*.
- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *secretName*.

Criar um nó de origem do Vertica

Pré-requisitos necessários

- Uma conexão de Catálogo de Dados AWS Glue do tipo Vertica, *connectionName* e um local temporário do Amazon S3, *temps3Path*, conforme descrito na seção the section called "Criar uma conexão Vertica" anterior.
- Uma tabela do Vertica da qual você gostaria de ler, *tableName*, ou consultar *targetQuery*.

Adicionar uma fonte de dados do Vertica

Para adicionar um nó de Fonte de dados – Vertica:

1. Escolha a conexão para sua fonte de dados do Vertica. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão do Vertica. Para mais informações, consulte a seção the section called “Criar uma conexão Vertica” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Escolha o Banco de dados que contém sua tabela.
3. *Escolha a **Área de preparação no Amazon S3** e insira um URI do S3A para tempS3Path*.
4. Escolha a Fonte do Vertica.

   - Escolher uma única tabela: acesse todos os dados de uma única tabela.
   - Inserir consulta personalizada: acesse um conjunto de dados de várias tabelas com base em sua consulta personalizada.
5. Se você escolheu uma única tabela, insira *tableName* e, opcionalmente, selecione um Esquema.

   Se você escolheu Inserir consulta personalizada, insira uma consulta SQL SELECT e, opcionalmente, selecione um Esquema.
6. Em Propriedades personalizadas do Vertica, insira parâmetros e valores conforme necessário.

Criar um nó de destino do Vertica

Pré-requisitos necessários

- Uma conexão de Catálogo de Dados AWS Glue do tipo Vertica, *connectionName* e um local temporário do Amazon S3, *temps3Path*, conforme descrito na seção the section called “Criar uma conexão Vertica” anterior.

Adicionar um destino de dados do Vertica

Para adicionar um nó de Destino de dados – Vertica:

1. Escolha a conexão para sua fonte de dados do Vertica. Como você o criou, ele deve estar disponível no menu suspenso. Se precisar criar uma conexão, escolha Criar conexão do Vertica. Para mais informações, consulte a seção the section called “Criar uma conexão Vertica” anterior.

   Depois de escolher uma conexão, você pode visualizar as propriedades da conexão clicando em Exibir propriedades.
2. Escolha o Banco de dados que contém sua tabela.
3. *Escolha a **Área de preparação no Amazon S3** e insira um URI do S3A para tempS3Path*.
4. Insira *tableName* e, opcionalmente, selecione um Esquema.
5. Em Propriedades personalizadas do Vertica, insira parâmetros e valores conforme necessário.

Opções avançadas

É possível fornecer opções avançadas ao criar um nó do Vertica. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexões do Vertica”.

Conexão com o WooCommerce

O WooCommerce é uma solução de software flexível de código aberto criada para sites baseados em WordPress. É comumente usado para criar lojas de comércio eletrônico online. Com essa solução de software, qualquer pessoa pode transformar seu site comum em uma loja online totalmente funcional.

Tópicos

- Suporte do AWS Glue para o WooCommerce
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do WooCommerce
- Configuração de conexões do WooCommerce
- Leitura de entidades do WooCommerce
- Opções de conexão do WooCommerce

Suporte do AWS Glue para o WooCommerce

O AWS Glue oferece suporte ao WooCommerce da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do WooCommerce.

Compatível como destino?

Nº

Versões da API do WooCommerce com suporte

Versões da API do WooCommerce com suporte:

- v3

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
    "Statement": [
     {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens",
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
 }
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do WooCommerce

Antes de poder usar o AWS Glue para transferir dados do WooCommerce, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do WooCommerce com um `consumerKey` e um `consumerSecret`.
- Sua conta do WooCommerce tem acesso à API com uma licença válida.

Se você atender a esses requisitos, poderá conectar o AWS Glue à conta do WooCommerce. Para conexões típicas, você não precisa fazer mais nada no WooCommerce.

Configuração de conexões do WooCommerce

O WooCommerce oferece suporte à autenticação personalizada. Para obter a documentação pública do WooCommerce sobre a geração das chaves de API necessárias para autorização personalizada, consulte Autenticação – Documentação da API REST do WooCommerce.

Para configurar uma conexão do WooCommerce:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:

- Para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com `consumerKey` e `consumerSecret` como chaves. Observação: é preciso criar um segredo por conexão em AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha WooCommerce.
   b. Forneça o `INSTANCE_URL` da instância do WooCommerce à qual você deseja se conectar.
   c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

   d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.
   e. Selecione as opções de rede se quiser usar sua rede.
2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do WooCommerce

Pré-requisito

Um objeto do WooCommerce do qual você deseja ler. Você precisará do nome do objeto, como cupom, pedido, produto, etc.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Cupom	Sim	Sim	Sim	Sim	Sim
Total do cupom	Não	Não	Não	Sim	Não
Total de clientes	Não	Não	Não	Sim	Não
Ordem	Sim	Sim	Sim	Sim	Sim
Total de pedidos	Não	Não	Não	Sim	Não
Gateway de pagamento	Não	Não	Não	Sim	Não
Produto	Sim	Sim	Sim	Sim	Sim
Atributo do produto	Sim	Sim	Sim	Sim	Sim
Categoria do produto	Sim	Sim	Sim	Sim	Sim
Análise do produto	Sim	Sim	Sim	Sim	Sim
Classe de envio do produto	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Tag do produto	Sim	Sim	Sim	Sim	Sim
Variação do produto	Sim	Sim	Sim	Sim	Sim
Total de produtos	Não	Não	Não	Sim	Não
Relatório (lista)	Não	Não	Não	Sim	Não
Total de análises	Não	Não	Não	Sim	Não
Relatório de vendas	Sim	Não	Não	Sim	Não
Método de envio	Não	Não	Não	Sim	Não
Zona de envio	Não	Não	Não	Sim	Não
Localização da zona de envio	Não	Não	Não	Sim	Não
Método da zona de envio	Não	Não	Não	Sim	Não
Alíquota	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Classe fiscal	Não	Não	Não	Sim	Não
Relatório dos mais vendidos	Sim	Não	Não	Sim	Não

Exemplo:

```
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"
    }
```

Detalhes de entidade e campo do WooCommerce:

Entidade	Campo	Tipo de dados	Operadores compatíveis
cupon	id	Inteiro	N/D
	código	String	EQUAL_TO
	valor	String	N/D
	status	String	N/D
	date_created	DateTime	N/D
	date_created_gmt	DateTime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	date_modified	DateTime	N/D
	date_modified_gmt	DateTime	N/D
	discount_type	String	N/D
	description	String	N/D
	date_expires	String	N/D
	date_expires_gmt	String	N/D
	usage_count	Inteiro	N/D
	individual_use	Booleano	N/D
	product_ids	Lista	N/D
	excluded_product_ids	Lista	N/D
	usage_limit	Inteiro	N/D
	usage_limit_per_user	Inteiro	N/D
	limit_usage_to_x_items	Inteiro	N/D
	free_shipping	Booleano	N/D
	product_categories	Lista	N/D
	excluded_product_categories	Lista	N/D
	exclude_sale_items	Booleano	N/D
	minimum_amount	String	N/D
	maximum_amount	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	email_restrictions	Lista	N/D
	used_by	Lista	N/D
	meta_data	Lista	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	after	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	modified_after	DateTime	EQUAL_TO
	modified_before	DateTime	EQUAL_TO
	dates_are_gmt	Booleano	EQUAL_TO
coupon-total	slug	String	N/D
	nome	String	N/D
	total	Inteiro	N/D
customer-total	slug	String	N/D
	nome	String	N/D
	total	Inteiro	N/D
ordem	id	Inteiro	N/D
	parent_id	Inteiro	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	número	String	N/D
	order_key	String	N/D
	created_via	String	N/D
	status	String	N/D
	currency	String	N/D
	version	String	N/D
	date_created	DateTime	N/D
	date_modified	DateTime	N/D
	discount_total	String	N/D
	discount_tax	String	N/D
	shipping_total	String	N/D
	shipping_tax	String	N/D
	cart_tax	String	N/D
	total	String	N/D
	total_tax	String	N/D
	prices_include_tax	Booleano	N/D
	customer_id	Inteiro	N/D
	customer_ip_address	String	N/D
	customer_user_agent	String	N/D
	customer_note	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	cobrança	Struct	N/D
	envio	Struct	N/D
	payment_method	String	N/D
	payment_method_title	String	N/D
	transaction_id	String	N/D
	date_paid	DateTime	N/D
	date_completed	DateTime	N/D
	cart_hash	String	N/D
	meta_data	Lista	N/D
	line_items	Lista	N/D
	tax_lines	Lista	N/D
	shipping_lines	Lista	N/D
	fee_lines	Lista	N/D
	coupon_lines	Lista	N/D
	reembolsos	Lista	N/D
	payment_url	String	N/D
	is_editable	Booleano	N/D
	needs_payment	Booleano	N/D
	needs_processing	Booleano	N/D
	date_created_gmt	DateTime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	date_modified_gmt	DateTime	N/D
	date_completed_gmt	DateTime	N/D
	date_paid_gmt	DateTime	N/D
	currency_symbol	String	N/D
	set_paid	Booleano	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	after	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	customer	Inteiro	EQUAL_TO
	product	Inteiro	EQUAL_TO
	dp	Inteiro	EQUAL_TO
	modified_before	DateTime	EQUAL_TO
	modified_after	DateTime	EQUAL_TO
	dates_are_gmt	Booleano	EQUAL_TO
order-total	slug	String	N/D
	nome	String	N/D
	total	Inteiro	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
payment-gateway	título	String	N/D
	description	String	N/D
	ordem	String	N/D
	enabled	Booleano	N/D
	method_title	String	N/D
	method_description	String	N/D
	method_supports	Lista	N/D
	configurações	String	N/D
	needs_setup	Booleano	N/D
	post_install_scripts	Lista	N/D
	settings_url	String	N/D
	connection_url	String	N/D
	setup_help_text	String	N/D
	required_settings_keys	Lista	N/D
product	id	Inteiro	N/D
	nome	String	N/D
	type	String	EQUAL_TO
	permalink	String	N/D
	date_created	DateTime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	date_created_gmt	DateTime	N/D
	date_modified	DateTime	N/D
	date_modified_gmt	DateTime	N/D
	catalog_visibility	String	N/D
	description	String	N/D
	short_description	String	N/D
	preço	String	N/D
	regular_price	String	N/D
	sale_price	String	N/D
	date_on_sale_from	DateTime	N/D
	date_on_sale_from_gmt	DateTime	N/D
	date_on_sale_to	DateTime	N/D
	date_on_sale_to_gmt	DateTime	N/D
	price_html	String	N/D
	purchasable	Booleano	N/D
	total_sales	Inteiro	N/D
	virtual	Booleano	N/D
	para download	Booleano	N/D
	downloads	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	download_limit	Inteiro	N/D
	download_expiry	Inteiro	N/D
	external_url	String	N/D
	button_text	String	N/D
	tax_status	String	N/D
	manage_stock	Booleano	N/D
	stock_quantity	Inteiro	N/D
	backorders	String	N/D
	backorders_allowed	Booleano	N/D
	backordered	Booleano	N/D
	sold_individually	Booleano	N/D
	weight	String	N/D
	dimensões	Struct	N/D
	shipping_required	Booleano	N/D
	shipping_taxable	Booleano	N/D
	shipping_class_id	Inteiro	N/D
	reviews_allowed	Booleano	N/D
	average_rating	String	N/D
	rating_count	Inteiro	N/D
	related_ids	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	upsell_ids	Lista	N/D
	cross_sell_ids	Lista	N/D
	parent_id	Inteiro	N/D
	purchase_note	String	N/D
	categories	Lista	N/D
	tags	Lista	N/D
	imagens	Lista	N/D
	attributes	Lista	N/D
	default_attributes	Lista	N/D
	variations	Lista	N/D
	grouped_products	Lista	N/D
	menu_order	Inteiro	N/D
	meta_data	Lista	N/D
	low_stock_amount	Inteiro	N/D
	jetpack_publicize_connections	Lista	N/D
	jetpack-related-posts	Lista	N/D
	jetpack_likes_enabled	Booleano	N/D
	jetpack_sharing_enabled	Booleano	N/D
	context	String	EQUAL_TO

Entidade	Campo	Tipo de dados	Operadores compatíveis
	pesquisar	String	EQUAL_TO
	after	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	slug	String	EQUAL_TO
	status	String	EQUAL_TO
	sku	String	EQUAL_TO
	featured	Booleano	EQUAL_TO
	tag	String	EQUAL_TO
	shipping_class	String	EQUAL_TO
	tax_class	String	EQUAL_TO
	on_sale	Booleano	EQUAL_TO
	stock_status	String	EQUAL_TO
	has_options	Booleano	N/D
	modified_after	DateTime	EQUAL_TO
	modified_before	DateTime	EQUAL_TO
	dates_are_gmt	Booleano	EQUAL_TO
	categoria	String	EQUAL_TO
	atributo	String	EQUAL_TO

Entidade	Campo	Tipo de dados	Operadores compatíveis
	min_price	String	EQUAL_TO
	max_price	String	EQUAL_TO
product-attribute	id	Inteiro	N/D
	nome	String	N/D
	slug	String	N/D
	type	String	N/D
	order_by	String	N/D
	has_archives	Booleano	N/D
	context	String	EQUAL_TO
product-attribute-term	id	Inteiro	N/D
	nome	String	N/D
	slug	String	N/D
	description	String	N/D
	menu_order	Inteiro	N/D
	contagem	Inteiro	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	hide_empty	Booleano	EQUAL_TO

Entidade	Campo	Tipo de dados	Operadores compatíveis
	parent	Inteiro	EQUAL_TO
	product	Inteiro	EQUAL_TO
product-category	id	Inteiro	N/D
	nome	String	N/D
	slug	String	EQUAL_TO
	description	String	N/D
	display	String	N/D
	image	Struct	N/D
	menu_order	Inteiro	N/D
	contagem	Inteiro	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	hide_empty	Booleano	EQUAL_TO
	parent	Inteiro	EQUAL_TO
	product	Inteiro	EQUAL_TO
product-review	id	Inteiro	N/D
	date_created	DateTime	N/D
	date_created_gmt	DateTime	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	product_id	Inteiro	N/D
	product_name	String	N/D
	product_permalink	String	N/D
	analisar	String	N/D
	rating	Inteiro	N/D
	verified	Booleano	N/D
	reviewer	String	N/D
	reviewer_email	String	N/D
	reviewer_avatar_urls	Struct	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	after	DateTime	EQUAL_TO
	antes	DateTime	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	status	String	EQUAL_TO
product-shipping-class	id	Inteiro	N/D
	nome	String	N/D
	slug	String	EQUAL_TO
	description	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	contagem	Inteiro	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	hide_empty	String	EQUAL_TO
	product	Inteiro	EQUAL_TO
product-tag	id	Inteiro	N/D
	nome	String	N/D
	slug	String	EQUAL_TO
	description	String	N/D
	contagem	Inteiro	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	hide_empty	Booleano	EQUAL_TO
	product	Inteiro	EQUAL_TO
product-total	slug	String	N/D
	nome	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	total	Inteiro	N/D
product-variation	id	Inteiro	N/D
	date_created	DateTime	N/D
	date_created_gmt	DateTime	N/D
	date_modified	DateTime	N/D
	date_modified_gmt	DateTime	N/D
	description	String	N/D
	permalink	String	N/D
	preço	String	N/D
	regular_price	String	N/D
	sale_price	String	N/D
	date_on_sale_from	DateTime	N/D
	date_on_sale_from_gmt	DateTime	N/D
	date_on_sale_to	DateTime	N/D
	date_on_sale_to_gmt	DateTime	N/D
	purchasable	Booleano	N/D
	virtual	Booleano	N/D
	para download	Booleano	N/D
	downloads	Lista	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	download_limit	Inteiro	N/D
	download_expiry	Inteiro	N/D
	tax_status	String	N/D
	manage_stock	Booleano	N/D
	stock_quantity	Inteiro	N/D
	backorders	String	N/D
	backorders_allowed	Booleano	N/D
	backordered	Booleano	N/D
	low_stock_amount	Inteiro	N/D
	weight	String	N/D
	dimensões	Struct	N/D
	shipping_class	String	N/D
	shipping_class_id	Inteiro	N/D
	image	Struct	N/D
	attributes	Lista	N/D
	menu_order	Inteiro	N/D
	meta_data	Lista	N/D
	context	String	EQUAL_TO
	pesquisar	String	EQUAL_TO
	after	DateTime	EQUAL_TO

Entidade	Campo	Tipo de dados	Operadores compatíveis
	antes	DateTime	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	slug	String	EQUAL_TO
	status	String	EQUAL_TO
	sku	String	EQUAL_TO
	tax_class	String	EQUAL_TO
	on_sale	Booleano	EQUAL_TO
	min_price	String	EQUAL_TO
	max_price	String	EQUAL_TO
	stock_status	String	EQUAL_TO
relatório	slug	String	N/D
	description	String	N/D
review-total	slug	String	N/D
	nome	String	N/D
	total	Inteiro	N/D
sales-report	total_sales	String	N/D
	net_sales	String	N/D
	average_sales	String	N/D
	total_orders	Inteiro	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	total_items	Inteiro	N/D
	total_tax	String	N/D
	total_shipping	String	N/D
	total_refunds	Inteiro	N/D
	total_discount	String	N/D
	totals_grouped_by	String	N/D
	totals	Struct	N/D
	total_customers	Inteiro	N/D
	context	String	EQUAL_TO
	período	String	EQUAL_TO
	date_min	Data	EQUAL_TO
	date_max	Data	EQUAL_TO
shipping-method	id	String	N/D
	título	String	N/D
	description	String	N/D
shipping-zone	id	Inteiro	EQUAL_TO
	nome	String	N/D
	ordem	Inteiro	N/D
shipping-zone-location	código	String	N/D
	type	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
shipping-zone-method	instance_id	Inteiro	N/D
	id	Inteiro	EQUAL_TO
	título	String	N/D
	ordem	Inteiro	N/D
	enabled	Booleano	N/D
	method_id	String	N/D
	method_title	String	N/D
	method_description	String	N/D
	configurações	Struct	N/D
tax-class	slug	String	N/D
	nome	String	N/D
tax-rate	id	Inteiro	N/D
	country	String	N/D
	estado	String	N/D
	postcode	String	N/D
	city	String	N/D
	postcodes	Lista	N/D
	cities	Lista	N/D
	rate	String	N/D
	nome	String	N/D

Entidade	Campo	Tipo de dados	Operadores compatíveis
	priority	Inteiro	N/D
	compound	Booleano	N/D
	envio	Booleano	N/D
	context	String	EQUAL_TO
	ordem	String	EQUAL_TO
	orderby	String	EQUAL_TO
	classe	String	EQUAL_TO
top-seller-report	nome	String	N/D
	product_id	Inteiro	N/D
	quantity	Inteiro	N/D
	context	String	EQUAL_TO
	período	String	EQUAL_TO
	date_min	Data	EQUAL_TO
	date_max	Data	EQUAL_TO

> **Note**
>
> Os tipos de dados Struct e List são convertidos no tipo de dados String, e o tipo de dados DateTime é convertido em Timestamp na resposta dos conectores.

Particionamento de consultas

Particionamento com base em registros:

É possível fornecer a opção adicional NUM_PARTITIONS do Spark se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em NUM_PARTITIONS subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

No particionamento com base em registros, o número total de registros presentes é consultado na API do WooCommerce e dividido por um número NUM_PARTITIONS fornecido. O número resultante de registros é então buscado simultaneamente por cada subconsulta.

- NUM_PARTITIONS: o número de partições.

As entidades a seguir oferecem suporte ao particionamento baseado em registros:

- cupon
- ordem
- product
- product-attribute
- product-attribute-term
- product-category
- product-review
- product-shipping-class
- product-tag
- product-variation
- tax-rate

Exemplo: .

```
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"
    }
```

Particionamento com base em registros:

A consulta original é dividida em NUM_PARTITIONS subconsultas que podem ser executadas pelas tarefas do Spark simultaneamente:

- NUM_PARTITIONS: o número de partições.

Exemplo: .

```
WooCommerce_read = glueContext.create_dynamic_frame.from_options(
    connection_type="WooCommerce",
    connection_options={
        "connectionName": "connectionName",
        "REALMID": "12345678901234567890",
        "ENTITY_NAME": "Bill",
        "API_VERSION": "v3",
        "NUM_PARTITIONS": "10"
    }
```

Opções de conexão do WooCommerce

Estas são as opções de conexão do WooCommerce:

- ENTITY_NAME(string): (obrigatório) usado para leitura. O nome do seu objeto no WooCommerce.
- API_VERSION(string): (obrigatório) usado para leitura. Versão da API Rest do WooCommerce que você deseja usar.
- REALM_ID(string): um ID que identifica uma empresa individual do WooCommerce Online para a qual você envia solicitações.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- FILTER_PREDICATE(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.
- INSTANCE_URL(string): (obrigatório) um URL de instância do WooCommerce válida com o formato: https://<instância>.wpcomstaging.com
- NUM_PARTITIONS(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.

Conectando-se ao Zendesk

O Zendesk é uma solução de gerenciamento de help desk baseada em nuvem que oferece ferramentas personalizáveis para criar um portal de atendimento ao cliente, uma base de conhecimento e comunidades on-line.

Tópicos

- AWS Glue suporte para o Zendesk
- Políticas contendo as API operações para criar e usar conexões
- Configuração do Zendesk
- Configuração de conexões do Zendesk
- Leitura de entidades do Zendesk
- Opções de conexão do Zendesk
- Limitações

AWS Glue suporte para o Zendesk

AWS Glue oferece suporte ao Zendesk da seguinte forma:

Compatível como fonte?

Sim. Você pode usar AWS Glue ETL trabalhos para consultar dados do Zendesk.

Compatível como destino?

Não.

Versões compatíveis do Zendesk API

As seguintes API versões do Zendesk são suportadas

- v2

Políticas contendo as API operações para criar e usar conexões

O exemplo de política a seguir descreve as AWS IAM permissões necessárias para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, use as seguintes IAM políticas gerenciadas:

- AWSGlueServiceRole— Concede acesso aos recursos que vários AWS Glue processos exigem para serem executados em seu nome. Esses recursos incluem AWS Glue Amazon S3IAM, CloudWatch Logs e Amazon. EC2 Se você seguir a convenção de nomenclatura dos recursos especificados nesta política, AWS Glue os processos terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess— Concede acesso total aos AWS Glue recursos quando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do AWS Glue console.

Configuração do Zendesk

Antes de usar AWS Glue para transferir dados do Zendesk, você deve atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Zendesk. Para obter mais informações, consulte Criação de uma conta do Zendesk.
- Sua conta do Zendesk está habilitada para API acesso.
- Sua conta do Zendesk permite que você instale aplicativos conectados.

Se você atender a esses requisitos, estará pronto para se conectar AWS Glue à sua conta do Zendesk.

Criação de uma conta do Zendesk

Para criar uma conta do Zendesk:

1. Vá para o https://www.zendesk.com/in/ registro/
2. Insira detalhes como seu e-mail de trabalho, nome, sobrenome, número de telefone, cargo, nome da empresa, número de funcionários na empresa, senha e idioma preferido. Em seguida, escolha Complete o teste de inscrição.
3. Depois que sua conta for criada, preencha o link de verificação que você recebeu para verificar seu endereço de e-mail.
4. Depois que o endereço de e-mail profissional for verificado, você será redirecionado para sua conta do Zendesk. Escolha a opção Comprar Zendesk para seu plano preferido. Observação: para o conector Zendesk, é recomendável comprar o plano Suite Enterprise.

Criação de um aplicativo cliente e credenciais OAuth 2.0

Para criar um aplicativo cliente e credenciais OAuth 2.0:

1. Faça login em sua conta do Zendesk onde você deseja que o aplicativo OAuth 2.0 seja criado https://www.zendesk.com/in/ login/
2. Clique no ícone de engrenagem. Escolha o link Ir para o centro de administração para abrir a página do centro de administração.
3. Escolha Aplicativos e integrações na barra lateral esquerda e selecione APIs> Zendesk. API
4. Na API página do Zendesk, escolha a guia OAuthClientes.
5. Escolha Adicionar cliente Oauth no lado direito.
6. Preencha os campos a seguir para criar um cliente:

a. Nome do cliente - insira um nome para seu aplicativo. Esse é o nome que os usuários verão quando solicitados a conceder acesso ao seu aplicativo e quando verificarem a lista de aplicativos de terceiros que têm acesso ao Zendesk.

b. Descrição - Opcional. Uma breve descrição do seu aplicativo que os usuários verão quando solicitados a conceder acesso a ele.

c. Empresa - Opcional. O nome da empresa que os usuários verão quando solicitados a conceder acesso ao seu aplicativo. As informações podem ajudá-los a entender a quem estão concedendo acesso.

d. Logotipo - Opcional. Esse é o logotipo que os usuários verão quando solicitados a conceder acesso ao seu aplicativo. A imagem pode serJPG,GIF, ouPNG. Para obter melhores resultados, faça o upload de uma imagem quadrada. Ele será redimensionado para a página de autorização.

e. Identificador exclusivo - O campo é preenchido automaticamente com uma versão reformatada do nome que você inseriu para seu aplicativo. Você pode alterá-lo, se desejar.

f. Redirecionar URLs - insira o URL ou URLs que o Zendesk deve usar para enviar a decisão do usuário de conceder acesso ao seu aplicativo.

   Por exemplo: https://us-east-1.console.aws.amazon.com/gluestudio/ oauth

7. Clique em Salvar.
8. Depois que a página for atualizada, um novo campo secreto pré-preenchido aparece na parte inferior. Esse é o valor “client_secret” especificado na especificação. OAuth2 Copie o valor secreto para sua área de transferência e salve-o em algum lugar seguro. Observação: os caracteres podem ultrapassar a largura da caixa de texto, portanto, certifique-se de selecionar tudo antes de copiar.
9. Clique em Salvar.

Configuração de conexões do Zendesk

O conector do Zendesk oferece suporte ao tipo de concessão de código de autorização.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O usuário que estiver criando uma conexão pode, por padrão, contar com uma aplicação conectada pertencente ao AWS Glue (aplicação cliente gerenciada pelo AWS Glue), na qual ele não precisa fornecer

quaisquer informações relacionadas ao OAuth, exceto o URL da instância do Zendesk. O console do AWS Glue redirecionará o usuário para o Zendesk, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Zendesk.

- Os usuários ainda podem optar por criar sua própria aplicação conectada no Zendesk e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, você ainda será redirecionado para o Zendesk para fazer login e autorizar o acesso do AWS Glue aos seus recursos.
- Esse tipo de concessão resulta em um token de acesso. O token de acesso nunca expira.

Para obter a documentação pública do Zendesk sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Tokens do OAuth para tipos de concessão.

Para configurar uma conexão do Zendesk:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para o tipo de concessão AuthorizationCode: para uma aplicação conectada gerenciada pelo cliente, o segredo deve conter o segredo do consumidor da aplicação conectada com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Nota: é preciso criar um segredo por conexão em AWS Glue.
2. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Zendesk.
   b. Forneça o INSTANCE_URL do Zendesk ao qual deseja se conectar.
   c. Forneça o ambiente do Zendesk.
   d. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
```

```
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

e. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

f. Selecione as opções de rede se quiser usar sua rede.

3. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Zendesk

Pré-requisito

Um objeto do Zendesk-do qual você deseja ler. Você precisará do nome do objeto, como tíquete, usuário ou artigo, conforme mencionado na tabela a seguir.

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Tíquete	S	S	S	S	N
Usuário	S	S	S	S	N
Organização	S	S	S	S	N
Artigo	S	S	N	S	N
Evento do tíquete	S	S	N	S	N
Evento de métrica do tíquete	S	S	N	S	N

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Comentário do tíquete	S	S	S	S	N
Campo do tíquete	S	S	N	S	N
Métrica do tíquete	S	S	N	S	N
Atividade do tíquete	S	S	N	S	N
Ignorar tíquete	N	S	N	S	N
Grupo	S	S	S	S	N
Associação a grupos	N	S	S	S	N
Classificação de satisfação	S	S	N	S	N
Visão	S	S	S	S	N
Trigger	S	S	S	S	N
Categoria do gatilho	N	S	S	S	N
Macro	S	S	S	S	N
Automação	N	S	S	S	N

Exemplo:

```
Zendesk_read = glueContext.create_dynamic_frame.from_options(
    connection_type="Zendesk",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "Account",
        "API_VERSION": "v2"
    }
```

Detalhes das entidades e dos campos do Zendesk:

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
artigos	url	String		
	id	Longo		
	author_id	Longo		
	body	String		
	comments_ disabled	Booleano		
	rascunho	Booleano		
	edited_at	DateTime		
	html_url	String		
	label_names	Listar		
	locale	String	EQUAL_TO	
	outdated	Booleano		
	outdated_locales	Listar		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	permissio n_group_id	Longo		
	position	Inteiro		
	promovido	Booleano		
	section_id	Longo		
	source_locale	String		
	name	String		
	title	String		
	user_segment_id	Longo		
	content_tags_id	Listar		
	vote_count	Inteiro		
	vote_sum	Inteiro		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	label_name	String	EQUAL_TO	
grupo	url	String		
	id	Longo		
	is_public	Booleano		
	name	String		
	description	String		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	padrão	Booleano		
	deleted	Booleano		
	created_at	DateTime		
	updated_at	DateTime		
	exclude_deleted	Booleano	EQUAL_TO	
Automation	url	String		
	id	Longo		
	title	String		
	active	Booleano		
	created_at	DateTime		
	updated_at	DateTime		
	padrão	Booleano		
	actions	Listar		
	posições	Inteiro		
	condições	struct		
	raw_title	String		
group-membership	url	String		
	id	Longo		
	user_id	Longo		
	group_id	Longo		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	padrão	Booleano		
	created_at	DateTime		
	updated_at	DateTime		
Macro	url	String		
	id	Longo		
	title	String		
	active	Booleano	EQUAL_TO	
	created_at	DateTime		
	updated_at	DateTime		
	padrão	Booleano		
	actions	Listar		
	position	Inteiro		
	description	String		
	raw_title	String		
	restrição	struct		
	access	String	EQUAL_TO	
	category	Inteiro	EQUAL_TO	
	group_id	Longo	EQUAL_TO	
	only_viewable	Booleano	EQUAL_TO	
organizações	url	String		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	id	Longo		
	external_id	String		
	name	String		
	domain_names	Listar		
	detalhes	String		
	observações	String		
	group_id	Longo		
	shared_tickets	Booleano		
	shared_comments	Booleano		
	tags	Listar		
	organization_fields	struct		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	DML_STATUS	String		Um campo definido pelo usuário usado para rastrear o status criado, atualizado e excluído do registro.

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
satisfaction-rating	url	String		
	id	Longo		
	assignee_id	Longo		
	comentário	String		
	group_id	Longo		
	razão	String		
	reason_code	Inteiro		
	reason_id	Longo		
	requester_id	Longo		
	pontuação	String	EQUAL_TO	
	ticket_id	Inteiro		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	start_time	DateTime	EQUAL_TO	
	end_time	DateTime	EQUAL_TO	
	DML_STATUS	String		Um campo definido pelo usuário usado para rastrear o status criado, atualizado e excluído do registro.

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
ticket-activity	actor	struct		
	actor_id	Longo		
	created_at	DateTime		
	id	Longo		
	objeto	struct		
	target	struct		
	title	String		
	updated_at	DateTime		
	url	String		
	usuário	struct		
	user_id	Longo		
	verb	String		
	since	DateTime	EQUAL_TO	
ticket-comment	id	Longo		
	tipo	String		
	author_id	Longo		
	body	String		
	html_body	String		
	plain_body	String		
	pública	Booleano		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	attachments	Listar		
	audit_id	Longo		
	via	struct		
	created_at	DateTime		
	metadata	struct		
	ticket_id	Inteiro	EQUAL_TO	
	include_inline_images	Booleano	EQUAL_TO	
ticket-events	id	Longo		
	ticket_id	Longo		
	timestamp	Longo		
	created_at	DateTime		
	updater_id	Longo		
	child_events	Listar		
	via	String		
	system	struct		
	event_type	String		
	comment_present	Booleano		
	comment_public	Booleano		
	via_reference_id	Longo		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	created_at	DateTime	EQUAL_TO	
	DML_STATUS	String		Um campo definido pelo usuário usado para rastrear o status criado, atualizado e excluído do registro.
ticket-field	url	String		
	id	Longo		
	tipo	String		
	title	String		
	raw_title	String		
	description	String		
	raw_description	String		
	position	Inteiro		
	active	Booleano		
	obrigatório	Booleano		
	collapsed_for_agents	Booleano		
	regexp_for_validation	String		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	title_in_portal	String		
	raw_title _in_portal	String		
	visible_in_portal	Booleano		
	editable_ on_portal	Booleano		
	required_ in_portal	Booleano		
	tag	String		
	created_at	DateTime		
	updated_at	DateTime		
	removível	Booleano		
	agent_des cription	String		
	custom_fi eld_options	Listar		
	custom_statuses	Listar		
	relationship_filter	struct		
	relations hip_target_type	String		
	sub_type_id	Inteiro		
	system_fi eld_options	Listar		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	locale	String	EQUAL_TO	
ticket-metric-events	id	Longo		
	horário	DateTime	EQUAL_TO	
	ticket_id	Inteiro		
	métrica	String		
	instance_id	Inteiro		
	tipo	String		
	DML_STATUS	String	EQUAL_TO	Um campo definido pelo usuário usado para rastrear o status criado, atualizado e excluído do registro.
ticket-metric	url	String		
	id	Longo		
	ticket_id	Inteiro		
	created_at	DateTime		
	updated_at	DateTime		
	group_stations	Inteiro		
	assignee_stations	Inteiro		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	reabre	Inteiro		
	responde	Inteiro		
	assignee_ updated_at	DateTime		
	requester _updated_at	DateTime		
	initially_assigned _at	DateTime		
	assigned_at	DateTime		
	solved_at	DateTime		
	last_comm ent_added_at	DateTime		
	reply_tim e_in_minutes	struct		
	first_resolution_t ime_in_minutes	struct		
	full_resolution_ti me_in_minutes	struct		
	agent_wai t_time_in _minutes	struct		
	requester _wait_tim e_in_minutes	struct		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	on_hold_time_in_seconds	struct		
	reply_time_in_seconds	struct		
	custom_status_updated_at	DateTime		
ticket-skip	created_at	DateTime		
	id	Longo		
	razão	String		
	bilhete	struct		
	ticket_id	Inteiro		
	updated_at	DateTime		
	user_id	Longo		
tíquetes	url	String		
	id	Longo		
	external_id	String	EQUAL_TO	
	tipo	String		
	subject	String		
	raw_subject	String		
	description	String		
	priority	String		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	status	String		
	recipient (destinatário)	String		
	requester (solicitante)	struct		
	requester_id	Longo		
	submitter_id	Longo		
	assignee_id	Longo		
	organization_id	Longo		
	group_id	Longo		
	collaborator_ids	Listar		
	emails_cc_ids	Listar		
	follower_ids	Listar		
	forum_topic_id	Ling		
	problem_id	Longo		
	has_incidents	Booleano		
	due_at	DateTime		
	tags	Listar		
	via	struct		
	custom_fields	Listar		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	satisfaction_rating	struct		
	sharing_agreement_ids	Listar		
	followup_ids	Listar		
	via_followup_source_id	Longo		
	ticket_form_id	Longo		
	brand_id	Longo		
	allow_channelback	Booleano		
	allow_attachments	Booleano		
	is_public	Booleano		
	from_messaging_channel	Booleano		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	assignee_email	String		
	attribute_value_ids	Listar		
	colaboradores	Listar		
	comentário	struct		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	custom_status_id	Longo		
	email_ccs	struct		
	seguidores	struct		
	macro_id	Longo		
	macros_ids	Listar		
	metadata	struct		
	safe_update	Booleano		
	updated_stamp	DateTime		
	via_id	Longo		
	voice_comment	struct		
	DML_STATUS	String		Um campo definido pelo usuário usado para rastrear o status criado, atualizado e excluído do registro.
trigger-category	url	String		
	id	String		
	name	String		
	updated_at	DateTime		
	created_at	DateTime		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	position	Inteiro		
Acionador	url	String		
	id	Longo		
	title	String		
	active	Booleano	EQUAL_TO	
	updated_at	DateTime		
	created_at	DateTime		
	padrão	Booleano		
	actions	Listar		
	condições	struct		
	description	String		
	position	Inteiro		
	raw_title	String		
	category_id	String	EQUAL_TO	
usuários	url	String		
	id	Longo		
	external_id	String	EQUAL_TO	
	email	String		
	active	Booleano		
	alias	String		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	chat_only	Booleano		
	custom_roll_id	Longo		
	roll_type	Inteiro		
	detalhes	String		
	last_login_at	DateTime		
	locale	String		
	locale_id	Inteiro		
	moderator	Booleano		
	observações	String		
	name	String		
	only_private_comments	Booleano		
	organization_id	Longo		
	default_group_id	Longo		
	phone	String		
	photo	struct		
	remote_photo_url	String		
	restricted_agent	Booleano		
	perfil	String	EQUAL_TO	
	compartilhado	Booleano		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	shared_agent	Booleano		
	tag	Listar		
	assinatura	String		
	suspended	Booleano		
	ticket_restriction	String		
	time_zone	String		
	iana_time_zone			
	two_factor_auth_enabled			
	user_fields			
	verified	Booleano		
	report_csv	Booleano		
	created_at	DateTime		
	updated_at	DateTime	EQUAL_TO	
	permission_set	Longo	EQUAL_TO	
	shared_phone_number	Booleano		

Entidade	Campo	Tipo de dados	Operadores compatíveis	Comentários
	DML_STATUS	String		Um campo definido pelo usuário usado para rastrear o status criado, atualizado e excluído do registro.
view	url	String		
	id	Longo		
	title	String		
	active	Booleano	EQUAL_TO	
	updated_at	DateTime		
	created_at	DateTime		
	padrão	Booleano		
	position	Inteiro		
	description	String		
	execution	struct		
	restrição	struct		
	raw_title	String		
	condições	struct		
	access	String	EQUAL_TO	
	group_id	Longo	EQUAL_TO	

> **Note**
>
> Os tipos de dados Struct e List são convertidos no tipo de dados String na resposta do conector.

Consultas de particionamento

Não há suporte para partições no Zendesk.

Opções de conexão do Zendesk

A seguir estão as opções de conexão para o Zendesk:

- `ENTITY_NAME`(String) - (Obrigatório) Usado para leitura. O nome do seu objeto no Zendesk.
- `API_VERSION`(String) - (Obrigatório) Usado para leitura. APIVersão do Zendesk Rest que você deseja usar. Por exemplo: v2.
- `SELECTED_FIELDS`(Lista<String>) - Padrão: vazio (SELECT*). Usado para leitura. Colunas que deseja selecionar para o objeto. Por exemplo: id, nome, url, created_at
- `FILTER_PREDICATE`(String): padrão: vazia. Usado para leitura. Ele deve estar no SQL formato Spark. Por exemplo: group_id = 100
- `QUERY`(String): padrão: vazia. Usado para leitura. SQLConsulta completa do Spark. Por exemplo: "SELECTid, url FROM users WHERE role=\" end-user\ ""
- `PARTITION_FIELD`(String): usado para leitura. Campo a ser usado para particionar a consulta. O campo padrão é `update_at` para entidades que suportam a exportação incremental API (`created_at`para `ticket-events` e `time` para`ticket-metric-events`).
- `LOWER_BOUND`(String): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- `UPPER_BOUND`(String): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido. Opcional; essa opção será tratada pelo conector se não for fornecida na opção de trabalho. Valor padrão - “2024-05-01T 20:55:02.000 Z
- `NUM_PARTITIONS`(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura. Opcional; essa opção será tratada pelo conector se não for fornecida na opção de trabalho. Valor padrão: 1.
- `IMPORT_DELETED_RECORDS`(String) - Padrão:FALSE. Usado para leitura. Para obter os registros excluídos durante a consulta.

- `ACCESS_TOKEN`- Token de acesso a ser usado na solicitação.
- `INSTANCE_URL`- URL da instância em que o usuário deseja executar as operações. Por exemplo: https://{subdomain}/.zendesk.com

Limitações

A seguir estão as limitações do conector Zendesk:

- A paginação baseada em offset limita o número de páginas que podem ser buscadas a 100, mas não é recomendada, pois o número total de registros que podem ser buscados é 10.000. No entanto, a paginação baseada em cursor implementada para o conector Zendesk supera essa limitação. Somente o operador do filtro EQUAL _TO é suportado pelo ZendeskAPI.

  Por causa dessa limitação, o particionamento não é suportado pelo conector Zendesk.
- Para a entidade “Ticket Event”, o limite de tarifa é de 10 solicitações por minuto. Ao executar um AWS Glue ETL trabalho, você pode receber um erro 429 (muitas solicitações).

Conexão com o Zoho CRM

O Zoho CRM atua como um repositório único para reunir as atividades de vendas, marketing e atendimento ao cliente e simplificar processos, políticas e pessoas em uma única plataforma. O Zoho CRM pode ser facilmente personalizado para atender às necessidades específicas de empresas de qualquer tipo e tamanho.

A plataforma de desenvolvedores do Zoho CRM oferece a combinação certa de ferramentas low-code e pro-code para que negócios/empresas automatizem o trabalho, integrem dados em toda a pilha corporativa e criem soluções personalizadas para a Web e dispositivos móveis.

Tópicos

- Suporte do AWS Glue ao Zoho CRM
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Zoho CRM
- Configuração de conexões do Zoho CRM
- Leitura de entidades do Zoho CRM
- Opções de conexão do Zoho CRM

- Limitações e notas do conector do Zoho CRM

Suporte do AWS Glue ao Zoho CRM

O AWS Glue oferece suporte ao Zoho CRM da seguinte maneira:

Compatível como fonte?

Sim: SYNC e ASYNC. Você pode usar trabalhos de ETL do AWS Glue para consultar dados do Zoho CRM.

Compatível como destino?

N.º

Versões compatíveis da API do Zoho CRM

As seguintes versões da API do Zoho CRM são compatíveis:

- v7

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:ListConnectionTypes",
                "glue:DescribeConnectionType",
                "glue:RefreshOAuth2Tokens"
                "glue:ListEntities",
                "glue:DescribeEntity"
            ],
            "Resource": "*"
        }
    ]
}
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Zoho CRM

Antes de poder usar o AWS Glue para transferir dados do Zoho CRM, você precisa atender aos seguintes requisitos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Ter uma conta do Zoho CRM.
- A conta do Zoho CRM precisa estar habilitada para acesso à API.
- Ter um cliente de API registrado no console da API para obter as credenciais do OAuth.

Configuração de conexões do Zoho CRM

O tipo de concessão determina como o AWS Glue se comunica com o Zoho CRM para solicitar acesso aos seus dados. A escolha afeta os requisitos que você deve atender antes de criar a conexão. O Zoho CRM só é compatível com o tipo de concessão AUTHORIZATION_CODE para OAuth 2.0.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o

usuário. É usado ao criar conexões por meio do console do AWS Glue. O console do AWS Glue redirecionará o usuário para o Zoho CRM, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo Glue acessem a instância do Zoho CRM.

- Os usuários ainda podem optar por criar sua própria aplicação conectada no Zoho CRM e fornecer os próprios ID de cliente, URL de autorização, URL de token e URL de instância quando criarem conexões por meio do Console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Zoho CRM para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso permanecerá válido por uma hora e poderá ser atualizado automaticamente sem a interação do usuário por meio do token de atualização.
- Para obter a documentação pública do Zoho CRM sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Autenticação.

Para configurar uma conexão do Zoho CRM:

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, selecione Zoho CRM.
   b. Forneça o `INSTANCE_URL` da instância do Zoho CRM à qual você deseja se conectar.
   c. Forneça o ID do cliente da aplicação cliente do usuário.
   d. Selecione o URL de autorização apropriado no menu suspenso.
   e. Selecione o URL do token apropriado no menu suspenso.
   f. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
```

```
            "Resource": "*"
        }
    ]
}
```

g. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

h. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.
3. Na configuração do trabalho do AWS Glue, forneça `connectionName` como uma Conexão de rede adicional.

Leitura de entidades do Zoho CRM

Pré-requisito

Objetos do Zoho CRM dos quais você deseja ler. Você precisará do nome do objeto.

Entidades compatíveis com a fonte de Sync:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Produto	Sim	Sim	Sim	Sim	Sim
Cotação	Sim	Sim	Sim	Sim	Sim
Ordem de compra	Sim	Sim	Sim	Sim	Sim
Solução	Sim	Sim	Sim	Sim	Sim
Chame	Sim	Sim	Sim	Sim	Sim
Tarefa	Sim	Sim	Sim	Sim	Sim

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Event	Sim	Sim	Sim	Sim	Sim
Fatura	Sim	Sim	Sim	Sim	Sim
Conta	Sim	Sim	Sim	Sim	Sim
Contato	Sim	Sim	Sim	Sim	Sim
Fornecedor	Sim	Sim	Sim	Sim	Sim
Campaign	Sim	Sim	Sim	Sim	Sim
Oferta	Sim	Sim	Sim	Sim	Sim
Lead	Sim	Sim	Sim	Sim	Sim
Módulo personali zado	Sim	Sim	Sim	Sim	Sim
Ordem de venda	Sim	Sim	Sim	Sim	Sim
Catálogos de preços	Sim	Sim	Sim	Sim	Sim
Caso	Sim	Sim	Sim	Sim	Sim

Exemplo:

```
zoho_read = glueContext.create_dynamic_frame.from_options(
    connection_type="ZOHO",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
```

```
        "API_VERSION": "v7",
        "INSTANCE_URL": "https://www.zohoapis.in/"
    }
```

Entidades compatíveis com a fonte de ASYNC:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Produto	Sim	Não	Não	Sim	Não
Cotação	Sim	Não	Não	Sim	Não
Ordem de compra	Sim	Não	Não	Sim	Não
Solução	Sim	Não	Não	Sim	Não
Chame	Sim	Não	Não	Sim	Não
Tarefa	Sim	Não	Não	Sim	Não
Event	Sim	Não	Não	Sim	Não
Fatura	Sim	Não	Não	Sim	Não
Conta	Sim	Não	Não	Sim	Não
Contato	Sim	Não	Não	Sim	Não
Fornecedor	Sim	Não	Não	Sim	Não
Campaign	Sim	Não	Não	Sim	Não
Oferta	Sim	Não	Não	Sim	Não
Lead	Sim	Não	Não	Sim	Não

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Módulo personali zado	Sim	Não	Não	Sim	Não
Ordem de venda	Sim	Não	Não	Sim	Não
Catálogos de preços	Sim	Não	Não	Sim	Não
Caso	Sim	Não	Não	Sim	Não

Exemplo:

```
zoho_read = glueContext.create_dynamic_frame.from_options(
    connection_type="ZOHO",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "entityName",
        "API_VERSION": "v7",
        "INSTANCE_URL": "https://www.zohoapis.in/",
        "TRANSFER_MODE": "ASYNC"
    }
```

Detalhes dos campos do Zoho CRM:

O Zoho CRM fornece endpoints para a busca de metadados de forma dinâmica para entidades compatíveis. Portanto, o suporte do operador é capturado no nível do tipo de dados.

Entidade	Tipo de dados	Operadores compatíveis
Entidades do Zoho (todas as entidades)	Inteiro	!=, =, <, <=, >, >=, BETWEEN
	String	Like, =, !=

Entidade	Tipo de dados	Operadores compatíveis
	BigInteger	!=, =, <, <=, >, >=, BETWEEN
	Booleano	=
	Duplo	!=, =, <, <=, >, >=, BETWEEN
	BigDecimal	!=, =, <, <=, >, >=, BETWEEN
	Data	!=, =, <, <=, >, >=, BETWEEN
	DateTime	!=, =, <, <=, >, >=, BETWEEN
	Struct	N/D
	Lista	N/D

Particionamento de consultas

O particionamento não é compatível no modo ASYNC.

Particionamento baseado em filtro (modo SYNC):

É possível fornecer as opções adicionais do Spark `PARTITION_FIELD`, `LOWER_BOUND`, `UPPER_BOUND` e `NUM_PARTITIONS` se quiser utilizar a simultaneidade no Spark. Com esses parâmetros, a consulta original seria dividida em `NUM_PARTITIONS` subconsultas, que poderiam ser executadas pelas tarefas do Spark simultaneamente.

- `PARTITION_FIELD`: o nome do campo a ser usado para particionar a consulta.
- `LOWER_BOUND`: um valor limite inferior inclusivo do campo de partição escolhido.

  No campo Datetime, aceitamos o formato de carimbo de data/hora do Spark usado em consultas SQL do Spark.

  Exemplos de valores válidos:

  ```
  "2024-09-30T01:01:01.000Z"
  ```

- `UPPER_BOUND`: um valor limite superior exclusivo do campo de partição escolhido.

- NUM_PARTITIONS: o número de partições.

Exemplo:

```
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"
    }
```

Opções de conexão do Zoho CRM

Estas são as opções de conexão do Zoho CRM:

- ENTITY_NAME (String): (obrigatório) usado para leitura. O nome do seu objeto no Zoho CRM.
- API_VERSION (String): (obrigatório) usado para leitura. Versão da API Rest do Zoho CRM que você deseja usar.
- SELECTED_FIELDS(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Colunas que deseja selecionar para o objeto.
- FILTER_PREDICATE(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- QUERY(String): padrão: vazia. Usado para leitura. Consulta completa do Spark SQL.
- PARTITION_FIELD(string): usado para leitura. Campo a ser usado para particionar a consulta.
- LOWER_BOUND(string): usado para leitura. Um valor limite inferior inclusivo do campo de partição escolhido.
- UPPER_BOUND(string): usado para leitura. Um valor limite superior exclusivo do campo de partição escolhido.
- NUM_PARTITIONS(Inteiro): padrão: 1. Usado para leitura. Número de partições para leitura.
- INSTANCE_URL (String): (obrigatório) usado para leitura. Um URL válido da instância do Zoho CRM.
- TRANSFER_MODE (String): usado para indicar se a consulta deve ser executada no modo ASYNC.

Limitações e notas do conector do Zoho CRM

Estas são as limitações ou notas do conector do Zoho CRM:

- Com a versão v7 da API, você pode buscar no máximo 100 mil registros. Consulte a documentação do Zoho.
- Para a entidade Evento, o rótulo “Reunião” é exibido conforme mencionado na documentação do Zoho.
- Na funcionalidade Selecionar tudo:
  - Você pode buscar no máximo 50 campos de SaaS para as chamadas GET e POST.
  - Se você quiser ter dados para algum campo específico que não pertença aos primeiros 50 campos, precisará fornecer manualmente a lista dos campos selecionados.
  - Se mais de 50 campos forem selecionados, todos os campos além dos 50 campos serão removidos e conterão dados nulos no Amazon S3.
  - No caso de uma expressão de filtro, se a lista de 50 campos fornecida pelo usuário não incluir “id” e “Created_Time”, uma exceção personalizada será gerada para solicitar que o usuário inclua estes campos.
- Os operadores de filtro podem variar de campo para campo, apesar de terem o mesmo tipo de dados. Portanto, você deve especificar manualmente um operador diferente para qualquer campo que acione um erro na plataforma SaaS.
- Na funcionalidade Classificar por:
  - Os dados só podem ser classificados por um único campo sem uma expressão de filtro, ao passo que os dados podem ser classificados por vários campos quando uma expressão de filtro é aplicada.
  - Se nenhuma ordem de classificação for especificada para o campo selecionado, os dados serão recuperados em ordem crescente, por padrão.
- As regiões compatíveis com o conector do Zoho CRM são EUA, Europa, Índia, Austrália e Japão.
- Limitações da funcionalidade de leitura assíncrona:
  - Limite, ordenar por e particionamento não são compatíveis no modo ASYNC.
  - No modo ASYNC, podemos transferir dados de até 500 páginas com 200 mil registros por página.
  - Em um intervalo de um minuto, somente dez solicitações podem ser baixadas. Quando você excede o limite de download, o sistema retorna um erro HTTP 429 e pausa todas as solicitações de download por um minuto antes que o processamento possa continuar.

- Depois de concluir o trabalho em massa, você poderá acessar o arquivo para download somente por um dia. Depois disso, você não poderá acessar o arquivo via endpoints.
- Um máximo de 200 campos selecionados podem ser fornecidos por um endpoint. Se você especificar mais de 200 campos selecionados em um endpoint, o sistema exportará automaticamente todos os campos disponíveis para esse módulo.
- Os campos externos criados em qualquer módulo não são compatíveis com as APIs de leitura em massa.
- A classificação e as cláusulas `Group_by` não são compatíveis via esse endpoint da API.
- Os valores dos campos com dados de saúde confidenciais serão recuperados somente quando a opção Restringir acesso a dados por meio da API nas configurações de conformidade estiver desabilitada. Se a opção estiver habilitada, o valor ficará vazio no resultado.
- Limites de filtragem e critérios
  - O número máximo de critérios que podem ser usados em uma consulta é 25.
  - A filtragem e os critérios em campos de texto de várias linhas não são compatíveis.

Conexão com o Zoom Meetings

O Zoom Meetings é uma plataforma de videoconferência baseada em nuvem que pode ser usada para reuniões de videoconferência, audioconferência, webinars, gravações de reuniões e bate-papo ao vivo.

Tópicos

- Suporte do AWS Glue para o Zoom Meetings
- Políticas que contêm as operações de API para criar e usar conexões
- Configuração do Zoom Meetings
- Configuração da aplicação cliente do Zoom Meetings
- Configuração das conexões do Zoom Meetings
- Leitura de entidades do Zoom Meetings
- Opções de conexão do Zoom Meetings
- Limitações do Zoom Meetings

Suporte do AWS Glue para o Zoom Meetings

O AWS Glue oferece suporte ao Zoom Meetings da seguinte forma:

Compatível como fonte?

Sim. É possível usar trabalhos de ETL do AWS Glue para consultar seus dados do Zoom Meetings.

Compatível como destino?

Nº

Versões da API do Zoom Meetings com suporte

Versões da API do Zoom Meetings com suporte:

- v2

Políticas que contêm as operações de API para criar e usar conexões

O exemplo de política a seguir descreve as permissões necessárias do AWS IAM para criar e usar conexões. Se você estiver criando um novo perfil, crie uma política que contenha o seguinte:

```
{
 "Version": "2012-10-17",
     "Statement": [
      {
             "Effect": "Allow",
             "Action": [
                 "glue:ListConnectionTypes",
                 "glue:DescribeConnectionType",
                 "glue:RefreshOAuth2Tokens",
                 "glue:ListEntities",
                 "glue:DescribeEntity"
             ],
             "Resource": "*"
         }
     ]
 }
```

Se você não quiser usar o método acima, como alternativa use as seguintes políticas do IAM gerenciadas:

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Glue quando uma identidade à qual a política está anexada usa o Console de Gerenciamento da AWS. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

Configuração do Zoom Meetings

Antes de poder usar o AWS Glue para transferir dados do Zoom Meetings, os seguintes requisitos deverão ser atendidos:

Requisitos mínimos

Estes são os requisitos mínimos:

- Você tem uma conta do Zoom Meetings.
- Sua conta do Zoom precisa estar habilitada para acesso à API.
- Você criou uma aplicação OAuth2 na sua conta do Zoom Meetings. Essa integração fornece as credenciais que o AWS Glue usa para acessar seus dados com segurança quando faz chamadas autenticadas para sua conta. Para ter mais informações, consulte the section called “Configuração da aplicação cliente do Zoom Meetings”.

Se você atender a esses requisitos, poderá conectar o AWS Glue à sua conta do Zoom Meetings. Para conexões típicas, você não precisa fazer mais nada no Zoom Meetings.

Configuração da aplicação cliente do Zoom Meetings

1. Faça login no Zoom App Marketplace.
2. Escolha Desenvolver>Criar aplicação.
3. Escolha Aplicação geral para uma aplicação baseada em OAuth 2.0.

4. Na página Informações básicas, adicione ou atualize informações sobre a aplicação, como o nome da aplicação, como a aplicação é gerenciada, as credenciais da aplicação e as informações do OAuth.
5. Na seção Selecionar como a aplicação é gerenciada, confirme como você deseja que sua aplicação seja gerenciada:
   a. Gerenciada por administrador: administradores da conta adicionam e gerenciam a aplicação
   b. Gerenciada pelo usuário: usuários individuais adicionam e gerenciam a aplicação. A aplicação tem acesso somente aos dados autorizados do usuário.
6. Credenciais da aplicação: o fluxo de criação gera automaticamente as credenciais da aplicação (ID do cliente e segredo do cliente) para sua aplicação.
7. Na seção Informações do OAuth, configure o OAuth para a sua aplicação.
   a. URL de redirecionamento do OAuth (obrigatório): insira seu URL de redirecionamento ou endpoint para configurar o OAuth entre sua aplicação e o Zoom.
   b. Usar URL de modo estrito (opcional)
   c. Verificação de subdomínio (opcional)
   d. Listas de permissão do OAuth (obrigatório): adicione quaisquer URLs exclusivos que o Zoom deva permitir como redirecionamentos válidos para seus fluxos do OAuth.
8. Na página Escopos, selecione os métodos da API do Zoom que sua aplicação tem permissão para chamar. Os escopos definem quais informações e recursos estão disponíveis para seu usuário. Selecione os seguintes escopos granulares:
   - user:read:list_users:admin
   - zoom_rooms:read:list_rooms:admin
   - group:read:list_members:admin
   - group:read:administrator:admin
   - group:read:list_groups:admin
   - report:read:admin
   - role:read:list_roles, role:read:list_roles:admin

   Depois que os escopos forem adicionados, escolha Continuar e a aplicação estará pronta para uso.

Para obter mais informações sobre a configuração do OAuth 2.0, consulte Integrações (aplicações OAuth).

Configuração das conexões do Zoom Meetings

O Zoom Meetings oferece suporte ao tipo de concessão AUTHORIZATION_CODE para OAuth2. O tipo de concessão determina como o AWS Glue se comunica com o Zoom Meetings para solicitar acesso aos seus dados.

- Esse tipo de concessão é considerado um OAuth de “três pernas”, pois conta com o redirecionamento dos usuários para um servidor de autorização de terceiros para autenticar o usuário. É usado ao criar conexões por meio do console do AWS Glue. O usuário que está criando uma conexão precisa fornecer informações relacionadas ao OAuth, como ID do cliente e segredo do cliente, para sua aplicação cliente do Zoom Meetings. O console do AWS Glue redirecionará o usuário para o Zoom, onde ele deverá fazer login e dar autorização para que as permissões solicitadas pelo AWS Glue acessem a instância do Zoom Meetings.
- Os usuários ainda podem optar por criar sua própria aplicação conectada no Zoom Meetings e fornecer seus próprios ID e segredo do cliente ao criar conexões por meio do console do AWS Glue. Nesse cenário, eles ainda serão redirecionados para o Zoom Meetings para fazer login e autorizar o acesso do AWS Glue aos recursos.
- Esse tipo de concessão resulta em um token de atualização e um token de acesso. O token de acesso tem vida curta e pode ser atualizado automaticamente sem a interação do usuário usando o token de atualização.
- Para obter a documentação pública do Zoom Meetings sobre como criar uma aplicação conectada para o fluxo de código de autorização do OAuth, consulte Uso do OAuth 2.0.

Para configurar uma conexão do Zoom Meetings:

1. No AWS Secrets Manager, crie um segredo com os seguintes detalhes:
   a. Para a aplicação conectada gerenciada pelo cliente, o segredo deve conter a aplicação conectada Segredo do consumidor com a chave `USER_MANAGED_CLIENT_APPLICATION_CLIENT_SECRET`.
   b. Observação: é necessário criar um segredo para a sua conexão no AWS Glue.

1. No AWS Glue Glue Studio, crie uma conexão em Conexões de dados seguindo estas etapas:
   a. Ao selecionar um Tipo de conexão, escolha Zoom Meetings.
   b. Forneça o ambiente do Zoom Meetings ao qual deseja se conectar.

c. Selecione o perfil do AWS IAM que o AWS Glue pode assumir e tem permissões para as seguintes ações:

```
{
"Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "secretsmanager:DescribeSecret",
                "secretsmanager:GetSecretValue",
                "secretsmanager:PutSecretValue",
                "ec2:CreateNetworkInterface",
                "ec2:DescribeNetworkInterface",
                "ec2:DeleteNetworkInterface",
            ],
            "Resource": "*"
        }
    ]
}
```

d. Selecione o `secretName` que você deseja usar para essa conexão no AWS Glue para colocar os tokens.

e. Selecione as opções de rede se quiser usar sua rede.

2. Conceda permissão ao perfil do IAM associado ao seu trabalho do AWS Glue para ler `secretName`.

Leitura de entidades do Zoom Meetings

Pré-requisito

Um objeto do Zoom Meetings do qual você deseja ler. Você precisará do nome do objeto, como `Group` ou `Zoom Rooms`.

Entidades compatíveis quanto à origem:

Entidade	Pode ser filtrada	Oferece suporte a limite	Oferece suporte a Ordenar por	Oferece suporte a Selecionar *	Oferece suporte a particion amento
Zoom Rooms	Não	Sim	Não	Sim	Não
Grupo	Não	Não	Não	Sim	Não
Membro do grupo	Sim	Sim	Não	Sim	Não
Administrador do grupo	Não	Sim	Não	Sim	Não
Relatório (diário)	Sim	Não	Não	Sim	Não
Perfis	Não	Não	Não	Sim	Não
Usuários	Sim	Sim	Não	Sim	Não

Exemplo:

```
zoom_read = glueContext.create_dynamic_frame.from_options(
    connection_type="zoom",
    connection_options={
        "connectionName": "connectionName",
        "ENTITY_NAME": "organization",
        "API_VERSION": "v2"
    }
)
```

Detalhes de entidade e campo do Zoom Meetings:

O Zoom Meetings carrega dinamicamente os campos disponíveis na entidade selecionada. Dependendo do tipo de dados de campo, ele é compatível com os operadores de filtro a seguir.

Entidade	Campo	Tipo de dados	Operadores compatíveis	
Zoom Room	status	String	=	
	type	String	=	
	unassigned_rooms	Booleano	=	
	location_id	String	=	
	room_id	String	N/D	
	activation_code	String	N/D	
	id	String	N/D	
	nome	String	N/D	
	tag_ids	String	N/D	
	query_name	String	N/D	
Relatório diário	mês	Data	=	
	date	Data	N/D	
	meeting_minutes	Inteiro	N/D	
	meetings	Inteiro	N/D	
	new_users	Inteiro	N/D	
	participantes	Inteiro	N/D	
	group_id	String	N/D	
Usuário	created_at	DateTime	N/D	
	dept	String	N/D	

Entidade	Campo	Tipo de dados	Operadores compatíveis	
	email	String	N/D	
	employee_unique_id	String	N/D	
	first_name	String	N/D	
	group_ids	Lista	N/D	
	host_key	String	N/D	
	id	String	N/D	
	im_group_ids	String	N/D	
	last_client_version	String	N/D	
	last_login_time	DateTime	N/D	
	last_name	String	N/D	
	plan_united_type	String	N/D	
	custom_attributes	Lista	N/D	
	pmi	BigInteger	N/D	
	role_id	String	=	
	status	String	=	
	timezone	String	N/D	
	type	Inteiro	N/D	
	verified	Inteiro	N/D	

Entidade	Campo	Tipo de dados	Operadores compatíveis	
	user_created_at	DateTime	N/D	
	display_name	String	N/D	
	phone_number	String	N/D	
	idioma	String	N/D	
	licença	String	=	
Grupo	id	String	N/D	
	nome	String	N/D	
	total_members	Inteiro	N/D	
Membro do grupo	email	String	N/D	
	first_name	String	N/D	
	id	String	N/D	
	last_name	String	N/D	
	type	Inteiro	N/D	
	primary_group	Booleano	N/D	
	member_id	String	N/D	
Administrador do grupo	id	String	N/D	
	email	String	N/D	
	nome	String	N/D	
perfil	description	String	N/D	
	id	String	N/D	

Entidade	Campo	Tipo de dados	Operadores compatíveis	
	nome	String	N/D	
	total_members	Inteiro	N/D	
	type	String	=	

Particionamento de consultas

O Zoom Meetings oferece suporte ao particionamento baseado em filtros ou ao particionamento baseado em registros.

Opções de conexão do Zoom Meetings

Estas são as opções de conexão do Zoom Meetings:

- `ENTITY_NAME`(string): (obrigatório) usado para leitura. O nome da entidade do Zoom Meetings. Por exemplo, `group`.
- `API_VERSION`(string): (obrigatório) usado para leitura. Versão da API Rest do Zoom Meetings que você deseja usar. O valor será `v2`, pois o Zoom Meetings atualmente oferece suporte somente à versão v2.
- `SELECTED_FIELDS`(Lista<String>): padrão: vazio(SELECIONE *). Usado para leitura. Uma lista de colunas separadas por vírgula que você deseja selecionar para a entidade selecionada.
- `FILTER_PREDICATE`(string): padrão: vazio. Usado para leitura. Deve estar no formato Spark SQL.
- `QUERY`(string): padrão: vazio. Usado para leitura. Consulta completa do Spark SQL.

Limitações do Zoom Meetings

A seguir estão as limitações ou notas do Zoom Meetings:

- O Zoom Meetings não oferece suporte para orderby.
- O Zoom Meetings não oferece suporte ao particionamento baseado em filtros, pois não há nenhum campo que possa satisfazer aos critérios exigidos.
- O Zoom Meetings não oferece suporte ao particionamento baseado em registros, pois não há suporte para o limite de paginação e a paginação baseada em offset.

Adicionar uma conexão JDBC usando seus próprios drivers JDBC

Você pode usar seu próprio driver JDBC quando usar uma conexão JDBC. Quando o driver padrão utilizado pelo crawler do AWS Glue não consegue se conectar a um banco de dados, você pode usar seu próprio driver JDBC. Por exemplo, se quiser usar o SHA-256 com seu banco de dados Postgres e os drivers postgres mais antigos não forem compatíveis, você poderá usar seu próprio driver JDBC.

Fontes de dados compatíveis

Fontes de dados compatíveis	Fontes de dados não compatíveis
MySQL	Snowflake
Postgres	
Oracle	
Redshift	
SQL Server	
Aurora*	

*Compatível se o driver JDBC nativo estiver sendo usado. Nem todos os recursos do driver podem ser aproveitados.

Adicionar um driver JDBC a uma conexão JDBC

> **Note**
>
> Se você optar por trazer suas próprias versões do driver JDBC, os crawlers do AWS Glue consumirão recursos em trabalhos do AWS Glue e buckets do Amazon S3 para garantir que o driver fornecido seja executado em seu ambiente. O uso adicional de recursos será refletido em sua conta. O custo dos crawlers e trabalhos do AWS Glue se enquadram na categoria do AWS Glue para cobrança. Além disso, fornecer seu próprio driver JDBC não significa que o crawler seja capaz de aproveitar todos os atributos do driver.

Para adicionar uma conexão JDBC a uma conexão JDBC:

1. Adicione o arquivo do driver JDBC a um local do Amazon S3. Você pode criar um bucket e/ou uma pasta ou usar os já existentes.
2. No console do AWS Glue, escolha Conexões no menu à esquerda em Catálogo de dados e crie uma nova conexão.
3. Preencha os campos para Propriedades da conexão e escolha JDBC como Tipo de conexão.
4. Em Acesso à conexão, insira a URL do JDBC e o Nome da classe do driver JDBC, opcional. O nome da classe do driver deve ser para uma fonte de dados compatível com os crawlers do AWS Glue.

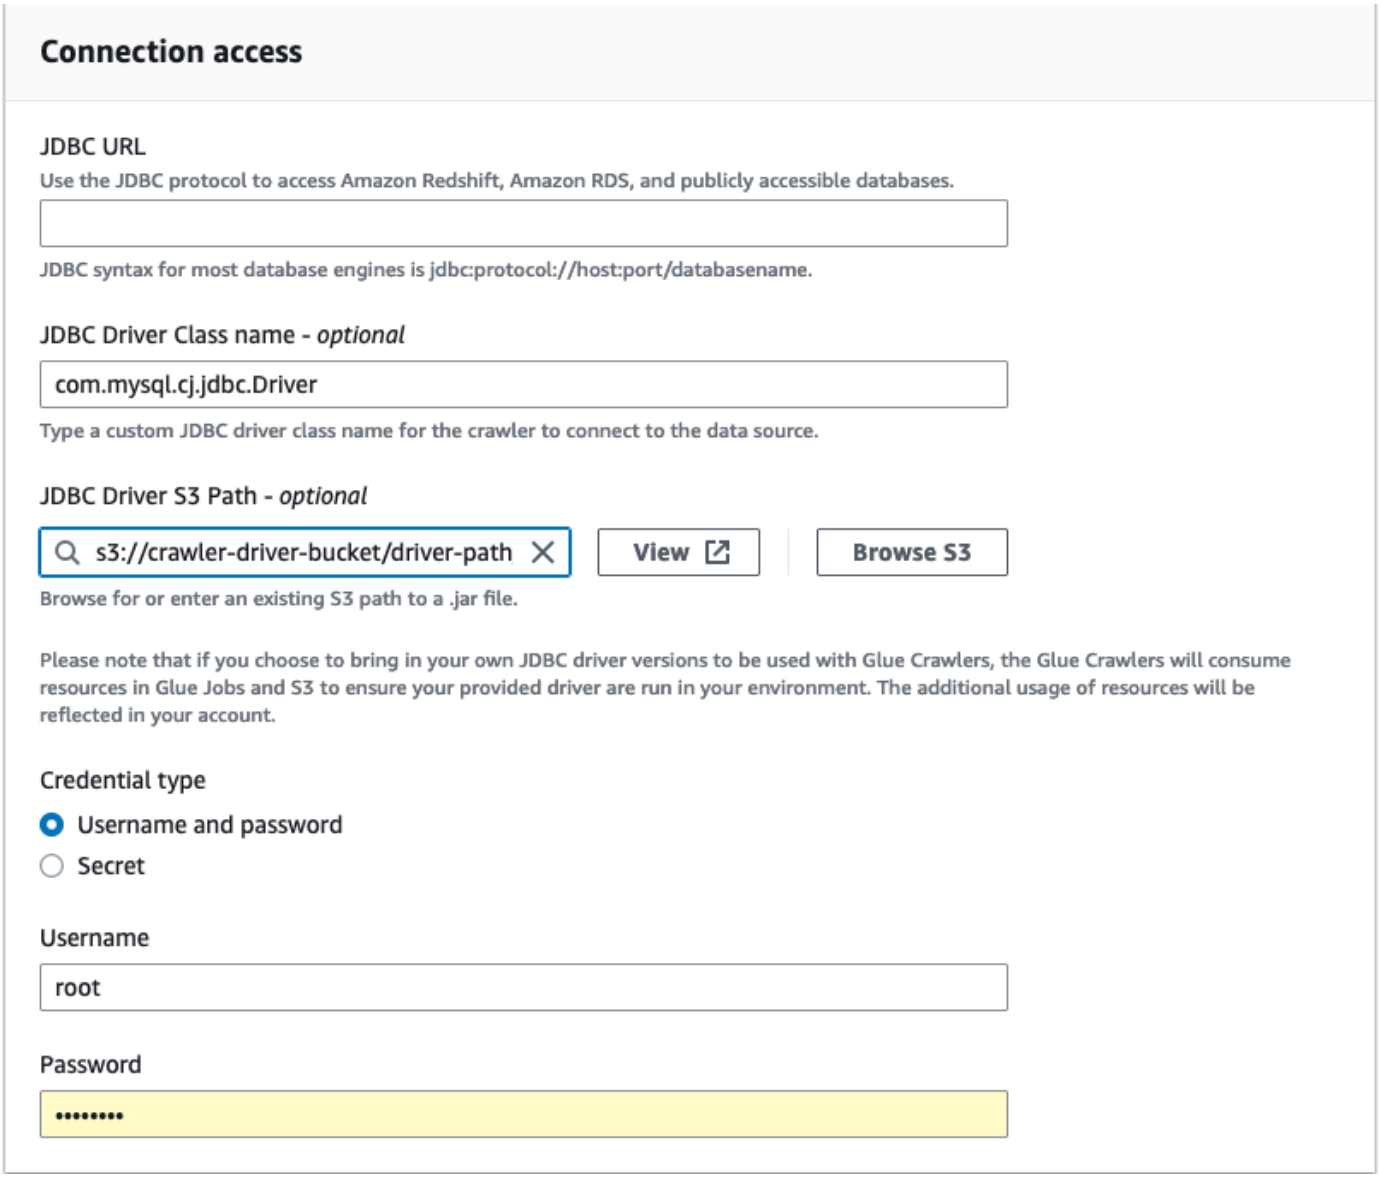

5. Escolha o caminho do Amazon S3 em que o driver JDBC está localizado em Caminho do Amazon S3 do driver JDBC, campo opcional.
6. Preencha os campos de Tipo de credencial se estiver inserindo um nome de usuário e senha ou segredo. Ao concluir, escolha Criar conexão.

> **Note**
>
> O teste de conexão não é compatível atualmente. Ao fazer crawling na fonte de dados com um driver JDBC que você forneceu, o crawler pula essa etapa.

7. Adicione a conexão recém-criada a um crawler. No console do AWS Glue, escolha Crawlers no menu esquerdo em Catálogo de dados e crie um novo crawler.
8. No assistente Adicionar crawler, na etapa 2, escolha Adicionar uma fonte de dados.

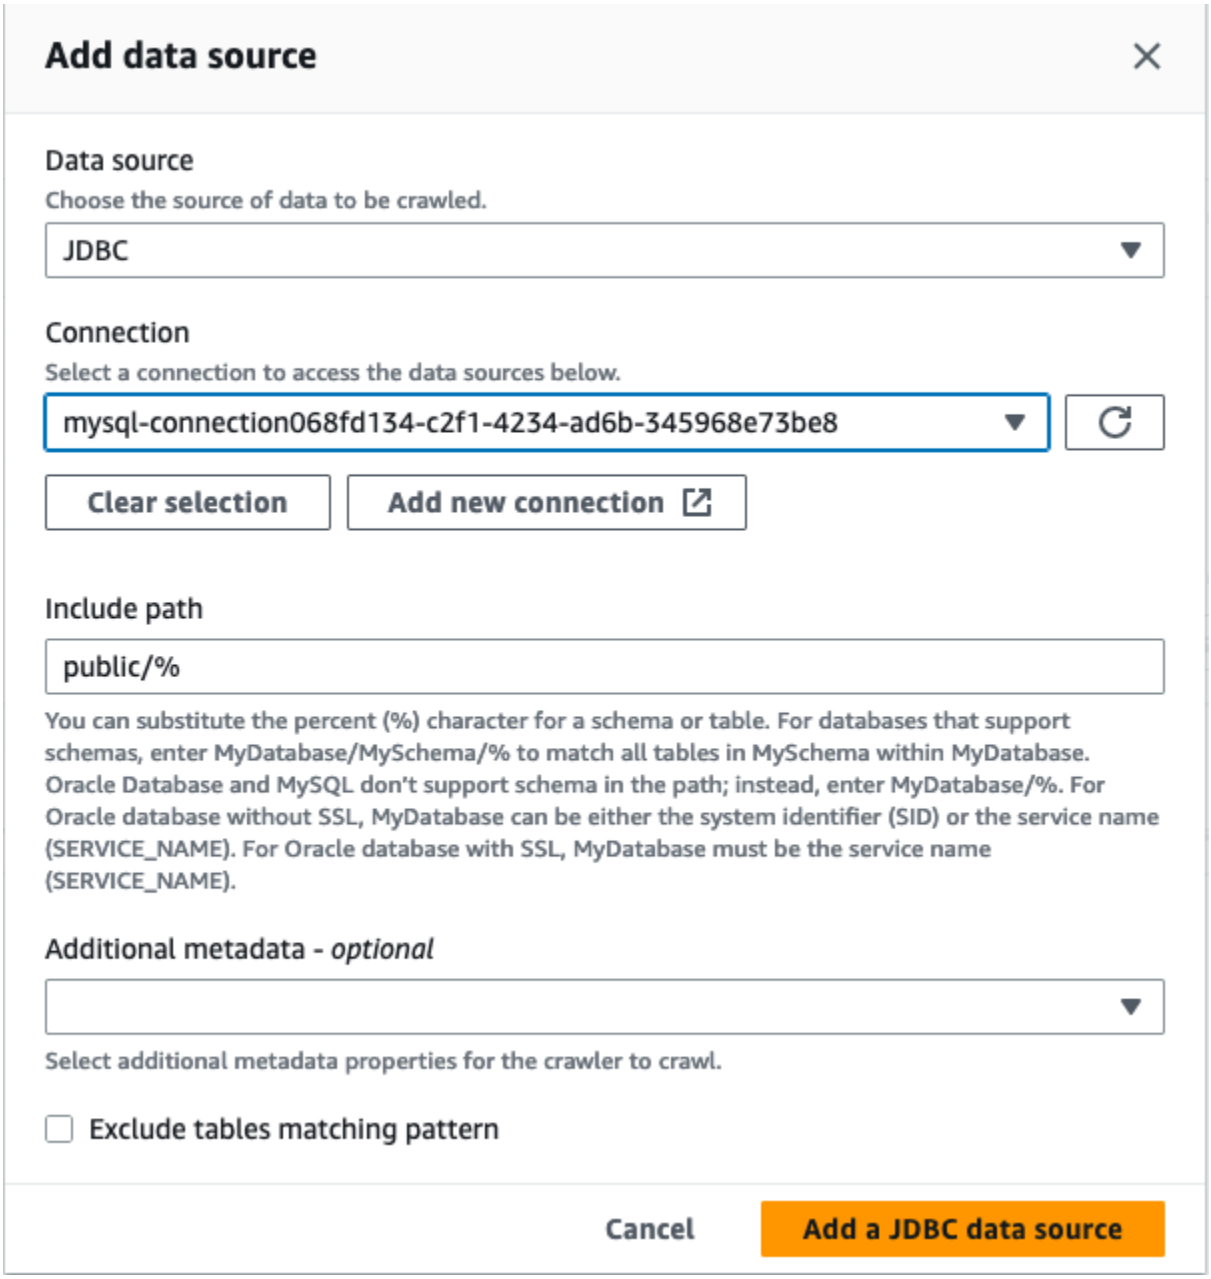

9. Escolha JDBC como fonte de dados e escolha a conexão que foi criada nas etapas anteriores. Concluído
10. Para usar seu próprio driver JDBC com um crawler do AWS Glue, adicione as seguintes permissões ao perfil usado pelo crawler:

    - Conceda permissões para as seguintes ações: `CreateJob`, `DeleteJob`, `GetJob`, `GetJobRun`, `StartJobRun`.
    - Conceda permissões para as ações do IAM: `iam:PassRole`

- Conceda permissões para as ações do Amazon S3: `s3:DeleteObjects`, `s3:GetObject`, `s3:ListBucket`, `s3:PutObject`.
- Conceda acesso de entidade principal de serviço a bucket/pasta na política do IAM.

Exemplo de política do 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"
            ]
        }
    ]
}
```

O crawler do AWS Glue cria duas pastas: _glue_job_crawler e _crawler.

Se o arquivo jar do driver estiver localizado na pasta `s3://amzn-s3-demo-bucket/driver.jar"`, adicione os seguintes recursos:

```
"Resource": [
                "arn:aws:s3:::amzn-s3-demo-bucket/_glue_job_crawler/*",
     "arn:aws:s3:::amzn-s3-demo-bucket/_crawler/*"
            ]
```

Se o arquivo jar do driver estiver localizado na pasta `s3://amzn-s3-demo-bucket/tmp/driver/subfolder/driver.jar"`, adicione os seguintes recursos:

```
"Resource": [
               "arn:aws:s3:::amzn-s3-demo-bucket/tmp/_glue_job_crawler/*",
    "arn:aws:s3:::amzn-s3-demo-bucket/tmp/_crawler/*"
            ]
```

11. Se você estiver usando uma VPC, deverá permitir o acesso ao endpoint do AWS Glue criando o endpoint de interface e adicionando-o à sua tabela de rotas. Para obter mais informações, consulte Creating an interface VPC endpoint for AWS Glue
12. Ao usar a criptografia no catálogo de dados, crie o endpoint de interface do AWS KMS e adicione-o à tabela de rotas. Para obter mais informações, consulte Creating a VPC endpoint for AWS KMS.

Usar conectores e conexões personalizados com o AWS Glue Studio

O AWS Glue oferece suporte integrado aos armazenamentos de dados usados com frequência (como Amazon Redshift, Amazon Aurora, Microsoft SQL Server, MySQL, MongoDB e PostgreSQL) usando conexões JDBC. O AWS Glue também permite usar drivers do JDBC personalizados em seus trabalhos de extração, transformação e carregamento (ETL). Para armazenamentos de dados que não são suportados nativamente, como aplicações SaaS, é possível usar conectores.

Um conector é um pacote de código opcional que ajuda a acessar armazenamentos de dados no AWS Glue Studio. É possível assinar vários conectores oferecidos no AWS Marketplace.

Ao criar trabalhos de ETL, é possível usar um datastore com suporte nativo, um conector do AWS Marketplace ou seus próprios conectores personalizados. Se você usar um conector, primeiro deve criar uma conexão para ele. Uma conexão que contém as propriedades necessárias para se conectar a um datastore específico. Você usa a conexão com suas origens e destinos de dados no trabalho de ETL. Conectores e conexões trabalham juntos para facilitar o acesso aos armazenamentos de dados.

As conexões a seguir estão disponíveis ao criar conexões para conectores:

- Amazon Aurora: um mecanismo de banco de dados relacional escalável e de alta performance com segurança, backup e restauração integrados e aceleração na memória.

- Amazon DocumentDB: um serviço de banco de dados de documentos escalável, altamente disponível e totalmente gerenciado que oferece suporte às APIs do MongoDB e SQL.
- Amazon Redshift: um serviço de banco de dados de documentos escalável, altamente disponível e totalmente gerenciado que oferece suporte às APIs do MongoDB e SQL.
- Azure SQL: um serviço de banco de dados relacional baseado em nuvem do Microsoft Azure que fornece recursos de armazenamento e gerenciamento de dados escaláveis, confiáveis e seguros.
- Cosmos DB: um serviço de banco de dados em nuvem distribuído globalmente do Microsoft Azure que fornece recursos de consulta e armazenamento de dados escaláveis e de alta performance.
- Google BigQuery: um data warehouse na nuvem com tecnologia sem servidor para executar consultas SQL rápidas em grandes conjuntos de dados.
- JDBC: um sistema de gerenciamento de banco de dados relacional (RDBMS) que usa uma API Java para se conectar e interagir com conexões de dados.
- Kafka: uma plataforma de processamento de fluxo de código aberto usada para streaming de dados e mensagens em tempo real.
- MariaDB: um fork do MySQL desenvolvido pela comunidade que oferece performance, escalabilidade e recursos aprimorados.
- MongoDB: um banco de dados multiplataforma orientado a documentos que fornece alta escalabilidade, flexibilidade e performance.
- MongoDB Atlas: uma oferta de banco de dados como serviço (DBaaS) baseada em nuvem do MongoDB que simplifica o gerenciamento e o dimensionamento das implantações do MongoDB.
- Microsoft SQL Server: um sistema de gerenciamento de banco de dados relacional (RDBMS) da Microsoft que fornece recursos robustos de armazenamento, análise e geração de relatórios de dados.
- Mixpanel: uma plataforma de análise que ajuda as empresas a analisar como os usuários interagem com seus sites, aplicações móveis e outros produtos digitais.
- MySQL: um sistema de gerenciamento de banco de dados relacional (RDBMS) de código aberto que é amplamente usado em aplicações Web e é conhecido por sua confiabilidade e escalabilidade.
- Rede: uma fonte de dados de rede representa um recurso ou serviço acessível pela rede que pode ser acessado por uma plataforma de integração de dados.
- OpenSearch: uma fonte de dados do OpenSearch é uma aplicação à qual o OpenSearch pode se conectar e ingerir dados.

- Oracle: um sistema de gerenciamento de banco de dados relacional (RDBMS) da Oracle Corporation que fornece recursos robustos de armazenamento, análise e geração de relatórios de dados.
- PostgreSQL: um sistema de gerenciamento de banco de dados relacional (RDBMS) de código aberto que fornece recursos robustos de armazenamento, análise e geração de relatórios de dados.
- Salesforce: o Salesforce fornece software de gerenciamento de relacionamento com o cliente (CRM) que ajuda nas atividades de vendas, atendimento ao cliente, comércio eletrônico e muito mais. Se você usa o Salesforce, pode conectar o AWS Glue à sua conta do Salesforce. Em seguida, é possível usar o Salesforce como fonte de dados ou destino em suas tarefas de ETL. Execute esses trabalhos para transferir dados entre os serviços do Salesforce e do AWS ou de outras aplicações com suporte.
- SAP HANA: uma plataforma de analytics e banco de dados em memória que fornece processamento rápido de dados, analytics avançada e integração de dados em tempo real.
- Snowflake: um data warehouse baseado em nuvem que fornece serviços de analytics e armazenamento de dados escaláveis e de alta performance.
- Teradata: um sistema de gerenciamento de banco de dados relacional (RDBMS) que fornece recursos de armazenamento, análise e geração de relatórios de dados de alta performance.
- Vertica: um data warehouse analítico orientado por colunas projetado para big data analytics que oferece performance rápida de consultas, analytics avançada e escalabilidade.

Criar conectores personalizados

Você também pode construir seu próprio conector e depois carregar o código do conector no AWS Glue Studio.

Os conectores personalizados são integrados ao AWS Glue Studio pela API de runtime do Spark no AWS Glue. O runtime do Spark no AWS Glue permite conectar qualquer conector compatível com a interface do Spark, Athena ou JDBC. Ele permite que você insira qualquer opção de conexão que esteja disponível com o conector personalizado.

Você pode encapsular todas as suas propriedades de conexão com conexões do AWS Glue e fornecer o nome da conexão ao seu trabalho de ETL. A integração com conexões do Data Catalog permite que você use as mesmas propriedades de conexão em várias chamadas em uma única aplicação Spark ou em diferentes aplicações.

Você pode especificar opções adicionais para a conexão. O script de trabalho que o AWS Glue Studio gera contém uma entrada `Datasource` que usa a conexão para ligar o conector com as opções de conexão especificadas. Por exemplo:

```
Datasource = glueContext.create_dynamic_frame.from_options(connection_type =
"custom.jdbc", connection_options = {"dbTable":"Account","connectionName":"my-custom-
jdbc-
connection"}, transformation_ctx = "DataSource0")
```

Para adicionar um conector personalizado ao AWS Glue Studio

1. Crie o código para o seu conector personalizado. Para ter mais informações, consulte Desenvolvimento de conectores personalizados.
2. Adicione suporte ao seu conector para os recursos do AWS Glue. Aqui estão alguns exemplos desses recursos e como eles são usados dentro do script de trabalho gerado pelo AWS Glue Studio:

   - Data type mapping (Mapeamento de tipo de dados): seu conector pode converter os tipos das colunas ao lê-las a partir do datastore subjacente. Por exemplo, um `dataTypeMapping` de `{"INTEGER":"STRING"}` converte todas as colunas do tipo `Integer` para colunas do tipo `String` ao analisar os registros e construir o `DynamicFrame`. Isso ajuda os usuários a converter colunas para tipos de sua escolha.

     ```
     DataSource0 = glueContext.create_dynamic_frame.from_options(connection_type
     = "custom.jdbc", connection_options = {"dataTypeMapping":{"INTEGER":"STRING"}",
     connectionName":"test-connection-jdbc"}, transformation_ctx = "DataSource0")
     ```

   - Partitioning for parallel reads (Particionamento para leituras paralelas): o AWS Glue permite leituras de dados paralelas do datastore ao particionar os dados em uma coluna. Você deve especificar a coluna de partição, o limite de partição inferior, o limite de partição superior e o número de partições. Esse recurso permite que você faça uso do paralelismo de dados e de vários executores do Spark alocados para a aplicação do 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")
     ```

- Usar o AWS Secrets Manager para armazenar credenciais): a conexão do Data Catalog também pode conter um `secretId` para um segredo armazenado no AWS Secrets Manager. O segredo da AWS pode armazenar com segurança informações de autenticação e credenciais e fornecê-las ao AWS Glue em runtime. Como alternativa, você pode especificar o `secretId` no script do Spark da seguinte forma:

```
DataSource = glueContext.create_dynamic_frame.from_options(connection_type
= "custom.jdbc", connection_options = {"connectionName":"test-connection-jdbc",
 "secretId"-> "my-secret-id"}, transformation_ctx = "DataSource0")
```

- Filtrando os dados de origem com predicados de linha e projeções de coluna: o runtime do Spark no AWS Glue também permite que os usuários propaguem consultas SQL para filtrar dados na origem com predicados de linha e projeções de coluna. Isso permite que seu trabalho de ETL carregue dados filtrados mais rapidamente a partir de armazenamentos de dados que suportam propagações. Uma consulta SQL de exemplo enviada para uma origem dos dados JDBC é: `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")
```

- Marcadores de trabalho: o AWS Glue suporta carregamento incremental de dados de fontes JDBC. O AWS Glue mantém o controle do último registro processado do datastore e processa novos registros de dados nas execuções de trabalho de ETL subsequentes. Os marcadores de trabalho usam a chave primária como a coluna padrão para a chave do marcador, desde que essa coluna aumente ou diminua sequencialmente. Para obter mais informações sobre marcadores de trabalhos, consulte Marcadores de trabalho no Guia do desenvolvedor do 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. Empacote o conector personalizado como um arquivo JAR e carregue-o no Amazon S3.

4. Teste seu conector personalizado. Para obter mais informações, consulte as instruções no GitHub em Glue Custom Connectors: Local Validation Tests Guide (Conectores personalizados do Glue: guia de testes de validação local).
5. No console do AWS Glue Studio, escolha Connectors (Conectores), no painel de navegação do console.
6. Na página Connectors (Conectores) escolha Create custom connector (Criar um conector personalizado).
7. Na página Create custom connector (Criar um conector personalizado), insira as informações a seguir:
   - O caminho para o local do arquivo JAR do código personalizado no Amazon S3.
   - Um nome para o conector que será usado pelo AWS Glue Studio.
   - Seu tipo de conector, que pode ser JDBC, Spark ou Athena.
   - O nome do ponto de entrada dentro do código personalizado que o AWS Glue Studio chama para usar o conector.
     - Para conectores JDBC, esse campo deve ser o nome da classe do driver do JDBC.
     - Para conectores do Spark, esse campo deve ser o nome da classe da origem dos dados totalmente qualificada, ou seu alias, que você usa ao carregar a origem dos dados do Spark com o operador `format`.
   - (Somente JDBC) o URL base usado pela conexão JDBC para o datastore.
   - (Opcional) uma descrição do conector personalizado.
8. Escolha Create connector (Criar conector).
9. Na página Connectors (Conectores), crie uma conexão que use esse conector, conforme descrito em Criar conexões para conectores.

Adição de conectores ao AWS Glue Studio

Um conector é um pedaço de código que facilita a comunicação entre o datastore e o AWS Glue. Você pode assinar um conector oferecido no AWS Marketplace ou pode criar seu próprio conector personalizado.

Assinatura dos conectores do AWS Marketplace

O AWS Glue Studio facilita a adição de conectores do AWS Marketplace.

Para adicionar um conector do AWS Marketplace no AWS Glue Studio

1. No console do AWS Glue Studio, escolha Connectors (Conectores), no painel de navegação do console.
2. Na página Conectores, escolha Ir para o AWS Marketplace.
3. No AWS Marketplace, em Featured products (Produtos em destaque), escolha o conector que você deseja usar. Você pode escolher um dos conectores em destaque ou usar a pesquisa. Você pode pesquisar o nome ou tipo de conector e usar opções para refinar os resultados da pesquisa.

   Se você desejar usar um dos conectores em destaque, escolha View product (Ver produto). Se você usou a pesquisa para localizar um conector, escolha o nome do conector.
4. Na página de produto do conector, use as guias para visualizar informações sobre o conector. Se você decidir adquirir esse conector, escolha Continue to Subscribe (Continuar para assinar).
5. Forneça as informações de pagamento e escolha Continue to Configure (Continuar para configurar).
6. Na página Configure this software (Configurar este software), escolha o método de implantação e a versão do conector a serem usados. Em seguida, escolha Continue to Launch (Continuar para iniciar).
7. Na página Lauch this software (Iniciar este software), você pode analisar as Usage Instructions (Instruções de uso) fornecidas pelo provedor do conector. Quando estiver pronto para continuar, escolha Ativar conexão no AWS Glue Studio.

   Após um curto período, o console apresenta a pagina Create marketplace connection (Criar conexão com o marketplace) no AWS Glue Studio.
8. Crie uma conexão que use esse conector, conforme descrito em Criar conexões para conectores.

   Como alternativa, você pode escolher Activate connector only (Ativar somente conector) para ignorar a criação de uma conexão no momento. Você deve criar uma conexão em uma data posterior para que possa usar o conector.

Criar conexões para conectores

Uma AWS Glue conexão é um objeto do Catálogo de Dados que armazena informações de conexão para um armazenamento de dados específico. As conexões armazenam credenciais de login, URI

cadeias de caracteres, informações de nuvem privada virtual (VPC) e muito mais. A criação de conexões no Data Catalog economiza o esforço de ter que especificar todos os detalhes da conexão cada vez que um trabalho é criado.

Para criar uma conexão para um conector

1. No AWS Glue Studio console, escolha Conectores no painel de navegação do console. Na seção Conexões de saída, escolha Criar conexão.
2. Escolha a fonte de dados para a qual deseja criar uma conexão na etapa 1 do assistente Criar conexão de dados. Há várias maneiras de visualizar as fontes de dados disponíveis, como:

   - Filtre as fontes de dados disponíveis escolhendo uma guia. Por padrão, Todos os conectores está selecionado.
   - Alterne a Lista para visualizar as fontes de dados como uma lista ou volte para a Grade para ver os conectores disponíveis no layout de grade.
   - Use a barra de pesquisa para restringir a lista de fontes de dados. À medida que você digita, as correspondências de pesquisa são exibidas e as fontes não correspondentes são removidas da exibição.

   Depois de escolher a fonte de dados, escolha Avançar.
3. Configure a conexão na Etapa 2 do assistente.

   Insira os detalhes da conexão. Dependendo do tipo de conector selecionado, será solicitado que você insira informações adicionais:

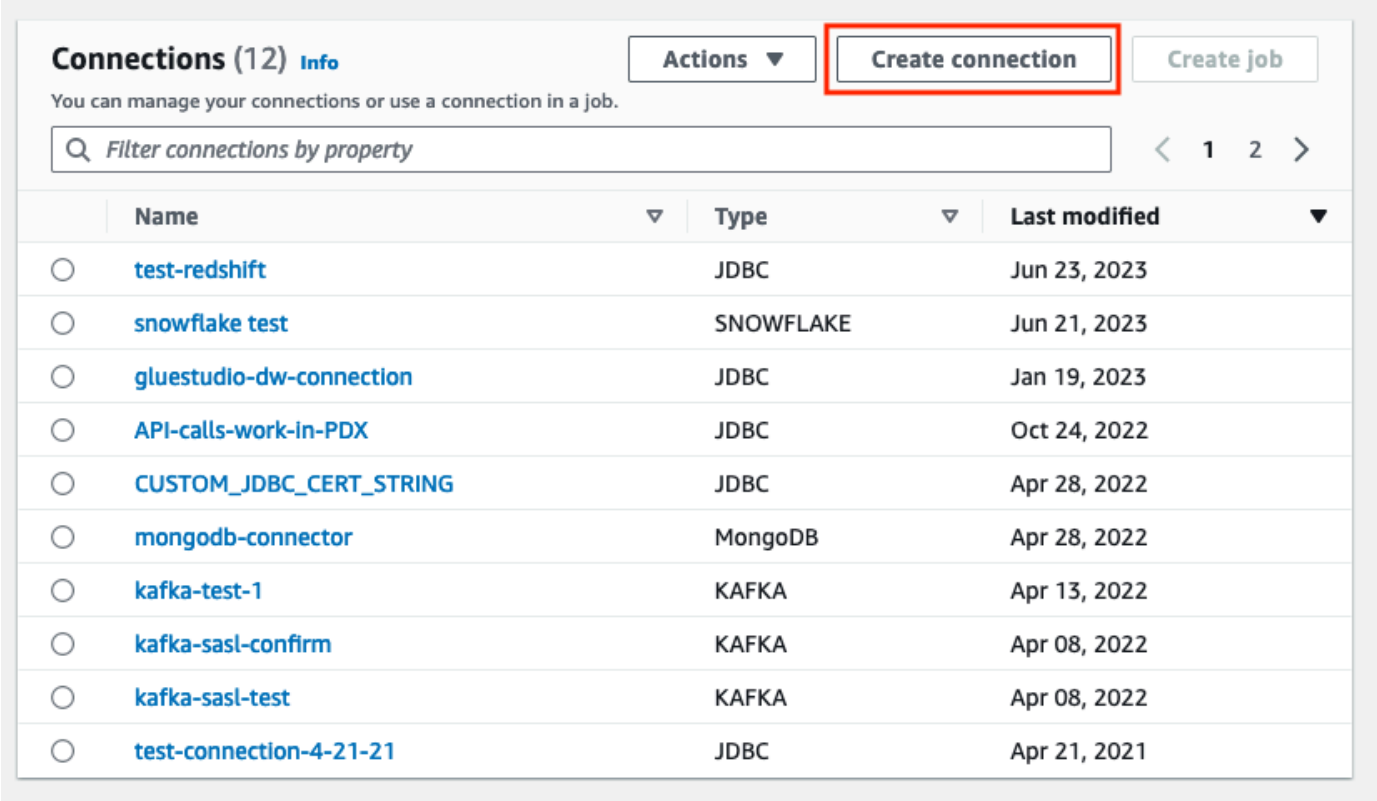

4. Escolha a fonte de dados para a qual deseja criar uma conexão na etapa 1 do assistente Criar conexão de dados. Há várias maneiras de visualizar as fontes de dados disponíveis. Por padrão, você verá todas as fontes de dados disponíveis em um layout de grade. Você também pode:

   - Alterne a Lista para visualizar as fontes de dados como uma lista ou volte para a Grade para ver os conectores disponíveis no layout de grade.
   - Use a barra de pesquisa para restringir a lista de fontes de dados. À medida que você digita, as correspondências de pesquisa são exibidas e as fontes não correspondentes são removidas da exibição.

   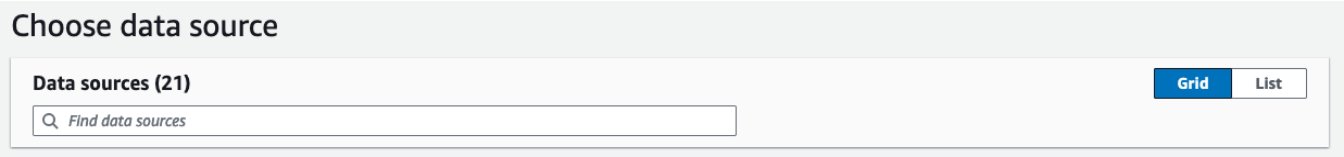

   Depois de escolher a fonte de dados, escolha Avançar.

5. Configure a conexão na Etapa 2 do assistente.

   Insira os detalhes da conexão. Dependendo do tipo de conector selecionado, talvez seja necessário inserir informações adicionais de conexão. Elas podem incluir:

- Detalhes da conexão: esses campos mudarão dependendo da fonte de dados à qual você está se conectando. Por exemplo, se você estiver se conectando aos bancos de dados do Amazon DocumentDB, você entrará no Amazon DocumentDB. URL Se você estiver se conectando Amazon Aurora, você escolherá a instância do banco de dados e inserirá o nome do banco de dados. A seguir estão os detalhes da conexão necessários para Amazon Aurora:

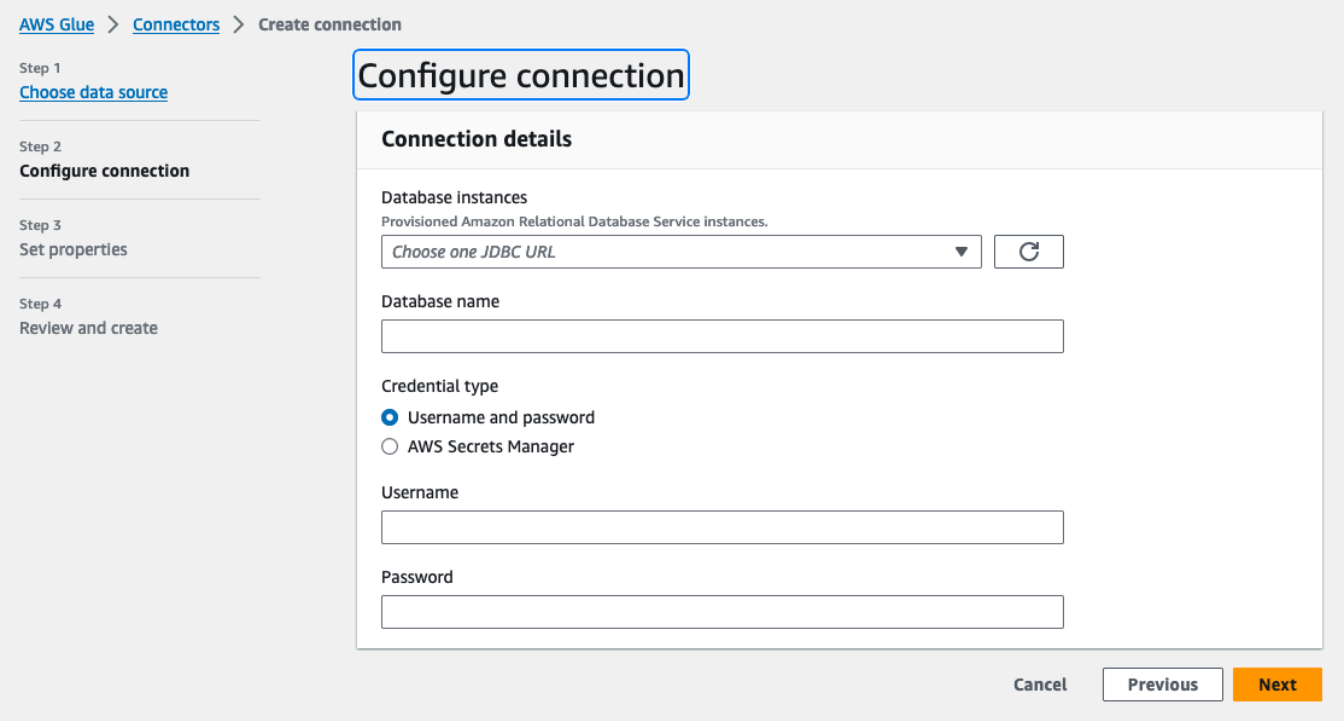

- Tipo de credencial: escolha entre Nome de usuário e senha ou AWS Secrets Manager. Insira as informações de autenticação solicitadas.
- Para conectores que usamJDBC, insira as informações necessárias para criar o JDBC URL para o armazenamento de dados.
- Se você usa uma nuvem privada virtual (VPC), insira as informações de rede da suaVPC.

6. Defina as propriedades da conexão na etapa 3 do assistente. É possível adicionar uma descrição e tags como parte opcional dessa etapa. O nome é obrigatório e pré-preenchido com um valor padrão. Escolha Próximo.
7. Revise a fonte, os detalhes e as propriedades da conexão. Se precisar fazer alterações, escolha Editar para a etapa no assistente. Ao concluir, escolha Criar conexão.

   Escolha Criar conexão.

   Você retorna para a página Connectors (Conectores) e o banner informativo indica que a conexão que foi criada. Agora é possível usar a conexão em seus trabalhos AWS Glue Studio .

Criar uma conexão Kafka

Ao criar uma conexão Kafka, selecionando Kafka no menu suspenso exibirá configurações adicionais para configurar:

- Detalhes do cluster do Kafka
- Autenticação
- Criptografia
- Opções de rede

Configurar detalhes do cluster do Kafka

1. Escolha o local do cluster. Você pode escolher entre um cluster de streaming gerenciado pela Amazon para Apache Kafka (MSK) ou um cluster Apache Kafka gerenciado pelo cliente. Para obter mais informações sobre o Amazon Managed Streaming para Apache Kafka, consulte Amazon Managed Streaming for Apache Kafka (). MSK

> **Note**
>
> Amazon Managed Streaming for Apache Kafka suporta apenas métodos TLS de autenticação SASL e/ SCRAM - SHA -512.

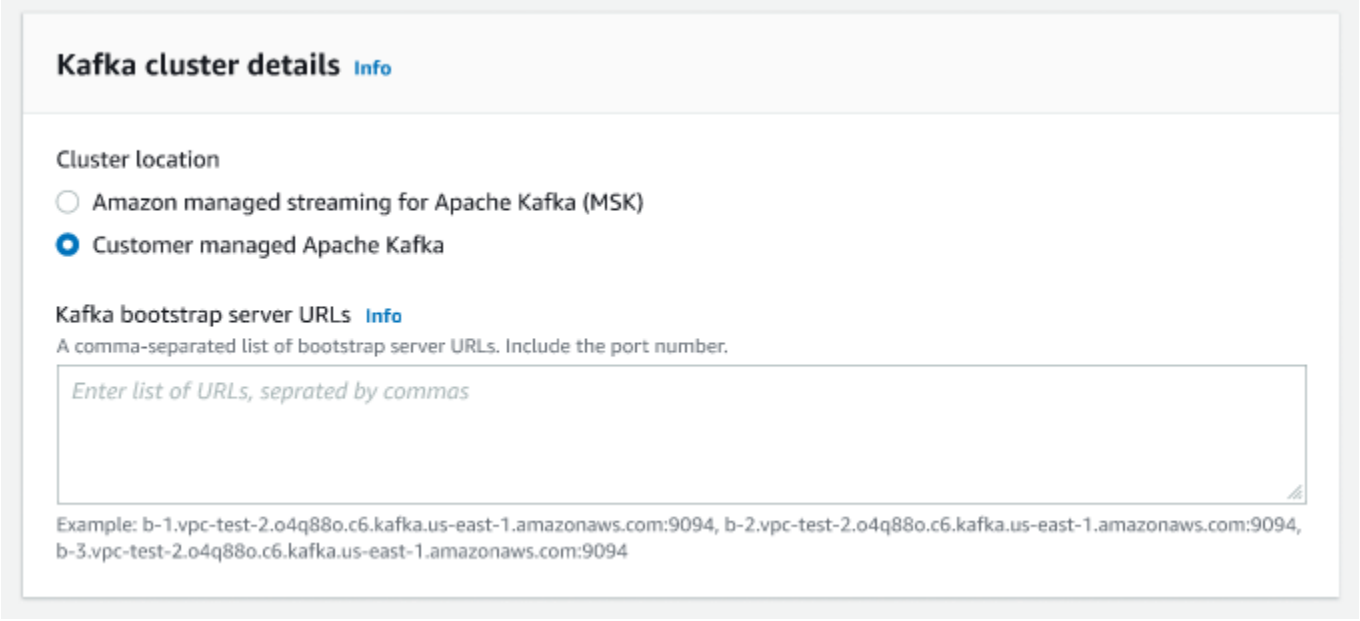

2. Insira o URLs para seus servidores de bootstrap Kafka. Você pode inserir mais de um separando cada servidor por uma vírgula. Inclua o número da porta no final do URL anexando `:<port number>`.

   Por exemplo: `b-1.vpc-test-2.034a88o.kafka-us-east-1.amazonaws.com:9094`

Selecione o método de autenticação

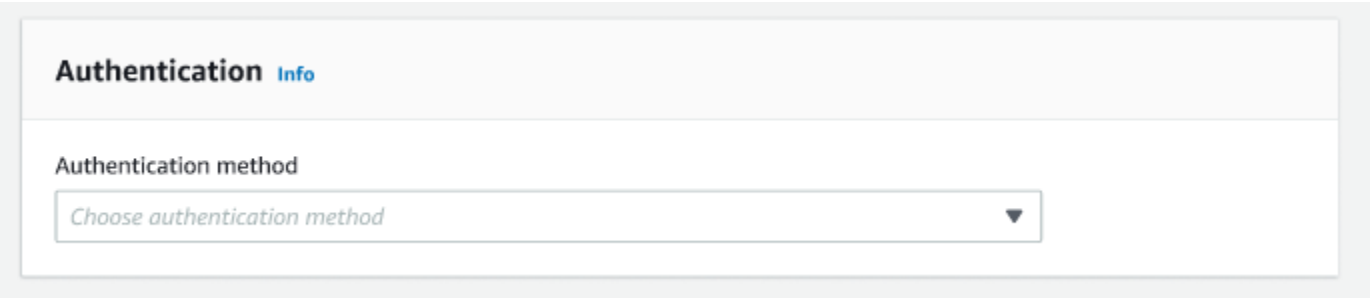

AWS Glue suporta a estrutura Simple Authentication and Security Layer (SASL) para autenticação. A SASL estrutura suporta vários mecanismos de autenticação e AWS Glue oferece os protocolos SCRAM (nome de usuário e senha), GSSAPI (protocolo Kerberos) e PLAIN (nome de usuário e senha).

Ao escolher um método de autenticação no menu suspenso, os seguintes métodos de autenticação de cliente podem ser selecionados:

- Nenhum - Sem autenticação. Isso é útil se você criar uma conexão para fins de teste.
- SASL/SCRAM- SHA -512 - Escolha esse método de autenticação para especificar as credenciais de autenticação. Existem duas opções disponíveis:
  - Use o AWS Secrets Manager (recomendado) - se você selecionar essa opção, poderá armazenar suas credenciais no AWS Secrets Manager e permitir o AWS Glue acesso às informações quando necessário. Especifique o segredo que armazena as credenciais SSL ou de SASL autenticação.

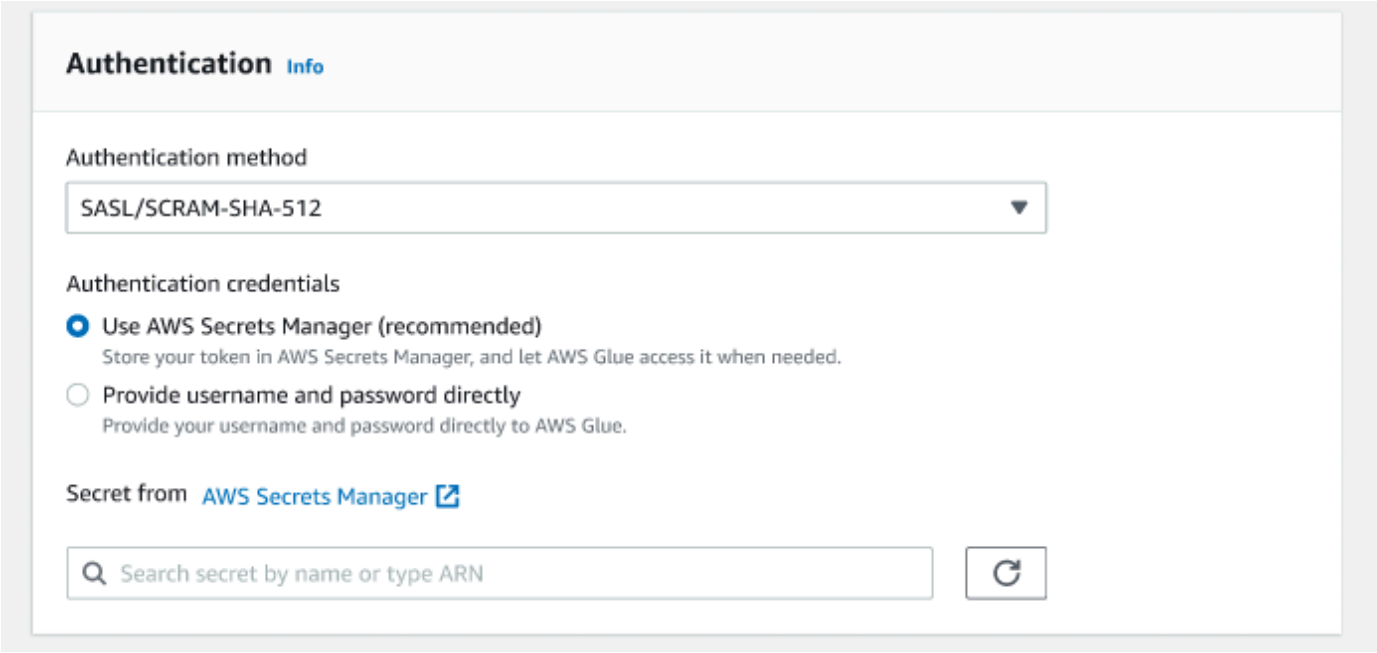

  - Forneça o nome de usuário e a senha diretamente.
- SASL/GSSAPI (Kerberos) - if you select this option, you can select the location of the keytab file, krb5.conf file and enter the Kerberos principal name and Kerberos service name. The locations for the keytab file and krb5.conf file must be in an Amazon S3 location. Since MSK does not yet support SASL/GSSAPI, essa opção só está disponível para clusters Apache Kafka gerenciados pelo cliente. Para obter mais informações, consulte a documentação do MIT Kerberos: Keytab.
- SASL/PLAIN- Escolha esse método de autenticação para especificar as credenciais de autenticação. Existem duas opções disponíveis:
  - Use o AWS Secrets Manager (recomendado) - se você selecionar essa opção, poderá armazenar suas credenciais no AWS Secrets Manager e permitir o AWS Glue acesso às informações quando necessário. Especifique o segredo que armazena as credenciais SSL ou de SASL autenticação.
  - Forneça o nome de usuário e a senha diretamente.
- SSLAutenticação do cliente - se você selecionar essa opção, poderá selecionar a localização do keystore do cliente Kafka navegando no Amazon S3. Opcionalmente, você pode inserir a senha do keystore do cliente Kafka e a senha da chave do cliente Kafka.

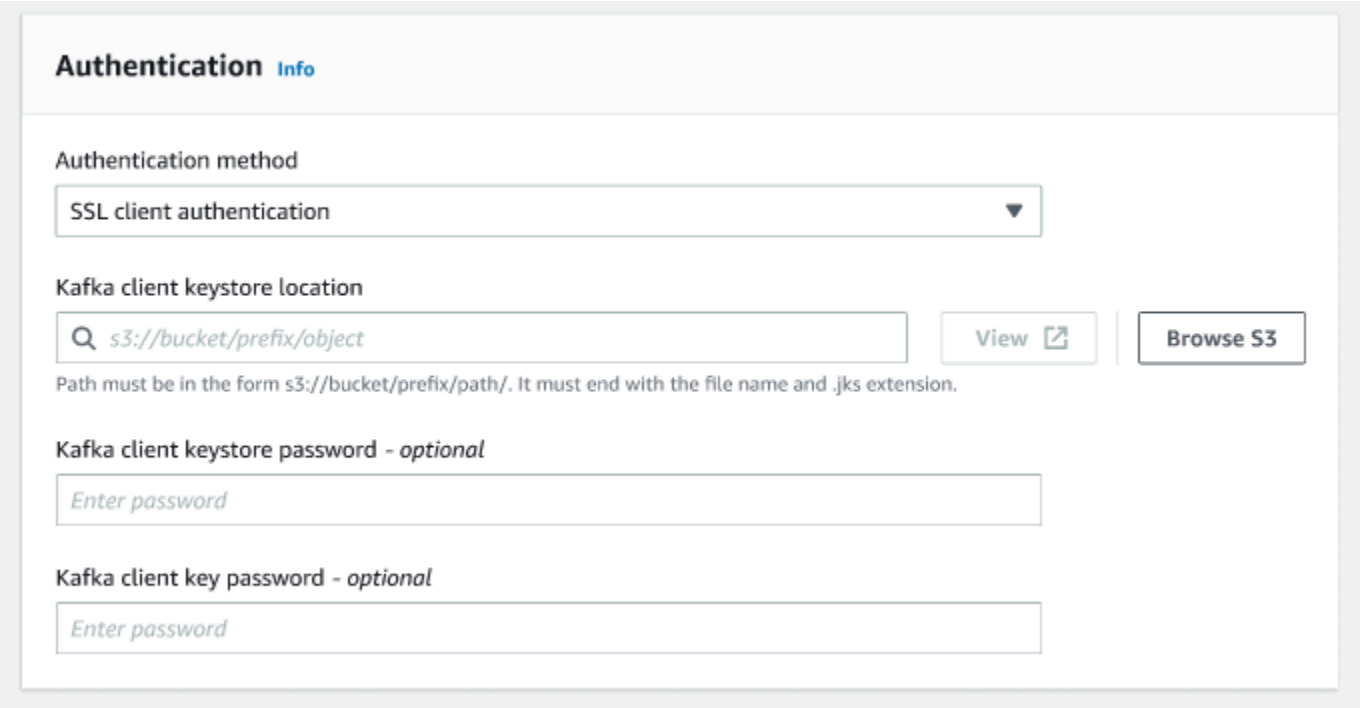

Definir as configurações de criptografia

1. Se a conexão do Kafka exigir SSL conexão, marque a caixa de seleção Exigir conexão. SSL Observe que a conexão falhará se não for possível se conectar novamenteSSL. SSLpara criptografia pode ser usado com qualquer um dos métodos de autenticação (SASL/SCRAM-SHA-512, SASL/GSSAPI, SASL/PLAINou Autenticação de SSL Cliente) e é opcional.

   Se o método de autenticação estiver definido como autenticação SSL do cliente, essa opção será selecionada automaticamente e será desativada para evitar alterações.
2. (Optional). Escolha o local do certificado privado da autoridade de certificação (CA). Observe que a localização da certificação deve estar em um local do S3. Selecione Browse (Navegar) para escolher o arquivo de um bucket S3 conectado. O caminho deve estar no formato `s3://bucket/prefix/filename.pem`. Deve terminar com o nome do arquivo e a extensão .pem.
3. Você pode optar por ignorar a validação do certificado de uma autoridade de certificação (CA). Escolha a caixa de seleção Ignorar a validação do certificado de uma autoridade de certificação (CA). Se esta caixa não estiver marcada, AWS Glue valida certificados para três algoritmos:

   - SHA256withRSA
   - SHA384withRSA
   - SHA512withRSA

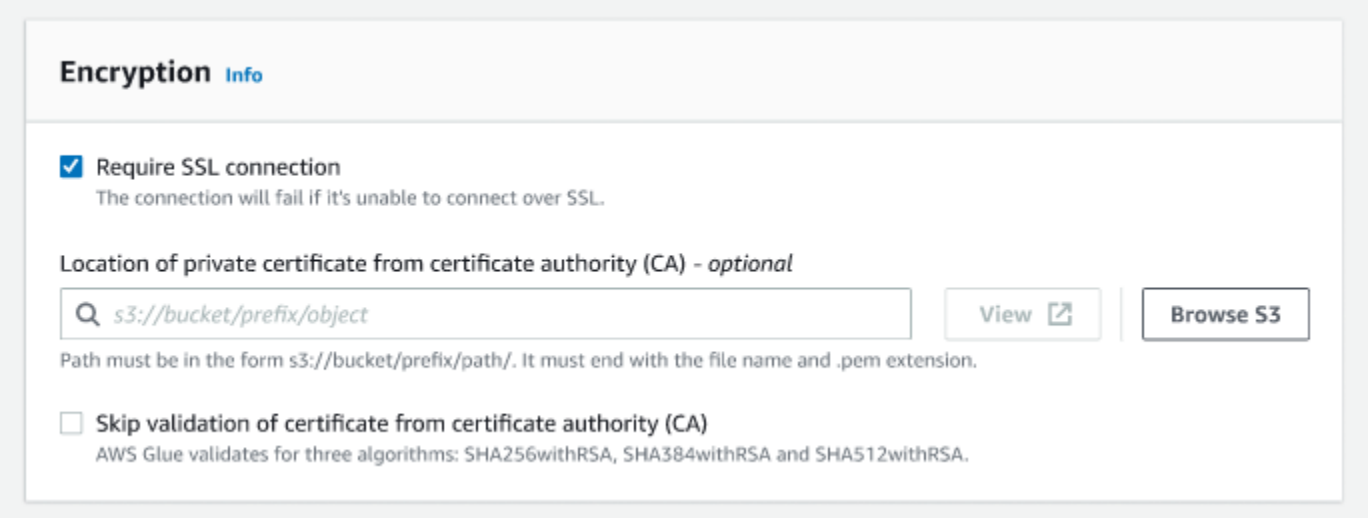

(Opcional) Opções de rede

A seguir estão as etapas opcionais para configurar VPC grupos de sub-rede e segurança. Se seu AWS Glue trabalho precisar ser executado em EC2 instâncias da Amazon em uma sub-rede de nuvem privada virtual (VPC), você deverá fornecer informações adicionais VPC de configuração específicas.

1. Escolha a VPC (nuvem privada virtual) que contém sua fonte de dados.
2. Escolha a sub-rede com sua. VPC
3. Escolha um ou mais grupos de segurança para permitir o acesso ao armazenamento de dados em sua VPC sub-rede. Os grupos de segurança estão associados aos ENI anexados à sua sub-rede. Você deve escolher pelo menos um grupo de segurança com uma regra de entrada de autorreferência para todas as portas. TCP

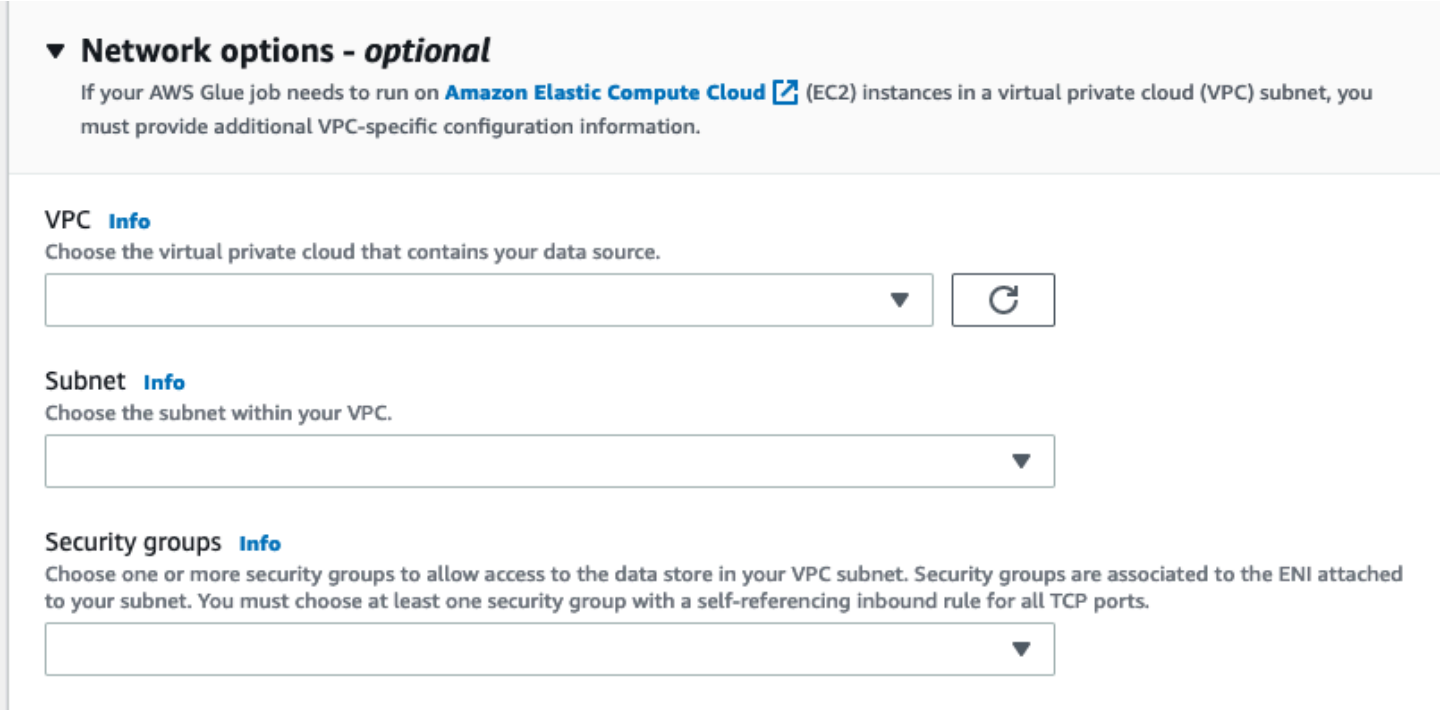

Criação de trabalhos com conectores personalizados

Você pode usar conectores e conexões para nós de origem e de destino de dados no AWS Glue Studio.

Tópicos

- Criar trabalhos que usam um conector para a origem dos dados
- Configurar propriedades de origem para nós que usam conectores
- Configurar propriedades de destino para nós que usam conectores

Criar trabalhos que usam um conector para a origem dos dados

Ao criar um novo trabalho, você pode escolher um conector para a origem e para os destinos dos dados.

Para criar um trabalho que use conectores para a origem ou destino dos dados

1. Faça login no AWS Management Console e abra o console do AWS Glue Studio em https://console.aws.amazon.com/gluestudio/.
2. Na página Connectors (Conectores), na lista de recursos Your connections (Suas conexões), escolha a conexão que você deseja usar em seu trabalho e escolha Create job (Criar trabalho).

Como alternativa, na página Jobs (Trabalhos) do AWS Glue Studio, em Create job (Criar trabalho), escolha Source and target added to the graph (Origem e destino adicionados ao gráfico). Na lista suspensa Source (Origem), escolha o conector personalizado que você deseja usar em seu trabalho. Também é possível escolher um conector para Target (Destino).

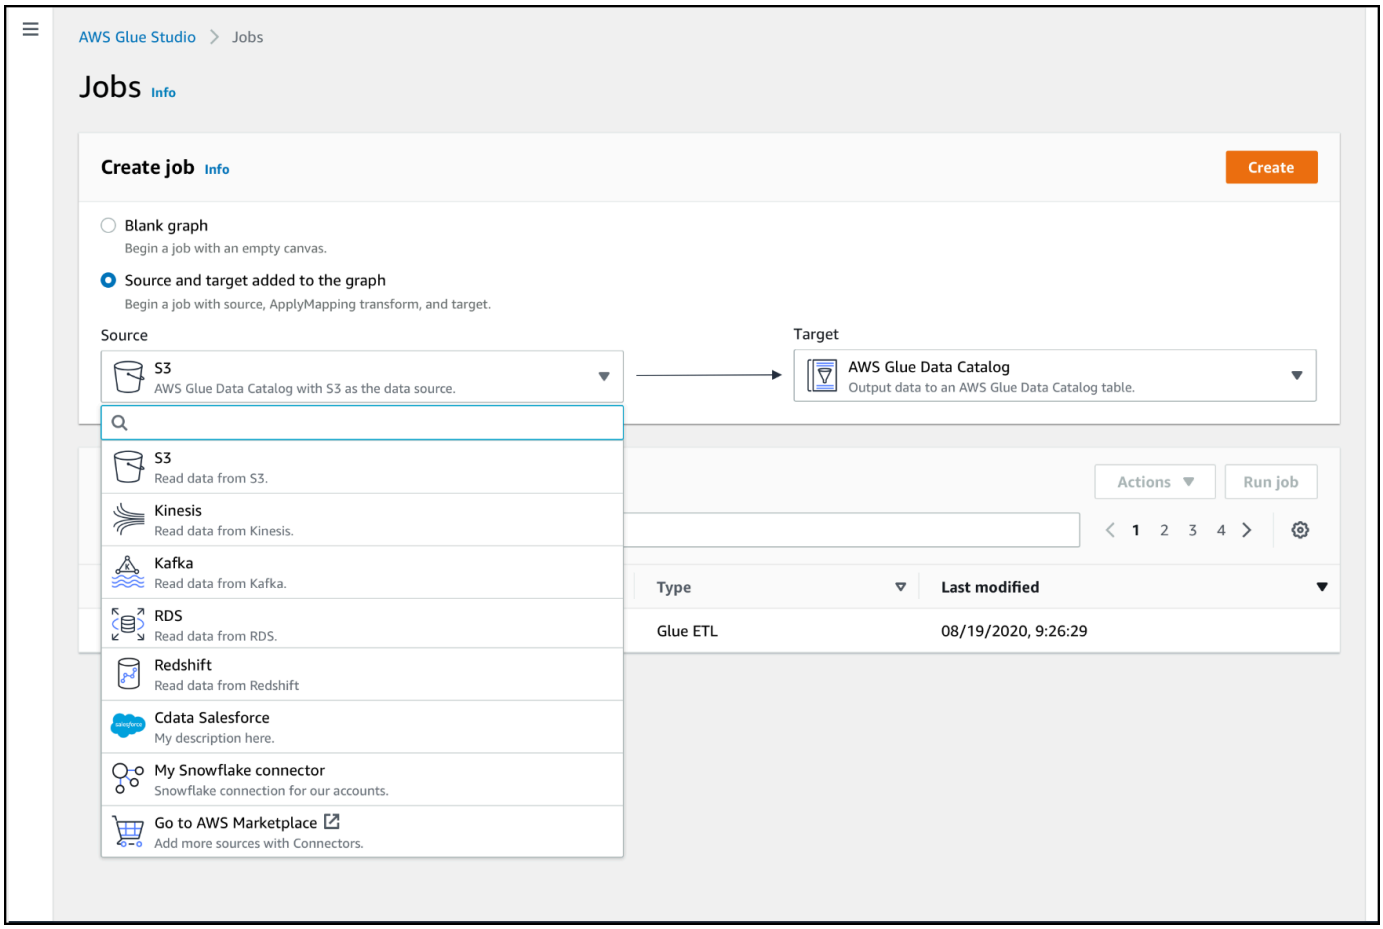

3. Escolha Create (Criar) para abrir o editor de trabalhos visual.
4. Configure o nó da origem dos dados, conforme descrito em Configurar propriedades de origem para nós que usam conectores.
5. Continue criando seu trabalho de ETL adicionando transformações, armazenamentos de dados adicionais e destinos de dados, conforme descrito em Iniciar trabalhos de ETL visual no AWS Glue Studio.
6. Personalize o ambiente de execução de trabalho configurando as propriedades do trabalho, conforme descrito em Modificar as propriedades do trabalho.
7. Salve o trabalho e o execute.

Configurar propriedades de origem para nós que usam conectores

Depois de criar um trabalho que usa um conector para a origem dos dados, o editor de trabalhos visual exibe um gráfico de trabalho com um nó de origem dos dados configurado para o conector. Você deve configurar as propriedades da origem dos dados para esse nó.

Para configurar as propriedades de um nó de origem dos dados que usa um conector

1. Escolha o nó da origem dos dados do conector no gráfico de trabalho ou adicione um novo nó e escolha o conector para Node type (Tipo de nó). Em seguida, no lado direito, no painel de detalhes do nó, escolha a guia Data source properties (Propriedades da origem dos dados), se ainda não estiver selecionada.

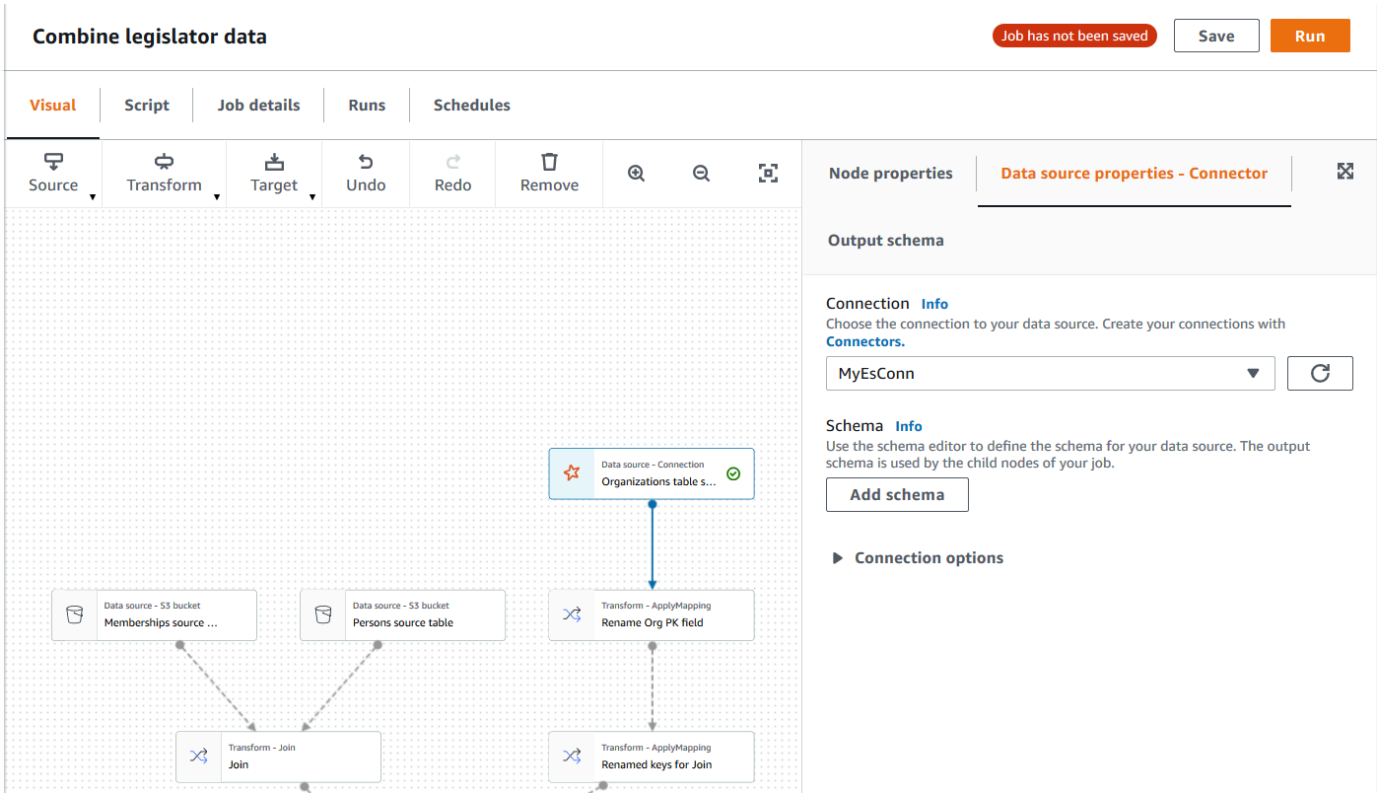

2. Na guia Data source properties (Propriedades da origem dos dados), escolha a conexão que você deseja usar para esse trabalho.

   Insira as informações adicionais necessárias para cada tipo de conexão:

JDBC

- Data source input type (Tipo de entrada da origem dos dados): opte por fornecer um nome de tabela ou uma consulta SQL como a origem dos dados. Dependendo da sua escolha, você precisará fornecer estas informações adicionais:
  - Table name (Nome da tabela): o nome da tabela na origem dos dados. Se a origem dos dados não usar o termo table (tabela), forneça o nome de uma estrutura de dados apropriada, conforme indicado pelas informações de uso do conector personalizado (disponíveis em AWS Marketplace).
  - Filter predicate (Filtrar predicado): uma cláusula de condição a ser usada ao ler a origem dos dados, semelhante a uma cláusula `WHERE`, que é usada para recuperar um subconjunto dos dados.
  - Query code (Código de consulta): insira uma consulta SQL a ser usada para recuperar um conjunto de dados específico da origem dos dados. Um exemplo de uma consulta SQL básica é:

    ```
    SELECT column_list FROM
                              table_name WHERE where_clause
    ```

- Schema (Esquema): como o AWS Glue Studio está usando informações armazenadas na conexão para acessar a origem dos dados em vez de recuperar informações de metadados de uma tabela do Data Catalog, você deve fornecer os metadados do esquema para a origem dos dados. Escolha Add schema (Adicionar esquema) para abrir o editor de esquemas.

  Para obter instruções sobre como usar o editor de esquemas, consulte Editar o esquema de um nó de transformação personalizada.

- Partition column (Coluna da partição): (opcional) você pode optar por particionar as leituras de dados fornecendo valores para Partition column (Coluna da partição), Lower bound (Limite inferior), Upper bound (Limite superior) e Number of partitions (Número de partições).

  Os valores de `lowerBound` e `upperBound` são usados para decidir o passo de partição, não para filtrar as linhas na tabela. Todas as linhas na tabela são particionadas e retornadas.

> **Note**
>
> O particionamento de colunas adiciona uma condição de particionamento extra à consulta usada para ler os dados. Ao usar uma consulta em vez de um nome de tabela, você deve validar se a consulta funciona com a condição de particionamento especificada. Por exemplo:
>
> - Se o seu formato de consulta for `"SELECT col1 FROM table1"`, teste a consulta anexando uma cláusula `WHERE` no final da consulta que usa a coluna de partição.
> - Se o seu formato de consulta for `"SELECT col1 FROM table1 WHERE col2=val"`, teste a consulta estendendo a cláusula `WHERE` com `AND` e uma expressão que usa a coluna de partição.

- Data type casting (Conversão de tipos de dados): se a origem dos dados usar tipos de dados que não estão disponíveis no JDBC, use essa seção para especificar como um tipo de dados da origem dos dados deve ser convertido em tipos de dados do JDBC. Você pode especificar até 50 conversões de tipos de dados diferentes. Todas as colunas na origem dos dados que usam o mesmo tipo de dados são convertidas da mesma maneira.

  Por exemplo, se você tiver três colunas na origem dos dados que usam o tipo de dados `Float`, e você indicar que o tipo de dados `Float` deve ser convertido para o tipo `String` do JDBC, então todas as três colunas que usam o tipo de dados `Float` são convertidas para o tipo de dados `String`.

- Job bookmark keys (Chaves de marcadores de trabalho): os marcadores de trabalho ajudam o AWS Glue a manter as informações de estado e a impedir o reprocessamento de dados antigos. Especifique uma ou mais colunas adicionais como chaves de marcadores. O AWS Glue Studio usa chaves de marcadores para rastrear dados que já foram processados durante uma execução anterior do trabalho de ETL. Todas as colunas que você usar para chaves de marcadores personalizadas devem ser estritamente monotônicas, aumentando ou diminuindo, mas lacunas são permitidas.

  Se você inserir várias chaves de marcadores, elas serão combinadas para formar uma única chave composta. Uma chave de marcadores de trabalho composta não deve conter colunas duplicadas. Se você não especificar chaves de marcadores, por padrão, o AWS Glue Studio usará a chave primária como chave de marcadores, desde que ela esteja aumentando ou diminuindo sequencialmente (sem lacunas). Se a tabela não tiver uma

chave primária, mas a propriedade de marcador de trabalho estiver habilitada, você deverá fornecer chaves de marcadores de trabalho personalizadas. Caso contrário, a pesquisa de chaves primárias a serem usadas como padrão falhará, assim como a execução do trabalho.

- Job bookmark keys sorting order (Ordem de classificação de chaves de marcadores de trabalhos): escolha se as chaves-valor aumentam ou diminuem sequencialmente.

Spark

- Schema (Esquema): como o AWS Glue Studio está usando informações armazenadas na conexão para acessar a origem dos dados em vez de recuperar informações de metadados de uma tabela do Data Catalog, você deve fornecer os metadados do esquema para a origem dos dados. Escolha Add schema (Adicionar esquema) para abrir o editor de esquemas.

  Para obter instruções sobre como usar o editor de esquemas, consulte Editar o esquema de um nó de transformação personalizada.

- Connection options (Opções de conexão): insira pares de chave-valor adicionais, conforme necessário, para fornecer informações ou opções de conexão adicionais. Por exemplo, você pode inserir um nome de banco de dados, nome de tabela, nome de usuário e senha.

  Por exemplo, para OpenSearch, você insere os seguintes pares de chave-valor, conforme descrito em the section called “ Tutorial: Usar o AWS Glue Connector for 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`

Para obter um exemplo das opções mínimas de conexão a serem usadas, consulte o script de teste de exemplo MinimalSparkConnectorTest.scala no GitHub, que mostra as opções de conexão que você normalmente forneceria em uma conexão.

Athena

- Table name (Nome da tabela): o nome da tabela na origem dos dados. Se você estiver usando um conector para ler a partir de logs do Athena-CloudWatch, você deve inserir o nome da tabela `all_log_streams`.
- Athena schema name (Nome do esquema do Athena): escolha o esquema na origem dos dados do Athena que corresponde ao banco de dados que contém a tabela. Se você estiver usando um conector para ler a partir de logs do Athena-CloudWatch, você deve inserir um esquema semelhante a `/aws/glue/`*`name`*.
- Schema (Esquema): como o AWS Glue Studio está usando informações armazenadas na conexão para acessar a origem dos dados em vez de recuperar informações de metadados de uma tabela do Data Catalog, você deve fornecer os metadados do esquema para a origem dos dados. Escolha Add schema (Adicionar esquema) para abrir o editor de esquemas.

  Para obter instruções sobre como usar o editor de esquemas, consulte Editar o esquema de um nó de transformação personalizada.
- Additional connection options (Opções de conexão adicionais): insira pares de chave-valor adicionais, conforme necessário, para fornecer informações ou opções de conexão adicionais.

Para ver um exemplo, consulte o arquivo `README.md` em https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Athena. Nas etapas deste documento, o código de exemplo mostra as opções de conexão mínimas necessárias, que são `tableName`, `schemaName` e `className`. O código de exemplo especifica essas opções como parte da variável `optionsMap`, mas você pode especificá-las para sua conexão e, em seguida, usar a conexão.

3. (Opcional) depois de fornecer as informações necessárias, você pode exibir o esquema de dados resultante para sua origem dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. O esquema exibido nessa guia é usado por todos os nós filhos adicionados ao gráfico de trabalho.
4. (Opcional) depois de configurar as propriedades do nó e da origem dos dados, você poderá previsualizar o conjunto de dados de sua origem dos dados escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função

do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Configurar propriedades de destino para nós que usam conectores

Se você usar um conector para o tipo de destino de dados, deverá configurar as propriedades do nó de destino de dados.

Para configurar as propriedades de um nó de destino de dados que usa um conector

1. Escolha o nó de destino de dados do conector no gráfico de trabalho. Em seguida, no lado direito, no painel de detalhes do nó, escolha a guia Data target properties (Propriedades de destino de dados), se ainda não estiver selecionada.
2. Na guia Data target properties (Propriedades de destino de dados), escolha a conexão a ser usada para gravar no destino.

   Insira as informações adicionais necessárias para cada tipo de conexão:

   JDBC

   - Connection (Conexão): escolha a conexão a ser usada com o conector. Para obter informações sobre como criar uma conexão, consulte Criar conexões para conectores.
   - Table name (Nome da tabela): o nome da tabela no destino dos dados. Se o destino dos dados não usar o termo table (tabela), forneça o nome de uma estrutura de dados apropriada, conforme indicado pelas informações de uso do conector personalizado (disponíveis em AWS Marketplace).
   - Batch size (Tamanho do lote; opcional): informe o número de linhas ou registros a serem inseridos na tabela de destino em uma única operação. O valor padrão é 1.000 linhas.

   Spark

   - Connection (Conexão): escolha a conexão a ser usada com o conector. Se você não criou uma conexão anteriormente, escolha Create connection (Criar conexão) para criar uma. Para obter informações sobre como criar uma conexão, consulte Criar conexões para conectores.

- Connection options (Opções de conexão): insira pares de chave-valor adicionais, conforme necessário, para fornecer informações ou opções de conexão adicionais. Você pode inserir um nome de banco de dados, um nome de tabela, um nome de usuário e senha.

  Por exemplo, para OpenSearch, você insere os seguintes pares de chave-valor, conforme descrito em the section called " Tutorial: Usar o AWS Glue Connector for 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`

  Para obter um exemplo das opções mínimas de conexão a serem usadas, consulte o script de teste de exemplo MinimalSparkConnectorTest.scala no GitHub, que mostra as opções de conexão que você normalmente forneceria em uma conexão.

3. Depois de fornecer as informações necessárias, você pode exibir o esquema de dados resultante para sua origem dos dados escolhendo a guia Output schema (Esquema de saída), no painel de detalhes do nó.

Gerenciar conectores e conexões

Você pode usar a página Conexões no AWS Glue para gerenciar seus conectores e conexões.

Tópicos

- Visualizar detalhes do conector e da conexão
- Editar conectores e conexões
- Excluir conectores e conexões
- Cancelar a assinatura de um conector

Visualizar detalhes do conector e da conexão

Você pode exibir informações resumidas sobre seus conectores e conexões nas tabelas de recursos Your connectors (Seus conectores) e Your connections (Suas conexões) na página Connectors (Conectores). Para visualizar as informações detalhadas, execute as etapas a seguir.

Para exibir detalhes do conector ou da conexão

1. No console do AWS Glue Studio, escolha Connectors (Conectores), no painel de navegação do console.
2. Escolha o conector ou conexão cujas informações detalhadas você deseja visualizar.
3. Escolha Actions (Ações) e, em seguida, escolha View details (Visualizar os detalhes), para abrir a página de detalhes desse conector ou conexão.
4. Na página de detalhes, você pode optar por Edit (Editar) ou Delete (Excluir) o conector ou a conexão.

   - Para conectores, você pode escolher Create connection (Criar conexão) para criar uma nova conexão que use o conector.
   - Para conexões, você pode escolher Create job (Criar trabalho) para criar um novo trabalho que use a conexão.

Editar conectores e conexões

Você usa a página Connectors (Conectores) para alterar as informações armazenadas em seus conectores e conexões.

Para modificar um conector ou conexão

1. No console do AWS Glue Studio, escolha Connectors (Conectores), no painel de navegação do console.
2. Escolha o conector ou conexão que você deseja alterar.
3. Escolha Ações e, em seguida, escolha Editar.

   Você também pode escolher View details (Visualizar os detalhes) e, na página de detalhes do conector ou da conexão, escolher Edit (Editar).
4. Na página Edit connector (Editar conector) ou Edit connection (Editar conexão), atualize as informações e escolha Save (Salvar).

Excluir conectores e conexões

Você pode usar a página Connectors (Conectores) para excluir conectores e conexões. Se você excluir um conector, todas as conexões que foram criadas para ele também devem ser excluídas.

Para remover conectores do AWS Glue Studio

1. No console do AWS Glue Studio, escolha Connectors (Conectores), no painel de navegação do console.
2. Escolha o conector ou conexão que você deseja excluir.
3. Escolha Ações e, em seguida, escolha Excluir.

   Você também pode escolher View details (Visualizar os detalhes) e, na página de detalhes do conector ou da conexão, escolher Delete (Excluir).
4. Confirme que você deseja remover o conector ou a conexão digitando **`Delete`** e escolha Delete (Excluir).

   Se você excluir um conector, todas as conexões que foram criadas para ele também devem ser excluídas.

Quaisquer trabalhos que utilizem uma conexão excluída deixarão de funcionar. Você pode editar os trabalhos para usar um datastore diferente ou removê-los. Para obter informações sobre como excluir um trabalho, consulte Excluir trabalhos.

Se você excluir um conector, isso não cancelará a assinatura do conector no AWS Marketplace. Para remover a assinatura de um conector excluído, siga as instruções em Cancelar a assinatura de um conector.

Cancelar a assinatura de um conector

Após excluir as conexões e o conector do AWS Glue Studio, você poderá cancelar sua assinatura do AWS Marketplace, se não precisar mais do conector.

> **Note**
>
> Se você cancelar a assinatura de um conector, isso não removerá o conector ou a conexão da sua conta. Quaisquer trabalhos que usem o conector e as conexões relacionadas não poderão mais usá-lo e falharão.

Antes de cancelar a assinatura ou assinar novamente um conector do AWS Marketplace, você deve excluir conexões e conectores existentes associados o produto do AWS Marketplace em questão.

Para cancelar a assinatura de um conector no AWS Marketplace

1. Faça login no console do AWS Marketplace em https://console.aws.amazon.com/marketplace.
2. Escolha Manage subscriptions (Gerenciar assinaturas).
3. Na página Manage subscriptions (Gerenciar assinaturas), escolha Manage (Gerenciar), ao lado da assinatura do conector que você deseja cancelar.
4. Escolha Actions (Ações) e escolha Cancel subscription (Cancelar assinatura).
5. Marque a caixa de seleção para confirmar que as instâncias em execução são cobradas em sua conta e escolha Yes, cancel subscription (Sim, cancelar assinatura).

Desenvolvimento de conectores personalizados

Você pode escrever código para ler ou gravar dados no seu datastore e formatar esses dados para usá-los com trabalhos do AWS Glue Studio. Você pode criar conectores para armazenamentos de dados do Spark, Athena e JDBC. O código de exemplo publicado no GitHub fornece uma visão geral das interfaces básicas que você precisa implantar.

Você precisará de um ambiente de desenvolvimento local para criar seu código de conector. Você pode usar qualquer IDE ou até mesmo um simples editor de linha de comando para escrever seu conector. Exemplos de ambientes de desenvolvimento incluem:

- Um ambiente Scala local com uma biblioteca local de ETL Maven do AWS Glue, conforme descrito em Desenvolver localmente com o Scala no Guia do desenvolvedor do AWS Glue.
- IntelliJ IDE, baixando o IDE de https://www.jetbrains.com/idea/.

Tópicos

- Desenvolvimento de conectores do Spark
- Desenvolvimento de conectores do Athena
- Desenvolvimento de conectores do JDBC
- Exemplos de uso de conectores personalizados com o AWS Glue Studio

- Desenvolver conectores do AWS Glue para o AWS Marketplace

Desenvolvimento de conectores do Spark

Você pode criar um conector do Spark para ler dados com o Spark DataSource API V2 (Spark 2.4).

Para criar um conector personalizado do Spark

Para desenvolver conectores do Spark, siga as etapas na biblioteca de exemplo do GitHub do AWS Glue, que está localizada em https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Spark/README.md.

Desenvolvimento de conectores do Athena

Você pode criar um conector do Athena para ser usado pelo AWS Glue e pelo AWS Glue Studio para consultar uma origem dos dados personalizada.

Para criar um conector personalizado do Athena

Para desenvolver conectores do Athena, siga as etapas na biblioteca de exemplo do GitHub do AWS Glue, que está localizada em https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/Athena.

Desenvolvimento de conectores do JDBC

Você pode criar um conector que usa o JDBC para acessar seus armazenamentos de dados.

Para criar um conector do JDBC personalizado

1. Instale as bibliotecas do runtime Spark do AWS Glue em seu ambiente de desenvolvimento local. Consulte as instruções na biblioteca de exemplo do GitHub do AWS Glue em https://github.com/aws-samples/aws-glue-samples/tree/master/GlueCustomConnectors/development/GlueSparkRuntime/README.md.
2. Implante o driver do JDBC responsável por recuperar dados da origem dos dados. Consulte a documentação do Java para o Java SE 8.

   Crie um ponto de entrada dentro do seu código que o AWS Glue Studio usará para localizar seu conector. O campo Class name (Nome da classe) deve ser o caminho completo do driver do JDBC.

3. Use a API `GlueContext` para ler dados com o conector. Os usuários podem adicionar mais opções de entrada no console do AWS Glue Studio para configurar a conexão com a origem dos dados, se necessário. Para obter um código de exemplo que mostra como ler e gravar em um banco de dados JDBC com um conector JDBC personalizado, consulte Valores de connectionType do AWS Marketplace e personalizados.

Exemplos de uso de conectores personalizados com o AWS Glue Studio

Você pode consultar os seguintes blogs para obter exemplos de uso de conectores personalizados:

- Desenvolvimento, teste e implantação de conectores personalizados para seus armazenamentos de dados com o AWS Glue
- Apache Hudi: Escrever tabelas Apache Hudi usando o AWS Glue Conector Personalizado
- Google BigQuery: Dados migratórios do Google BigQuery para o Amazon S3 usando os AWS Glue conectores personalizados
- Snowflake (JDBC): Realizar transformações de dados usando o Snowflake e AWS Glue
- SingleStore: Construir ETL rápido usando o SingleStore e AWS Glue
- Salesforce: Insirir dados do Salesforce no Amazon S3 usando o conector personalizado CData JDBC com AWS Glue -
- MongoDB: Construir AWS Glue trabalhos Spark ETL usando o Amazon DocumentDB (com compatibilidade MongoDB) e o MongoDB
- Amazon Relational Database Service (Amazon RDS): Construir AWS Glue trabalhos Spark ETL trazendo seus próprios drivers JDBC para o Amazon RDS
- MySQL (JDBC): https://github.com/aws-samples/aws-glue-samples/blob/master/GlueCustomConnectors/development/Spark/SparkConnectorMySQL.scala

Desenvolver conectores do AWS Glue para o AWS Marketplace

Como um parceiro da AWS, você pode criar conectores personalizados e carregá-los no AWS Marketplace para vender para clientes do AWS Glue.

O processo para desenvolver o código do conector é o mesmo que para conectores personalizados, mas o processo de carregamento e verificação do código do conector é mais detalhado. Consulte as instruções em Creating Connectors for AWS Marketplace (Criar conectores para) no site do GitHub.

Restrições de uso de conectores e conexões no AWS Glue Studio

Quando você estiver usando conectores personalizados ou conectores do AWS Marketplace, observe as seguintes restrições:

- A API testConnection não é suportada com conexões criadas para conectores personalizados.
- A criptografia de senha de conexão do Data Catalog não é suportada com conectores personalizados.
- Você não pode usar marcadores de trabalho se especificar um predicado de filtro para um nó de fonte de dados que usa um conector JDBC.
- A criação de uma conexão com o Marketplace não é suportada fora da interface do usuário do AWS Glue Studio.

Testar uma conexão do AWS Glue

Como prática recomendada, antes de usar uma conexão do AWS Glue em um trabalho de ETL, use o console do AWS Glue para testar a conexão. O AWS Glue usa os parâmetros da conexão para confirmar que pode acessar o datastore e relata qualquer erro encontrado. Para obter informações sobre as conexões do AWS Glue, consulte Conectar a dados.

Como testar uma conexão do AWS Glue

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Catálogo de dados, selecione Conexões. Você também pode escolher Conexões de dados acima de Catálogo de dados no painel de navegação.
3. Em Conexões, marque a caixa de seleção ao lado da conexão desejada e selecione Ações. No menu suspenso , escolha Testar conexão.
4. Na caixa de diálogo Test connection (Testar conexão), selecione uma função ou escolha Create IAM role (Criar função do IAM) para acessar o console do AWS Identity and Access Management (IAM), a fim de criar uma função. A função deve ter permissões no datastore.
5. Selecione a opção Confirmar.

   O teste é iniciado e pode levar vários minutos para ser concluído. Se o teste falhar, escolha Solucionar problemas para ver as etapas para resolver o problema.

6. Escolha Logs para ver os logs. do CloudWatch. É necessário ter as permissões do IAM exigidas para visualizar os logs. Para obter mais informações, consulte AWS Managed (Predefined) Policies for CloudWatch Logs no Amazon CloudWatch Logs User Guide.

Configurando AWS chamadas para passar por seu VPC

O parâmetro de trabalho especial `disable-proxy-v2` permite que você encaminhe suas chamadas para serviços como Amazon S3, CloudWatch, e AWS Glue por meio de seu. VPC Por padrão, AWS Glue usa um proxy local para enviar tráfego por meio do AWS Glue VPC para baixar scripts e bibliotecas do Amazon S3, enviar solicitações CloudWatch para publicação de registros e métricas e enviar solicitações AWS Glue para acessar catálogos de dados. Esse proxy permite que o trabalho funcione normalmente, mesmo que você VPC não configure uma rota adequada para outros AWS serviços, como Amazon S3 CloudWatch, e. AWS Glue AWS Glue agora oferece um parâmetro para você desativar esse comportamento. Para obter mais informações, consulte Parâmetros de trabalho usados por AWS Glue. AWS Glue continuará usando o proxy local para publicar CloudWatch registros de seus AWS Glue trabalhos.

> **Note**
>
> - Esse recurso é compatível com AWS Glue trabalhos com a AWS Glue versão 2.0 e superior. Ao usar esse recurso, você precisa garantir que VPC tenha configurado uma rota para o Amazon S3 por meio de um endpoint de serviço NAT VPC ou.
> - O parâmetro de trabalho obsoleto `disable-proxy` somente direciona suas chamadas para o Amazon S3 para baixar scripts e bibliotecas por meio do seu. VPC É recomendável usar o novo parâmetro `disable-proxy-v2` em seu lugar.

Exemplo de uso

Crie um AWS Glue trabalho com`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"}'
```

Conectando-se a um armazenamento de JDBC dados em um VPC

Normalmente, você cria recursos dentro da Amazon Virtual Private Cloud (AmazonVPC) para que eles não possam ser acessados pela Internet pública. Por padrão, não é AWS Glue possível acessar recursos dentro de umVPC. AWS Glue Para permitir o acesso a recursos dentro do seuVPC, você deve fornecer informações adicionais de configuração VPC específicas que incluam VPC sub-rede IDs e grupo de segurança. IDs AWS Glue usa essas informações para configurar interfaces de rede elásticas que permitem que sua função se conecte com segurança a outros recursos em sua privacidade. VPC

Ao usar um VPC endpoint, adicione-o à sua tabela de rotas. Para obter mais informações, consulte Criação de um VPC endpoint de interface para AWS Glue e. Pré-requisitos

Ao usar criptografia no Catálogo de Dados, crie o endpoint da KMS interface e adicione-o à sua tabela de rotas. Para obter mais informações, consulte Criação de um VPC endpoint para AWS KMS.

Acessando VPC dados usando interfaces de rede elástica

Quando AWS Glue se conecta a um armazenamento de JDBC dados em umVPC, AWS Glue cria uma interface de rede elástica (com o prefixo`Glue_`) em sua conta para acessar seus VPC dados. Você não pode excluir essa interface de rede, desde que ela esteja conectada AWS Glue a. Como parte da criação da interface de rede elástica, AWS Glue associe um ou mais grupos de segurança a ela. AWS Glue Para permitir a criação da interface de rede, os grupos de segurança associados ao recurso devem permitir o acesso de entrada com uma regra de origem. Esta regra contém um security group associado ao recurso. Isso concede acesso para a interface de rede elástica ao seu armazenamento de dados que contém o mesmo security group.

Para permitir AWS Glue a comunicação com seus componentes, especifique um grupo de segurança com uma regra de entrada autorreferenciada para todas as portas. TCP Ao criar uma regra de autorreferência, você pode restringir a fonte ao mesmo grupo de segurança no VPC e não abri-la para todas as redes. O grupo de segurança padrão para você VPC pode já ter uma regra de entrada de autorreferência para. `ALL Traffic`

Você pode criar regras no VPC console da Amazon. Para atualizar as configurações da regra por meio do AWS Management Console, navegue até o VPC console (https://console.aws.amazon.com/vpc/) e selecione o grupo de segurança apropriado. Especifique a regra de entrada para `ALL TCP` para que a fonte tenha o mesmo nome do security group. Para obter mais informações sobre as regras do grupo de segurança, consulte Grupos de segurança para você VPC.

Cada interface de rede elástica recebe um endereço IP privado do intervalo de endereços IP nas sub-redes que você especifica. A interface de rede não tem nenhum endereço IP público atribuído. AWS Glue requer acesso à Internet (por exemplo, para acessar AWS serviços que não têm VPC endpoints). Você pode configurar uma instância de tradução de endereço de rede (NAT) dentro da suaVPC, ou você pode usar o VPC NAT gateway da Amazon. Para obter mais informações, consulte NATGateways no Guia do VPC usuário da Amazon. Você não pode usar diretamente um gateway de Internet conectado a você VPC como uma rota na tabela de rotas de sub-rede porque isso exige que a interface de rede tenha endereços IP públicos.

Os atributos da VPC rede `enableDnsHostnames` e `enableDnsSupport` devem ser definidos como verdadeiros. Para obter mais informações, consulte Usando DNS com seu VPC.

> **Important**
>
> Não coloque seu armazenamento de dados em uma sub-rede pública nem em uma sub-rede privada que não tenha acesso à Internet. Em vez disso, conecte-o somente a sub-redes privadas que tenham acesso à Internet por meio de uma NAT instância ou de um gateway da Amazon VPCNAT.

Propriedades da interface de rede elástica (ENI)

Para criar a interface de rede elástica, você precisa fornecer as seguintes propriedades:

VPC

O nome do VPC que contém seu armazenamento de dados.

Sub-rede

A sub-rede na VPC que contém seu armazenamento de dados.

Grupos de segurança

Os grupos de segurança associados ao seu armazenamento de dados. AWS Glue associa esses grupos de segurança à interface de rede elástica que está conectada à sua VPC sub-rede. Para permitir que AWS Glue os componentes se comuniquem e também impedir o acesso de outras redes, pelo menos um grupo de segurança escolhido deve especificar uma regra de entrada de autorreferência para todas as portas. TCP

Para obter informações sobre como gerenciar um VPC com o Amazon Redshift, consulte Gerenciando clusters em uma Amazon Virtual Private Cloud () VPC.

Para obter informações sobre como gerenciar um VPC com o Amazon Relational Database Service (RDSAmazon), consulte Trabalhando com uma instância de banco de dados RDS Amazon em VPC um.

Usar uma conexão do MongoDB ou do MongoDB Atlas

Após criar uma conexão para o MongoDB ou para o MongoDB Atlas, você poderá usá-la em seu trabalho de ETL. Você cria uma tabela no AWS Glue Data Catalog e especifica a conexão do MongoDB ou do MangoDB Atlas para o atributo `connection` da tabela.

O AWS Glue armazena o `url` de sua conexão e credenciais na conexão do MongoDB. Os formatos de URI de conexão são os seguintes:

- Para o MongoDB: mongodb://host:port/database. O host pode ser um nome de host, um endereço IP ou um soquete de domínio do UNIX. Se a string de conexão não especificar uma porta, a porta padrão do MongoDB, 27017, será usada.
- Para o MongoDB Atlas: mongodb+srv://server.example.com/database. O host pode ser um nome de host que corresponde a um registro SRV do DNS. O formato SRV não requer porta e usará a porta 27017, padrão do MongoDB.

Além disso, é possível especificar opções em seu script de trabalho. Para ter mais informações, consulte the section called “Conexão do MongoDB”.

Rastreando um armazenamento de dados do Amazon S3 usando um endpoint VPC

Para fins de segurança, auditoria ou controle, você pode querer que seu armazenamento de dados Amazon S3 ou tabelas do Catálogo de Dados com suporte do Amazon S3 sejam acessadas somente por meio de um ambiente Amazon Virtual Private Cloud (Amazon). VPC Este tópico descreve como criar e testar uma conexão com o armazenamento de dados do Amazon S3 ou tabelas do catálogo de dados com suporte do Amazon S3 em VPC um endpoint usando o tipo de conexão. `Network`

Realize as seguintes tarefas para executar um crawler no armazenamento de dados:

- the section called “Pré-requisitos”
- the section called “Criar a conexão com o Amazon S3”
- the section called “Testar a conexão com o Amazon S3”
- the section called “Criar um crawler para um armazenamento de dados do Amazon S3”
- the section called “Executar um crawler”

Pré-requisitos

Verifique se você atendeu a esses pré-requisitos para configurar seu armazenamento de dados Amazon S3 ou tabelas do Catálogo de Dados com suporte do Amazon S3 para serem acessadas por meio de um ambiente Amazon Virtual Private Cloud (Amazon). VPC

- Um configuradoVPC. Por exemplo: vpc-01685961063b0d84b. Para obter mais informações, consulte Introdução à Amazon VPC no Guia do VPC usuário da Amazon.
- Um endpoint Amazon S3 conectado ao. VPC Por exemplo: vpc-01685961063b0d84b. Para obter mais informações, consulte Endpoints para Amazon S3 no Guia do usuário da VPCAmazon.

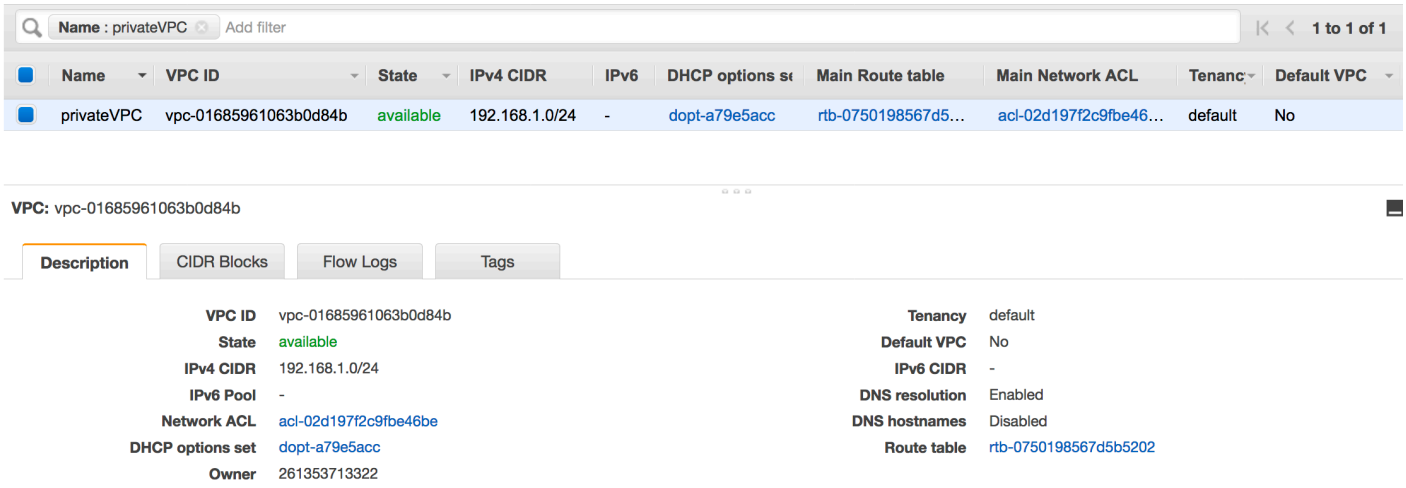

- Uma entrada de rota apontando para o VPC ponto final. Por exemplo, vpce-0ec5da4d265227786 na tabela de rotas usada pelo endpoint (vpce-0ec5da4d265227786). VPC

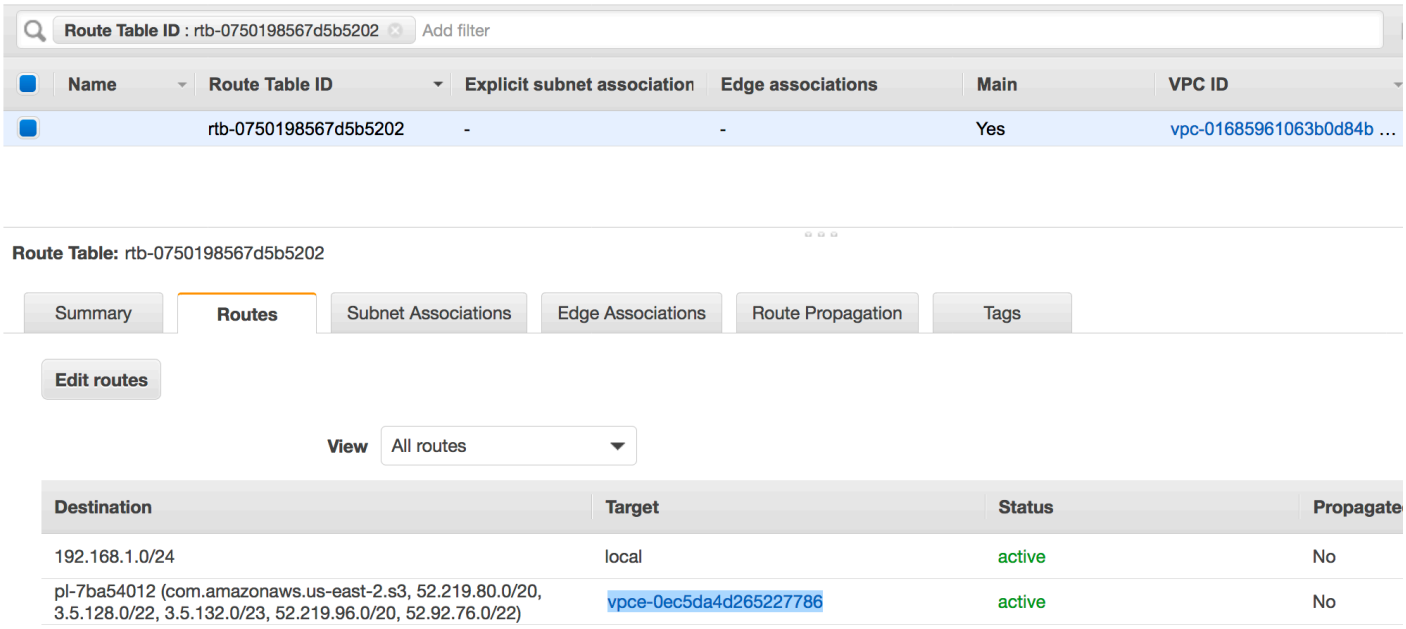

- Uma rede ACL conectada ao VPC permite o tráfego.
- Um grupo de segurança anexado ao VPC permite o tráfego.

Criar a conexão com o Amazon S3

Normalmente, você cria recursos dentro da Amazon Virtual Private Cloud (AmazonVPC) para que eles não possam ser acessados pela Internet pública. Por padrão, não é AWS Glue possível acessar recursos dentro de umVPC. AWS Glue Para permitir o acesso a recursos dentro do seuVPC, você deve fornecer informações adicionais de configuração VPC específicas que incluam VPC sub-rede IDs e grupo de segurança. IDs Para criar uma conexão `Network`, você precisa especificar as seguintes informações:

- UMA VPC IDENTIFICAÇÃO
- Uma sub-rede dentro do VPC
- Um grupo de segurança

Para configurar uma conexão `Network`:

1. Escolha Add connection (Adicionar conexão) no painel de navegação do console do AWS Glue .
2. Insira o nome da conexão e escolha Network (Rede) como o tipo de conexão. Escolha Próximo.

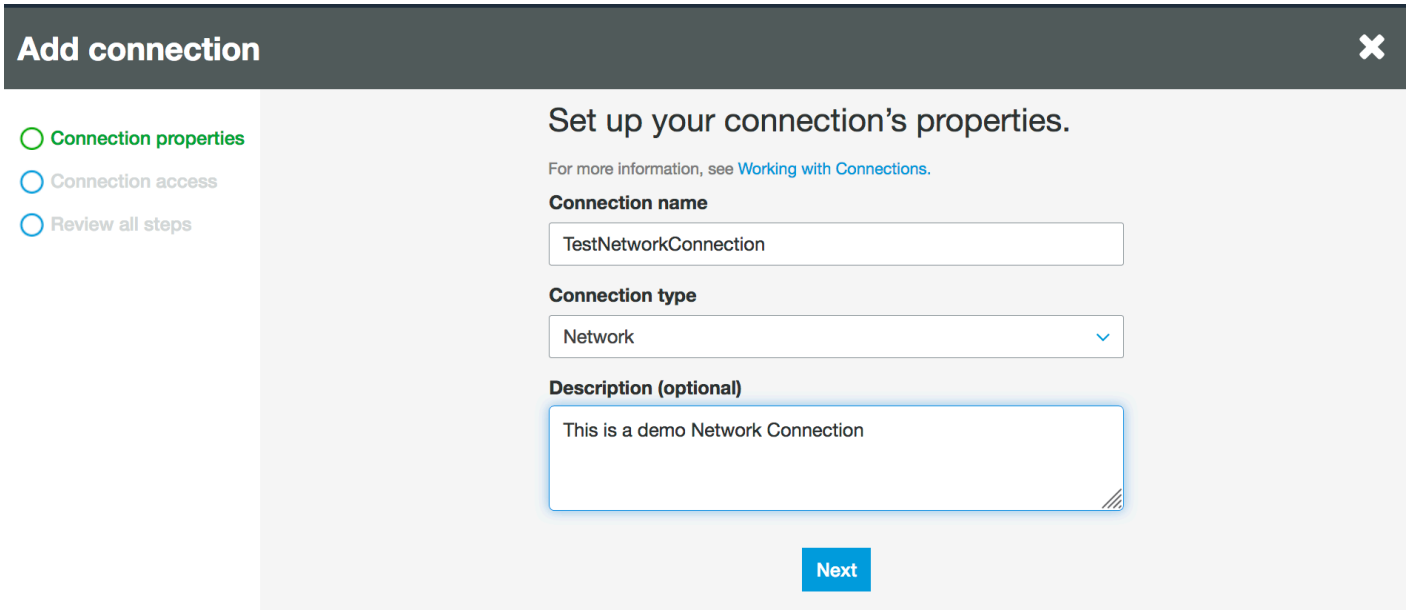

3. Configure as VPC informações dos grupos de sub-rede e segurança.
   - VPC: escolha o VPC nome que contém seu armazenamento de dados.
   - Sub-rede: escolha a sub-rede dentro da sua. VPC
   - Grupos de segurança: escolha um ou mais grupos de segurança que permitam acesso ao armazenamento de dados em seuVPC.

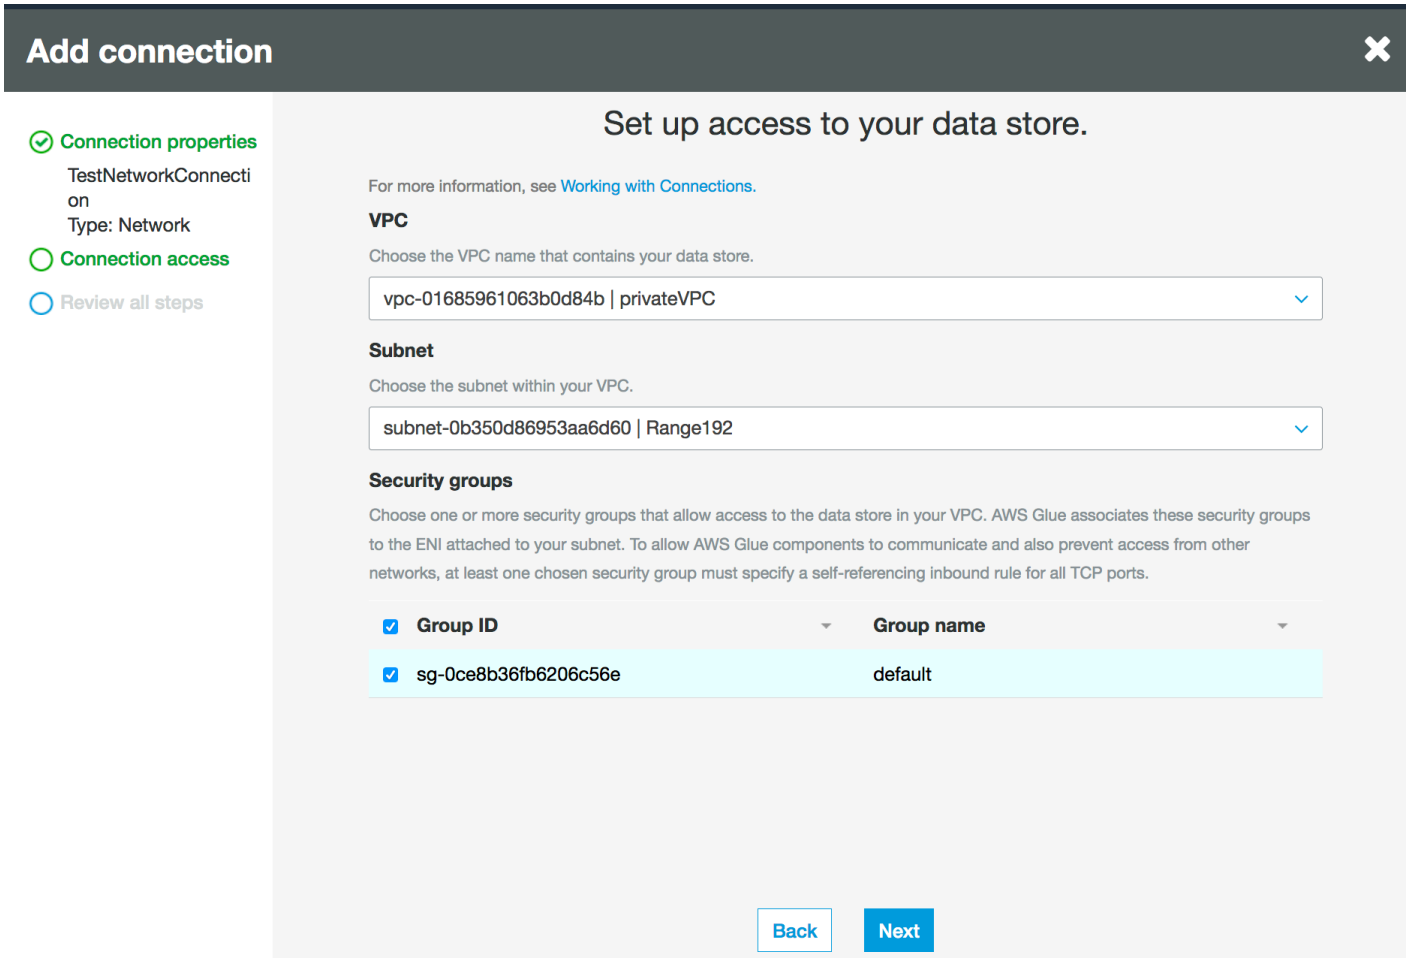

4. Escolha Próximo.
5. Verifique as informações de conexão e escolha Finish (Encerrar).

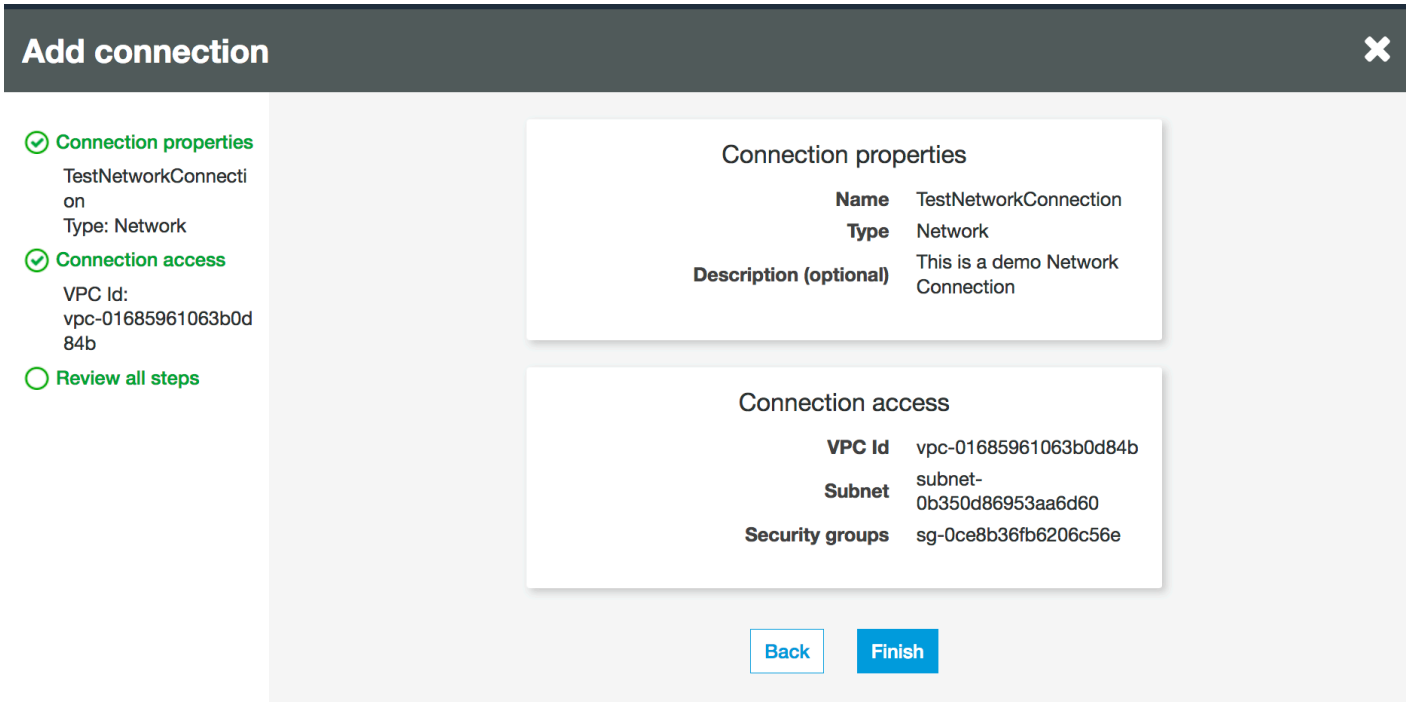

Testar a conexão com o Amazon S3

Depois de criar sua `Network` conexão, você pode testar a conectividade com seu armazenamento de dados do Amazon S3 em um VPC endpoint.

Os seguintes erros podem ocorrer ao testar uma conexão:

- INTERNETCONNECTIONERROR: indica um problema de conexão com a Internet
- INVALIDBUCKETERROR: indica um problema com o bucket do Amazon S3
- S3 CONNECTIONERROR: indica uma falha na conexão com o Amazon S3
- INVALIDCONNECTIONTYPE: indica que o tipo de conexão não tem o valor esperado, `NETWORK`
- INVALIDCONNECTIONTESTTYPE: indica um problema com o tipo de teste de conexão de rede
- INVALIDTARGET: indica que o bucket do Amazon S3 não foi especificado corretamente

Para testar uma conexão `Network`:

1. Selecione a conexão Network (Rede) no console do AWS Glue .
2. Selecione Test connection (Testar conexão).
3. Escolha a IAM função que você criou na etapa anterior e especifique um bucket do Amazon S3.

4. Escolha Test connection (Testar conexão) para iniciar o teste. Pode levar algum tempo para que o resultado seja exibido.

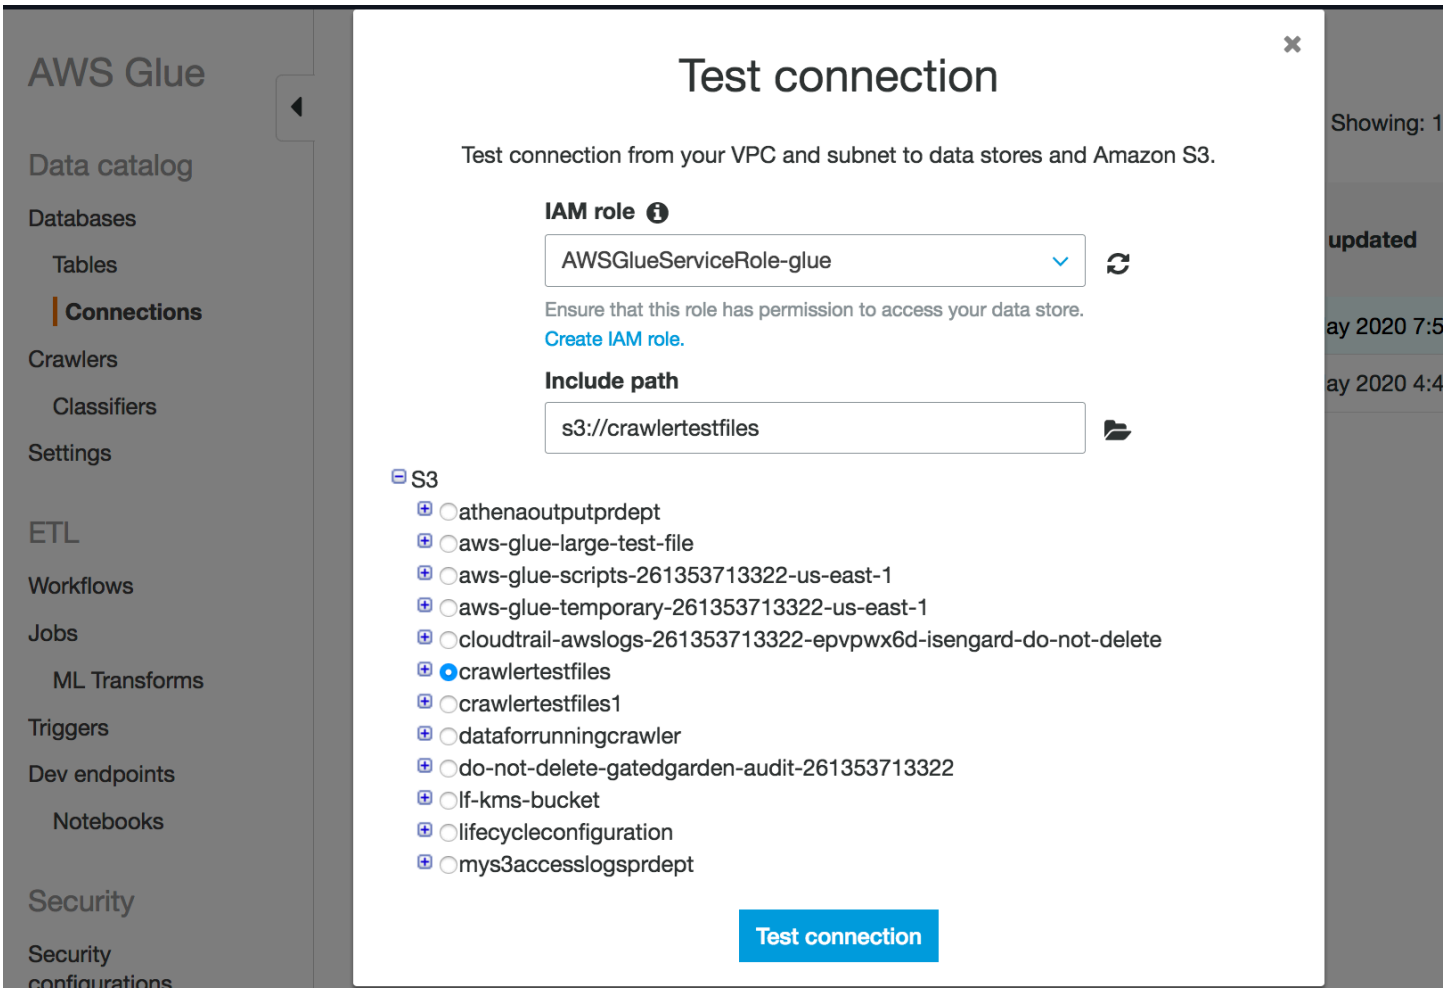

Se você receber um erro, faça o seguinte:

- Os privilégios corretos foram fornecidos para a função selecionada.
- O bucket do Amazon S3 correto foi fornecido.
- Os grupos de segurança e a rede ACL permitem o tráfego de entrada e saída necessário.
- O VPC que você especificou está conectado a um endpoint do Amazon S3VPC.

Após ter testado com êxito a conexão, você pode criar um crawler.

Criar um crawler para um armazenamento de dados do Amazon S3

Agora é possível criar um crawler que especifica a conexão `Network` que você criou. Para obter mais detalhes sobre como criar um crawler, consulte Configurar um crawler.

1. Comece escolhendo Crawlers no painel de navegação do console. AWS Glue
2. Escolha Adicionar crawler.
3. Especifique o nome do crawler e escolha Next (Próximo).
4. Quando a origem dos dados for solicitada, escolha S3 e especifique o prefixo do bucket do Amazon S3 e a conexão criada anteriormente.

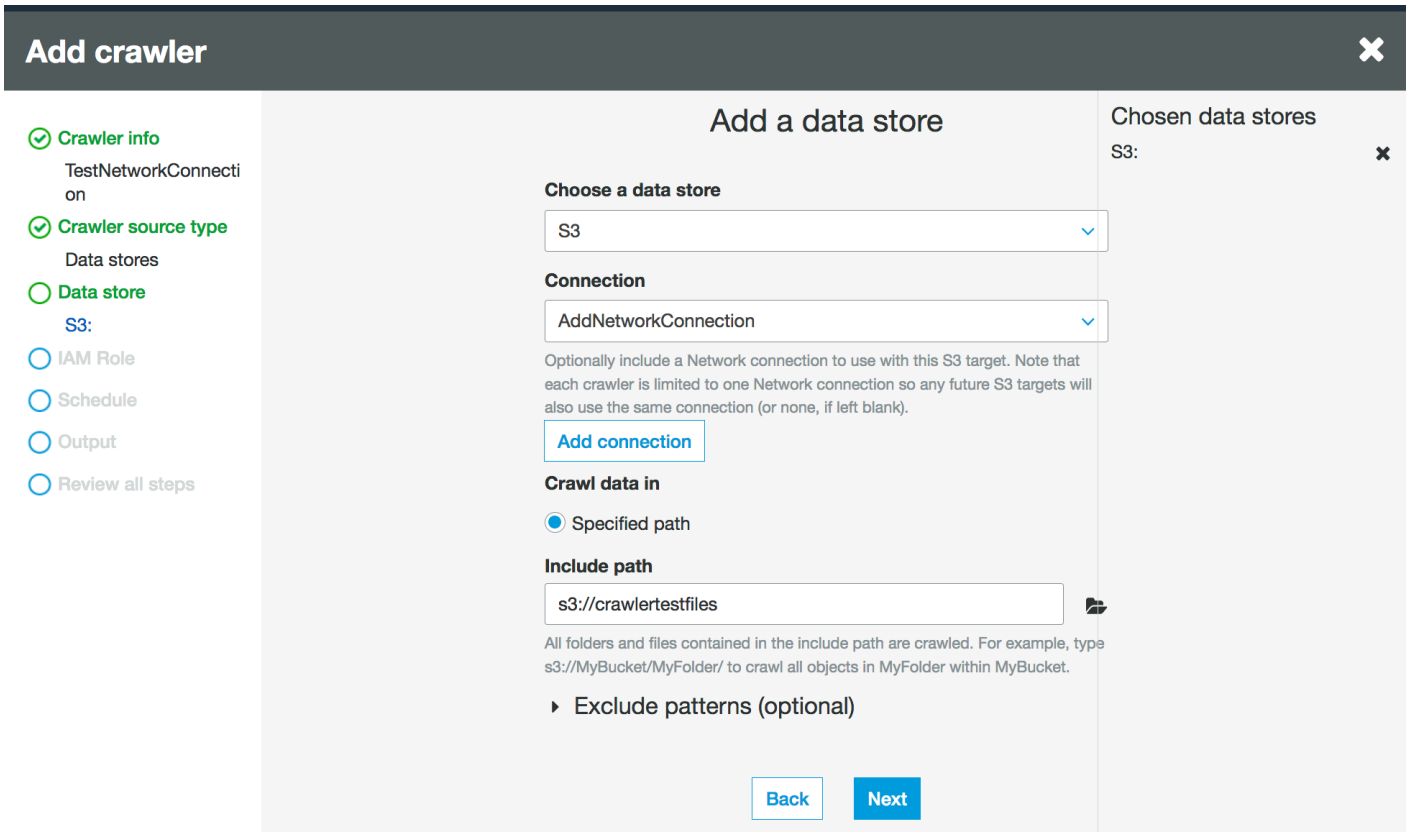

5. Se precisar, adicione outro armazenamento de dados na mesma conexão de rede.
6. Escolha a IAM função. A IAM função deve permitir o acesso ao AWS Glue serviço e ao bucket do Amazon S3. Para obter mais informações, consulte the section called “Configurar um crawler”.

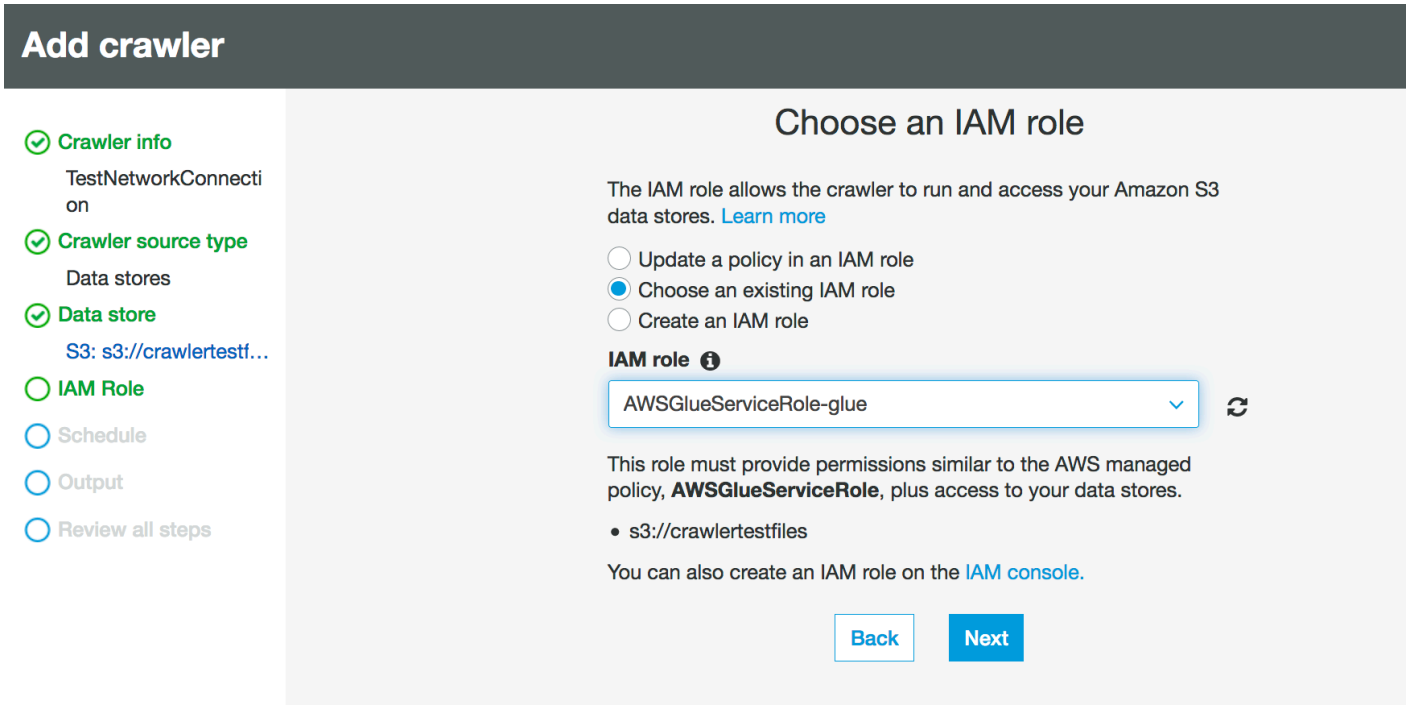

7. Defina a programação do crawler.
8. Escolha um banco de dados existente no Data Catalog ou crie uma nova entrada de banco de dados.

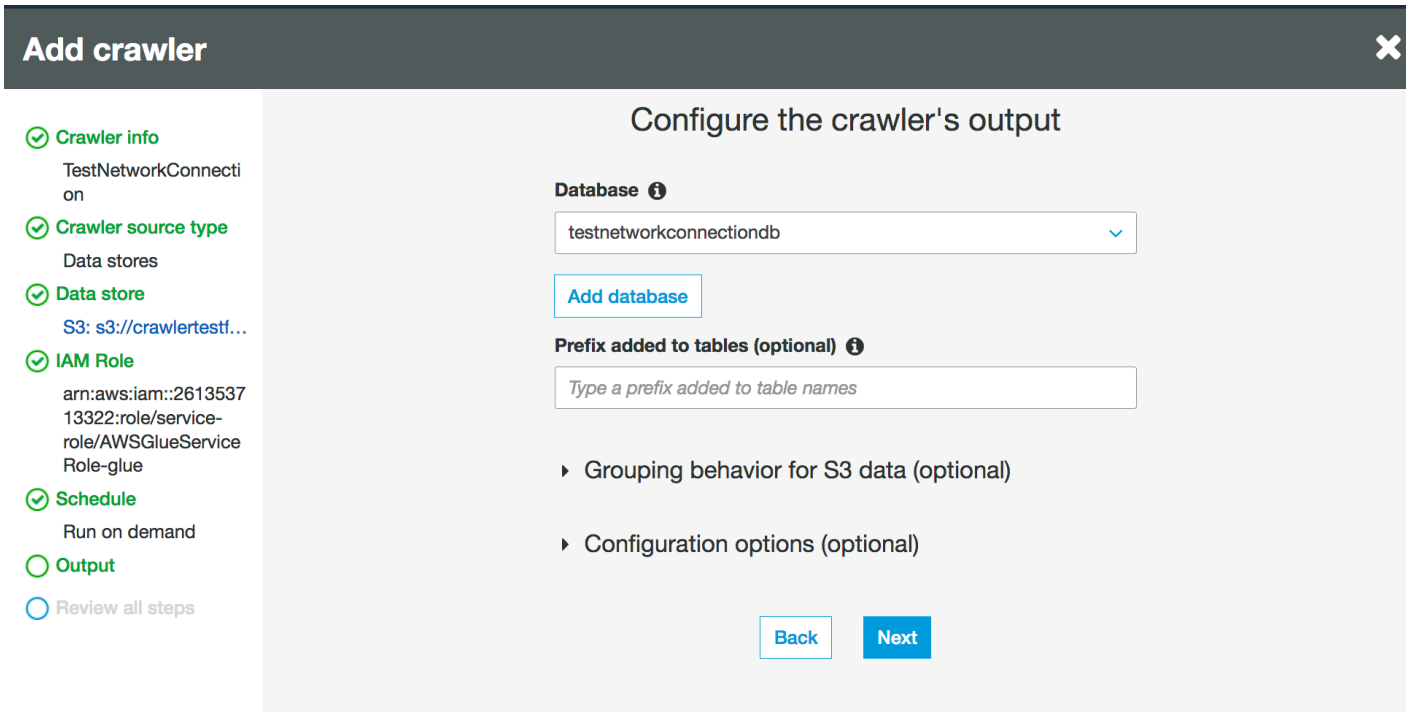

9. Conclua a configuração restante.

Criação de um crawler para tabelas de catálogo de dados baseadas no Amazon S3

Agora é possível criar um crawler que especifica a conexão de `Network` que você criou e um tipo de fonte de catálogo. Para obter mais detalhes sobre como criar um crawler, consulte Configurar um crawler.

1. Comece escolhendo Crawlers no painel de navegação do console. AWS Glue
2. Escolha Adicionar crawler.
3. Especifique o nome do crawler e escolha Next (Próximo).
4. Quando o tipo de fonte do crawler for solicitado, escolha Existing catalog tables (Tabelas de catálogo existentes) e especifique as tabelas de catálogo existentes para crawling na lista de tabelas disponíveis.

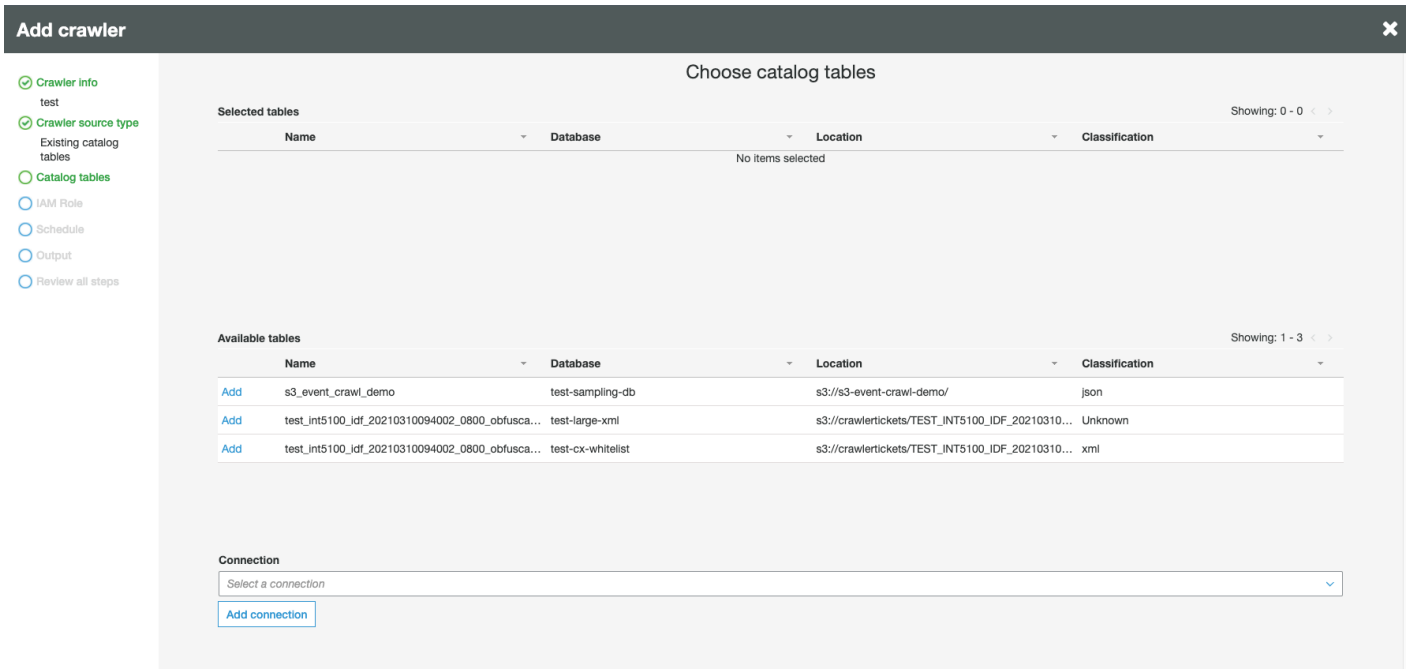

5. Escolha a IAM função. A IAM função deve permitir o acesso ao AWS Glue serviço e ao bucket do Amazon S3. Para obter mais informações, consulte the section called “Configurar um crawler”.
6. Defina a programação do crawler.
7. Escolha um banco de dados existente no Data Catalog ou crie uma nova entrada de banco de dados.
8. Conclua a configuração restante e revise suas etapas.

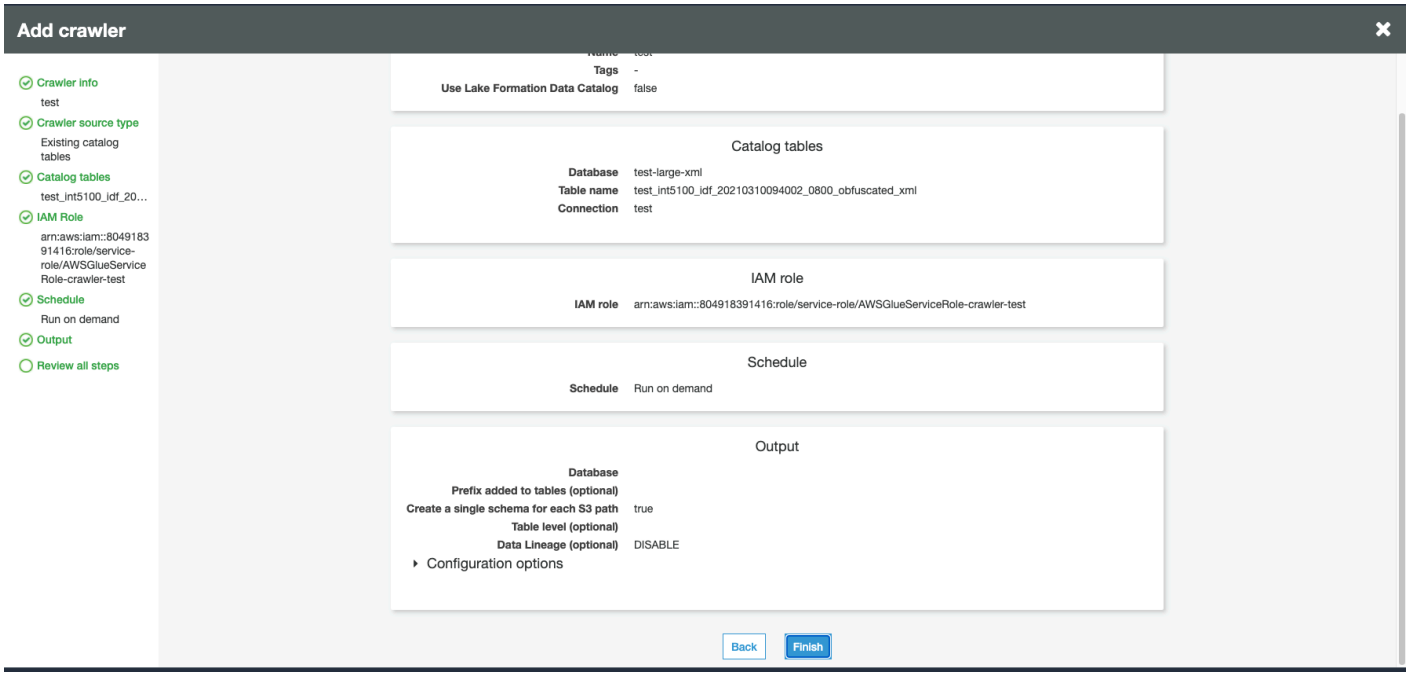

Executar um crawler

Execute seu crawler.

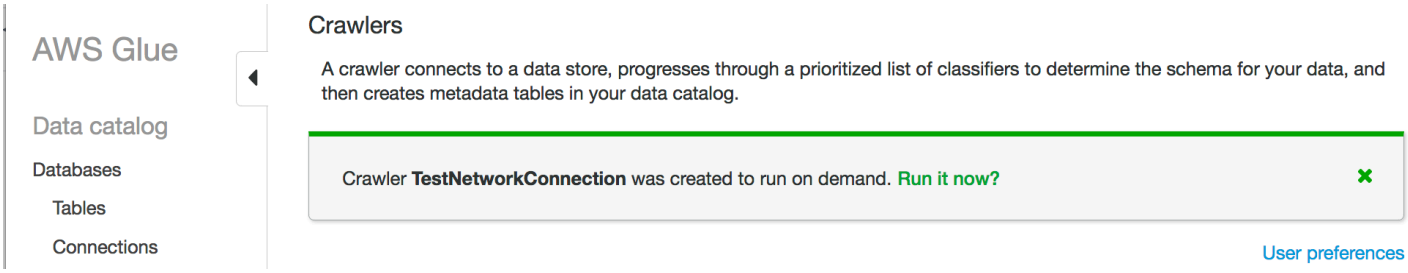

Solução de problemas

Para solucionar problemas relacionados aos buckets do Amazon S3 usando um VPC gateway, consulte Por que não consigo me conectar a um bucket do S3 usando um endpoint de gateway? VPC

Trabalhar com dados protegidos pelo AWS Lake Formation

Acesso total a uma tabela

O AWS Glue é compatível com acesso total à tabela (FTA) para tabelas protegidas pelo AWS Lake Formation. Isso permite que seus trabalhos de ETL leiam e gravem dados com permissões completas de tabela.

Pré-requisitos

- Perfis e permissões adequados do IAM
- AWS Lake Formation configurado para seu catálogo de dados
- Tipos de tabela compatíveis (Hive ou Iceberg)

Considerações importantes

Permissões obrigatórias

- Permissão `lakeformation:GetDataAccess` do IAM
- Permissões AWS Lake Formation de tabela
- Permissões de acesso ao bucket do Amazon S3

Tipos de tabela compatíveis

- Tabelas Hive
- Tabelas Iceberg

Limitações

- Não compatível com Spark Streaming
- Não pode ser usado simultaneamente com controle de acesso de alta granularidade.
- Não compatível com tabelas Delta ou Hudi

Práticas recomendadas

1. Antes da execução do trabalho, certifique-se de que os perfis do IAM estejam configurados corretamente.
2. Teste as permissões de acesso em um ambiente de desenvolvimento.
3. Monitore os logs de execução de trabalhos em busca de problemas relacionados à permissão.
4. Mantenha uma documentação clara dos padrões de acesso.

Solução de problemas

Os problemas comuns incluem:

- Ausência de permissões do IAM
- Configuração incorreta do AWS Lake Formation
- Problemas de compatibilidade de tipo de tabela

Para obter instruções completas de configuração e detalhes de configuração, consulte Using AWS Lake Formation with full table access.

Solução de problemas de conexão no AWS Glue

Quando um crawler ou um trabalho do AWS Glue usa propriedades de conexão para acessar um armazenamento de dados, você pode encontrar erros ao tentar se conectar. O AWS Glue usa endereços IP privados na sub-rede ao criar interfaces de rede elástica na nuvem privada virtual (VPC) e sub-rede especificadas. Grupos de segurança especificados na conexão do são aplicados a cada uma das interfaces de rede elásticas. Verifique se os security groups concedem acesso de saída e permitem conectividade com o cluster de banco de dados.

Além disso, o Apache Spark exige conectividade bidirecional entre os nós do driver e do executor. Um dos security groups precisa permitir regras de entrada em todas as portas TCP. Você pode impedir que o security group seja aberto ao público, restringindo sua fonte para ele próprio com um security group de autorreferência.

Veja a seguir algumas ações típicas que você pode realizar para solucionar problemas de conexão:

- Verifique o endereço da porta da sua conexão.

- Verifique a string de nome de usuário e senha na sua conexão ou segredo.
- Para um armazenamento de dados JDBC, verifique se ele permite conexões de entrada.
- Verifique se seu armazenamento de dados pode ser acessado dentro da VPC.
- Se você armazenar suas credenciais de conexão usando o AWS Secrets Manager, verifique se o perfil do IAM para o AWS Glue tem permissão para acessar seu segredo. Para obter mais informações, consulte Exemplo: permissão para recuperar valores de segredos no Guia do usuário do AWS Secrets Manager. Dependendo da sua configuração de rede, talvez também seja necessário criar um endpoint da VPC para estabelecer uma conexão privada entre sua VPC e o Secrets Manager. Para obter mais informações, consulte Usar um endpoint da VPC no AWS Secrets Manager.

Tutorial: Usar o AWS Glue Connector for Elasticsearch

O Elasticsearch é um conhecido mecanismo de pesquisa e análise de código aberto para casos de uso, como análise de logs, monitoramento de aplicações em tempo real e análise de transmissões de cliques. Você pode usar o OpenSearch como um armazenamento de dados para seus trabalhos de extração, transformação e carregamento (ETL) configurando o AWS Glue Connector for Elasticsearch no AWS Glue Studio. Esse conector está disponível gratuitamente no AWS Marketplace.

> **Note**
>
> O AWS Marketplace Elasticsearch Spark Connector foi descontinuado. Use o AWS Glue Connector for Elasticsearch em seu lugar.

Neste tutorial, mostraremos como se conectar aos nós do Amazon OpenSearch Service com um número mínimo de etapas.

Tópicos

- Pré-requisitos
- Etapa 1: (opcional) Criar um segredo da AWS para as informações do cluster do OpenSearch
- Etapa 2: Assinar o conector
- Etapa 3: Ativar o conector no AWS Glue Studio e criar uma conexão
- Etapa 4: Configurar uma função do IAM para o trabalho de ETL

- Etapa 5: Criar um trabalho que usa a conexão do OpenSearch
- Etapa 6: Executar o trabalho

Pré-requisitos

Para usar este tutorial, você deve ter o seguinte:

- Acessar o AWS Glue Studio
- Acesso a um cluster do OpenSearch na Nuvem AWS
- (Opcional) Acesso ao AWS Secrets Manager.

Etapa 1: (opcional) Criar um segredo da AWS para as informações do cluster do OpenSearch

Para armazenar e usar com segurança sua credencial de conexão, salve-a no AWS Secrets Manager. O segredo que você criar será usado pela conexão, mais tarde no tutorial. Os pares chave-valor de credenciais serão alimentados no AWS Glue Connector for Elasticsearch como opções de conexão normais.

Para obter mais informações sobre criação de segredos, consulte Criar e gerenciar segredos com o AWS Secrets Manager no Manual do usuário do AWS Secrets Manager.

Para criar um segredo da AWS

1. Faça login no console do AWS Secrets Manager.
2. Na página de introdução do serviço ou na página da lista de Secrets (Segredos), escolha Store a new secret (Armazenar um novo segredo).
3. Na página Store a new secret (Armazenar um novo segredo), selecione Other type of secret (Outro tipo de segredo). Essa opção significa que você precisa fornecer a estrutura e os detalhes do seu segredo.
4. Adicione um par de Key (Chave) e Value (Valor) para o nome de usuário do cluster do OpenSearch. Por exemplo:

   `es.net.http.auth.user`: *`nome de usuário`*
5. Escolha + Add row (Adicionar linha) e insira outro par de chave-valor para a senha. Por exemplo:

`es.net.http.auth.pass`: *senha*

6. Escolha Próximo.
7. Insira um nome para o segredo. Por exemplo: meu-segredo-es. Se preferir, você também pode inserir uma descrição.

   Registre o nome secreto, que é usado posteriormente neste tutorial, e escolha Next (Próximo).
8. Escolha Next (Próximo) novamente e, depois, escolha Store (Armazenar) para criar o segredo.

Próxima etapa

Etapa 2: Assinar o conector

Etapa 2: Assinar o conector

O AWS Glue Connector for Elasticsearch está disponível gratuitamente no AWS Marketplace.

Para assinar o AWS Glue Connector for Elasticsearch no AWS Marketplace

1. Se você ainda não configurou a conta da AWS para usar o License Manager, faça o seguinte:
   a. Abra o console do AWS License Manager em https://console.aws.amazon.com/license-manager.
   b. Escolha Create customer managed license (Criar licença gerenciada pelo cliente).
   c. Na janela Permissões do IAM (configuração única), escolha Concedo as permissões necessárias ao AWS License Manager e depois escolha Conceder permissões.

      Se você não vir essa janela, você já configurou as permissões necessárias.
2. Abra o console do AWS Glue Studio em https://console.aws.amazon.com/gluestudio/.
3. No console do AWS Glue Studio, expanda o ícone de menu
   ( )
   e escolha Connectors (Conectores) no painel de navegação.
4. Na página Conectores, escolha Ir para o AWS Marketplace.
5. No AWS Marketplace, na seção Pesquisar produtos da AWS Glue Studio, insira Conector do AWS Glue para Elasticsearch no campo de pesquisa e pressione Enter.
6. Escolha o nome do conector, AWS Glue Connector for Elasticsearch.

7. Na página de produto do conector, use as guias para visualizar informações sobre o conector. Quando estiver tudo pronto para continuar, escolha Continue to Subscribe (Avançar para assinar).
8. Revise e aceite os termos de uso do software. Clique em Accept Terms (Aceitar os termos).
9. Quando o processo de assinatura for concluído, você verá uma notificação: "Thank you for subscribing to this product! You can now configure your software" (Obrigado por assinar este produto! Agora você pode configurar o software). Acima do banner, encontra-se o botão Continue to Configuration(Continuar em Configuração). Escolha Continue to Configuration (Continuar para configuração).
10. Escolha a opção Fulfillment (Atendimento) na página Configure this software (Configurar este software). Você também pode escolher o AWS Glue 1.0/2.0 ou o AWS Glue 3.0. Em seguida, escolha Continue to Launch (Continuar em Iniciar).

Próxima etapa

Etapa 3: Ativar o conector no AWS Glue Studio e criar uma conexão

Etapa 3: Ativar o conector no AWS Glue Studio e criar uma conexão

Depois de escolher Continue to Launch (Avançar para iniciar), você verá a página Launch this software (Iniciar este software) no AWS Marketplace. Depois de usar o link para ativar o conector no AWS Glue Studio, você cria uma conexão.

Para implantar o conector e criar uma conexão no AWS Glue Studio

1. Na página Launch this software (Iniciar este software) no console do AWS Marketplace, escolha Usage Instructions (Instruções de uso) e, em seguida, selecione o link na janela exibida.

   Seu navegador é redirecionado para a página Create marketplace connection (Criar conexão com o marketplace) do console do AWS Glue Studio.
2. Insira um nome para a conexão. Por exemplo: minha-conexão-es.
3. Na seção Connection access (Acesso à conexão), em Connection credential type (Tipo de credencial de conexão), escolha User name and password (Nome de usuário e senha).
4. Em segredo da AWS, insira o nome do seu segredo. Por exemplo: meu-segredo-es.
5. Na seção Network options (Opções de rede), insira as informações da VPC para conectar ao cluster do OpenSearch.

6. Esoclha Create connection and activate connector (Criar conexão e ativar o conector).

Próxima etapa

Etapa 4: Configurar uma função do IAM para o trabalho de ETL

Etapa 4: Configurar uma função do IAM para o trabalho de ETL

Ao criar o trabalho de ETL do AWS Glue, você especifica uma função do AWS Identity and Access Management (IAM) para o trabalho usar. A função deve conceder acesso a todos os recursos usados pelo trabalho, incluindo o Amazon S3 (para quaisquer origens, destinos, scripts, arquivos de driver e diretórios temporários) e também objetos do AWS Glue Data Catalog.

A função do IAM assumida para o trabalho de ETL do AWS Glue também deve ter acesso ao segredo que foi criado na seção anterior. Por padrão, a função gerenciada pela AWS `AWSGlueServiceRole` não tem acesso ao segredo. Para configurar o controle de acesso a seus segredos, consulte Autenticação e controle de acesso para o AWS Secrets Manager e Limitar acesso a segredos específicos.

Para configurar uma função do IAM para o trabalho de ETL

1. Configure as permissões descritas em the section called “Revise IAM as permissões necessárias para ETL trabalhos”.
2. Configure as permissões adicionais necessárias ao usar conectores com o AWS Glue Studio, conforme descrito em the section called “Permissões necessárias para usar conectores”.

Próxima etapa

Etapa 5: Criar um trabalho que usa a conexão do OpenSearch

Etapa 5: Criar um trabalho que usa a conexão do OpenSearch

Depois de criar uma função para o seu trabalho de ETL, você pode criar um trabalho no AWS Glue Studio que usa a conexão e o conector para o Open Spark ElasticSearch.

Se seu trabalho for executado em uma Amazon Virtual Private Cloud (Amazon VPC), certifique-se de que a VPC esteja configurada corretamente. Para ter mais informações, consulte the section called “Configurar uma VPC para seu trabalho de ETL”.

Para criar um trabalho que usa o Elasticsearch Spark Connector

1. Em AWS Glue Studio, escolha Connectors (Conectores).
2. Na lista Your connections (Suas conexões), selecione a conexão que você acabou de criar e escolha Create job (Criar trabalho).
3. No editor de trabalhos visual, escolha o nó de origem dos dados. À direita, na guia Data source properties - Connector (Propriedades da origem dos dados: conector), configure informações adicionais para o conector.

   a. Escolha Add schema (Adicionar esquema) e insira o esquema do conjunto de dados na origem dos dados. As conexões não usam tabelas armazenadas no Data Catalog, o que significa que AWS Glue Studio não conhece o esquema dos dados. Você deve fornecer manualmente essas informações de esquema. Para obter instruções sobre como usar o editor de esquemas, consulte the section called “Editar o esquema de um nó de transformação personalizada”.

   b. Expanda Connection options (Opções de conexão).

   c. Escolha Add new option (Adicionar nova opção) e insira as informações necessárias para o conector que não foram inseridas no segredo da AWS:

      - es.nodes: https://<endpoint do domínio do OpenSearch>
      - es.port: 443
      - path: test
      - es.nodes.wan.only: true

      Para obter uma explicação sobre essas opções de conexão, consulte: https://www.elastic.co/guide/en/elasticsearch/hadoop/current/configuration.html.

4. Adicione um nó de destino ao gráfico.

   Seu destino de dados pode ser o Amazon S3 ou pode usar informações de um AWS Glue Data Catalog ou um conector para gravar dados em um local diferente. Por exemplo, você pode usar uma tabela do Data Catalog para gravar em um banco de dados no Amazon RDS ou pode usar um conector como destino de dados para gravar em armazenamentos de dados que não são suportados nativamente no AWS Glue.

   Se você escolher um conector para o destino dos dados, deverá escolher uma conexão criada para esse conector. Além disso, se exigido pelo provedor do conector, você deve adicionar

opções para fornecer mais informações ao conector. Se você usar uma conexão que contenha informações para um segredo da AWS, então não será preciso fornecer a autenticação com o nome do usuário e senha nas opções de conexão.

5. Opcionalmente, adicione mais fontes de dados, e um ou mais nós de transformação, conforme descrito em the section called “Transformar dados com transformações gerenciadas do AWS Glue”.
6. Configure as propriedades do trabalho conforme descrito em the section called “Modificar as propriedades do trabalho”, começando com a etapa 3, e salve o trabalho.

Próxima etapa

Etapa 6: Executar o trabalho

Etapa 6: Executar o trabalho

Depois de salvar o trabalho, você pode executá-lo para realizar as operações de ETL.

Para executar o trabalho que você criou para o AWS Glue Connector for Elasticsearch

1. Usando o console do AWS Glue Studio, na página do editor visual, escolha Run (Executar).
2. No banner de sucesso, escolha Run Details (Detalhes da execução), ou você pode escolher a opção Runs (Execuções) do editor visual para visualizar informações sobre a execução do trabalho.

Criando AWS Glue trabalhos com sessões interativas

Os engenheiros de dados podem criar trabalhos do AWS Glue de forma mais fácil e rápida do que antes usando sessões interativas no AWS Glue.

Tópicos

- Visão geral das sessões interativas do AWS Glue
- Conceitos básicos das sessões interativas do AWS Glue
- Configuração de sessões interativas do AWS Glue para cadernos do Jupyter e do AWS Glue Studio
- Converter um script ou caderno em um trabalho do AWS Glue
- Trabalhar com operações de streaming em sessões do AWS Glue interativas
- Desenvolver e testar scripts de trabalho do AWS Glue localmente
- Endpoints de desenvolvimento

Visão geral das sessões interativas do AWS Glue

Com as sessões interativas do AWS Glue, você pode criar, testar e executar aplicações de analytics e preparação de dados rapidamente. As sessões interativas fornecem uma interface programática e visual para criação e teste de scripts de extração, transformação e carregamento (ETL) para preparação de dados. As sessões interativas executam aplicações de analytics do Apache Spark e fornecem acesso sob demanda a um ambiente do runtime remoto do Spark. O AWS Glue gerencia de forma transparente o Spark sem servidor para essas sessões interativas.

Sessões interativas são flexíveis, portanto você pode criar e testar aplicações a partir do ambiente de sua escolha. Você pode criar e trabalhar com sessões interativas por meio do AWS Command Line Interface e da API. Você pode usar cadernos compatíveis com o Jupyter para criar e testar visualmente seus scripts de caderno. As sessões interativas fornecem um kernel do Jupyter de código aberto que se integra em quase qualquer lugar que o Jupyter o faça, incluindo a integração com IDEs como PyCharm, IntelliJ e VS Code. Isso permite que você crie código em seu ambiente local e execute-o perfeitamente no backend de sessões interativas.

Usando a API de sessões interativas, os clientes podem executar programaticamente as aplicações que usam a analytics do Apache Spark sem necessidade de gerenciar a infraestrutura do Spark. Você pode executar uma ou mais instruções do Spark em uma única sessão interativa.

As sessões interativas, portanto, fornecem uma maneira mais rápida, barata e mais flexível de criar e executar aplicações de analytics e preparação de dados. Para aprender a usar sessões interativas, consulte a documentação nesta seção. Magic suportado pelo AWS Glue

Limitações

- Marcadores de trabalho não são compatíveis com sessões interativas.
- A criação de trabalhos de caderno usando a AWS Command Line Interface não tem suporte.
- Cadernos do AWS Glue Studio não são compatíveis com Scala.

Conceitos básicos das sessões interativas do AWS Glue

Estas seções descrevem como executar sessões interativas do AWS Glue localmente.

Pré-requisitos para configurar sessões interativas localmente

Veja a seguir os pré-requisitos para instalar sessões interativas:

- As versões compatíveis do Python são 3.6 a 3.10+.
- Veja as seções abaixo para obter instruções para macOS/Linux e Windows.

Instalação do Jupyter e de kernels do Jupyter para sessões interativas do AWS Glue

Use o seguinte para instalar o kernel localmente.

O comando, `install-glue-kernels`, instala o jupyter kernelspec para os kernels pyspark e spark e também instala logos no diretório correto.

```
pip3 install --upgrade jupyter boto3 aws-glue-sessions
```

```
install-glue-kernels
```

Execução do Jupyter

Conclua as etapas a seguir para executar o Jupyter Notebook.

1. Para executar o Jupyter Notebook, execute o comando a seguir.

```
jupyter notebook
```

2. Escolha New (Novo) e escolha um dos kernels do AWS Glue para começar a codificar no AWS Glue.

Configuração de credenciais e região da sessão

Instruções para macOS/Linux

As sessões interativas do AWS Glue exigem as mesmas permissões do IAM que trabalhos e endpoints de desenvolvimento do AWS Glue. Especifique a função usada com sessões interativas de uma das duas formas a seguir:

1. Com as mágicas `%iam_role` e `%region`
2. Com uma linha adicional em `~/.aws/config`

Configurar uma função de sessão com mágica

Na primeira célula, digite `%iam_role <YourGlueServiceRole>` na primeira célula executada.

Configurar uma função de sessão com **`~/.aws/config`**

É possível especificar o perfil de serviço do AWS Glue para sessões interativas no próprio caderno ou armazená-la junto com a configuração da AWS CLI. Se tiver uma função que você costuma usar com trabalhos do AWS Glue, essa será a função. Se não tiver um perfil que você usa para trabalhos do AWS Glue, siga as instruções neste guia Configurar permissões do IAM para o AWS Glue a fim de configurar um.

Para definir essa função como a função padrão para sessões interativas:

1. Em um editor de texto, abra `~/.aws/config`.
2. Procure o perfil que você usa para o AWS Glue. Se você não usar um perfil, use o perfil `[Default]`.
3. Adicione uma linha no perfil para a função que você pretende usar como `glue_role_arn=<AWSGlueServiceRole>`.

4. [Opcional]: se o seu perfil não tiver uma região padrão definida, é recomendável adicionar uma com `region=us-east-1`, substituindo `us-east-1` pela região desejada.
5. Salve a configuração.

Para ter mais informações, consulte Sessões interativas com o IAM.

Instruções para Windows

As sessões interativas do AWS Glue exigem as mesmas permissões do IAM que trabalhos e endpoints de desenvolvimento do AWS Glue. Especifique a função usada com sessões interativas de uma das duas formas a seguir:

1. Com as mágicas `%iam_role` e `%region`
2. Com uma linha adicional em `~/.aws/config`

Configurar uma função de sessão com mágica

Na primeira célula, digite `%iam_role <YourGlueServiceRole>` na primeira célula executada.

Configurar um perfil de sessão com o **`~/.aws/config`**

É possível especificar o perfil de serviço do AWS Glue para sessões interativas no próprio caderno ou armazená-la junto com a configuração da AWS CLI. Se tiver uma função que você costuma usar com trabalhos do AWS Glue, essa será a função. Se não tiver uma função que você usa para trabalhos do AWS Glue, siga as instruções no guia Configurar permissões do IAM para o AWS Glue a fim de configurar uma.

Para definir essa função como a função padrão para sessões interativas:

1. Em um editor de texto, abra `~/.aws/config`.
2. Procure o perfil que você usa para o AWS Glue. Se você não usar um perfil, use o perfil `[Default]`.
3. Adicione uma linha no perfil para a função que você pretende usar como `glue_role_arn=<AWSGlueServiceRole>`.
4. [Opcional]: se o seu perfil não tiver uma região padrão definida, é recomendável adicionar uma com `region=us-east-1`, substituindo `us-east-1` pela região desejada.
5. Salve a configuração.

Para ter mais informações, consulte Sessões interativas com o IAM.

Atualização com base na prévia das sessões interativas

O kernel foi atualizado com novos nomes quando foi lançado com a versão 0.27. Para limpar as versões de prévia dos kernels, execute o seguinte em um terminal ou PowerShell.

> **Note**
>
> Se você fizer parte de qualquer outra prévia do AWS Glue que exija um modelo de serviço personalizado, remover o kernel removerá o modelo de serviço personalizado.

```
# 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/
```

Usar sessões interativas com o SageMaker AI Studio

Sessões interativas do AWS Glue é um ambiente de runtime do Apache Spark sob demanda e sem servidor que cientistas e engenheiros de dados podem usar para criar, testar e executar aplicações de analytics e preparação de dados rapidamente. É possível executar uma sessão interativa do AWS Glue iniciando um caderno do Amazon SageMaker AI Studio Classic.

Para obter mais informações, consulte Preparar dados usando sessões interativas do AWS Glue.

Uso de sessões interativas com o Microsoft Visual Studio Code

Pré-requisitos

- Instale as sessões interativas do AWS Glue e verifique se funcionam com o Jupyter Notebook.
- Baixe e instale o Visual Studio Code with Jupyter. Para mais detalhes, consulte Jupyter Notebook in VS Code (Jupyter Notebook no VS Code).

Para começar com sessões interativas com o VSCode

1. Desabilite a inicialização automática do Jupyter no VS Code.

   No Visual Studio Code, os kernels do Jupyter serão iniciados automaticamente, o que impedirá que suas mágicas entrem em vigor, pois a sessão já terá sido iniciada. Para desativar o início automático no Windows, vá para Arquivo > Preferências > Extensões > Jupyter > clique com o botão direito do mouse em Jupyter e escolha Configurações de extensão.

   No MacOS, vá para Código > Configurações > Extensões > Jupyter > clique com o botão direito do mouse em Jupyter e escolha Configurações de extensão.

   Role para baixo até ver Jupyter: desativar o início automático do Jupyter. Marque a caixa “Quando verdadeiro, desativa a inicialização automática do Jupyter para você. Em vez disso, execute uma célula para iniciar o Jupyter."

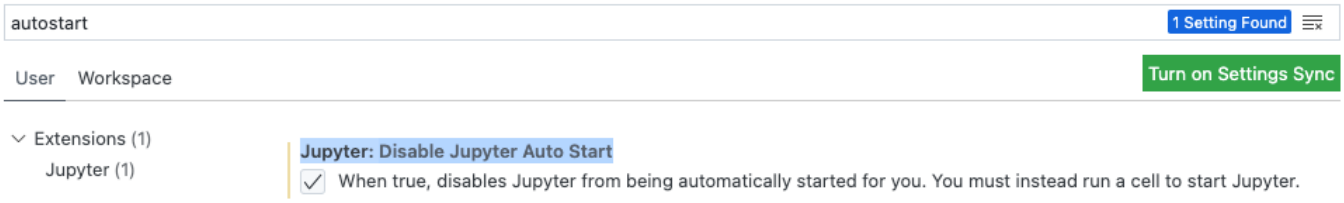

2. Acesse File > New File > Save (Arquivo > Novo arquivo > Salvar) para salvar o arquivo atual com o nome de sua preferência com uma extensão `.ipynb` ou selecione jupyter em select a language (selecionar um idioma) e salve o arquivo.

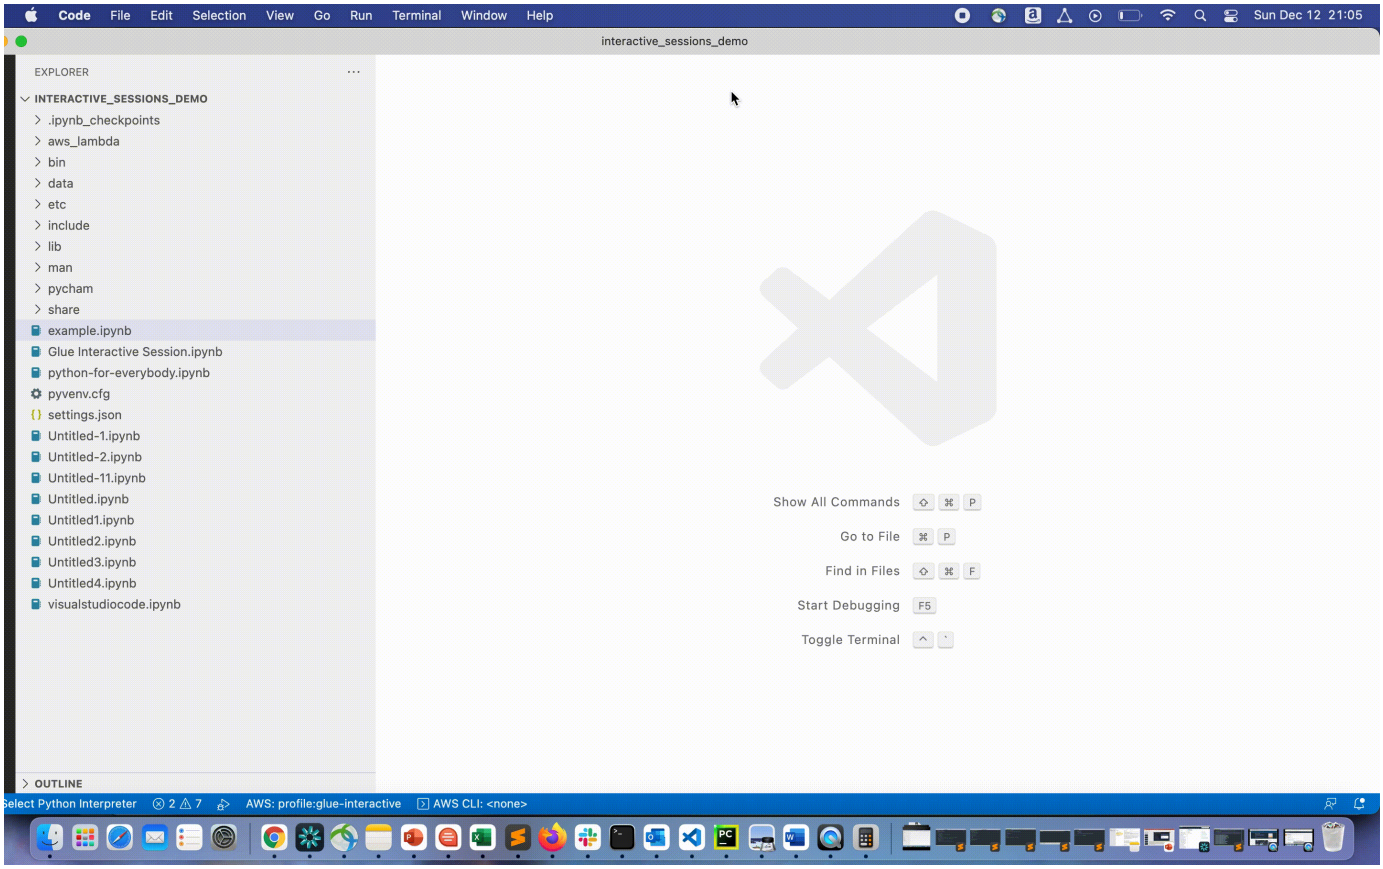

3. Clique duas vezes no arquivo. O shell do Jupyter será exibido e um caderno será aberto.

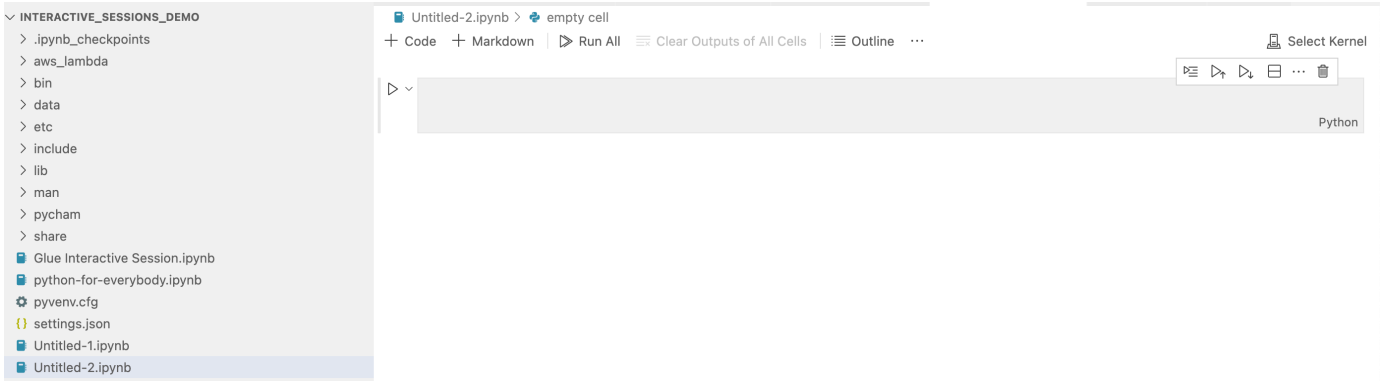

4. No Windows, quando você cria um arquivo pela primeira vez, por padrão nenhum kernel é selecionado. Clique em Select Kernel (Selecionar kernel) e uma lista de kernels disponíveis será exibida. Escolha Glue PySpark.

   No MacOS, se você não encontrar o kernel do Glue PySpark, tente as seguintes etapas:

   1. Execute uma sessão local do Jupyter para obter o URL.

      Por exemplo, execute o comando a seguir para executar o caderno Jupyter.

```
jupyter notebook
```

Quando o caderno for executado pela primeira vez, você verá uma URL parecida com `http://localhost:8888/?token=3398XXXXXXXXXXXXXXX`.

Copie o URL.

2. No VS Code, clique no kernel atual e Selecionar outro kernel..., e selecione Servidor Jupyter existente.... Cole o URL que você copiou da etapa acima.

   Se você receber uma mensagem de erro, consulte o wiki do VS Code Jupyter.

3. Se for bem-sucedido, isso definirá o kernel como Glue PySpark.

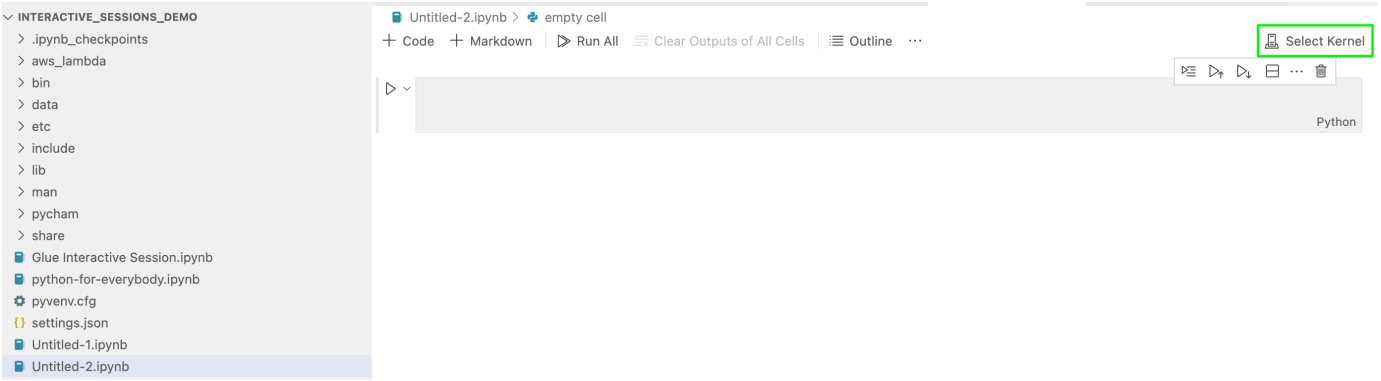

Selecione o kernel Glue PySpark ou Glue Spark (para Python e Scala, respectivamente).

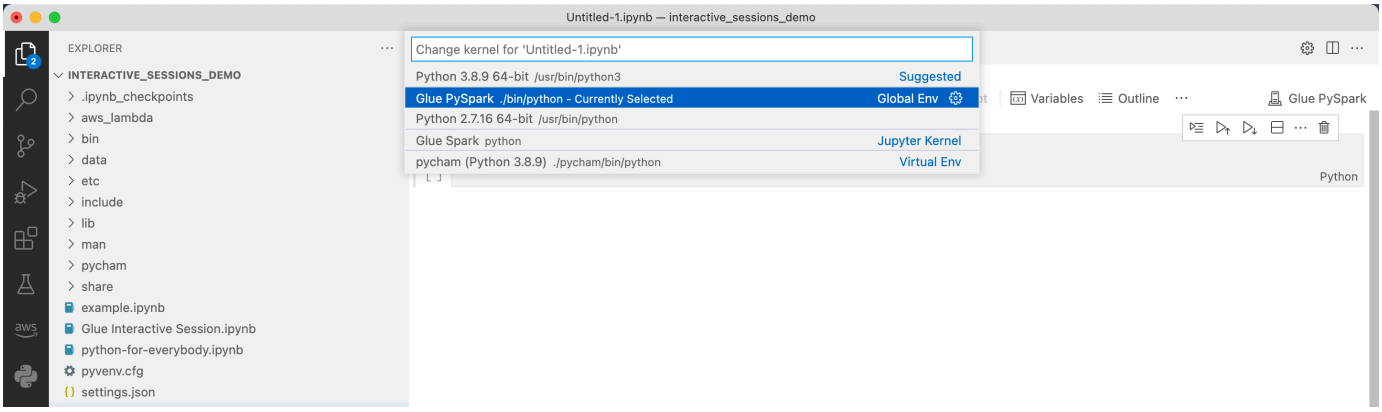

Caso não encontre os kernels AWS Glue PySpark e AWS Glue Spark na lista suspensa, verifique se instalou o kernel AWS Glue na etapa acima ou se a configuração `python.defaultInterpreterPath` do Visual Studio Code está correta. Para obter mais informações, consulte a descrição da configuração python.defaultInterpreterPath.

5. Criar um AWS Glue Interactive Session. Prossiga para criar uma sessão da mesma maneira que você fez no caderno Jupyter. Especifique qualquer mágica na parte superior da primeira célula e execute uma declaração de código.

Sessões interativas com o IAM

Essas seções descrevem as considerações de segurança para sessões interativas do AWS Glue.

Tópicos

- Entidades principais do IAM usadas com sessões interativas
- Configuração de uma entidade principal do cliente
- Configuração de uma função do runtime
- Tornar sua sessão privada com TagOnCreate
- Considerações sobre políticas do IAM

Entidades principais do IAM usadas com sessões interativas

Você usa duas entidades principais do IAM com sessões interativas do AWS Glue

- Client principal (Entidade principal do cliente): a entidade principal do cliente (um usuário ou perfil) autoriza operações de API para sessões interativas de um cliente do AWS Glue configurado com as credenciais baseadas na identidade da entidade principal. Por exemplo, poderia ser um perfil do IAM que você normalmente usa para acessar o console do AWS Glue. Também poderia ser um perfil atribuído a um usuário do IAM cujas credenciais são usadas para a AWS Command Line Interface ou um cliente do AWS Glue usado pelo kernel de sessões interativas do Jupyter.
- Perfil de runtime: o perfil de runtime é um perfil do IAM que a entidade principal do cliente repassa para as operações de API de sessões interativas. O AWS Glue usa esse perfil para executar instruções na sessão. Por exemplo, essa função pode ser a usada para execução de trabalhos de ETL do AWS Glue.

  Para ter mais informações, consulte Configuração de uma função do runtime.

Configuração de uma entidade principal do cliente

Você deve anexar uma política de identidade à entidade principal do cliente para permitir que ela chame a API de sessões interativas. Esse perfil deve ter acesso de `iam:PassRole` ao perfil de

execução que você repassaria para a API de sessões interativas, como `CreateSession`. Por exemplo, é possível anexar a política gerenciada AWSGlueConsoleFullAccess a um perfil do IAM, a qual permite que todos os usuários do IAM na conta com a política anexada acessem todas as sessões criadas nessa conta (por exemplo, a instrução de runtime ou a instrução de cancelamento).

Se você quiser proteger a sessão e torná-la privada apenas para certos perfis do IAM, como os associados ao usuário que criou a sessão, é possível usar o controle de autorização baseado em tag de sessão interativa do AWS Glue, denominado TagOnCreate. Para obter mais informações, consulte Tornar sua sessão privada com TagOnCreate sobre como uma política gerenciada com escopo reduzido e baseada em etiquetas de proprietário pode tornar sua sessão privada com TagOnCreate. Para obter mais informações sobre políticas baseadas em identidade, consulte Políticas baseadas em identidade para o AWS Glue.

Configuração de uma função do runtime

Você deve passar uma função do IAM para a operação da API CreateSession para permitir que o AWS Glue assuma e execute instruções em sessões interativas. A função deve ter as mesmas permissões do IAM que as necessárias para execução de um trabalho típico do AWS Glue. Por exemplo, você pode criar uma função de serviço usando a política AWSGlueServiceRole que permite que o AWS Glue chame serviços da AWS em seu nome. Se você usar o console do AWS Glue, ele criará automaticamente uma função de serviço em seu nome ou usará uma existente. Você também pode criar sua própria função do IAM e anexar sua própria política do IAM para permitir permissões semelhantes.

Se você quiser proteger a sessão e torná-la privada apenas para o usuário do IAM que a criou, é possível usar o controle de autorização baseado em tag de sessão interativa do AWS Glue, denominado TagOnCreate. Para obter mais informações, consulte Tornar sua sessão privada com TagOnCreate sobre como uma política gerenciada com escopo reduzido e baseada em etiquetas de proprietário pode tornar sua sessão privada com TagOnCreate. Para obter mais informações sobre políticas baseadas em identidade, consulte Políticas baseadas em identidade para Glue AWS. Se você estiver criando a função de execução por conta própria diretamente do console do IAM e quiser tornar seu serviço privado com o recurso TagOnCreate, siga as etapas abaixo.

1. Crie uma função do IAM com o tipo de função definido como `Glue`.
2. Anexe a seguinte política gerenciada do AWS Glue: AwsGlueSessionUserRestrictedServiceRole
3. Adicione o prefixo do nome da política AwsGlueSessionUserRestrictedServiceRole ao nome da função. Por exemplo, é possível criar uma função com o nome

AwsGlueSessionUserRestrictedServiceRole-myrole e anexar a política gerenciada AwsGlueSessionUserRestrictedServiceRole do AWS Glue.

4. Anexe uma política de confiança como a seguinte para permitir que o AWS Glue assuma a função:

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

Para um kernel do Jupyter de sessões interativas, você pode especificar a chave `iam_role` em seu perfil da AWS Command Line Interface. Para obter mais informações, consulte Configurar sessões com ~/.aws/config. Se você estiver interagindo com sessões interativas usando um bloco de anotações do AWS Glue, poderá passar o perfil de execução no magic `%iam_role`, na primeira célula que executar.

Tornar sua sessão privada com TagOnCreate

As sessões interativas do AWS Glue são compatíveis com marcação e Tag Based Authorization (TBAC – Autorização baseada em etiquetas) para sessões interativas como um recurso nomeado. Além da TBAC usando as APIs TagResource e UntagResource, as sessões interativas do AWS Glue são compatíveis com o recurso TagOnCreate para “etiquetar” uma sessão com uma determinada etiqueta somente durante a criação da sessão com a operação CreateSession. Isso também significa que essas etiquetas serão removidas com DeleteSession, também conhecido por UntagOnDelete.

O recurso TagOnCreate oferece um poderoso mecanismo de segurança para tornar sua sessão privada para o criador da sessão. Por exemplo, você pode anexar uma política do IAM com a

RequestTag “owner“ e o valor de ${aws:userId} a uma entidade principal de cliente (por exemplo, um usuário do IAM) para só permitir a criação de uma sessão se uma tag “owner” com um valor correspondente de userId dos chamadores for fornecida como a tag userId na solicitação CreateSession. Essa política permite que as sessões interativas do AWS Glue criem um recurso de sessão e marquem a sessão com a etiqueta userId somente durante o tempo de criação da sessão. Além disso, é possível reduzir o escopo do acesso (por exemplo, execução de instruções) à sessão somente ao criador (também conhecido como etiqueta de proprietário com o valor ${aws:userId}) da sessão anexando uma política do IAM com o ResourceTag “owner” ao perfil de execução que você transmitiu durante CreateSession.

A fim de facilitar o uso do recurso TagOnCreate para tornar uma sessão privada para o criador da sessão, o AWS Glue fornece políticas gerenciadas e funções de serviço especializadas.

Se quiser criar uma sessão interativa do AWS Glue usando uma entidade principal AssumeRole do IAM (ou seja, usando uma credencial fornecida assumindo um perfil do IAM) e desejar tornar a sessão privada para o criador, use políticas semelhantes às AWSGlueSessionUserRestrictedNotebookPolicy e AWSGlueSessionUserRestrictedNotebookServiceRole respectivamente. Essas políticas permitem que o AWS Glue use ${aws:PrincipalTag} para extrair o valor da etiqueta do proprietário. Isso requer que você repasse uma etiqueta userId com o valor ${aws:userId} como SessionTag na credencial de assumir função. Consulte Etiquetas de sessão de ID. Se você estiver usando uma instância do Amazon EC2 com um perfil da instância que distribui a credencial e quiser criar uma sessão ou interagir com a sessão diretamente da instância do Amazon EC2, será necessário repassar uma etiqueta userId com o valor ${aws:userId} como SessionTag na credencial de assumir função.

Por exemplo, se você estiver criando uma sessão usando uma credencial de entidade principal AssumeRole do IAM e quiser tornar seu serviço privado com o recurso TagOnCreate, siga as etapas abaixo.

1. Crie você mesmo uma função de runtime no console do IAM. Anexe a política gerenciada AwsGlueSessionUserRestrictedNotebookServiceRole do AWS Glue e adicione o prefixo do nome da política AwsGlueSessionUserRestrictedNotebookServiceRole ao nome da função. Por exemplo, você pode criar uma função com o nome AwsGlueSessionUserRestrictedNotebookServiceRole-myrole e anexar a política gerenciada AwsGlueSessionUserRestrictedNotebookServiceRole do AWS Glue.
2. Anexe uma política de confiança como a exibida abaixo para permitir que o AWS Glue assuma a função acima.

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

3. Crie outra função nomeada com um prefixo AwsGlueSessionUserRestrictedNotebookPolicy e anexe a política gerenciada AwsGlueSessionUserRestrictedNotebookPolicy do AWS Glue para tornar a sessão privada. Além da política gerenciada, anexe a seguinte política em linha para permitir iam:PassRole para a função que você criou na etapa 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. Anexe uma política de confiança como a seguinte ao IAM acima para que o AWS Glue assuma a função.

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

> **Note**
>
> Opcionalmente, você pode usar uma só função (p. ex., função de caderno) e anexar ambas as políticas gerenciadas AwsGlueSessionUserRestrictedNotebookServiceRole e AwsGlueSessionUserRestrictedNotebookPolicy vistas acima. Anexe também a política em linha adicional para permitir `iam:passrole` da sua função para o AWS Glue. Por fim, anexe a política de confiança acima para permitir `sts:AssumeRole` e `sts:TagSession`.

AWSGlueSessionUserRestrictedNotebookPolicy

A política WSGlueSessionUserRestrictedNotebookPolicy só fornecerá acesso para criar uma sessão interativa do AWS Glue no caderno se houver uma chave de tag "owner" e um valor que corresponda ao ID de usuário da AWS da entidade principal (usuário ou perfil). Para mais informações, consulte

Onde você pode usar variáveis de política. Essa política é anexada à entidade principal (usuário ou perfil) que cria cadernos de sessões interativas do AWS Glue no AWS Glue Studio. Essa política também permite acesso suficiente ao bloco de anotações do AWS Glue Studio para interagir com os recursos da sessão interativa do AWS Glue Studio que são criados com o valor da etiqueta “owner” correspondente ao ID de usuário da AWS da entidade principal. Essa política nega permissão para alterar ou remover etiquetas “owner” de um recurso de sessão do AWS Glue após a criação da sessão.

AWSGlueSessionUserRestrictedNotebookServiceRole

AWSGlueSessionUserRestrictedNotebookServiceRole fornece acesso suficiente ao caderno do AWS Glue Studio para interagir com os recursos da sessão interativa do AWS Glue que forem criados com a tag "owner" e o valor correspondente ao ID de usuário da AWS da entidade principal (usuário ou perfil) do criador do caderno. Para mais informações, consulte Onde você pode usar variáveis de política. Essa política de função de serviço é anexada à função que é repassada como mágica para um caderno ou repassada como função de execução para a API CreateSession. Essa política também permite criar uma sessão interativa do AWS Glue com base em um bloco de anotações exclusivamente mediante uma chave de etiqueta “owner” e valor correspondente ao ID de usuário da AWS da entidade principal. Essa política nega permissão para alterar ou remover etiquetas “owner” de um recurso de sessão do AWS Glue após a criação da sessão. Essa política também inclui permissões para gravação e leitura de buckets do Amazon S3, gravação de logs do CloudWatch, criação e exclusão de tags para recursos do Amazon EC2 usados pelo AWS Glue.

Tornar sua sessão privada com políticas de usuário

Você pode anexar a política AWSGlueSessionUserRestrictedPolicy aos perfis do IAM anexados a cada um dos usuários da sua conta para impedir que eles criem uma sessão apenas com uma tag "owner" com um valor correspondente ao seu próprio ${aws:userId}. Em vez de usar o AWSGlueSessionUserRestrictedNotebookPolicy e AWSGlueSessionUserRestrictedNotebookServiceRole, você precisa usar políticas semelhantes às políticas AWSGlueSessionUserRestrictedPolicy e AWSGlueSessionUserRestrictedServiceRole, respectivamente. Para mais informações, consulte Usar políticas baseadas em identidade. Essa política limita o escopo do acesso a uma sessão apenas ao criador, a ${aws:userId} do usuário que criou a sessão com a tag "owner" com seu próprio ${aws:userId}. Se você mesmo tiver criado o perfil de execução usando o console do IAM seguindo as etapas em Configuração de uma função do runtime, então, além de anexar a política gerenciada AwsGlueSessionUserRestrictedPolicy, anexe também a política em linha a seguir para cada um dos usuários da sua conta para permitir `iam:PassRole` para o perfil de execução que você criou anteriormente.

```
{
    "Version": "2012-10-17",
    "Statement": [{
        "Effect": "Allow",
        "Action": [
            "iam:PassRole"
        ],
        "Resource": [
            "arn:aws:iam::*:role/AwsGlueSessionUserRestrictedServiceRole*"
        ],
        "Condition": {
            "StringLike": {
                "iam:PassedToService": [
                    "glue.amazonaws.com"
                ]
            }
        }
    }]
}
```

AWSGlueSessionUserRestrictedPolicy

A AWSGlueSessionUserRestrictedPolicy fornece acesso para criar uma sessão interativa do AWS Glue usando a API CreateSession somente mediante o fornecimento de uma chave de tag "owner" e valor correspondente ao ID de usuário da AWS. Essa política de identidade é anexada ao usuário do IAM que invoca a API CreateSession. Essa política também permite interagir com os recursos da sessão interativa do AWS Glue que foram criados com a etiqueta de “owner” (proprietário) e valor correspondente aos seus IDs de usuário da AWS. Essa política nega permissão para alterar ou remover etiquetas “owner” de um recurso de sessão do AWS Glue após a criação da sessão.

AWSGlueSessionUserRestrictedServiceRole

AWSGlueSessionUserRestrictedServiceRole fornece acesso total a todos os recursos do AWS Glue, com exceção das sessões e permite que os usuários criem e usem somente as sessões interativas associadas ao usuário. Esta política também inclui outras permissões necessárias pelo AWS Glue para gerenciar recursos do Glue em outros serviços da AWS. A política também permite adicionar tags aos recursos do AWS Glue em outros serviços da AWS.

Considerações sobre políticas do IAM

Sessões interativas são recursos do IAM no AWS Glue. Como elas são recursos do IAM, o acesso e a interação a uma sessão são regidos pelas políticas do IAM. Com base nas políticas do IAM anexadas a uma entidade principal do cliente ou função de execução configurada por um administrador, uma entidade principal do cliente (usuário ou função) poderá criar novas sessões e interagir com suas próprias sessões e outras sessões.

Se um administrador anexou uma política do IAM, como AWSGlueConsoleFullAccess ou AWSGlueServiceRole, que permita acesso a todos os recursos do AWS Glue nessa conta, as entidades principais clientes poderão colaborar entre si. Por exemplo, se as políticas permitirem, um usuário do IAM poderá interagir com as sessões criadas por outros usuários.

Se você quiser configurar uma política ajustada às suas necessidades específicas, consulte a documentação do IAM sobre configuração de recursos para uma política. Por exemplo, para isolar as sessões que pertencem a um usuário, você pode usar o atributo TagOnCreate que é compatível com as sessões interativas do AWS Glue. Consulte Tornar sua sessão privada com TagOnCreate .

As sessões interativas são compatíveis com a limitação de criação de sessões com base em determinadas condições da VPC. Consulte Controlar políticas que controlam configurações usando chaves de condição.

Configuração de sessões interativas do AWS Glue para cadernos do Jupyter e do AWS Glue Studio

Introdução às mágicas do Jupyter

As mágicas do Jupyter são comandos que podem ser executados no início de uma célula ou como um corpo inteiro de célula. As mágicas começam com `%` para mágicas de linha e `%%` para mágicas de células. Mágicas de linha, como `%region` e `%connections`, podem ser executadas com várias mágicas em uma célula ou com código incluído no corpo da célula, como no exemplo a seguir.

```
%region us-east-2
%connections my_rds_connection
dy_f = glue_context.create_dynamic_frame.from_catalog(database='rds_tables',
 table_name='sales_table')
```

As mágicas de célula devem usar toda a célula e podem fazer com que o comando englobe várias linhas. Veja um exemplo de `%%sql` abaixo.

```
%%sql
select * from rds_tables.sales_table
```

Mágicas compatíveis com sessões interativas do AWS Glue para Jupyter

Veja a seguir mágicas que você pode usar com sessões interativas do AWS Glue para cadernos do Jupyter.

Magics de sessões

Nome	Tipo	Descrição
`%help`	n/a	Retorna uma lista de descrições e tipos de entrada para todos os comandos magic.
`%profile`	String	Especifica um perfil na sua configuração da AWS a ser usada como provedor de credenciais.
`%region`	String	Especifica a Região da AWS na qual uma sessão será inicializada. Padrão do `~/.aws/configure.` Exemplo: `%region us-west-1`
`%idle_timeout`	Int	O número de minutos de inatividade após o qual uma sessão atingirá o tempo limite após a execução de uma célula. O valor de tempo limite de inatividade padrão para sessões de ETL do Spark é o tempo limite padrão, 2.880 minutos (48 horas). Para outros tipos de sessão, consulte a documentação correspondente. Exemplo: `%idle_timeout 3000`

Nome	Tipo	Descrição
`%session_id`	n/a	Retorna o ID da sessão em execução.
`%session_id_prefix`	String	Definir uma string que precederá todos os IDs de sessão no formato [prefixo_ id_sessão]-[id_sessão]. Um UUID aleatório será gerado se um ID de sessão não for fornecido. Essa mágica não é compatível quando você executa um caderno Jupyter no AWS Glue Studio. Exemplo: `%session_id_prefix 001`
`%status`		Retornar o status da atual da sessão AWS Glue, incluindo sua duração, configura ção e usuário/função responsável pela execução.
`%stop_session`		Interrompe a sessão atual.
`%list_sessions`		Lista todas as sessões em execução atualmente por nome e ID.
`%session_type`	String	Define o tipo de sessão como Streaming, ETL ou Ray. Exemplo: `%session_type Streaming`
`%glue_version`	String	A versão do AWS Glue a ser usada pela sessão. Exemplo: `%glue_version 3.0`

Mágica para selecionar tipos de trabalho

Nome	Tipo	Descrição
`%streaming`	Cadeia de caracteres	Altera o tipo de sessão para transmissão do AWS Glue.
`%etl`	String	Altera o tipo de sessão para ETL do AWS Glue.
%glue_ray	String	Altera o tipo de sessão para AWS Glue para Ray. Consulte Mágicas compatíveis com sessões interativas do AWS Glue Ray.

Mágicas de configuração do AWS Glue para Spark

A mágica `%%configure` é um dicionário formatado em json que consiste em todos os parâmetros de configuração para uma sessão. Cada parâmetro pode ser especificado aqui ou por meio de magics individuais.

Nome	Tipo	Descrição
`%%configure`	Dicionário	Especifica um dicionário formatado em JSON que consiste em todos os parâmetros de configuração para uma sessão. Cada parâmetro pode ser especificado aqui ou por meio de magics individuais. Para obter uma lista de parâmetros e exemplos de como usar `%%configure` , consulte %%configure argumentos da mágica da célula.
`%iam_role`	String	Especificar um ARN de função do IAM com o qual executar sua sessão. Padrão de ~/.aws/configure.

Nome	Tipo	Descrição
		Exemplo: `%iam_role AWSGlueServiceRole`
`%number_of_workers`	Int	O número de operadores de um worker_type definido que são alocados quando um trabalho é executado. `worker_type` também precisa estar definido. O `number_of_workers` padrão é 5. Exemplo: `%number_of_workers 2`
`%additional_python_modules`	Listar	Lista separada por vírgulas de módulos adicionais do Python para incluir no cluster (pode ser do Pypi ou do S3). Exemplo: `%additional_python_modules pandas, numpy` .

Nome	Tipo	Descrição

`%%tags`	String	Adiciona tags a uma sessão. Especifique as tags entre colchetes { }. Cada par de nomes de tag está entre parênteses (" ") e separado por uma vírgula (,).
		
		`%%tags`
		`{"billing":"Data-Platform",`
		`"team":"analytics"}`
		
		Use a mágica `%status` para ver as tags associadas à sessão.
		
		`%status`
		
		`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']`

Nome	Tipo	Descrição

`%%assume_role`	Dicionário	Especifique um dicionário formatado em json ou uma string ARN do perfil do IAM para criar uma sessão para acesso entre contas.
		
		Exemplo com ARN:
		
		`%%assume_role`
		`{`
		`  'arn:aws:iam::XXXXXXXXXXXX:`
		`role/AWSGlueServiceRole'`
		`}`
		
		Exemplo com credenciais:
		
		` %%assume_role`
		`{{`
		`    "aws_access_key_id" =`
		` "XXXXXXXXXXXX",`
		`    "aws_secret_access_key" =`
		` "XXXXXXXXXXXX",`
		`    "aws_session_token" =`
		` "XXXXXXXXXXXX"`
		`}}`

%%configure argumentos da mágica da célula

A mágica `%%configure` é um dicionário formatado em json que consiste em todos os parâmetros de configuração para uma sessão. Cada parâmetro pode ser especificado aqui ou por meio de magics individuais. Veja abaixo exemplos de argumentos compatíveis com a mágica da célula `%%configure`. Use o prefixo `--` para os argumentos de execução especificados para o trabalho. Exemplo:

```
%%configure
{
   "--user-jars-first": "true",
```

```
   "--enable-glue-datacatalog": "false"
}
```

Para obter mais informações sobre parâmetros de trabalho, consulte Parâmetros de trabalho.

Configuração da sessão

Parâmetro	Tipo	Descrição

`max_retries`	Int	O número máximo de novas tentativas desse trabalho em caso de falha.
		`%%configure`
		`{`
		`  "max_retries": "0"`
		`}`

`max_concurrent_runs`	Int	O número máximo de execuções simultâneas permitidas para um trabalho.
		Exemplo:
		`%%configure`
		`{`
		`  "max_concurrent_runs": "3"`
		`}`

Parâmetros da sessão

Parâmetro	Tipo	Descrição
`--enable-spark-ui`	Booleano	Ative a interface de usuário do Spark para monitorar e depurar trabalhos de AWS Glue ETL. `%%configure`

Parâmetro	Tipo	Descrição

		<pre>{
		  "--enable-spark-ui": "true"
		}</pre>

`--spark-event-logs-path`	String	Especifica um caminho do Amazon S3. Quando usar o atributo de monitoramento da interface do usuário do Spark.
		
		Exemplo:
		
		<pre>%%configure
		{
		  "--spark-event-logs-path":
		 "s3://path/to/event/logs/"
		}</pre>

`--script_location`	String	Especifica o caminho do S3 para um script que executa um trabalho.
		
		Exemplo:
		
		<pre>%%configure
		{
		  "script_location": "s3://new-
		folder-here"
		}</pre>

Parâmetro	Tipo	Descrição

`--SECURITY_CONFIGURATION`	String	O nome de uma configuração de segurança do AWS Glue.
		
		Exemplo:
		
		`%%configure`
		`{`
		`"--security_configuration": { "encryption_type": "kms", "kms_key_id": "YOUR_KMS_KEY_ARN" }`
		`}`

`--job-language`	String	A linguagem de programação de script. Aceita um valor de 'scala' ou 'python'. O padrão é 'python'.
		
		Exemplo:
		
		`%%configure`
		`{`
		`"--job-language": "scala"`
		`}`

Parâmetro	Tipo	Descrição

`--class`	String	A classe Scala que serve como ponto de entrada para o seu script Scala. O padrão é null.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--class": "className"`
		`}`

`--user-jars-first`	Booleano	Prioriza os arquivos JAR extras do cliente no classpath. O padrão é null.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--user-jars-first": "true"`
		`}`

`--use-postgres-driver`	Booleano	Prioriza o driver JDBC do Postgres no caminho da classe para evitar um conflito com o driver JDBC do Amazon Redshift. O padrão é null.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--use-postgres-driver": "true"`
		`}`

Parâmetro	Tipo	Descrição

`--extra-files`	List(string)	Os caminhos do Amazon S3 para arquivos adicionais, como arquivos de configuração, que o AWS Glue copia para o diretório de trabalho do script antes de executá-lo.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--extra-files": "s3://path/to/additional/files/"`
		`}`

`--job-bookmark-option`	String	Controla o comportamento de um marcador de trabalho. Aceita um valor de 'job-bookmark-enable', 'job-bookmark-disable' ou 'job-bookmark-pause'. O padrão é 'job-bookmark-disable'.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--job-bookmark-option": "job-bookmark-enable"`
		`}`

Parâmetro	Tipo	Descrição

`--TempDir`	String	Especifica um caminho do Amazon S3 para um bucket que pode ser usado como um diretório temporário para o trabalho. O padrão é null.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--TempDir": "s3://path/to/temp/dir"`
		`}`

`--enable-s3-parquet-optimized-committer`	Booleano	Habilita o committer otimizado para EMRFS otimizado para Amazon S3 a gravar dados Parquet no Amazon S3. O padrão é 'true'.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--enable-s3-parquet-optimized-committer": "false"`
		`}`

Parâmetro	Tipo	Descrição

`--enable-rename-algorithm-v2`	Booleano	Define a versão do algoritmo de renomeação do EMRFS como versão 2. O padrão é 'true'.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--enable-rename-algorithm-v2": "true"`
		`}`

`--enable-glue-datacatalog`	Booleano	Habilita o uso do catálogo de dados do AWS Glue como um metastore do Apache Spark Hive.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--enable-glue-datacatalog": "true"`
		`}`

`--enable-metrics`	Booleano	Habilita a coleta de métricas para criar perfis de trabalhos para a execução da tarefa. O padrão é 'false'.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--enable-metrics": "true"`
		`}`

Parâmetro	Tipo	Descrição

`--enable-continuous-cloudwatch-log`	Booleano	Habilita o registro em log contínuo em tempo real para trabalhos do AWS Glue. O padrão é 'false'.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--enable-continuous-cloudwatch-log": "true"`
		`}`

`--enable-continuous-log-filter`	Booleano	Especifica um filtro padrão ou nenhum filtro quando você cria ou edita um trabalho habilitado para registro em log contínuo. O padrão é 'true'.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--enable-continuous-log-filter": "true"`
		`}`

Parâmetro	Tipo	Descrição

`--continuous-log-stream-prefix`	String	Especifica um prefixo personalizado de fluxo de logs do Amazon CloudWatch para um trabalho habilitado para registro em log contínuo. O padrão é null.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--continuous-log-stream-prefix": "prefix"`
		`}`

`--continuous-log-conversionPattern`	String	Especifica um padrão personalizado de conversão de logs para um trabalho habilitado para registro em log contínuo. O padrão é null.
		
		Exemplo:
		
		`%%configure`
		`{`
		`  "--continuous-log-conversionPattern": "pattern"`
		`}`

Parâmetro	Tipo	Descrição

`--conf`	String	Controla os parâmetros de configuração do Spark. Destina-se a casos de uso avançados. Use `--conf` antes de cada parâmetro. Exemplo:
		`%%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"`
		`}`

timeout	Int	Determina o tempo máximo que a sessão do Spark deve esperar pela conclusão de uma declaração antes de ser encerrada.
		`%%configure`
		`{`
		`"timeout": "30"`
		`}`

ajuste de escala automático	Booleano	Determina se deve ou não usar o ajuste de escala automático.
		`%%configure`
		`{`
		`"--enable-auto-scaling": "true"`
		`}`

Mágica de trabalhos do Spark (ETL e streaming)

Nome	Tipo	Descrição
`%worker_type`	Cadeia de caracteres	Padrão, G.1X ou G.2X. `number_of_workers` também deve estar definido. O worker_type padrão é G.1X.

`%connections`	Listar	Especifica uma lista separada por vírgulas de conexões para usar na sessão.
		
		Exemplo:
		
		`%connections my_rds_connection`
		`dy_f = glue_context.create_dynamic_frame.from_catalog(database='rds_tables', table_name='sales_table')`

`%extra_py_files`	Listar	Lista separada por vírgulas de arquivos Python adicionais do Amazon S3.
`%extra_jars`	Listar	Lista separada por vírgulas de JARs adicionais para incluir no cluster.
`%spark_conf`	String	Especifique configurações personalizadas do Spark para sua sessão. Por exemplo, `%spark_conf spark.serializer=org.apache.spark.serializer.KryoSerializer` .

Mágicas para trabalhos do Ray

Nome	Tipo	Descrição
`%min_workers`	Int	O número mínimo de operadores alocados a um trabalho do Ray. Padrão: 1.

Nome	Tipo	Descrição
		Exemplo: `%min_workers 2`
`%object_memory_head`	Int	A porcentagem de memória livre no nó principal da instância após uma inicializ ação a quente. Mínimo: 0. Máximo: 100. Exemplo: `%object_memory_head 100`
%object_memory_worker	Int	A porcentagem de memória livre nos nós de processamento da instância após uma inicialização a quente. Mínimo: 0. Máximo: 100. Exemplo: `%object_memory_worker 100`

Magics de ação

Nome	Tipo	Descrição
`%%sql`	Cadeia de caracteres	Executar o código SQL. Todas as linhas após a mágica `%%sql` inicial serão transmitidas como parte do código SQL. Exemplo: `%%sql select * from rds_tables.sales_table`

`%matplot`	Figura Matplotli b	Visualize seus dados usando a biblioteca matplotlib.
		
		Exemplo:
		
		`import matplotlib.pyplot as plt`
		
		`# Set X-axis and Y-axis values`
		`x = [5, 2, 8, 4, 9]`

Nome	Tipo	Descrição

		`y = [10, 4, 8, 5, 2]`
		
		`# Create a bar chart`
		`plt.bar(x, y)`
		
		`# Show the plot`
		`%matplot plt`

`%plotly`	Figura Ploty	Visualize seus dados usando a biblioteca ploty.
		
		Exemplo:
		
		`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`

Nomeação de sessões

As sessões interativas do AWS Glue são recursos da AWS que exigem um nome. Os nomes devem ser exclusivos para cada sessão e podem ser restringidos pelos administradores do IAM. Para ter mais informações, consulte Sessões interativas com o IAM. O kernel do Jupyter gera automaticamente nomes de sessão exclusivos para você. No entanto, é possível nomear as sessões manualmente de duas maneiras:

1. Usar o arquivo de configuração AWS Command Line Interface localizado em `~.aws/config`. Consulte Configuração do AWS Config com a AWS Command Line Interface.
2. Usar as mágicas `%session_id_prefix`. Consulte Mágicas compatíveis com sessões interativas do AWS Glue para Jupyter .

Um nome de sessão é gerado da seguinte forma:

- Quando o prefixo e o session_id forem fornecidos: o nome da sessão será {prefixo}-{UUID}.
- Quando nada for fornecido: o nome da sessão será {UUID}.

A aplicação de prefixos aos nomes de sessão permite que você reconheça sua sessão ao listá-la na AWS CLI ou no console.

Especificação de um perfil do IAM para sessões interativas

Você deve especificar uma função do AWS Identity and Access Management (IAM) a ser usada com o código de ETL do AWS Glue que você executa com sessões interativas.

A função requer as mesmas permissões do IAM que são necessárias para executar trabalhos do AWS Glue. Consulte Criar um perfil do IAM para o AWS Glue para obter mais informações sobre como criar uma função para trabalhos e sessões interativas do AWS Glue.

É possível especificar as funções do IAM de duas formas:

- Usar o arquivo de configuração AWS Command Line Interface localizado em `~.aws/config` (recomendada). Para obter mais informações, consulte Configurar sessões com ~/.aws/config.

  > **Note**
  >
  > Quando a mágica `%profile` é usada, a configuração para `glue_iam_role` do respectivo perfil é respeitada.

- Uso da mágica %iam_role. Para ter mais informações, consulte Mágicas compatíveis com sessões interativas do AWS Glue para Jupyter .

Configurar sessões com perfis nomeados

As sessões interativas do AWS Glue usam as mesmas credenciais que a AWS Command Line Interface ou boto3. As sessões interativas aceitam e trabalham com perfis nomeados como a AWS CLI encontrada em `~/.aws/config` (Linux e MacOS) ou `%USERPROFILE%\.aws\config` (Windows). Para obter mais informações, consulte Usar perfis nomeados.

As sessões interativas aproveitam os perfis nomeados permitindo que o perfil de serviço e o prefixo do ID da sessão do AWS Glue sejam especificados em um perfil. Para configurar uma

função de perfil, adicione uma linha para a chave `iam_role` e/ou `session_id_prefix` ao seu perfil nomeado, conforme apresentado abaixo. O `session_id_prefix` não requer haspas. Por exemplo, se você quiser adicionar um `session_id_prefix`, insira o valor de `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>
```

Se tiver um método personalizado de geração de credenciais, você também poderá configurar seu perfil para usar o parâmetro `credential_process` em seu arquivo `~/.aws/config`. Por exemplo:

```
[profile developer]
region=us-east-1
credential_process = "/Users/Dave/generate_my_credentials.sh" --username helen
```

Você encontrará mais detalhes sobre a aquisição de credenciais por meio do parâmetro `credential_process` em: Credenciais de fornecimento com um processo externo.

Se não houver uma região ou `iam_role` definidas no perfil que você está usando, será necessário especificá-las usando as mágicas `%region` e `%iam_role` na primeira célula que você executar.

Converter um script ou caderno em um trabalho do AWS Glue

Há duas formas de converter um script ou caderno em um trabalho do AWS Glue:

- Usar nbconvert para converter seu arquivo de documento de caderno `.ipynb` do Jupyter em um arquivo `.py`. Para mais informações, consulte nbconvert: Convert Notebooks to other formats (nbconvert: converter cadernos para outros formatos).
- Carregue o arquivo no AWS Glue Studio Notebooks.
  - No console do AWS Glue Studio, escolha Jobs (Trabalhos) no menu de navegação.
  - Na seção Create job (Criar trabalho), escolha Jupyter Notebook.
  - Na seção Options (Opções), escolha Upload and edit an existing notebook (Carregar e editar um caderno existente).
  - Selecione Choose file (Escolher arquivo) para carregar um arquivo `.ipynb`.

Trabalhar com operações de streaming em sessões do AWS Glue interativas

Alterar o tipo de sessão de transmissão

Use a mágica de configuração das sessões interativas do AWS Glue, `%streaming`, para definir o trabalho que você está executando e inicializar uma sessão interativa de transmissão.

Amostrar o fluxo de entrada para desenvolvimento interativo

Uma ferramenta que obtivemos para ajudar a aprimorar a experiência interativa em sessões interativas do AWS Glue é a adição de um novo método em `GlueContext` para obter um snapshot de um fluxo em um DynamicFrame estático. `GlueContext` permite inspecionar, interagir e implementar seu fluxo de trabalho.

Com a instância de classe `GlueContext`, você poderá localizar o método `getSampleStreamingDynamicFrame`. Os argumentos necessários para esse método são:

- `dataFrame`: o DataFrame de streaming do Spark
- `options`: veja as opções disponíveis abaixo

As opções disponíveis incluem:

- windowSize: também chamado de Microbatch Duration (Duração de microlote). Esse parâmetro determinará quanto tempo uma consulta de transmissão aguardará após o acionamento do lote anterior. Esse valor de parâmetro deve ser inferior a `pollingTimeInMs`.

- pollingTimeInMs: o período total do tempo de execução do método. Ele acionará pelo menos um microlote para obter registros de amostra do fluxo de entrada.
- recordPollingLimit: esse parâmetro ajuda você a limitar o número total de registros que você vai sondar no fluxo.
- (Opcional) Você também pode usar `writeStreamFunction` para aplicar essa função personalizada a cada função de amostragem de registro. Veja abaixo exemplos em Scala e 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**
>
> Quando o `DynFrame` amostrado estiver vazio, isso pode acontecer por alguns motivos:
>
> - A fonte de transmissão está definida como “Latest” (Mais recente), e nenhum novo dado foi ingerido durante o período de amostragem.

- O tempo de sondagem não é suficiente para processar os registros ingeridos. Os dados não serão exibidos, a menos que o lote inteiro tenha sido processado.

Executar aplicativos de transmissão em sessões interativas

Em sessões interativas do AWS Glue, você pode executar o aplicativo de transmissão do AWS Glue assim como criaria um aplicativo de transmissão no console do AWS Glue. Como as sessões interativas são baseadas em sessão, encontrar exceções no runtime não faz com que a sessão seja interrompida. Agora temos o benefício adicional de desenvolver sua função em lote iterativamente. Por exemplo:

```
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 =
 {**})
```

No exemplo acima, incluímos um uso inválido de um método e, ao contrário dos trabalhos normais do AWS Glue que sairão de toda a aplicação, o contexto de codificação e as definições do usuário são totalmente preservados e a sessão permanece operacional. Não há necessidade de fazer o bootstrap de um novo cluster e executar novamente toda a transformação anterior. Isso permite que você mantenha o foco em iterar rapidamente suas implementações de função em lote para obter resultados desejáveis.

É importante observar que o Interactive Session avalia cada instrução de maneira bloqueadora para que a sessão execute apenas uma instrução por vez. Como as consultas de transmissão são contínuas e infinitas, as sessões com consultas de transmissão ativa não poderão processar instruções de acompanhamento a menos que sejam interrompidas. Você pode emitir o comando de interrupção diretamente do Jupyter Notebook e nosso kernel processará o cancelamento para você.

Considere como exemplo a seguinte sequência de instruções que estão aguardando a execução:

```
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 continously
      Result: Constantly updated with each microbatch

Statement 3:
      val number2 = df.count()
      #This will not be executed as previous statement will be running indefinitely
```

Desenvolver e testar scripts de trabalho do AWS Glue localmente

Ao desenvolver e testar seus scripts de trabalho do AWS Glue para Spark, existem várias opções disponíveis:

- Console do AWS Glue Studio
  - Editor visual
  - Editor de scripts
  - Cadernos do AWS Glue Studio
- Sessões interativas
  - Bloco de anotações Jupyter
- Docker image (Imagem do Docker)
  - Desenvolvimento local
  - Desenvolvimento remoto

É possível escolher qualquer uma das opções acima dependendo das suas necessidades.

Se você preferir uma experiência com nenhum ou pouco código, o editor visual do AWS Glue Studio será uma boa opção.

Se preferir uma experiência interativa de caderno, o caderno do AWS Glue Studio é uma boa opção. Para obter mais informações, consulte Usar cadernos com o AWS Glue Studio e o AWS Glue. Se quiser usar seu próprio ambiente local, sessões interativas são uma boa opção. Para obter mais informações, consulte Usar sessões interativas com o AWS Glue.

Se você prefere a experiência de desenvolvimento local/remoto, a imagem do Docker é uma boa opção. Isso ajuda a desenvolver e testar scripts de trabalho do AWS Glue para Spark em qualquer lugar de sua preferência sem gerar custos com o AWS Glue.

Se preferir o desenvolvimento local sem o Docker, instalar o diretório da biblioteca de ETL do AWS Glue localmente é uma boa opção.

Desenvolver usando o AWS Glue Studio

O editor visual do AWS Glue Studio é uma interface gráfica que facilita a criação, a execução e o monitoramento de trabalhos do tipo extrair, transformar e carregar (ETL) no AWS Glue. Você pode compor visualmente fluxos de trabalho de transformação de dados e executá-los perfeitamente no mecanismo de ETL sem servidor baseado no Apache Spark do AWS Glue. Você pode inspecionar os resultados do esquema e dos dados em cada etapa do trabalho. Para obter mais informações, consulte o Manual do usuário do AWS Glue Studio.

Desenvolvimento com sessões interativas

Sessões interativas permitem criar e testar aplicações no ambiente de sua escolha. Para obter mais informações, consulte Usar sessões interativas com o AWS Glue.

Desenvolvimento e teste de trabalhos do AWS Glue localmente usando uma imagem do Docker

Para uma plataforma de dados pronta para produção, o processo de desenvolvimento e o pipeline de CI/CD para trabalhos do AWS Glue é um tópico chave. Você pode desenvolver e testar com flexibilidade trabalhos do AWS Glue em um contêiner do Docker. O AWS Glue hospeda imagens do Docker no Docker Hub para configurar seu ambiente de desenvolvimento com utilitários adicionais. Você pode usar seu IDE, caderno ou REPL preferido com a biblioteca ETL do AWS Glue. Este tópico descreve o processo de desenvolvimento e teste de trabalhos do AWS Glue na versão 5.0 em um contêiner do Docker, usando uma imagem do Docker.

Imagens do Docker disponíveis

As seguintes imagens do Docker estão disponíveis para o AWS Glue no Amazon ECR:

- Para a versão 5.0 do AWS Glue: `public.ecr.aws/glue/aws-glue-libs:5`
- Para o AWS Glue versão 4.0: `public.ecr.aws/glue/aws-glue-libs:glue_libs_4.0.0_image_01`

- Para o AWS Glue versão 3.0: `public.ecr.aws/glue/aws-glue-libs:glue_libs_3.0.0_image_01`
- Para o AWS Glue versão 2.0: `public.ecr.aws/glue/aws-glue-libs:glue_libs_2.0.0_image_01`

> **Note**
>
> As imagens do Docker do AWS Glue são compatíveis tanto com a arquitetura x86_64 quanto com a arm64.

Neste exemplo, usamos `public.ecr.aws/glue/aws-glue-libs:5` e executamos o contêiner em uma máquina local (Mac, Windows ou Linux). Esta imagem de contêiner foi testada para trabalhos do Spark do AWS Glue na versão 5.0. A imagem contém o seguinte:

- Amazon Linux 2023
- AWS Glue ETL Library
- Apache Spark 3.5.4
- Bibliotecas de formatos de tabela abertos: Apache Iceberg 1.7.1, Apache Hudi 0.15.0 e Delta Lake 3.3.0
- Cliente do Catálogo de Dados do AWS Glue
- Conector do Amazon Redshift para Apache Spark
- Conector do Amazon DynamoDB para Apache Hadoop

Para configurar o contêiner, realize a extração da imagem do Galeria Pública do ECR e, em seguida, execute o contêiner. Este tópico demonstra como executar o contêiner usando os seguintes métodos, dependendo de suas necessidades:

- `spark-submit`
- Shell REPL (`pyspark`)
- `pytest`
- Código do Visual Studio

Pré-requisitos

Antes de começar, verifique se o Docker está instalado e se o daemon do Docker está em execução. Para obter instruções de instalação, consulte a documentação do Docker para Mac ou Linux. A máquina que executa o Docker hospeda o contêiner do AWS Glue. Verifique também se você tem pelo menos 7 GB de espaço em disco para a imagem no host que executa o Docker.

Para obter mais informações sobre as restrições ao desenvolver código do AWS Glue localmente, consulte Local development restrictions.

Como configurar a AWS

Para habilitar chamadas de API da AWS provenientes do contêiner, configure as credenciais da AWS seguindo as etapas. Nas seções a seguir, usaremos este perfil nomeado da AWS.

1. Crie um perfil nomeado da AWS.
2. Abra o `cmd` no Windows ou em um terminal no Mac ou no Linux e execute o seguinte comando no terminal:

```
PROFILE_NAME="<your_profile_name>"
```

Nas seções apresentadas a seguir, usaremos este perfil nomeado da AWS.

Caso esteja executando o Docker no Windows, clique com o botão direito do mouse no ícone do Docker e selecione Alternar para contêineres do Linux antes de realizar a extração da imagem.

Execute o seguinte comando para extrair a imagem da Galeria Pública do ECR:

```
docker pull public.ecr.aws/glue/aws-glue-libs:5
```

Execução do contêiner

Agora, você pode executar um contêiner utilizando essa imagem. É possível escolher qualquer um dos seguintes dependendo das suas necessidades.

spark-submit

Você pode executar um script de trabalho do AWS Glue executando o comando `spark-submit` no contêiner.

1. Escreva seu script e salve-o como `sample.py` no exemplo abaixo. Depois disso, armazene-o no diretório `/local_path_to_workspace/src/` usando os seguintes comandos:

```
$ WORKSPACE_LOCATION=/local_path_to_workspace
$ SCRIPT_FILE_NAME=sample.py
$ mkdir -p ${WORKSPACE_LOCATION}/src
$ vim ${WORKSPACE_LOCATION}/src/${SCRIPT_FILE_NAME}
```

2. Essas variáveis são usadas no comando “docker run”, apresentado abaixo. O código de exemplo (sample.py) usado no comando “spark-submit” abaixo está incluído no apêndice ao final deste tópico.

   Execute o comando a seguir para executar o comando `spark-submit` no contêiner a fim de enviar uma nova aplicação 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. (Opcionalmente) Configure `spark-submit` para corresponder ao seu ambiente. Por exemplo, você pode passar suas dependências com a configuração `--jars`. Para obter informações adicionais, consulte Carregar dinamicamente as propriedades do Spark na documentação do Spark.

Shell REPL (Pyspark)

É possível executar um shell REPL (`read-eval-print loops`) para desenvolvimento interativo. Execute o comando a seguir para executar o comando PySpark no contêiner e iniciar o 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
```

Você visualizará a seguinte saída:

```
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'.
>>>
```

Com este shell REPL, é possível programar e testar de forma interativa.

Pytest

Para a execução de teste de unidade, recomenda-se o uso do `pytest` para scripts de trabalhos do Spark no AWS Glue. Execute os comandos a seguir para preparação.

```
$ 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}
```

Use o seguinte comando para executar o `pytest` por meio do `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"
```

Após a execução dos testes de unidades pelo `pytest`, sua saída será semelhante a isto:

```
============================= 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 =========================
```

Configuração do contêiner para utilizar o Visual Studio Code

Para configurar o contêiner com o Visual Studio Code, conclua as seguintes etapas:

1. Instale o Visual Studio Code.
2. Instalar o Python.
3. Instale Visual Studio Code Remote - Containers
4. Abra a pasta de espaço de trabalho no Visual Studio Code.
5. Pressione `Ctrl+Shift+P` (no Windows ou no Linux) ou `Cmd+Shift+P` (no Mac).
6. Digite `Preferences: Open Workspace Settings (JSON)`.
7. Pressione Enter.
8. Cole o seguinte JSON e salve-o.

```
{
    "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/",
    ]
}
```

Para configurar o contêiner:

1. Execute o contêiner do 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. Inicie o Visual Studio Code.
3. Escolha Remote Explorer (Explorador remoto) no menu esquerdo e escolha `amazon/aws-glue-libs:glue_libs_4.0.0_image_01`.
4. Clique com o botão direito do mouse e escolha Anexar na janela atual.

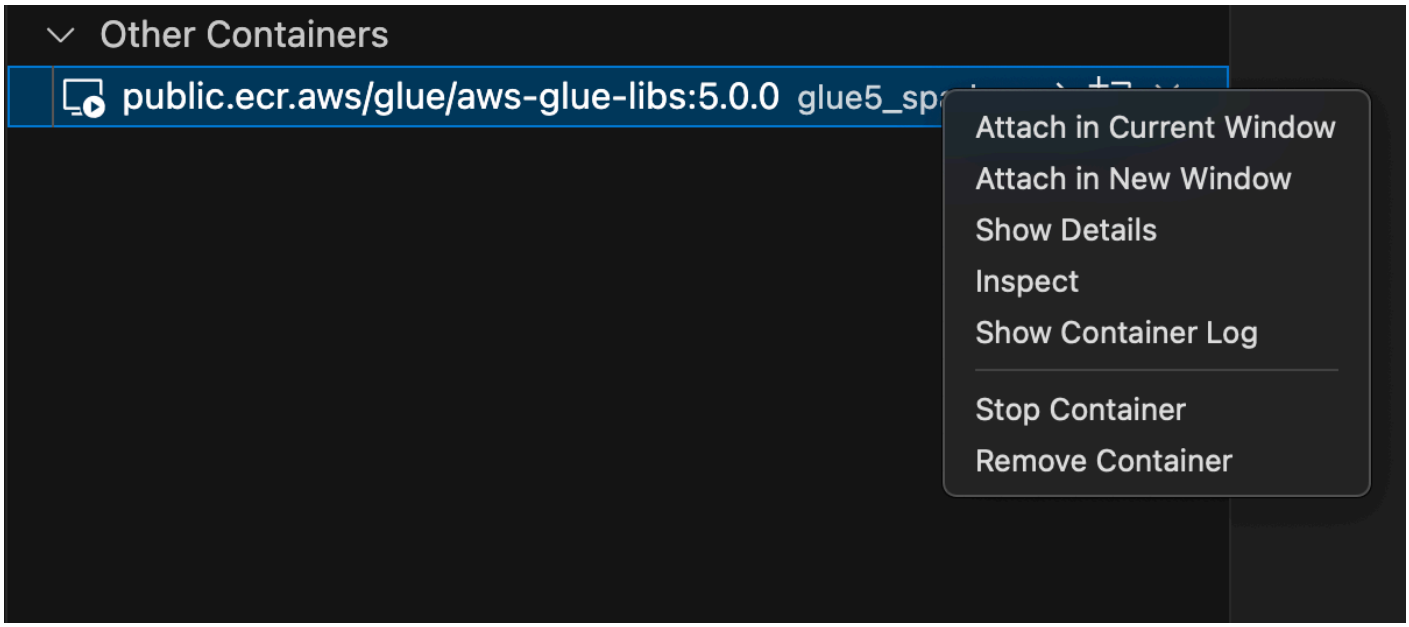

5. Se a caixa de diálogo apresentada a seguir aparecer, escolha Entendi.

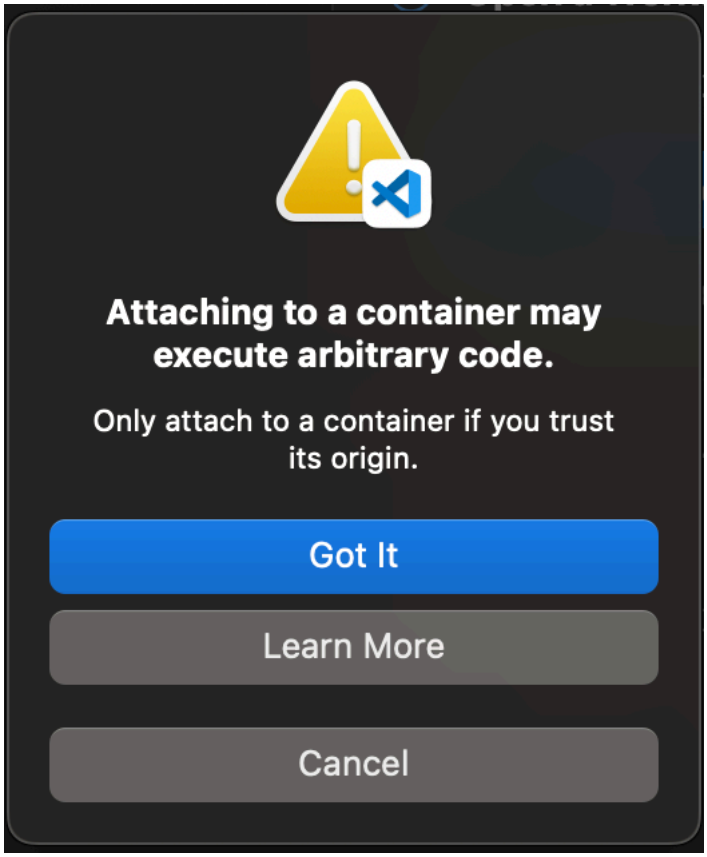

6. Abra o `/home/handoop/workspace/`.

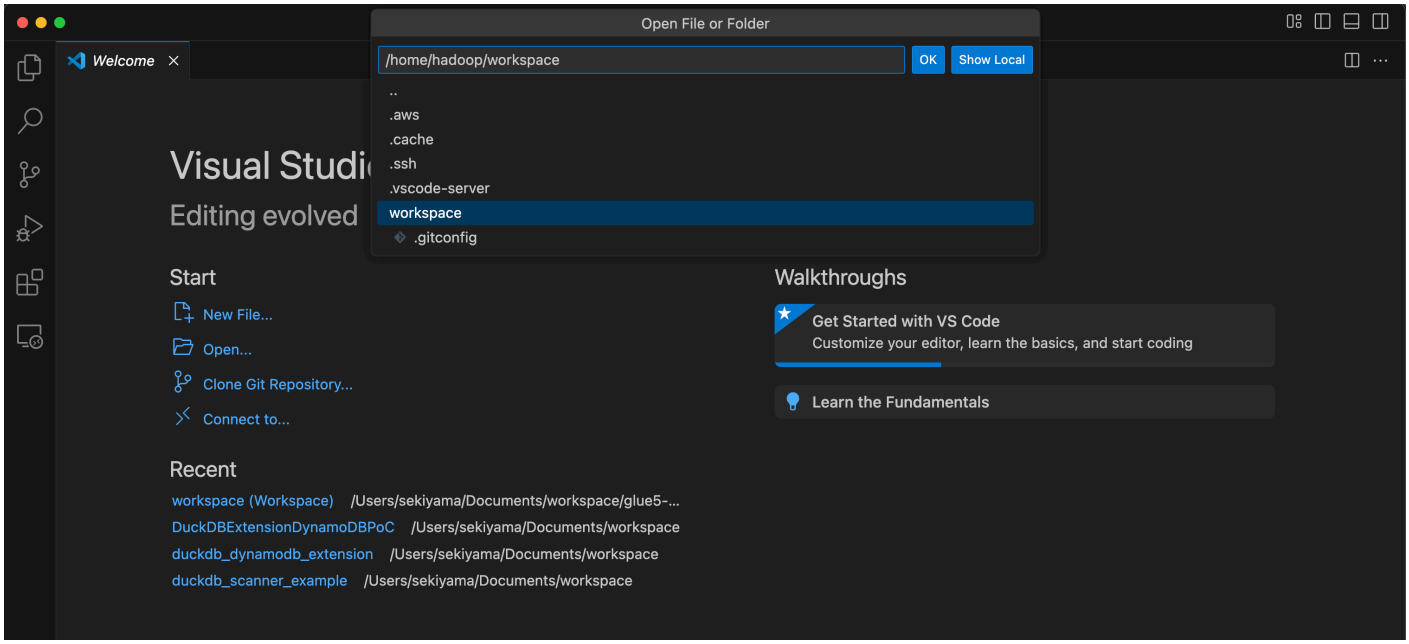

7. Crie um script do PySpark do AWS Glue e escolha Executar.

   Você verá a execução do script com sucesso.

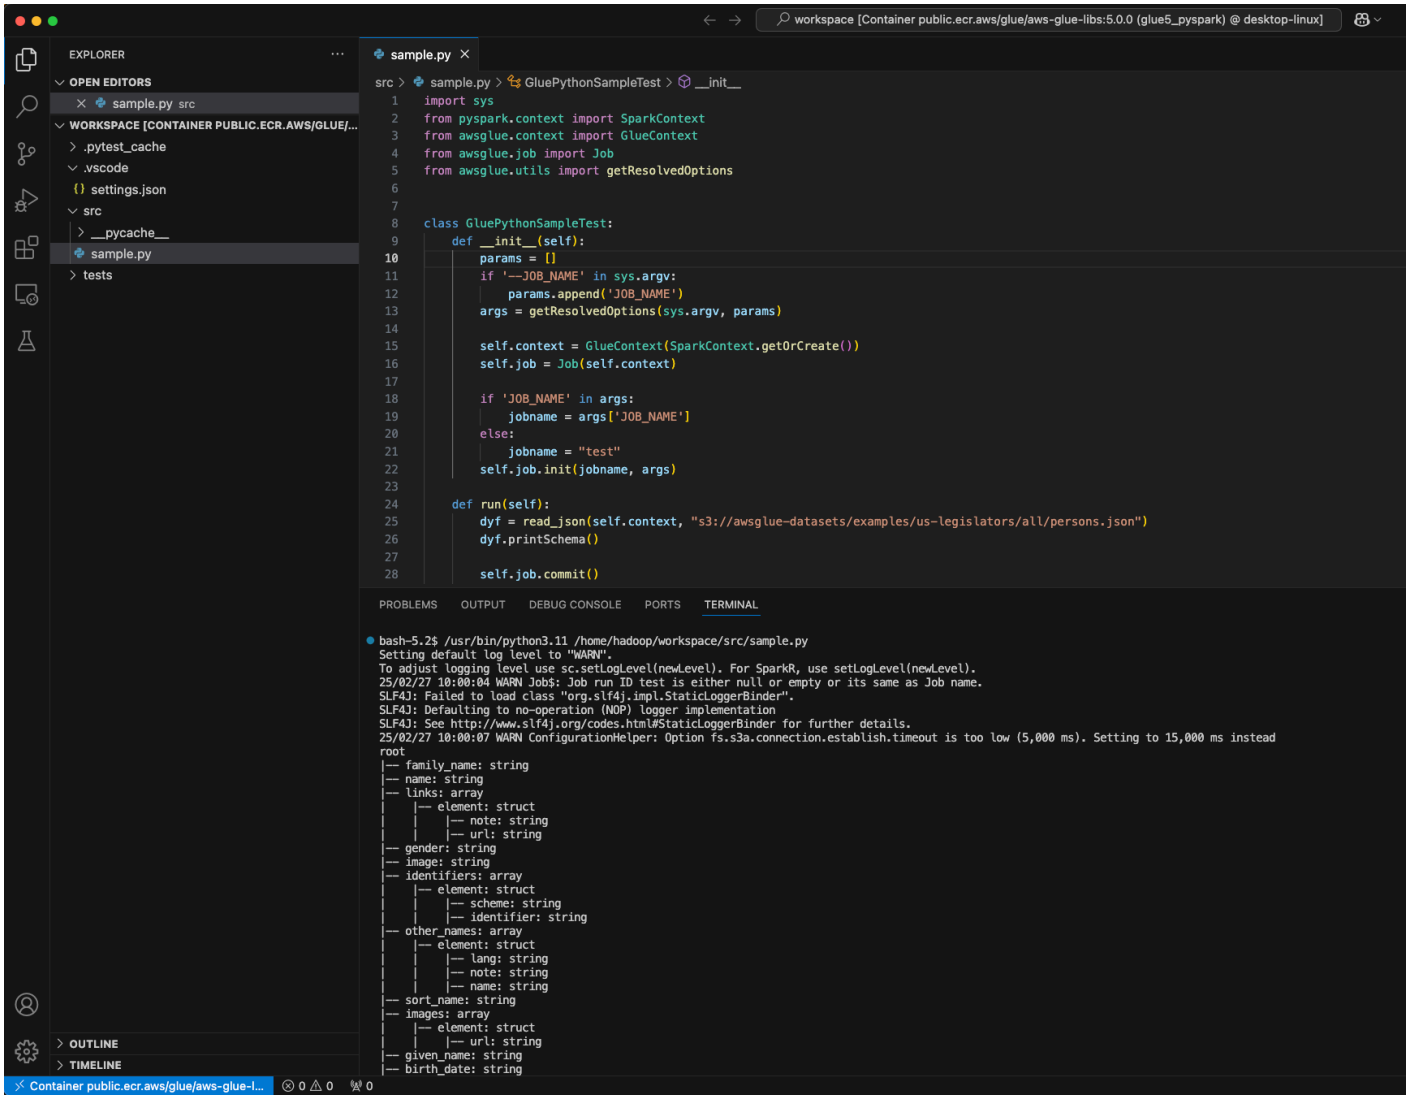

Alterações entre a imagem do Docker do AWS Glue 4.0 e do AWS Glue 5.0

As principais alterações entre a imagem do Docker do AWS Glue 4.0 e do AWS Glue 5.0 são:

- No AWS Glue 5.0, existe uma única imagem de contêiner para trabalhos tanto em lote quanto em streaming. Isso representa uma diferença em relação à versão Glue 4.0, que usava imagens distintas para cada tipo de trabalho.
- No AWS Glue 5.0, o nome de usuário padrão do contêiner é `hadoop`. No AWS Glue 4.0, o nome de usuário padrão era `glue_user`.
- No AWS Glue 5.0, várias bibliotecas adicionais, incluindo JupyterLab e Livy, foram removidas da imagem. No entanto, é possível instalá-las manualmente.

- No AWS Glue 5.0, todas as bibliotecas Iceberg, Hudi e Delta são carregadas previamente por padrão, e a variável de ambiente `DATALAKE_FORMATS` não é mais requerida. Antes do AWS Glue 4.0, a variável de ambiente `DATALAKE_FORMATS` era usada para especificar quais formatos de tabela específicos deveriam ser carregados.

A lista apresentada acima se refere especificamente à imagem do Docker. Para obter mais informações sobre as atualizações do AWS Glue 5.0, consulte os seguintes artigos: Introducing AWS Glue 5.0 for Apache Spark e Migrar o AWS Glue para trabalhos do Spark para o AWS Glue versão 5.0.

Considerações

É importante lembrar que os recursos apresentados a seguir não são compatíveis quando a imagem do contêiner do AWS Glue é utilizada para desenvolver scripts de trabalhos localmente.

- Marcadores de trabalho
- Gravador em Parquet do AWS Glue (Uso do formato Parquet no AWS Glue)
- Transformação FillMissingValues
- Transformação FindMatches
- Leitor de SIMD vetorizado para CSV
- A propriedade customJdbcDriverS3Path para carregar o driver JDBC do caminho do Amazon S3
- AWS Glue Data Quality
- Detecção de dados sensíveis
- Distribuição de credenciais com base em permissões do AWS Lake Formation

Apêndice: adição de drivers JDBC e bibliotecas do Java

Para adicionar um driver JDBC que não esteja disponível no contêiner, você pode criar um novo diretório no seu espaço de trabalho com os arquivos em JAR necessários e montar esse diretório em `/opt/spark/jars/` no comando “docker run”. Os arquivos em JAR encontrados em `/opt/spark/jars/` dentro do contêiner são automaticamente adicionados ao Spark Classpath e estarão disponíveis para uso durante a execução do trabalho.

Por exemplo, use o comando “docker run” apresentado a seguir para adicionar os arquivos em JARs do driver JDBC ao shell REPL do 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
```

Conforme mencionado em Considerações, a opção de conexão `customJdbcDriverS3Path` não é compatível com a importação de um driver JDBC personalizado usando o Amazon S3 nas imagens de contêiner do AWS Glue.

Endpoints de desenvolvimento

> **Note**
>
> A experiência do console para endpoints de desenvolvimento foi removida em 31 de março de 2023. A criação, a atualização e o monitoramento de endpoints de desenvolvimento ainda estão disponíveis por meio do API de endpoints de desenvolvimento e da CLI do AWS Glue.

É altamente recomendável migrar de endpoints de desenvolvimento para sessões interativas pelos motivos listados abaixo. Para ver as ações necessárias para migrar endpoints de desenvolvimento para sessões interativas, consulte Migrar de endpoints de desenvolvimento para sessões interativas.

Descrição	Endpoints de desenvolvimento	Sessões interativas
Compatibilidade com versão do Glue	Compatível com o AWS Glue versões 0.9 e 1.0	Compatível com o AWS Glue versões 2.0 e posteriores
A partir de agora, os endpoints de desenvolvimento não estarão disponíveis nas regiões Ásia-Pacífico (Jacarta) (`ap-southeast-3`), Oriente Médio (EAU) (`me-centra`	No momento, sessões interativas não estão disponíveis na região Oriente Médio (EAU) (`me-centra l-1`), mas podem ser	

Descrição	Endpoints de desenvolvimento	Sessões interativas
`l-1`) Europa (Espanha) (`eu-south-2`), Europa (Zurique) (`eu-central-2`) nem outras regiões novas	disponibilizadas posterior mente	
Método de acesso ao cluster do Spark	Compatível com SSH, shell do REPL, caderno Jupyter, IDE (por exemplo, PyCharm)	Compatível com caderno do AWS Glue Studio, o caderno Jupyter, vários IDEs (por exemplo, Visual Studio Code, PyCharm) e caderno do SageMaker AI
Tempo até o primeiro byte	Requer de 10 a 15 minutos para configurar um cluster do Spark	Pode levar até 1 minuto para configurar um cluster efêmero do Spark
O modelo de preços	A AWS cobra pelos endpoints de desenvolvimento com base no tempo que o endpoint é provisionado e no número de DPUs. Os endpoints de desenvolvimento não têm tempo limite. Há uma duração mínima para cobrança de 10 minutos para cada endpoint de desenvolvimento provision ado. Além disso, a AWS cobra pelas instâncias do caderno Jupyter no Amazon EC2 e pelos caderno do SageMaker AI quando você os configura com o endpoint de desenvolv imento.	A AWS cobra por sessões interativas com base no tempo que a sessão permanece ativa e no número de DPUs. As sessões interativas têm tempos limites de inatividade configuráveis. Os cadernos do AWS Glue Studio oferecem uma interface integrada para sessões interativas e são oferecidos sem custo adicional . Há uma duração mínima para cobrança de 1 minuto para cada sessão interativa. Os cadernos do AWS Glue Studio fornecem uma interface embutida para sessões interativas e são oferecidos sem custo adicional

Descrição	Endpoints de desenvolvimento	Sessões interativas
Experiência de console	Disponível somente por meio da CLI e da API	Disponível por meio do console, da CLI e de APIs do AWS Glue

Migrar de endpoints de desenvolvimento para sessões interativas

Use a lista de verificação a seguir para determinar o método apropriado para migrar de endpoints de desenvolvimento para sessões interativas.

Seu script depende de recursos específicos do AWS Glue 0.9 ou 1.0 (por exemplo, HDFS, YARN etc.)?

Se a resposta for sim, consulte Migrar trabalhos do AWS Glue para o AWS Glue versão 3.0 para saber como migrar do Glue 0.9 ou 1.0 para o Glue 3.0 e versões posteriores.

Qual método você usa para acessar o endpoint de desenvolvimento?

Se você usar este método	Então faça isso
Caderno do SageMaker AI, caderno Jupyter ou JupyterLab	Migre para o caderno AWS Glue Studio baixando os arquivos `.ipynb` no Jupyter e crie um novo trabalho de caderno AWS Glue Studio carregando o arquivo `.ipynb`. Ou então, você pode usar o SageMaker AI Studio e selecionar o kernel do AWS Glue.
Notebook do Zeppelin	Converta o caderno em um caderno Jupyter manualmente, copiando e colando o código, ou automaticamente, usando um conversor de terceiros, como o ze2nb. Em seguida, use o caderno no caderno do AWS Glue Studio ou do SageMaker AI Studio.
IDE	Consulte Criar trabalhos do AWS Glue com o PyCharm usando as sessões interativas do

Se você usar este método	Então faça isso
	AWS Glue ou Usar sessões interativas com o código do Microsoft Visual Studio.
RESPOSTA	Instale o `aws-glue-session package` localmente e depois execute o seguinte comando: • Para Python: `jupyter console --kernal glue_pyspark` • Para Scala: `jupyter console --kernal glue_spark`
SSH	Não há nenhuma opção correspondente nas sessões interativas. Como alternativa, você pode usar uma imagem do Docker. Para saber mais, consulte Desenvolver usando com uma imagem do Docker.

As seções a seguir fornecem mais informações sobre o uso de endpoints de desenvolvimento para desenvolver trabalhos no AWS Glue versão 1.0.

Tópicos

- Desenvolver scripts com endpoints de desenvolvimento
- Gerenciar cadernos

Desenvolver scripts com endpoints de desenvolvimento

> **Note**
>
> Os endpoints de desenvolvimento só são compatíveis com as versões do AWS Glue anteriores à 2.0. Para um ambiente interativo onde você possa criar e testar scripts de ETL, use Notebooks on AWS Glue Studio.

O AWS Glue pode criar um ambiente, conhecido como endpoint de desenvolvimento, que você pode usar para desenvolver e testar iterativamente seus scripts de extração, transformação e carregamento (ETL). Você pode criar, editar e excluir endpoints de desenvolvimento usando o console ou a API do AWS Glue.

Gerenciar o ambiente de desenvolvimento

Ao criar um endpoint de desenvolvimento, você fornece valores de configuração para provisionar o ambiente de desenvolvimento. Esses valores informam ao AWS Glue como configurar a rede para que você possa acessar o endpoint de forma segura e o endpoint possa acessar seus armazenamentos de dados.

Depois, é possível criar um notebook que se conecte ao endpoint e usá-lo para criar e testar seu script de ETL. Quando estiver satisfeito com os resultados do seu processo de desenvolvimento, você poderá criar um trabalho de ETL que execute seu script. Com esse processo, você pode adicionar funções e depurar seus scripts de forma interativa.

Siga os tutoriais nesta seção para saber como usar seu endpoint de desenvolvimento com notebooks.

Tópicos

- Fluxo de trabalho do endpoint de desenvolvimento
- Como os endpoints de desenvolvimento do AWS Glue funcionam com cadernos do SageMaker
- Adicionar um endpoint de desenvolvimento
- Acessar o endpoint de desenvolvimento
- Tutorial: configurar um caderno Jupyter no JupyterLab para testar e depurar scripts de ETL
- Tutorial: usar um caderno do SageMaker AI com seu endpoint de desenvolvimento
- Tutorial: usar um shell REPL com seu endpoint de desenvolvimento
- Tutorial: configurar um PyCharm Professional com um endpoint de desenvolvimento
- Configuração avançada: compartilhar endpoints de desenvolvimento entre vários usuários

Fluxo de trabalho do endpoint de desenvolvimento

Para usar um endpoint de desenvolvimento do AWS Glue, você pode seguir este fluxo de trabalho:

1. Crie um endpoint de desenvolvimento usando o console ou a API. O endpoint é executado em uma nuvem privada virtual (VPC) com seus grupos de segurança definidos.

2. O console ou a API sonda o endpoint de desenvolvimento até que ele seja provisionado e esteja pronto para operar. Quando estiver pronto, conecte-se ao endpoint de desenvolvimento usando um dos seguintes métodos para criar e testar scripts do AWS Glue.

   - Crie um caderno do SageMaker AI em sua conta. Para obter mais informações sobre como criar um notebook, consulte the section called “Criação de código com notebooks AWS Glue Studio”.
   - Abra uma janela de terminal para se conectar diretamente a um endpoint de desenvolvimento.
   - Se tiver a versão profissional do PyCharm Python IDE do JetBrains, conecte-a a um endpoint de desenvolvimento e use-a para desenvolver de forma interativa. Se você inserir as instruções `pydevd` no seu script, o PyCharm poderá oferecer suporte a pontos de interrupção remotos.

3. Ao concluir a depuração e o teste no seu endpoint de desenvolvimento, você poderá excluí-lo.

Como os endpoints de desenvolvimento do AWS Glue funcionam com cadernos do SageMaker

Uma das maneiras comuns de acessar seus endpoints de desenvolvimento é usar o Jupyter em cadernos do SageMaker. O caderno Jupyter é um aplicação Web de código aberto que é amplamente utilizada em visualização, análise, machine learning etc. Um caderno do SageMaker do AWS Glue oferece uma experiência de caderno Jupyter com endpoints de desenvolvimento do AWS Glue. No caderno do SageMaker do AWS Glue, o ambiente de caderno Jupyter é pré-configurado com SparkMagic, um plugin de código aberto do Jupyter para enviar trabalhos do Spark para um cluster remoto do Spark. Apache Livy é um serviço que permite a interação com um cluster remoto do Spark por meio de uma API REST. No caderno do SageMaker do AWS Glue, o SparkMagic está configurado para chamar a API REST em um servidor Livy em execução em um endpoint de desenvolvimento do AWS Glue.

O fluxo de texto a seguir explica como cada componente funciona:

Notebook do SageMaker do AWS Glue: (Jupyter → SparkMagic) → (rede) → endpoint de desenvolvimento do AWS Glue: (Apache Livy → Apache Spark)

Depois de executar o script do Spark escrito em cada parágrafo em um caderno Jupyter, o código do Spark é enviado ao servidor Livy via SparkMagic e, em seguida, um trabalho do Spark chamado “livy-session-N” é executado no cluster do Spark. Esse trabalho é chamado de sessão do Livy. O trabalho do Spark será executado enquanto a sessão do caderno estiver ativa. O trabalho do Spark

será terminado quando você desligar o kernel do Jupyter do caderno, ou quando o tempo da sessão se esgotar. Um trabalho do Spark é iniciado por arquivo de caderno (.ipynb).

Você pode usar um único endpoint de desenvolvimento do AWS Glue com várias instâncias de cadernos do SageMaker. Você pode criar vários arquivos de caderno em cada instância de cadernos do SageMaker. Quando você abre um arquivo de cada caderno e executa os parágrafos, uma sessão do Livy é iniciada por arquivo de caderno no cluster do Spark via SparkMagic. Cada sessão do Livy corresponde a um único trabalho do Spark.

Comportamento padrão para endpoints de desenvolvimento do AWS Glue e cadernos do SageMaker

Os trabalhos do Spark são executados com base na configuração do Spark. Existem várias maneiras de definir a configuração do Spark (por exemplo, configuração do cluster do Spark, configuração do SparkMagic etc.).

Por padrão, o Spark aloca recursos de cluster para uma sessão do Livy com base na configuração do cluster do Spark. Em endpoints de desenvolvimento do AWS Glue, a configuração do cluster depende do tipo de operador. Esta tabela explica as configurações comuns por tipo de operador.

	Padrão	G.1X	G.2X
`spark.driver.memory`	5G	10G	20G
`spark.executor.memory`	5G	10G	20G
`spark.executor.cores`	4	8	16
`spark.dynamicAllocation.enabled`	VERDADEIRO	VERDADEIRO	VERDADEIRO

O número máximo de executores do Spark é calculado automaticamente pela combinação de DPU (ou `NumberOfWorkers`) e tipo de operador.

	Padrão	G.1X	G.2X
O número máximo de executores do Spark	`(DPU - 1) * 2 - 1`	`(NumberOfWorkers - 1)`	`(NumberOfWorkers - 1)`

Por exemplo, se o endpoint de desenvolvimento tiver dez operadores e o tipo de operador for `G.1X`, então você terá nove executores do Spark e todo o cluster terá 90G de memória de executor, uma vez que cada executor terá 10G de memória.

Independentemente do tipo de operador especificado, a alocação dinâmica de recursos do Spark será ativada. Se um conjunto de dados for grande o suficiente, o Spark pode alocar todos os executores em uma única sessão do Livy, já que `spark.dynamicAllocation.maxExecutors` não é definido por padrão. Isso significa que outras sessões do Livy no mesmo endpoint de desenvolvimento esperarão para iniciar novos executores. Se o conjunto de dados for pequeno, o Spark poderá alocar executores em várias sessões do Livy ao mesmo tempo.

> **Note**
>
> Para obter mais informações sobre como os recursos são alocados em diferentes casos de uso e como você define uma configuração para modificar o comportamento, consulte Configuração avançada: compartilhar endpoints de desenvolvimento entre vários usuários.

Adicionar um endpoint de desenvolvimento

Use endpoints de desenvolvimento para desenvolver e testar iterativamente seus scripts de extração, transformação e carregamento (ETL) no AWS Glue. Só é possível trabalhar com endpoints de desenvolvimento por meio do AWS Command Line Interface.

1. Em uma janela de linha de comando, insira um comando semelhante ao seguinte.

```
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"
```

Esse comando especifica o AWS Glue versão 1.0. Como essa versão oferece suporte ao Python 2 e ao Python 3, você pode usar o parâmetro `arguments` para indicar a versão desejada do Python. Se o parâmetro `glue-version` for omitido, o AWS Glue versão 0.9 será assumido. Para obter mais informações sobre as versões do AWS Glue, consulte o Glue version job property.

Para obter informações sobre parâmetros de linha de comando adicionais, consulte create-dev-endpoint na Referência de comandos da AWS CLI.

2. (Opcional) Insira o comando a seguir para verificar o status do endpoint de desenvolvimento. Quando o status mudar para `READY`, o endpoint de desenvolvimento estará pronto para uso.

```
aws glue get-dev-endpoint --endpoint-name "endpoint1"
```

Acessar o endpoint de desenvolvimento

Quando você cria um endpoint de desenvolvimento em uma nuvem privada virtual (VPC), o AWS Glue retorna apenas um endereço IP privado. O campo de endereço IP público não é preenchido. Quando você cria um endpoint de desenvolvimento não seja da VPC, o AWS Glue retorna somente um endereço IP público.

Se o endpoint de desenvolvimento tiver um Public address (Endereço público), confirme se ele está acessível com a chave privada SSH do endpoint de desenvolvimento, como no exemplo a seguir.

```
ssh -i dev-endpoint-private-key.pem glue@public-address
```

Suponha que o endpoint de desenvolvimento tenha um Private address (Endereço privado), a sub-rede da VPC seja roteável pela Internet pública e seus grupos de segurança permitam acesso de entrada do cliente. Nesse caso, siga estas etapas para anexar um Elastic IP address (Endereço IP elástico) a um endpoint de desenvolvimento para permitir o acesso na Internet.

> **Note**
>
> Se você deseja usar endereços IP elásticos, a sub-rede que está sendo usada requer um gateway de Internet associado por meio da tabela de rotas.

Como acessar um endpoint de desenvolvimento anexando um endereço IP elástico

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Dev endpoints (Endpoints de desenvolvimento) e navegue até a página de detalhes do endpoint de desenvolvimento. Registre o Private address (Endereço privado) a ser usado na próxima etapa.
3. Abra o console do Amazon EC2 em https://console.aws.amazon.com/ec2/.
4. No painel de navegação, em Network & Security (Rede e segurança), selecione Network Interfaces (Interfaces de rede).
5. Pesquise o Private DNS (IPv4) (DNS privado (IPv4)) que corresponde ao Private address (Endereço privado) na página de detalhes do endpoint de desenvolvimento do console do AWS Glue.

   Pode ser necessário alterar as colunas que são exibidas no console do Amazon EC2. Anote o Network interface ID (ID da interface de rede) (ENI) desse endereço (por exemplo, `eni-12345678`).
6. No console do Amazon EC2, em Network & Security (Rede e segurança), escolha Elastic IPs (IPs elásticos).
7. Escolha Allocate new address (Alocar novo endereço) e, depois, escolha Allocate (Alocar) para alocar um novo endereço IP elástico.
8. Na página Elastic IPs (IPs elásticos), selecione o Elastic IP (IP elástico) recém-alocado. Em seguida, selecione Actions (Ações) e Associate address (Associar endereço).
9. Na página Associate address (Associar endereço), faça o seguinte:

   - Em Resource type (Tipo de recurso), selecione Network interface (Interface de rede).
   - No campo Network interface (Interface de rede), digite o Network interface ID (ID da interface de rede) (ENI) do endereço privado.
   - Selecione Associar.

10. Confirme se o endereço IP elástico recém-associado está acessível com a chave privada SSH associada ao endpoint de desenvolvimento, como no exemplo a seguir.

```
ssh -i dev-endpoint-private-key.pem glue@elastic-ip
```

Para obter informações sobre como usar um bastion host para obter acesso SSH ao endereço privado do endpoint de desenvolvimento, consulte o post do blog de segurança da AWS Securely Connect to Linux Instances Running in a Private Amazon VPC.

Tutorial: configurar um caderno Jupyter no JupyterLab para testar e depurar scripts de ETL

Neste tutorial, você conectará um caderno Jupyter no JupyterLab em execução em sua máquina local a um endpoint de desenvolvimento. Você o faz para que possa executar, depurar e testar interativamente scripts de extração, transformação e carregamento (ETL) do AWS Glue antes de implantá-los. Este tutorial usa o redirecionamento de portas Secure Shell (SSH) para conectar sua máquina local a um endpoint de desenvolvimento do AWS Glue. Para obter mais informações, consulte Redirecionamento de portas na Wikipédia.

Etapa 1: Instalar o JupyterLab e o Sparkmagic

Você pode instalar o JupyterLab usando o `conda` ou `pip`. O `conda` é um sistema de gerenciamento de pacotes e de ambientes de código aberto que é executado no Windows, macOS e Linux. Já o `pip` é o instalador de pacotes para Python.

Se estiver instalando no macOS, é necessário ter o Xcode instalado antes de instalar o Sparkmagic.

1. Instale o JupyterLab, o Sparkmagic e as extensões relacionadas.

```
$ conda install -c conda-forge jupyterlab
$ pip install sparkmagic
$ jupyter nbextension enable --py --sys-prefix widgetsnbextension
$ jupyter labextension install @jupyter-widgets/jupyterlab-manager
```

2. Verifique o diretório `sparkmagic` de `Location`.

```
$ pip show sparkmagic | grep Location
```

```
Location: /Users/username/.pyenv/versions/anaconda3-5.3.1/lib/python3.7/site-
packages
```

3. Altere seu diretório para o mesmo retornado para `Location` e instale os kernels para Scala e 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. Faça download de um arquivo de amostra `config`.

```
$ curl -o ~/.sparkmagic/config.json https://raw.githubusercontent.com/jupyter-
incubator/sparkmagic/master/sparkmagic/example_config.json
```

   Neste arquivo de configuração, você pode configurar parâmetros relacionados ao Spark, como `driverMemory` e `executorCores`.

Etapa 2: Iniciar o JupyterLab

Quando você inicia o JupyterLab, seu navegador da Web padrão é aberto automaticamente e o URL `http://localhost:8888/lab/workspaces/{workspace_name}` é exibido.

```
$ jupyter lab
```

Etapa 3: iniciar o redirecionamento de porta SSH para se conectar ao endpoint de desenvolvimento

Em seguida, use o encaminhamento de porta local SSH para encaminhar uma porta local (aqui, 8998) ao destino remoto definido por AWS Glue (`169.254.76.1:8998`).

1. Abra uma janela do terminal separada que conceda acesso ao SSH. No Microsoft Windows, você pode usar o shell BASH fornecido pelo Git for Windows (Git para Windows) ou instalar o Cygwin.
2. Execute o seguinte comando SSH, modificado da seguinte forma:

   - Substitua *`private-key-file-path`* pelo caminho do arquivo `.pem` que contém a chave privada correspondente à chave pública que você usou para criar seu endpoint de desenvolvimento.

- Se você estiver redirecionando uma porta diferente de 8998, substitua 8998 pelo número da porta que está de fato usando localmente. O endereço `169.254.76.1:8998` é a porta remota e não é alterada por você.
- Substitua *`dev-endpoint-public-dns`* pelo endereço DNS público do seu endpoint de desenvolvimento. Para encontrar esse endereço, navegue até seu endpoint de desenvolvimento no console do AWS Glue, escolha o nome e copie o valor de Public address (Endereço público) listado na página Endpoint details (Detalhes do endpoint).

```
ssh -i private-key-file-path -NTL 8998:169.254.76.1:8998 glue@dev-endpoint-public-
dns
```

Você provavelmente verá uma mensagem de aviso semelhante à seguinte:

```
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
+JflSnp21X7aTP3BcFnHYLEts.
Are you sure you want to continue connecting (yes/no)?
```

Digite **`yes`** (sim) e deixe aberta a janela do terminal enquanto utiliza o JupyterLab.

3. Verifique se o redirecionamento de porta SSH está funcionando corretamente com o endpoint de desenvolvimento.

```
$ curl localhost:8998/sessions
{"from":0,"total":0,"sessions":[]}
```

Etapa 4: executar um fragmento de script simples em um parágrafo do caderno

Agora seu caderno no JupyterLab deve funcionar com seu endpoint de desenvolvimento. Digite o seguinte fragmento de script no seu caderno e execute-o.

1. Verifique se o Spark está sendo executado com êxito. O comando a seguir instrui o Spark a calcular 1 e, em seguida, imprimir o valor.

```
spark.sql("select 1").show()
```

2. Verifique se a integração com o AWS Glue Data Catalog está funcionando. O comando a seguir lista as tabelas do Data Catalog.

```
spark.sql("show tables").show()
```

3. Verifique se um fragmento de script simples que usa as bibliotecas do AWS Glue funciona.

   O script a seguir usa os metadados da tabela `persons_json` no AWS Glue Data Catalog para criar um `DynamicFrame` dos seus dados de exemplo. Em seguida, ele imprime a contagem de itens e o esquema desses dados.

```
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()
```

O resultado do script é o seguinte:

```
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
```

Solução de problemas

- Durante a instalação do JupyterLab, se o seu computador estiver atrás de um proxy corporativo ou firewall, você poderá encontrar erros de HTTP e SSL devido a perfis de segurança personalizados gerenciados por departamentos de TI corporativos.

  Segue-se um exemplo de um erro típico que ocorre quando `conda` não consegue se conectar aos seus próprios repositórios:

  ```
  CondaHTTPError: HTTP 000 CONNECTION FAILED for url <https://repo.anaconda.com/pkgs/
  main/win-64/current_repodata.json>
  ```

  Isso pode acontecer porque sua empresa pode bloquear conexões com repositórios amplamente utilizados em comunidades de Python e JavaScript. Para obter mais informações, consulte Installation Problems (Problemas de instalação) no site do JupyterLab.
- Se encontrar um erro de conexão recusada ao tentar se conectar ao seu endpoint de desenvolvimento, pode ser que você esteja usando um endpoint de desenvolvimento desatualizado. Tente criar um novo endpoint de desenvolvimento e se reconectar.

Tutorial: usar um caderno do SageMaker AI com seu endpoint de desenvolvimento

No AWS Glue, você pode criar um endpoint de desenvolvimento e, depois, criar um caderno do SageMaker AI para ajudar a desenvolver os scripts de ETL e machine learning. Um caderno do SageMaker AI é uma instância de computação de machine learning totalmente gerenciada que executa a aplicação Caderno Jupyter.

1. No console do AWS Glue, escolha Dev endpoints para navegar até a lista de endpoints de desenvolvimento.
2. Marque a caixa de seleção ao lado do nome de um endpoint de desenvolvimento que você deseja usar e, no menu Action (Ação), escolha Create SageMaker notebook (Criar bloco de anotações do SageMaker).
3. Preencha a página Create and configure a notebook (Criar e configurar um bloco de anotações) da seguinte forma:

   a. Insira um nome de bloco de anotações.

   b. Em Attach to development endpoint (Anexar ao endpoint de desenvolvimento), verifique o endpoint de desenvolvimento.

   c. Crie ou escolha uma função do AWS Identity and Access Management (IAM).

      A criação de uma função é recomendada. Se você usar uma função existente, verifique se ela tem as permissões necessárias. Para obter mais informações, consulte the section called “Etapa 6: criar uma política do IAM para cadernos do SageMaker AI”.

   d. (Opcional) Escolha uma VPC, uma sub-rede e um ou mais grupos de segurança.

   e. (Opcional) Escolha uma chave de criptografia do AWS Key Management Service.

   f. (Opcional) Adicione tags para a instância do bloco de anotações.
4. Escolha Criar caderno. Na página Notebooks (Blocos de anotações), escolha o ícone de atualização no canto superior direito e continue até que o Status seja `Ready`.
5. Marque a caixa de seleção ao lado do nome do novo bloco de anotações e escolha Open notebook (Abrir bloco de anotações).
6. Criar um novo bloco de anotações: na página jupyter, escolha New (Novo) e Sparkmagic (PySpark).

   Sua tela agora deve ser semelhante ao seguinte:

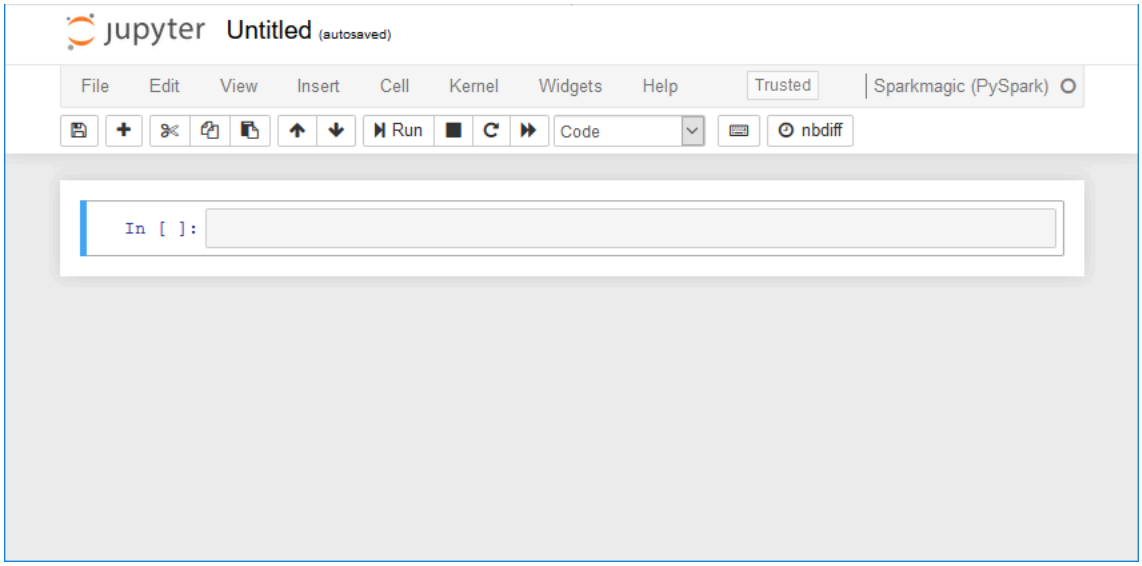

7. (Opcional) Na parte superior da página, escolha Untitled (Sem título) e dê um nome ao bloco de anotações.
8. Para iniciar um aplicativo do Spark, digite o seguinte comando no bloco de anotações e, na barra de ferramentas, escolha Run (Executar).

```
spark
```

Após um pequeno atraso, você deve ver a seguinte resposta:

```
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. Criar um quadro dinâmico e executar uma consulta: copie, cole e execute o seguinte código, que gera a contagem e o esquema da tabela `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()
```

Tutorial: usar um shell REPL com seu endpoint de desenvolvimento

No AWS Glue, você pode criar um endpoint de desenvolvimento e, em seguida, invocar um shell REPL (Read–Evaluate–Print Loop) para executar o código PySpark de forma incremental. Dessa forma, você poderá depurar interativamente seus scripts de ETL antes de implantá-los.

Para usar um REPL em um endpoint de desenvolvimento, você precisa ter autorização para SSH no endpoint.

1. No computador local, abra uma janela de terminal que possa executar comandos SSH e cole o comando SSH editado. Execute o comando .

   Pressupondo que você aceitou a versão 1.0 padrão do AWS Glue com Python 3 para o endpoint de desenvolvimento, a saída será assim:

```
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
      ____              __
     / __/__  ___ _____/ /__
    _\ \/ _ \/ _ `/ __/  '_/
   /__ / .__/\_,_/_/ /_/\_\   version 2.4.3
      /_/

Using Python version 3.6.8 (default, Aug  2 2019 17:42:44)
SparkSession available as 'spark'.
>>>
```

2. Digite a instrução `print(spark.version)` para ver se o shell REPL está funcionando corretamente. Se a versão Spark for exibida, seu REPL está pronto para ser usado.
3. Agora você pode tentar executar o seguinte script simples, linha por linha, no 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()
```

Tutorial: configurar um PyCharm Professional com um endpoint de desenvolvimento

Este tutorial mostra como conectar o IDE Python PyCharm Professional sendo executado em sua máquina local a um endpoint de desenvolvimento para que você possa executar, depurar e testar de forma interativa scripts de ETL (extração, transformação e carregamento) do AWS Glue antes de implantá-los. As instruções e capturas de tela no tutorial são baseadas no PyCharm Professional versão 2019.3.

Para se conectar a um endpoint de desenvolvimento de forma interativa, você precisa ter PyCharm Professional instalado. Você não pode fazer isso usando a edição gratuita.

> **Note**
>
> O tutorial usa o Amazon S3 como a fonte dos dados. Se você quiser usar uma fonte de dados JDBC, execute o endpoint de desenvolvimento em uma nuvem privada virtual (VPC). Para se conectar com SSH a um endpoint de desenvolvimento em uma VPC, você deve criar um túnel SSH. Este tutorial não inclui instruções para criar um túnel SSH. Para obter informações sobre como usar o SSH para se conectar a um endpoint de desenvolvimento em uma VPC, consulte Securely Connect to Linux Instances Running in a Private Amazon VPC no blog de segurança da AWS.

Tópicos

- Conectar o PyCharm Professional a um endpoint de desenvolvimento
- Implantar o script no endpoint de desenvolvimento
- Configurar um intérprete remoto
- Executar seu script no endpoint de desenvolvimento

Conectar o PyCharm Professional a um endpoint de desenvolvimento

1. Crie um novo projeto Python puro no PyCharm, chamado `legislators`.
2. Crie um arquivo chamado `get_person_schema.py` no projeto com o seguinte conteúdo:

```
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. Execute um destes procedimentos:

   - Para o AWS Glue versão 0.9, faça download do arquivo da biblioteca Python do AWS Glue, `PyGlue.zip`, em `https://s3.amazonaws.com/aws-glue-jes-prod-us-east-1-assets/etl/python/PyGlue.zip` para um local conveniente na sua máquina local.
   - Para o AWS Glue versão 1.0 ou versões posteriores, faça download do arquivo da biblioteca Python do AWS Glue, `PyGlue.zip`, em `https://s3.amazonaws.com/aws-glue-jes-prod-us-east-1-assets/etl-1.0/python/PyGlue.zip` para um local conveniente na sua máquina local.

4. Adicione o `PyGlue.zip` como raiz de conteúdo do seu projeto no PyCharm:

   - No PyCharm, escolha File, Settings para abrir a caixa de diálogo Settings. Você também pode pressionar `Ctrl+Alt+S`.
   - Expanda o projeto `legislators` e escolha Project Structure. Em seguida, escolha + Add Content Root no painel direito.
   - Navegue até o local em que você salvou `PyGlue.zip`, selecione-o, e escolha Apply.

   A tela Settings deve ser semelhante à seguinte:

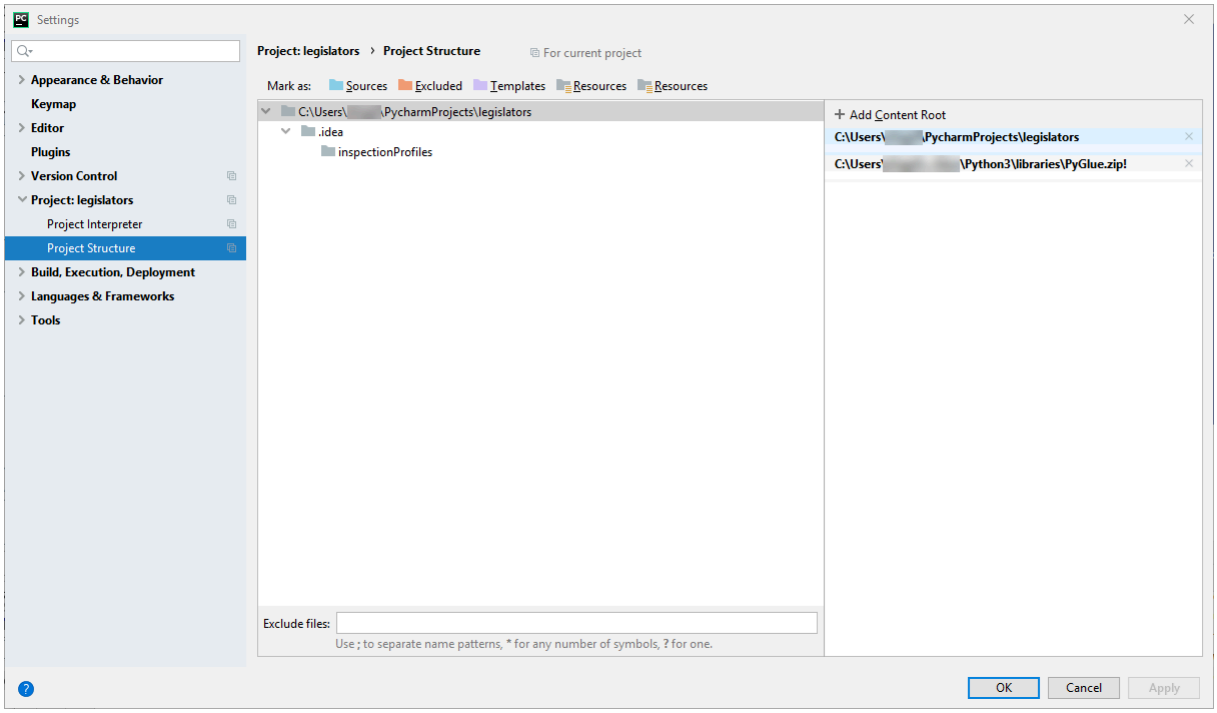

Mantenha a caixa de diálogo Settings aberta depois de selecionar Apply.

5. Configure as opções de implantação para fazer upload do script local no seu endpoint de desenvolvimento usando SFTP (esse recurso está disponível somente no PyCharm Professional):

   - Na caixa de diálogo Settings, expanda a seção Build, Execution, Deployment. Escolha a subseção Deployment.
   - Escolha o ícone + na parte superior do painel central para adicionar um novo servidor. Defina o Type (Tipo) como SFTP e dê um nome a ele.
   - Defina o SFTP host (Host SFTP) como Public address (Endereço público) do endpoint de desenvolvimento, conforme listado na página de detalhes. Escolha o nome do endpoint de desenvolvimento no console do AWS Glue para exibir a página de detalhes. Para um endpoint de desenvolvimento em execução em uma VPC, defina o SFTP host (Host SFTP) como o endereço do host e a porta local do túnel SSH como o endpoint de desenvolvimento.
   - Defina User name como `glue`.
   - Defina Auth type como Key pair (OpenSSH or Putty). Defina Private key file (Arquivo de chave privada) navegando até o local em que o arquivo de chave privada do endpoint de desenvolvimento está localizado. Observe que PyCharm só é compatível com tipos de chave DSA, RSA e ECDSA OpenSSH, e não aceita chaves no formato privado de Putty. Você pode

usar uma versão atualizada de `ssh-keygen` para gerar um tipo de par de chaves aceito pelo PyCharm, usando uma sintaxe como a seguinte:

```
ssh-keygen -t rsa -f <key_file_name> -C "<your_email_address>"
```

- Escolha Test connection (Conexão de teste) e permita que a conexão seja testada. Se a conexão for concluída com sucesso, escolha Apply.

A tela Settings agora deve ser semelhante à seguinte:

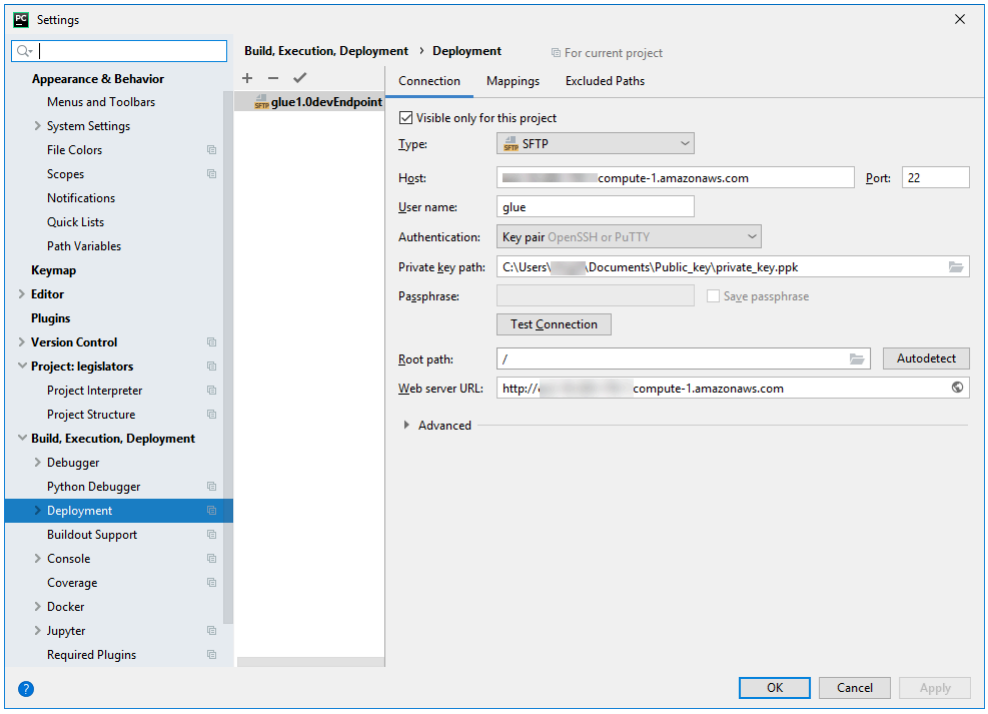

Novamente, mantenha a caixa de diálogo Settings aberta depois de selecionar Apply.

6. Mapeie o diretório local até um diretório remoto para implantação:

   - No painel direito da página Deployment, escolha a guia central na parte superior, nomeada Mappings.
   - Na coluna Deployment Path, insira um caminho abaixo de `/home/glue/scripts/` para implantação do caminho do seu projeto. Por exemplo: `/home/glue/scripts/legislators`.
   - Selecione Apply (Aplicar).

   A tela Settings agora deve ser semelhante à seguinte:

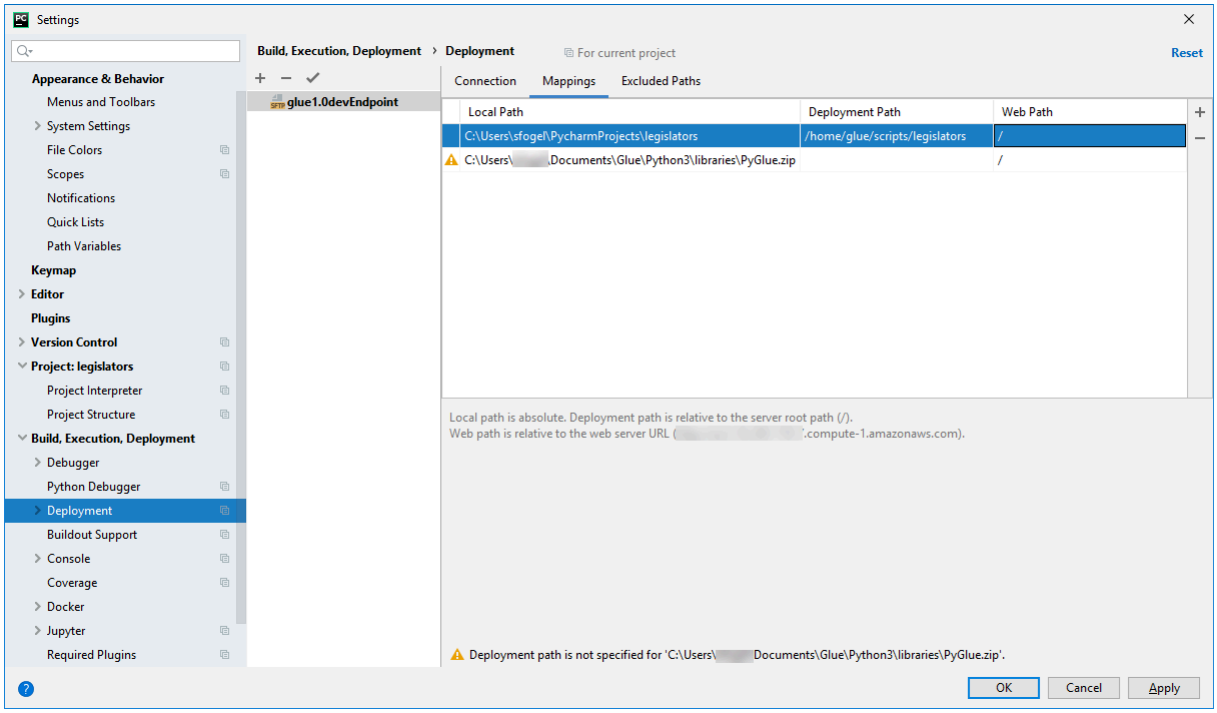

Escolha OK para fechar a caixa de diálogo Settings (Configurações).

Implantar o script no endpoint de desenvolvimento

1. Escolha Tools (Ferramentas), Deployment (Implantação) e o nome para o qual você configurou seu endpoint de desenvolvimento, conforme mostrado na seguinte imagem:

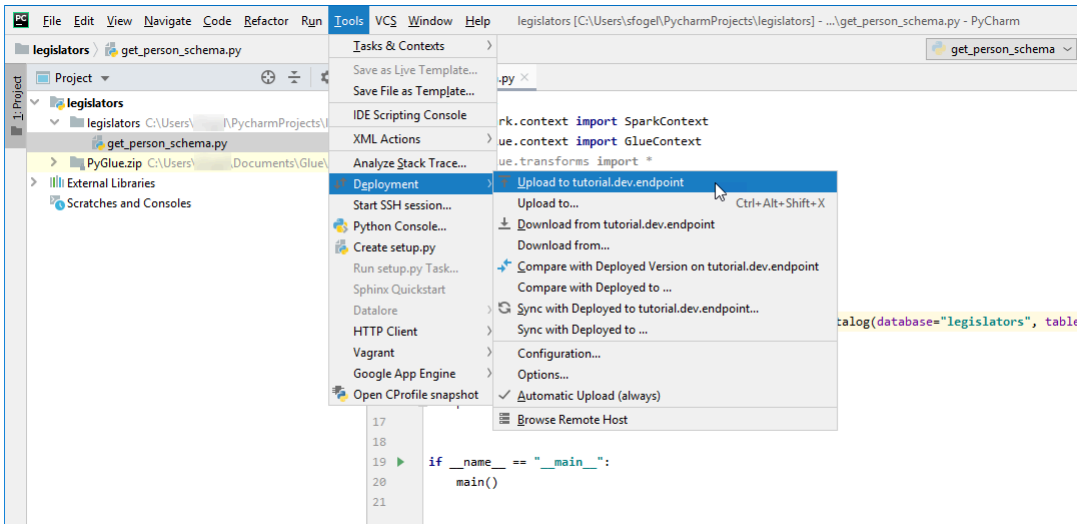

Depois que seu script for implantado, a parte inferior da tela exibirá o seguinte:

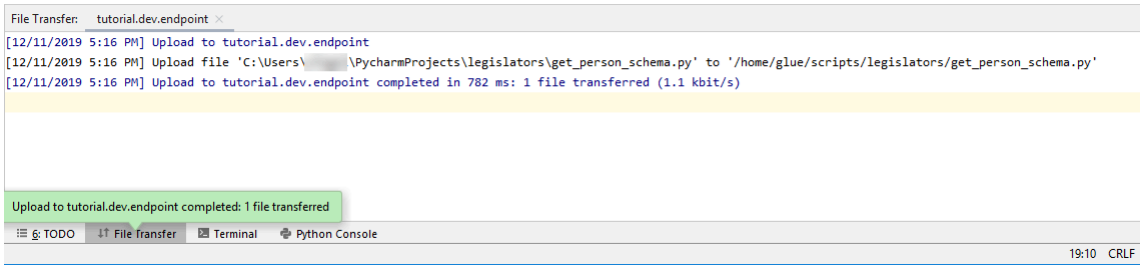

2. Na barra de menus, escolha Tools (Ferramentas), Deployment (Implantação), Automatic Upload (always) (Upload automático (sempre)). Verifique se uma marca de seleção aparece ao lado de Automatic Upload (always) (Upload automático (sempre)).

   Quando essa opção está habilitada, o PyCharm carrega automaticamente os arquivos alterados no endpoint de desenvolvimento.

Configurar um intérprete remoto

Configure o PyCharm para usar o intérprete Python no endpoint de desenvolvimento.

1. No menu File (Arquivo), escolha Settings (Configurações).
2. Expanda os legislators (legisladores) do projeto e escolha Project Interpreter (Intérprete do projeto).
3. Escolha o ícone de engrenagem ao lado da lista Project Interpreter (Intérprete do projeto) e escolha Add (Adicionar).
4. Na caixa de diálogo Add Python Interpreter (Adicionar intérprete Python), no painel esquerdo, escolha SSH Interpreter (Intérprete SSH).
5. Escolha Existing server configuration (Configuração de servidor existente) e, na lista Deployment configuration (Configuração de implantação), escolha sua configuração.

   Sua tela deve ser semelhante à seguinte imagem.

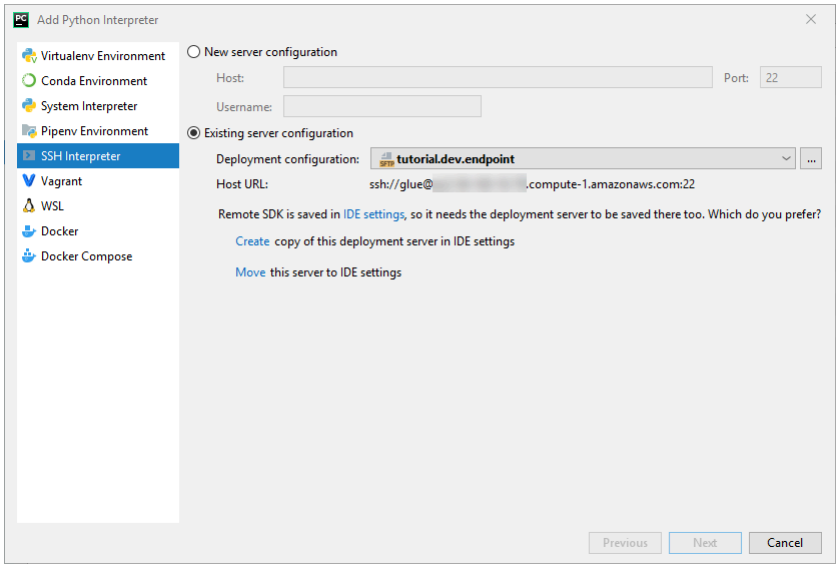

6. Escolha Move this server to IDE settings (Mover este servidor para configurações do IDE) e Next (Avançar).
7. No campo Interpreter (Intérprete), altere o caminho para `/usr/bin/gluepython` se você estiver usando Python 2 ou para `/usr/bin/gluepython3` se estiver usando Python 3. Em seguida, escolha Finish (Concluir).

Executar seu script no endpoint de desenvolvimento

Para executar o script:

- No painel esquerdo, clique com o botão direito do mouse no nome do arquivo e escolha Run '***<filename>***' (Executar <nome do arquivo>).

  Após uma série de mensagens, a saída final deve mostrar a contagem e o esquema.

```
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
```

Agora você está pronto para depurar seu script remotamente no endpoint de desenvolvimento.

Configuração avançada: compartilhar endpoints de desenvolvimento entre vários usuários

Esta seção explica como você pode aproveitar os endpoints de desenvolvimento com cadernos do SageMaker em casos de uso típicos a fim de compartilhar endpoints de desenvolvimento entre vários usuários.

Configuração de locação única

Em casos de uso de locatário único, para simplificar a experiência do desenvolvedor e para evitar contenção por recursos, é recomendável que cada desenvolvedor use seu próprio endpoint de desenvolvimento dimensionado para o projeto em que está trabalhando. Isso também simplifica as decisões relacionadas ao tipo de operador e à contagem de DPU, deixando-as à discrição do desenvolvedor e do projeto em que estão trabalhando.

Você não precisará cuidar da alocação de recursos, a menos que execute vários arquivos de caderno simultaneamente. Se você executar um código em vários arquivos de caderno ao mesmo tempo, várias sessões do Livy serão iniciadas simultaneamente. Para segregar configurações de cluster do Spark a fim de executar várias sessões do Livy ao mesmo tempo, você pode seguir as etapas que são introduzidas em casos de uso multilocatário.

Por exemplo, se o endpoint de desenvolvimento tiver dez operadores e o tipo de operador for `G.1X`, então você terá nove executores do Spark e todo o cluster terá 90G de memória de executor, uma vez que cada executor terá 10G de memória.

Independentemente do tipo de operador especificado, a alocação dinâmica de recursos do Spark será ativada. Se um conjunto de dados for grande o suficiente, o Spark pode alocar todos os executores em uma única sessão do Livy, já que `spark.dynamicAllocation.maxExecutors` não é definido por padrão. Isso significa que outras sessões do Livy no mesmo endpoint de desenvolvimento esperarão para iniciar novos executores. Se o conjunto de dados for pequeno, o Spark poderá alocar executores em várias sessões do Livy ao mesmo tempo.

> **Note**
>
> Para obter mais informações sobre como os recursos são alocados em diferentes casos de uso e como você define uma configuração para modificar o comportamento, consulte Configuração avançada: compartilhar endpoints de desenvolvimento entre vários usuários.

Configuração de locação múltipla

> **Note**
>
> Observe que os endpoints de desenvolvimento são destinados a emular o ambiente de ETL do AWS Glue como um ambiente de locatário único. Embora o uso de multilocatário seja possível, esse é um caso de uso avançado e é recomendado que a maioria dos usuários mantenha um padrão de locação única para cada endpoint de desenvolvimento.

Em casos de uso multilocatário, talvez seja necessário cuidar da alocação de recursos. O principal fator é o número de usuários simultâneos que usam um caderno Jupyter ao mesmo tempo. Se sua equipe estiver distribuída ao redor do mundo de forma a seguir um fluxo de trabalho de 24 horas por dia e houver apenas um usuário do Jupyter em cada fuso horário, então o número de usuários

simultâneos será apenas um e você não precisará se preocupar com a alocação de recursos. No entanto, se seu caderno for compartilhado entre vários usuários e cada um enviar código de forma ad-hoc, então você precisará considerar os pontos abaixo.

Para particionar recursos de cluster do Spark entre vários usuários, você pode usar as configurações do SparkMagic. Há duas maneiras diferentes de configurar o SparkMagic.

(A) Usar a diretiva %%configure -f

Se você quiser modificar a configuração por sessão do Livy a partir do caderno, poderá executar a diretiva `%%configure -f` no parágrafo do caderno.

Por exemplo, se você deseja executar a aplicação Spark em cinco executores, pode executar o seguinte comando no parágrafo do caderno.

```
%%configure -f
{"numExecutors":5}
```

Em seguida, você verá apenas cinco executores em execução para o trabalho na IU do Spark.

Recomendamos limitar o número máximo de executores para alocação dinâmica de recursos.

```
%%configure -f
{"conf":{"spark.dynamicAllocation.maxExecutors":"5"}}
```

(B) Modificar o arquivo Config do SparkMagic

O SparkMagic funciona com base na API do Livy. O SparkMagic cria sessões do Livy com configurações como: `driverMemory`, `driverCores`, `executorMemory`, `executorCores`, `numExecutors`, `conf` etc. Esses são os principais fatores que determinam a quantidade de recursos consumidos de todo o cluster do Spark. O SparkMagic permite que você forneça um arquivo de configuração para especificar os parâmetros que são enviados ao Livy. Você pode ver um arquivo de configuração de exemplo neste repositório do GitHub.

Se você quiser modificar a configuração em todas as sessões do Livy a partir de um caderno, poderá modificar `/home/ec2-user/.sparkmagic/config.json` para adicionar `session_config`.

Para modificar o arquivo de configuração em uma instância de cadernos do SageMaker, siga estas etapas.

1. Abra um caderno do SageMaker.
2. Abra o kernel do terminal.
3. Execute os seguintes comandos:

```
sh-4.2$ cd .sparkmagic
sh-4.2$ ls
config.json logs
sh-4.2$ sudo vim config.json
```

Por exemplo, você pode adicionar estas linhas a `/home/ec2-user/.sparkmagic/config.json` e reiniciar o kernel do Jupyter a partir do caderno.

```
  "session_configs": {
    "conf": {
      "spark.dynamicAllocation.maxExecutors":"5"
    }
  },
```

Diretrizes e práticas recomendadas

Para evitar esse tipo de conflito de recursos, você pode usar algumas abordagens básicas, como:

- Ter um cluster do Spark maior, aumentando `NumberOfWorkers` (escalonando horizontalmente) e atualizando `workerType`(escalonando verticalmente)
- Alocar menos recursos por usuário (menos recursos por sessão do Livy)

Sua abordagem dependerá do seu caso de uso. Se você tiver um endpoint de desenvolvimento maior e não houver uma grande quantidade de dados, a possibilidade de um conflito de recursos diminuirá significativamente porque o Spark pode alocar recursos com base em uma estratégia de alocação dinâmica.

Como descrito acima, o número máximo de executores do Spark é calculado automaticamente pela combinação de DPU (ou `NumberOfWorkers`) e tipo de operador. Cada aplicação do Spark inicia um driver e vários executores. Para calcular, você precisará de `NumberOfWorkers = NumberOfExecutors + 1`. A matriz abaixo explica quanta capacidade você precisa em seu endpoint de desenvolvimento com base no número de usuários simultâneos.

Número de usuários simultâneos de cadernos	Número de executores do Spark que você deseja alocar por usuário	NumberOfWorkers (número de operadores) total para seu endpoint de desenvolvimento
3	5	18
10	5	60
50	5	300

Se você quiser alocar menos recursos por usuário, `spark.dynamicAllocation.maxExecutors` (ou `numExecutors`) seria o parâmetro mais fácil de configurar como um parâmetro de sessão do Livy. Se você definir a configuração abaixo em `/home/ec2-user/.sparkmagic/config.json`, então o SparkMagic atribuirá um máximo de cinco executores por sessão do Livy. Isso ajudará a segregar recursos por sessão do Livy.

```
"session_configs": {
    "conf": {
      "spark.dynamicAllocation.maxExecutors":"5"
    }
  },
```

Suponha que haja um endpoint de desenvolvimento com 18 operadores (G.1X) e que haja três usuários de cadernos simultâneos. Se a configuração da sua sessão tiver `spark.dynamicAllocation.maxExecutors=5`, então cada usuário poderá fazer uso de um driver e cinco executores. Não haverá conflitos de recursos, mesmo quando você executar vários parágrafos do caderno ao mesmo tempo.

Trade-offs

Com esta configuração de sessão `"spark.dynamicAllocation.maxExecutors":"5"`, você poderá evitar erros de conflito de recursos e não precisará aguardar a alocação de recursos quando houver acessos simultâneos de usuários. No entanto, mesmo quando há muitos recursos livres (por exemplo, não há outros usuários simultâneos), o Spark não pode atribuir mais de cinco executores à sessão do Livy.

Outras observações

É uma boa prática interromper o kernel do Jupyter quando você parar de usar um caderno. Isso liberará recursos e outros usuários de cadernos poderão usar esses recursos imediatamente, sem aguardar a expiração do kernel (desligamento automático).

Problemas comuns

Mesmo ao seguir as diretrizes, você pode enfrentar certos problemas.

Sessão não encontrada

Ao tentar executar um parágrafo do caderno mesmo que sua sessão do Livy já tenha terminado, você verá a mensagem abaixo. Para ativar a sessão do Livy, você precisa reiniciar o kernel do Jupyter escolhendo Kernel > Restart (Reiniciar) no menu do Jupyter e, em seguida, executar o parágrafo do caderno novamente.

```
An error was encountered:
Invalid status code '404' from http://localhost:8998/sessions/13 with error payload:
 "Session '13' not found."
```

Não há recursos suficientes do YARN

Ao tentar executar um parágrafo do caderno mesmo que o cluster do Spark não tenha recursos suficientes para iniciar uma nova sessão do Livy, você verá a mensagem abaixo. Muitas vezes, você pode evitar esse problema seguindo as diretrizes, no entanto, ainda haverá a possibilidade de você encontrar esse problema. Para contornar o problema, você pode conferir se há sessões ativas e desnecessárias do Livy. Se houver sessões do Livy desnecessárias, você precisará terminá-las para liberar os recursos do cluster. Consulte a próxima seção para obter detalhes.

```
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.
```

Monitoramento e depuração

Esta seção descreve técnicas para monitorar recursos e sessões.

Monitorar e depurar a alocação de recursos do cluster

Você pode observar a interface do usuário do Spark para monitorar quantos recursos são alocados por sessão do Livy e quais são as configurações efetivas do Spark no trabalho. Para habilitar a interface do usuário do Spark, consulte Habilitar a interface do usuário Web do Apache Spark para endpoints de desenvolvimento.

(Opcional) Se você precisar de uma visualização em tempo real da interface do usuário do Spark, poderá configurar um túnel SSH para o servidor de histórico do Spark em execução no cluster do Spark.

```
ssh -i <private-key.pem> -N -L 8157:<development endpoint public address>:18080
 glue@<development endpoint public address>
```

Você pode abrir http://localhost:8157 no navegador para visualizar a interface do usuário do Spark localmente.

Liberar sessões do Livy desnecessárias

Reveja estes procedimentos para encerrar quaisquer sessões desnecessárias do Livy a partir de um caderno ou de um cluster do Spark.

(a). Terminar sessões do Livy a partir de um caderno

Você pode desligar o kernel em um caderno Jupyter para terminar sessões do Livy desnecessárias.

(b). Terminar sessões do Livy a partir de um cluster do Spark

Se houver sessões do Livy desnecessárias que ainda estejam em execução, você pode terminá-las no cluster do Spark.

Como pré-requisito para executar esse procedimento, você precisa configurar sua chave SSH pública para o seu endpoint de desenvolvimento.

Para fazer login no cluster do Spark, execute o seguinte comando:

```
$ ssh -i <private-key.pem> glue@<development endpoint public address>
```

Você pode executar o seguinte comando para ver as sessões do Livy ativas:

```
$ yarn application -list
20/09/25 06:22:21 INFO client.RMProxy: 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
```

Em seguida, você pode desligar a sessão do Livy com o seguinte comando:

```
$ yarn application -kill application_1601003432160_0005
20/09/25 06:23:38 INFO client.RMProxy: 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
```

Gerenciar cadernos

> **Note**
>
> Os endpoints de desenvolvimento só são compatíveis com as versões do AWS Glue anteriores à 2.0. Para um ambiente interativo onde você possa criar e testar scripts de ETL, use Cadernos no AWS Glue Studio.

Um caderno permite desenvolver e testar interativamente seus scripts de ETL (extrair, transformar e carregar) em um endpoint de desenvolvimento. O AWS Glue fornece uma interface para cadernos Jupyter do SageMaker AI. Com o AWS Glue, é possível criar e gerenciar cadernos do SageMaker AI. Você também pode abrir cadernos do SageMaker AI no console do AWS Glue.

Além disso, você pode usar o Apache Spark com o SageMaker AI em endpoints de desenvolvimento do AWS Glue que oferecem suporte ao SageMaker AI (mas não a trabalhos de ETL do AWS Glue). O SageMaker Spark é uma biblioteca de código aberto do Apache Spark para SageMaker AI. Para obter mais informações, consulte Uso do Apache Spark com o Amazon SageMaker.

Important

O gerenciamento de cadernos do SageMaker AI com endpoints de desenvolvimento do AWS Glue está disponível nas seguintes regiões da AWS:

Região	Código
Leste dos EUA (Ohio)	`us-east-2`
Leste dos EUA (N. da Virgínia)	`us-east-1`
Oeste dos EUA (N. da Califórnia)	`us-west-1`
Oeste dos EUA (Oregon)	`us-west-2`
Ásia-Pacífico (Tóquio)	`ap-northeast-1`
Ásia-Pacífico (Seul)	`ap-northeast-2`
Ásia-Pacífico (Mumbai)	`ap-south-1`
Ásia-Pacífico (Singapura)	`ap-southeast-1`
Ásia-Pacífico (Sydney)	`ap-southeast-2`
Canadá (Central)	`ca-central-1`
Europa (Frankfurt)	`eu-central-1`
Europa (Irlanda)	`eu-west-1`
Europa (Londres)	`eu-west-2`

Criar trabalhos ETL visuais com o AWS Glue Studio

Um trabalho do AWS Glue encapsula um script que se conecta aos dados de origem, os processa e, depois, os grava no destino de dados. Normalmente, um trabalho executa scripts de extração, transformação e carga (ETL). Os trabalhos podem executar scripts desenhados para os ambientes de runtime do Apache Spark e do Ray. Os trabalhos também podem executar scripts Python de uso geral (trabalhos do shell do Python). Os acionadores do AWS Glue podem iniciar trabalhos com base em uma programação ou um evento, ou sob demanda. É possível monitorar trabalhos para entender as métricas do runtime, status de conclusão, duração e hora de início.

Você pode usar scripts gerados pelo AWS Glue ou fornecer os seus próprios scripts. Com um esquema de fonte e um local de destino ou esquema, o gerador de códigos do AWS Glue Studio pode criar automaticamente um script da API Apache Spark (PySpark). Você pode usar esse script como ponto de partida e editá-lo para atingir seus objetivos.

O AWS Glue pode gravar arquivos de saída em vários formatos de dados. Cada tipo de trabalho pode ser compatível com diferentes formatos de saída. Para alguns formatos de dados, é possível gravar formatos de compressão comuns.

Fazer login no console AWS Glue

Um trabalho no AWS Glue consiste na lógica de negócios que realiza o trabalho de extração, transformação e carregamento (ETL). Você pode criar trabalhos na seção ETL do console do AWS Glue.

Para visualizar trabalhos existentes, faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/. Em seguida, escolha a guia Jobs no AWS Glue. A lista Jobs exibe o local do script associado a cada trabalho, a hora em que o trabalho foi modificado pela última vez e a opção atual do marcador de trabalho.

Ao criar um novo trabalho, ou depois de ter salvo seu trabalho, você pode usar o AWS Glue Studio para modificar seus trabalhos de ETL. Você pode fazer isso editando os nós no editor visual ou editando o script de trabalho no modo de desenvolvedor. Você também pode adicionar e remover nós no editor visual para criar trabalhos de ETL mais complicados.

Próximas etapas para criar um trabalho no AWS Glue Studio

Use o editor de trabalhos visual para configurar nós para seu trabalho. Cada nó representa uma ação, como ler dados do local de origem ou aplicar uma transformação aos dados. Cada nó adicionado ao trabalho tem propriedades que fornecem informações sobre o local dos dados ou a transformação.

As próximas etapas para criar e gerenciar seus trabalhos são:

- Iniciar trabalhos de ETL visual no AWS Glue Studio
- Visualizar o script de trabalho
- Modificar as propriedades do trabalho
- Salvar o trabalho
- Iniciar uma execução de trabalho
- Exibir informações para execuções de trabalho recentes
- Acessar o painel de monitoramento de trabalhos

Iniciar trabalhos de ETL visual no AWS Glue Studio

Você pode usar a interface visual simples no AWS Glue Studio para criar seus trabalhos de ETL. Você pode usar a página Jobs (Trabalhos) para criar novos trabalhos. Você também pode usar um editor de scripts ou bloco e anotações para trabalhar diretamente com código no script de trabalho de ETL do AWS Glue Studio.

Na página Jobs (Trabalhos), você também pode ver todos os trabalhos que criou com o AWS Glue Studio ou o AWS Glue. Você pode exibir, gerenciar e executar seus trabalhos nessa página.

Veja também o tutorial do blog em outro exemplo de como criar trabalhos de ETL com o AWS Glue Studio.

Iniciar trabalhos no AWS Glue Studio

O AWS Glue permite criar um trabalho por meio de uma interface visual, um caderno de código interativo ou com um editor de scripts. Você pode iniciar um trabalho clicando em qualquer uma das opções ou criar um novo trabalho com base em um trabalho de exemplo.

Exemplos de trabalhos de criação de trabalho com a ferramenta de sua escolha. Por exemplo, exemplos de trabalhos permitem que você crie um trabalho ETL visual que une arquivos CSV em

uma tabela de catálogo, crie um trabalho em um caderno de código interativo com o AWS Glue para Ray ou AWS Glue para Spark ao trabalhar com pandas ou crie uma tarefa em um caderno de código interativo com o SparkSQL.

Criando um trabalho no AWS Glue Studio do zero

1. Faça login no AWS Management Console e abra o console do AWS Glue Studio em https://console.aws.amazon.com/gluestudio/.
2. No painel de navegação, escolha Trabalhos.
3. Na seção Criar trabalho, escolha uma opção de configuração para o seu trabalho.

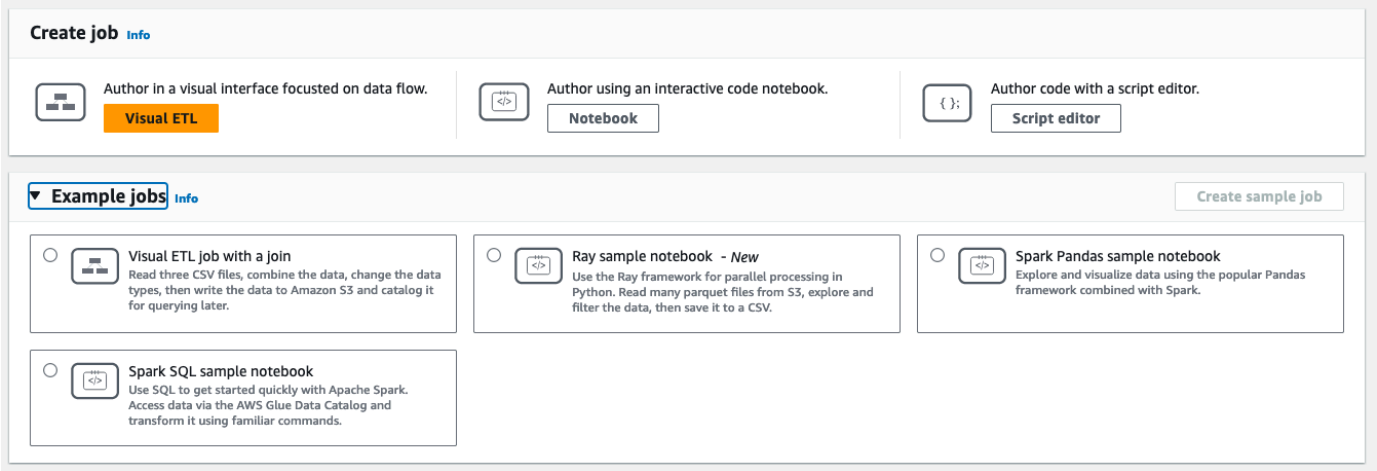

Opções para criar um trabalho do zero:

- Visual ETL: criar em uma interface visual focada no fluxo de dados
- Criar usando um caderno de código interativo: criar trabalhos interativamente em uma interface de caderno baseada em cadernos Jupyter

  Quando seleciona esta opção, você deve fornecer informações adicionais antes de criar uma sessão de criação de caderno. Para obter mais informações sobre como especificar essas informações, consulte Conceitos básicos de cadernos no AWS Glue Studio.
- Editor de scripts Spark: para aqueles familiarizados com programação e escrita de scripts de ETL, escolha essa opção para criar um novo trabalho de ETL do Spark. Escolha o mecanismo (Python shell, Ray, Spark (Python) ou Spark (Scala). Em seguida, escolha Começar do zero ou Carregar script. Carregar um script existente a partir de um arquivo local. Se você optar por usar o editor de scripts, não será possível usar o editor de trabalhos visual para criar ou editar seu trabalho.

Um trabalho do Spark é executado em um ambiente Apache Spark gerenciado pelo AWS Glue. Por padrão, novos scripts são codificados em Python. Para escrever um novo script em Scala, consulte Criar e editar scripts em Scala no AWS Glue Studio.

Criar um trabalho no AWS Glue Studio partir de um trabalho de exemplo

Você pode optar por criar um trabalho a partir de um trabalho de exemplo. Na seção Trabalhos de exemplo, escolha um trabalho de exemplo e, em seguida, escolha Criar trabalho de exemplo. A criação de um trabalho de exemplo a partir de uma das opções fornece um modelo rápido com o qual você pode trabalhar.

1. Faça login no AWS Management Console e abra o console do AWS Glue Studio em https://console.aws.amazon.com/gluestudio/.
2. No painel de navegação, escolha Trabalhos.
3. Selecione uma opção para criar um trabalho a partir de um trabalho de exemplo:
   - Trabalho de ETL visual para unir várias fontes: ler três arquivos CSV, combinar os dados, alterar os tipos de dados e, em seguida, gravar os dados no Amazon S3 e catalogá-los para consulta posterior.
   - Notebook Spark usando Pandas: explorar e visualizar dados usando a popular estrutura do Panda combinada com o Spark.
   - Caderno Spark usando SQL: usar SQL para começar a usar rapidamente o Apache Spark. Acessar dados por meio do catálogo de dados do AWS Glue e transformá-los usando comandos familiares.
4. Escolha Criar trabalho de exemplo.

Recursos do editor de trabalhos

O editor de trabalhos fornece os seguintes recursos para criar e editar trabalhos.

- Um diagrama visual do seu trabalho, com um nó para cada tarefa de trabalho: nós de origem de dados para lê-los, transformar nós para modificá-los, nós de destino de dados para gravá-los.

  Você pode exibir e configurar as propriedades de cada nó no diagrama de trabalho. Você também pode exibir os dados de esquema e de exemplo de cada nó no diagrama de trabalho. Esses

recursos ajudam você a verificar se seu trabalho está modificando e transformando os dados da maneira correta, sem ter que executar o trabalho.

- Uma guia de exibição e edição de scripts, onde você pode modificar o código gerado para seu trabalho.
- Uma guia de detalhes do trabalho, onde você pode configurar uma variedade de configurações para personalizar o ambiente no qual seu trabalho de ETL do AWS Glue é executado.
- Uma guia de execuções, onde você pode exibir as execuções atuais e anteriores do trabalho, visualizar o status da execução do trabalho e acessar os logs da execução do trabalho.
- Uma guia Qualidade de dados, na qual você pode aplicar regras de qualidade de dados ao seu trabalho.
- Uma guia de programações, na qual você pode configurar o momento de início de seu trabalho ou configurar execuções recorrentes de um trabalho.
- Uma guia Controle de versão, na qual você pode configurar um serviço Git para usar com seu trabalho.

Usar previsualizações de esquema no editor de trabalhos visual

Ao criar ou editar seu trabalho, você pode usar a guia Output schema (Esquema de saída) para exibir o esquema dos dados.

Antes que você possa ver o esquema, o editor de trabalhos precisa de permissões para acessar a origem dos dados. Você pode especificar uma função do IAM para um nó na guia Job details (Detalhes do trabalho) do editor ou na guia Output schema (Esquema de saída). Se a função do IAM tiver todas as permissões necessárias para acessar a origem dos dados, você poderá visualizar o esquema na guia Output schema (Esquema de saída) de um nó.

Usar previsualizações de dados no editor de trabalhos visual

As pré-visualizações de dados ajudam você a criar e testar seu trabalho usando um exemplo dos seus dados sem precisar executá-lo repetidamente. Ao usar a pré-visualização de dados, você pode:

- Testar um perfil do IAM para garantir que ele tenha acesso a suas fontes ou destinos de dados.
- Verificar se a transformação está modificando os dados da maneira pretendida. Por exemplo, se você usar uma transformação de filtro, pode certificar-se de que o filtro está selecionando o subconjunto correto de dados.

- Verifique seus dados. Se o conjunto de dados contiver colunas com valores de vários tipos, a visualização de dados mostrará uma lista de tuplas para elas. Cada tupla contém o tipo de dado e seu valor.

> **Note**
>
> Se você usar uma sessão de visualização de dados e um SQL personalizado ou um nó de código personalizado, a sessão de visualização de dados executará o SQL ou o bloco de código no estado em que se encontra para todo o conjunto de dados.

Ao criar ou editar seu trabalho, você pode usar a guia Visualização de dados abaixo da tela do trabalho para visualizar uma amostra dos seus dados. Uma nova sessão de pré-visualização de dados será iniciada automaticamente quando o perfil já estiver configurado no trabalho ou um perfil do IAM padrão tiver sido configurado na conta. Se um perfil não tiver sido configurado anteriormente, você poderá iniciar uma sessão selecionando o perfil.

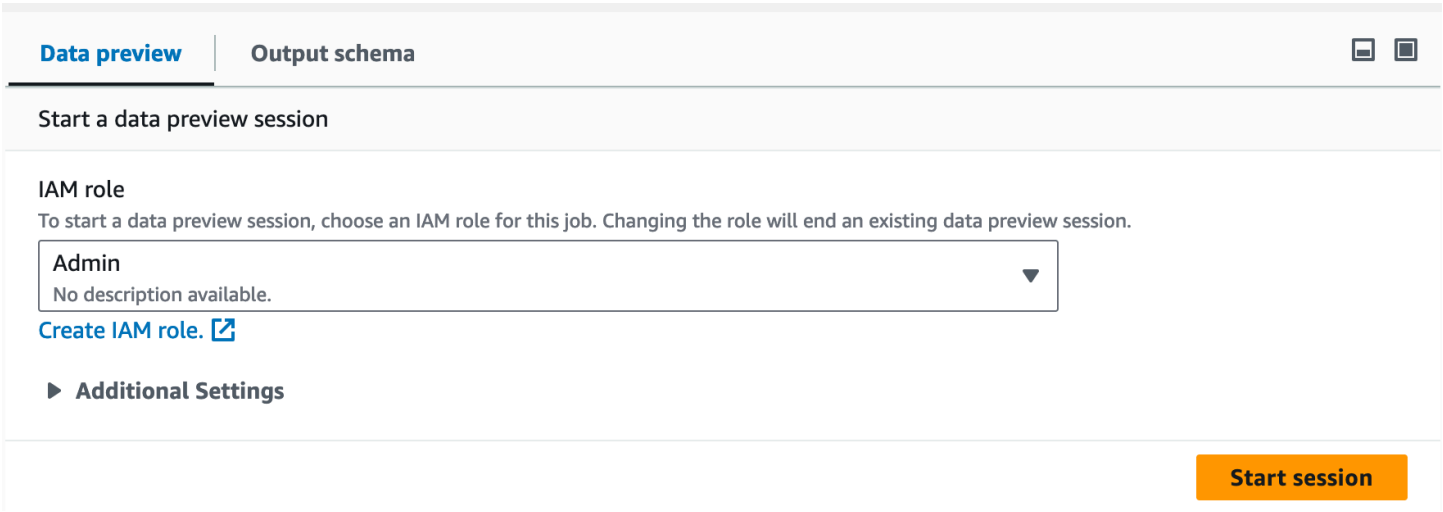

> **Note**
>
> O perfil que você escolher para a sessão de pré-visualização de dados também será usado para o trabalho.

É possível ver o status e o progresso da sua sessão, bem como os detalhes da sessão, clicando no ícone de informações.

Quando a sessão estiver pronta, o AWS Glue Studio carregará os dados para o nó selecionado. É possível visualizar o % concluído à medida que a sessão avança.

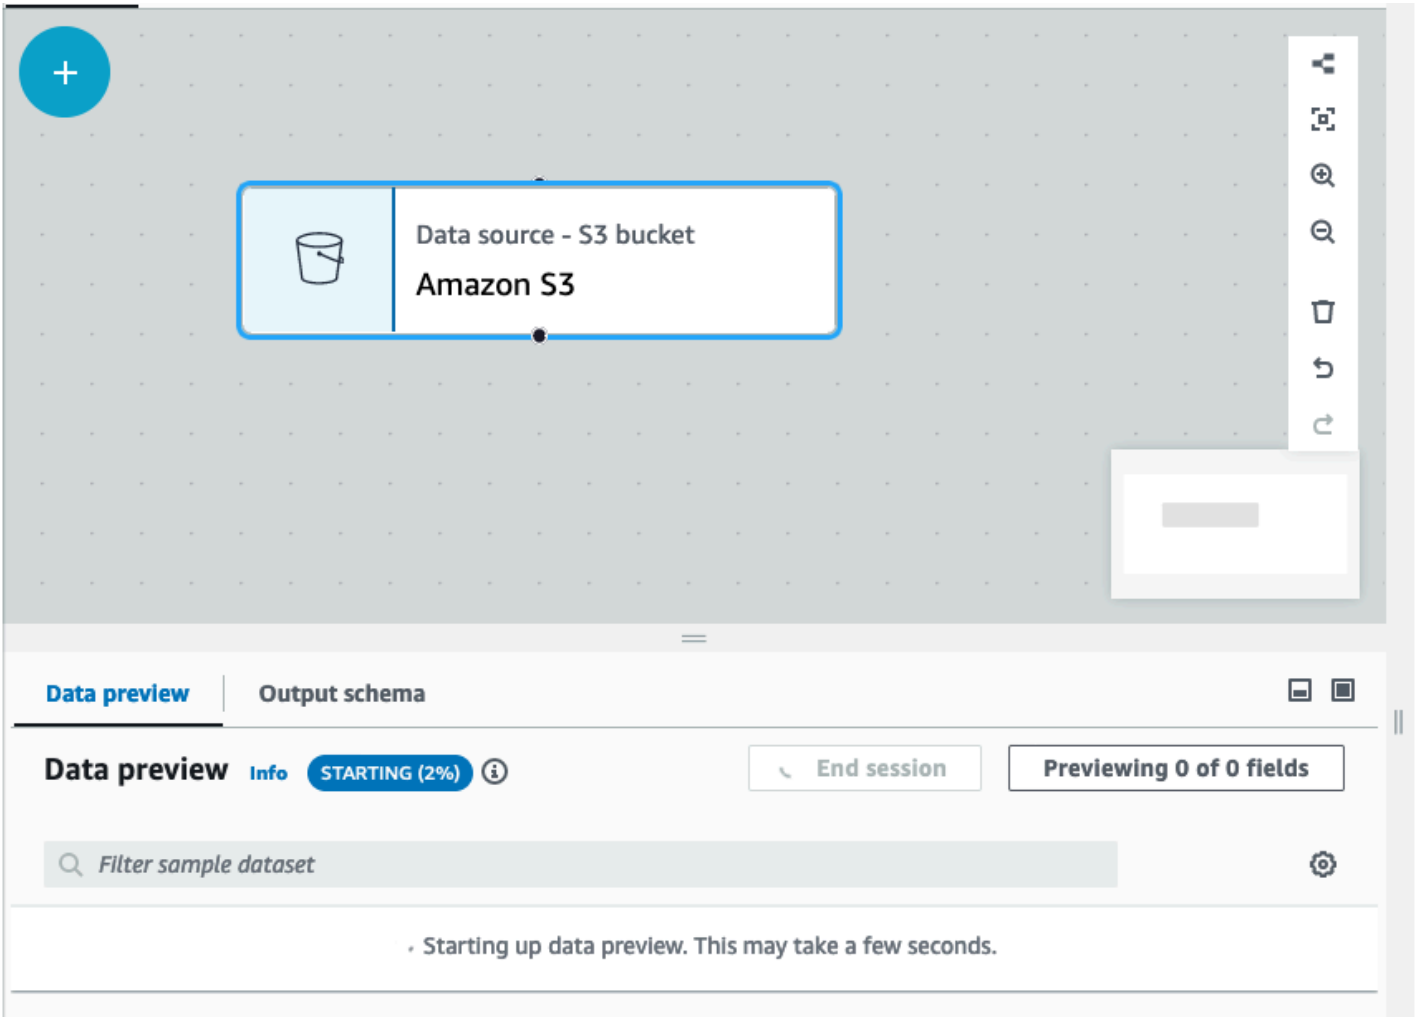

À medida que você criar seu trabalho visual, o AWS Glue Studio atualizará automaticamente o esquema do nó selecionado quando você alternar Inferir esquema da sessão na guia Esquema de saída.

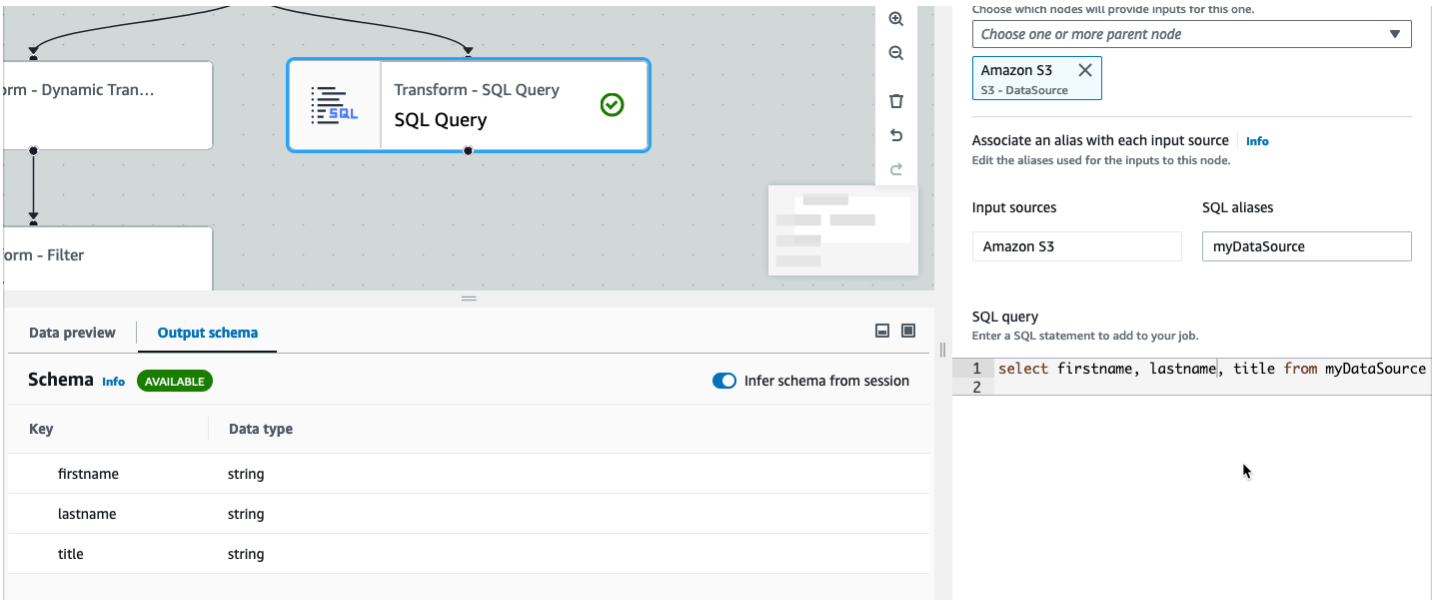

Para configurar suas preferências de pré-visualização de dados:

Escolha o ícone de configurações (um símbolo de engrenagem) para configurar suas preferências de previsualizações de dados. Essas configurações se aplicam a todos os nós no diagrama de trabalho. É possível:

- Optar por quebrar o texto de uma linha para a próxima. Essa opção é habilitada por padrão
- Alterar o número de linhas (o padrão é 200)
- Escolher ou, se necessário, criar um perfil do IAM
- Optar por iniciar automaticamente uma nova sessão ao criar um trabalho. Isso fornece uma nova sessão interativa ao criar trabalhos. Essa configuração é aplicável no nível da conta. Uma vez definida, a configuração será aplicada a todos os usuários da sua conta ao editar qualquer trabalho.
- Escolher inferir automaticamente o esquema. Os esquemas de saída serão automaticamente inferidos para o nó selecionado
- Optar por importar automaticamente bibliotecas do AWS Glue. Isso é útil porque evitará que a pré-visualização de dados reinicie novas sessões ao adicionar novas transformações que exijam a reinicialização da sessão

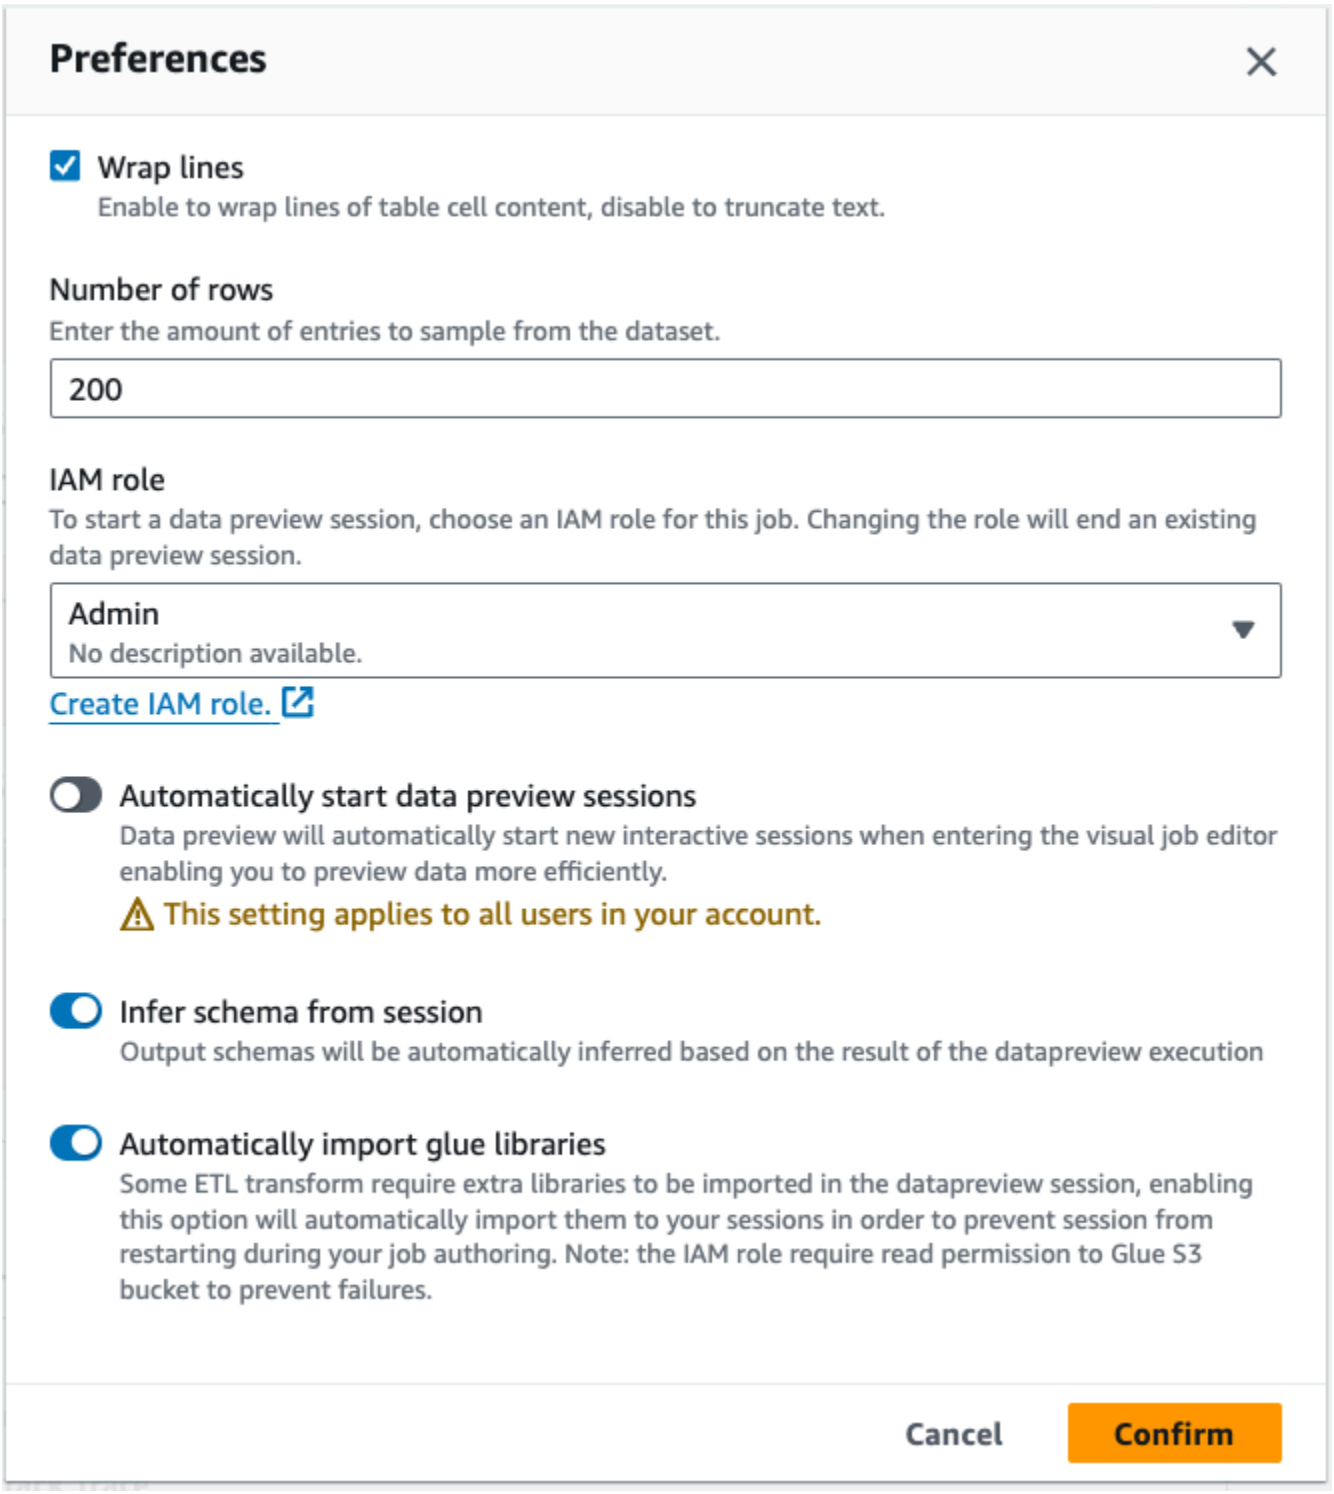

Os recursos adicionais incluem a capacidade de:

- Selecione o botão Previewing x of y fields (Previsualização de x de y campos) para selecionar quais colunas (campos) serão previsualizadas. Quando você previsualiza seus dados usando as

configurações padrão, o editor de trabalhos mostra as cinco primeiras colunas do seu conjunto de dados. Você pode alterar essa opção para mostrar todas ou nenhuma (não recomendado).

- Role pela janela de pré-visualização de dados, tanto na horizontal quanto na vertical.
- Use o botão maximizar para expandir a guia Visualização de dados para sobrepor o gráfico do trabalho e visualizar melhor os dados e as estruturas de dados. Da mesma forma, use o botão minimizar para minimizar a guia Visualização de dados. Você também pode pegar o painel da alça e arrastar para cima para expandir a guia Visualização de dados.

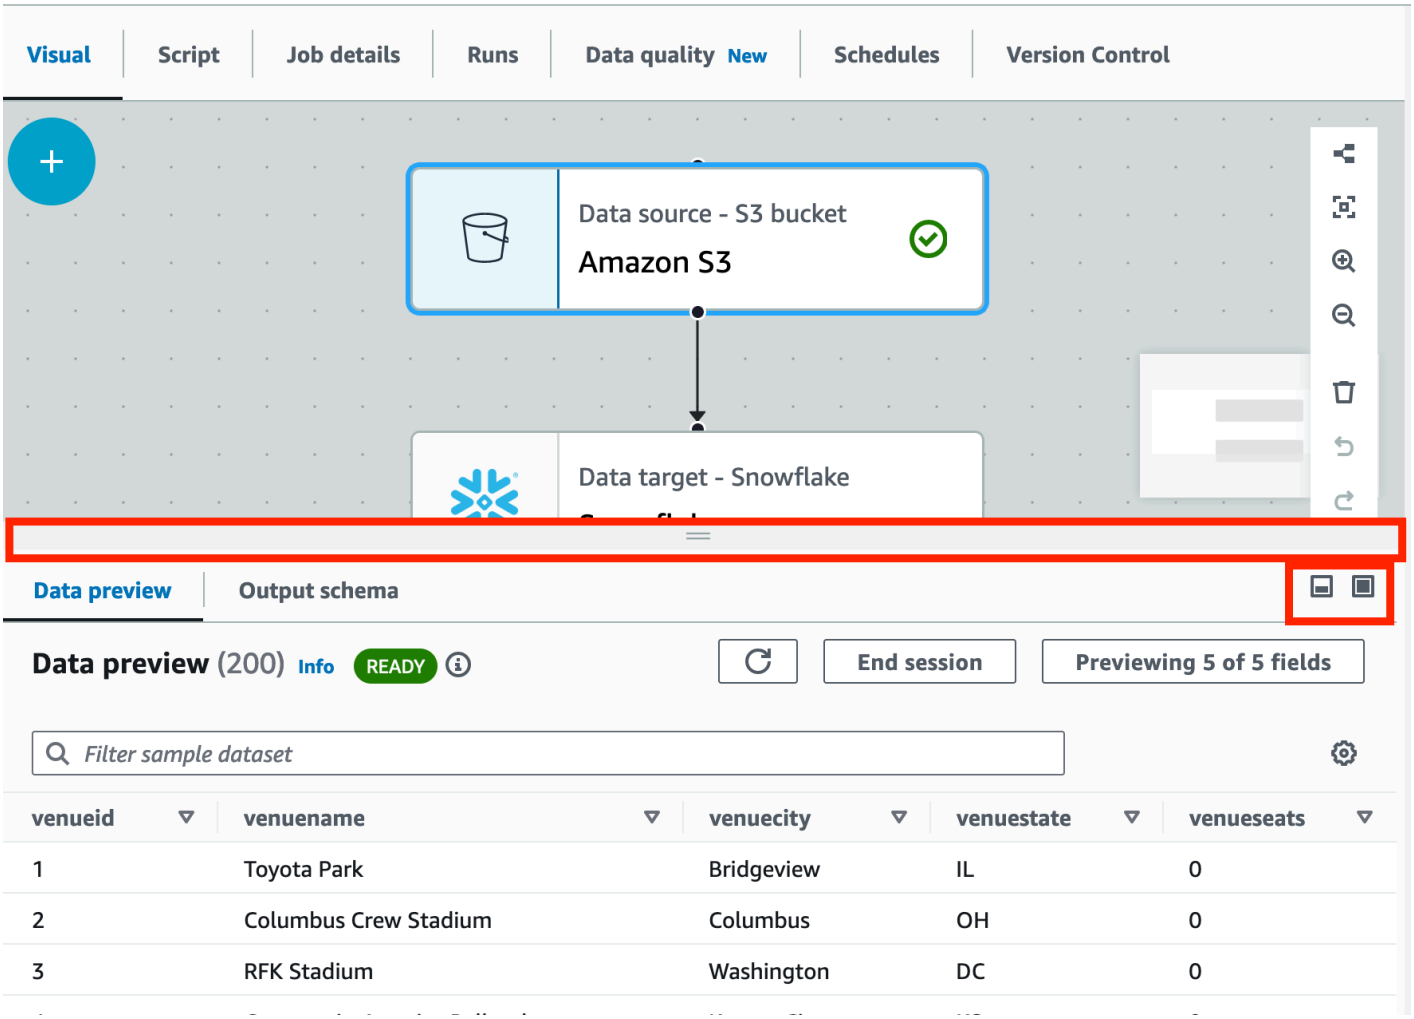

- Use Encerrar sessão para interromper a visualização dos dados. Ao interromper a sessão, você pode escolher um novo perfil do IAM e definir configurações adicionais (como ativar ou desativar configurações) para iniciar automaticamente uma nova sessão, inferir um esquema ou importar AWS Glue bibliotecas e iniciar a sessão novamente.

Restrições ao usar previsualizações de dados

Ao usar previsualizações de dados, você pode encontrar as seguintes restrições ou limitações.

- Na primeira vez que você escolhe a guia Data preview (Previsualização de dados), deve escolher uma função do IAM. Essa função deve ter as permissões exigidas para acessar os dados e outros recursos necessários para criar as previsualizações de dados.
- Depois de fornecer uma função do IAM, leva um tempo até que os dados estejam disponíveis para visualização. Para conjuntos de dados com menos de 1 GB de dados, pode levar até um minuto. Se você tiver um conjunto de dados grande, deverá usar partições para melhorar o tempo de carregamento. Carregar dados diretamente no Amazon S3 apresenta a melhor performance.
- Se você tiver um conjunto de dados muito grande e levar mais de 15 minutos para consultar os dados para a previsualização, a solicitação excederá o tempo limite. As pré-visualizações de dados têm um tempo limite de inatividade de 30 minutos. Para aliviar isso, reduza o tamanho do conjunto de dados para usar previsualizações de dados.
- Por padrão, você vê as 50 primeiras colunas na guia Data preview (Previsualização de dados). Se as colunas não tiverem valores de dados, você receberá uma mensagem informando que não há dados para exibir. Você pode aumentar o número de linhas de amostra ou de colunas diferentes selecionadas para ver os valores dos dados.
- No momento, as previsualizações de dados não são suportadas para origens de dados de transmissão ou para origens de dados que usam conectores personalizados.
- Erros em um nó afetam todo o trabalho. Se qualquer nó tiver um erro nas previsualizações de dados, ele aparecerá em todos os nós até que você o corrija.
- Se você alterar uma origem de dados para o trabalho, os nós filhos dessa origem de dados talvez precisem ser atualizados para corresponder ao novo esquema. Por exemplo, se você tiver um nó ApplyMapping que modifica uma coluna e ela não existir na origem de dados de substituição, será necessário atualizar o nó de transformação ApplyMapping.
- Se você exibir a guia Data preview (Previsualização de dados) para um nó de transformação de consulta SQL e tal consulta usar um nome de campo incorreto, a guia Data preview (Previsualização de dados) exibirá um erro.

Geração de código de script

Quando você usa o editor visual para criar um trabalho, o código ETL é gerado automaticamente para você. O AWS Glue Studio cria um script de trabalho funcional e completo e o salva em um local do Amazon S3.

Existem duas formas de código geradas pelo AWS Glue Studio: a versão original, ou clássica, e uma versão mais nova e racionalizada. Por padrão, o novo gerador de código é usado para criar o script de trabalho. Você pode gerar um script de trabalho usando o gerador de código clássico na guia Script escolhendo o botão Generate classic script (Gerar script clássico).

Algumas das diferenças na nova versão do código gerado incluem:

- Blocos de comentários grandes não são mais adicionados ao script
- As estruturas de saída no código usam o nome do nó especificado no editor visual. No script clássico, as estruturas de saída são simplesmente nomeadas `DataSource0`, `DataSource1`, `Transform0`, `Transform1`, `DataSink0`, `DataSink1` e assim por diante.
- Comandos longos são divididos em várias linhas para eliminar a necessidade de rolar pela página para ver o comando inteiro.

Novos recursos no AWS Glue Studio exigem a nova versão da geração de código e não funcionarão com o script de código clássico. Você será solicitado a atualizar esses trabalhos ao tentar executá-los.

Transformar dados com transformações gerenciadas do AWS Glue

O AWS Glue Studio fornece dois tipos de transformação:

- Transformações nativas do AWS Glue, disponíveis para todos os usuários e gerenciadas pelo AWS Glue.
- Transformações visuais personalizadas, permitem que você carregue suas próprias transformações para usar no AWS Glue Studio

Nós de transformação de dados gerenciados pelo AWS Glue

O AWS Glue Studio fornece um conjunto de transformações integradas que você pode usar para processar seus dados. Seus dados passam de um nó no diagrama de trabalho para outro em uma estrutura de dados chamada `DynamicFrame`, que é uma extensão para um `DataFrame` do Apache Spark SQL.

No diagrama previamente preenchido de um trabalho, entre os nós de fonte de dados e de destino de dados está o nó de transformação Change Schema. Você pode configurar esse nó de transformação para modificar seus dados ou pode usar transformações adicionais.

As transformações integradas a seguir estão disponíveis no AWS Glue Studio:

- ChangeSchema: mapear chaves de propriedade de dados na fonte de dados para chaves de propriedade de dados no destino dos dados. Você pode renomear chaves, modificar os tipos de dados para chaves e escolher quais chaves remover do conjunto de dados.
- SelectFields (Selecionar campos): escolha as chaves de propriedade de dados que você deseja manter.
- DropFields (Descartar campos): escolha as chaves de propriedade de dados que você deseja descartar.
- RenameField (Renomear campo): renomeie uma única chave de propriedade de dados.
- Spigot (Torneira): grave amostras dos dados em um bucket do Amazon S3.
- Join (Unir): una dois conjuntos de dados em um só, usando uma frase de comparação nas chaves de propriedade de dados especificadas. Você pode usar junção inner (interna), outer (externa), left (à esquerda), right (à direita), left semi (semi à esquerda) e left anti (anti à esquerda).
- Union: combinar linhas de mais de uma fonte de dados que tenham o mesmo esquema.
- SplitFields (Dividir campos): divida chaves de propriedade de dados em dois `DynamicFrames`. A saída é uma coleção de `DynamicFrames`: um com chaves de propriedade de dados selecionadas e outro com as chaves de propriedade de dados restantes.
- SelectFromCollection (Selecionar na coleção): escolha um `DynamicFrame` a partir de uma coleção de `DynamicFrames`. A saída é o `DynamicFrame` selecionado.
- FillMissingValues (Preencher valores ausentes): localize registros no conjunto de dados que têm valores ausentes e adicione um novo campo com um valor determinado por imputação.
- Filter (Filtro): divida um conjunto de dados em dois, com base em uma condição de filtro.
- Drop Null Fields (Descartar campos nulos): remove colunas do conjunto de dados se todos os valores na coluna forem "null" (nulo).
- Drop Duplicates (Eliminar duplicatas): remove linhas da sua fonte de dados escolhendo combinar linhas inteiras ou especificar chaves.
- SQL: insira o código SparkSQL em um campo de entrada de texto para usar uma consulta SQL para transformar os dados. A saída é um único `DynamicFrame`.
- Agregar: executa um cálculo (como média, soma, mínimo, máximo) em campos e linhas selecionados, e cria um novo campo com os valores recém-calculados.
- Nivelar: extraia campos dentro de structs para campos de nível superior.
- UUID: adicione uma coluna com um identificador universal exclusivo para cada linha.

- Identificador: adicione uma coluna com um identificador numérico para cada linha.
- Em timestamp: converta uma coluna em tipo timestamp.
- Formatar timestamp: converta uma coluna de timestamp em uma string formatada.
- Transformação de roteador condicional: aplique várias condições aos dados de entrada. Cada linha dos dados de entrada avaliada por uma condição de filtro de grupo e processada no grupo correspondente.
- Transformação Concatenate Columns: Criar uma nova coluna de strings usando os valores de outras colunas com um espaçador opcional.
- Transformação Split String: permite que você divida uma string em uma matriz de tokens usando uma expressão regular para definir como a divisão é feita.
- Transformação Array To Columns: extrair alguns ou todos os elementos de uma coluna do tipo matriz para novas colunas.
- Transformação Add Current Timestamp: permite marcar as linhas com a hora em que os dados foram processados. Isso é útil para fins de auditoria ou para rastrear a latência no pipeline de dados.
- Transformação Pivot Rows to Columns: agregar uma coluna numérica girando valores únicos nas colunas selecionadas que se tornam novas colunas. Se várias colunas forem selecionadas, os valores serão concatenados para nomear as novas colunas.
- Transformação Unpivot Columns To Rows: converter colunas em valores de novas colunas, gerando uma linha para cada valor único.
- Transformação Autobalance Processing: redistribuir os dados entre os operadores para melhorar a performance. Isso ajuda nos casos em que os dados estão desbalanceados ou, como vêm da fonte, não permitem processamento paralelo suficiente.
- Transformação Derived Column: definir uma nova coluna com base em uma fórmula matemática ou expressão SQL na qual você pode usar outras colunas nos dados, além de constantes e literais.
- Transformação Lookup: adicionar colunas de uma tabela de catálogo definida quando as chaves correspondem às colunas de pesquisa nos dados.
- Transformação Explode Array Map Into Rows: extrair valores de uma estrutura aninhada em linhas individuais que são mais fáceis de manipular.
- Transformação Record matching: invocar uma transformação de classificação de dados de machine learning Record Matching existente.

- Transformação Remove null rows: remover do conjunto de dados as linhas que têm todas as colunas nulas ou vazias.
- Transformação Parse JSON comumn: analisar uma coluna de strings contendo dados JSON e a converter em uma estrutura ou coluna de matriz, dependendo se o JSON for um objeto ou uma matriz, respectivamente.
- Transformação Extract JSON path: extrair novas colunas de uma coluna de strings JSON.
- EssaTransformação Extract stringtransformaçãofragmentsextraifrom a regular expression: extrair fragmentos de string usando uma expressão regular e criacriar uma nova coluna a partir dela, ou várias colunas se estiver usando grupos regex.
- Custom transform (Transformação personalizada): insira o código em um campo de entrada de texto para usar transformações personalizadas. A saída é uma coleção de `DynamicFrames`.

Usando uma fórmula de preparação de dados no AWS Glue Studio

A transformação da fórmula de preparação de dados permite que você crie uma fórmula de preparação de dados do zero usando uma interface de criação interativa em estilo de grade. Também permite que você importe uma fórmula disponível do AWS Glue DataBrew e depois a edite no AWS Glue Studio.

O nó Fórmula de preparação de dados está disponível no painel Recursos. Você pode conectar o nó Fórmula de preparação de dados a outro nó no fluxo de trabalho visual, seja ele um nó de fonte de dados ou outro nó de transformação. Depois de escolher uma fórmula e uma versão do AWS Glue DataBrew, as etapas aplicadas na fórmula ficam visíveis na guia de propriedades do nó.

Pré-requisitos

- Ao importar uma fórmula do AWS Glue DataBrew, você tem as permissões necessárias do IAM, conforme descrito em Importar uma fórmula do AWS Glue DataBrew no AWS Glue Studio.
- Uma sessão de pré-visualização de dados deve ser criada.

Limitações

- As fórmulas do AWS Glue DataBrew são apenas compatíveis em regiões comerciais do DataBrew.
- Nem todas as fórmulas do AWS Glue DataBrew são compatíveis com o AWS Glue. Algumas fórmulas não poderão ser executadas no AWS Glue Studio.

  - Fórmulas com transformações `UNION` e `JOIN` não são compatíveis, no entanto, o AWS Glue Studio já possui nós de transformação “Join” e “Union” que podem ser usados antes ou depois de um nó de Fórmula de preparação de dados.
- Os nós de Data Preparation Recipe são compatíveis com trabalhos a partir do AWS Glue versão 4.0. Essa versão será selecionada automaticamente depois que um nó de Data Preparation Recipe for adicionado ao trabalho.
- Nós Data Preparation Recipe exigem o Python. Isso é definido automaticamente quando o nó Data Preparation Recipe é adicionado ao trabalho.
- Adicionar um novo nó de Fórmula de preparação de dados ao gráfico visual reiniciará automaticamente sua sessão de pré-visualização de dados com as bibliotecas corretas para usar o nó de Fórmula de preparação de dados.
- As seguintes transformações não são compatíveis para importação ou edição em um nó de Fórmula de preparação de dados: `GROUP_BY`, `PIVOT`, `UNPIVOT` e `TRANSPOSE`.

Recursos adicionais

Depois de selecionar a transformação da Fórmula de preparação de dados, será possível executar ações adicionais depois de escolher Criar fórmula.

- Adicionar etapa: você pode adicionar etapas adicionais a uma fórmula, conforme necessário, escolhendo o ícone de adicionar etapa, ou pode usar a barra de ferramentas no painel de pré-visualização e escolher uma ação.

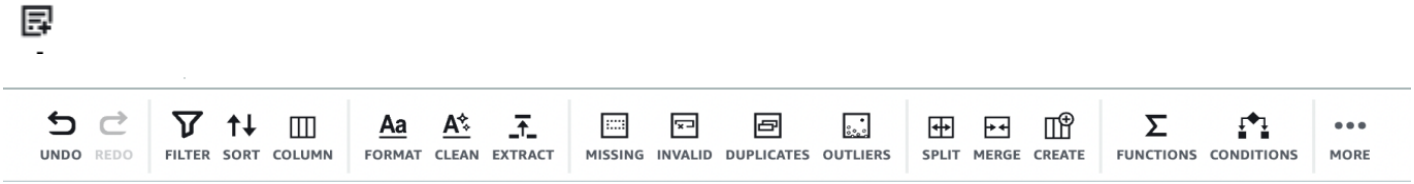

- Importar fórmula: escolha Mais e depois Importar fórmula para usar em seu trabalho do AWS Glue Studio.

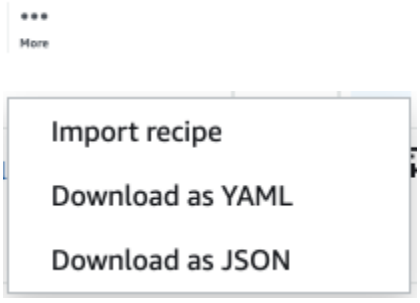

- Baixar como YAML: escolha Mais e depois Baixar como YAML para baixar sua fórmula e salvá-la fora do AWS Glue Studio.
- Baixar como JSON: escolha Mais e depois Baixar como JSON para baixar sua fórmula e salvá-la fora do AWS Glue Studio.
- Desfazer e refazer etapas da fórmula: você pode desfazer e refazer etapas da fórmula no painel Pré-visualizar ao trabalhar com dados na grade.

Criar e executar fórmulas de preparação de dados em um trabalho visual de ETL do AWS Glue

Nesse cenário, você pode criar fórmulas de preparação de dados sem precisar primeiro criá-las no DataBrew. Antes de começar a criar fórmulas, você deve:

- Ter uma sessão ativa de pré-visualização de dados em execução. Quando a sessão de pré-visualização de dados estiver PRONTA, a Fórmula do autor ficará ativa e você poderá começar a criá-la ou editá-la.

- Certifique-se de que a opção Importar bibliotecas do Glue automaticamente esteja ativada.

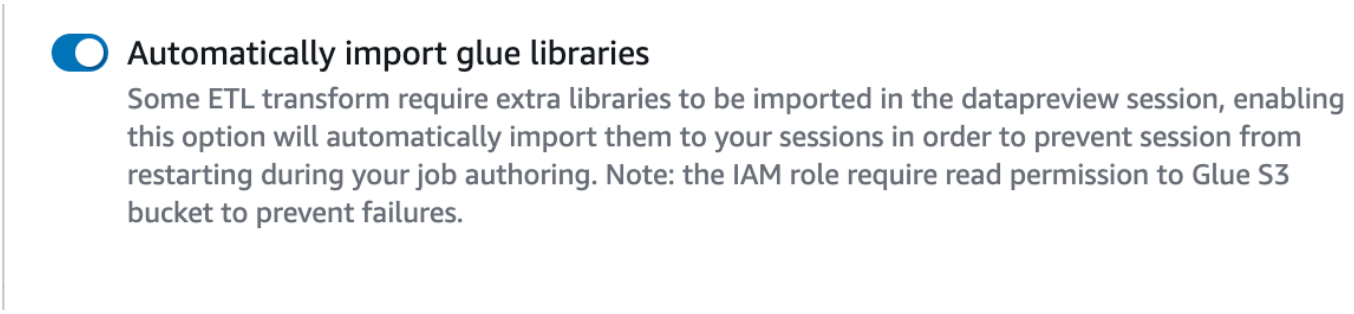

  Você pode fazer isso escolhendo o ícone de engrenagem no painel Pré-visualização de dados.

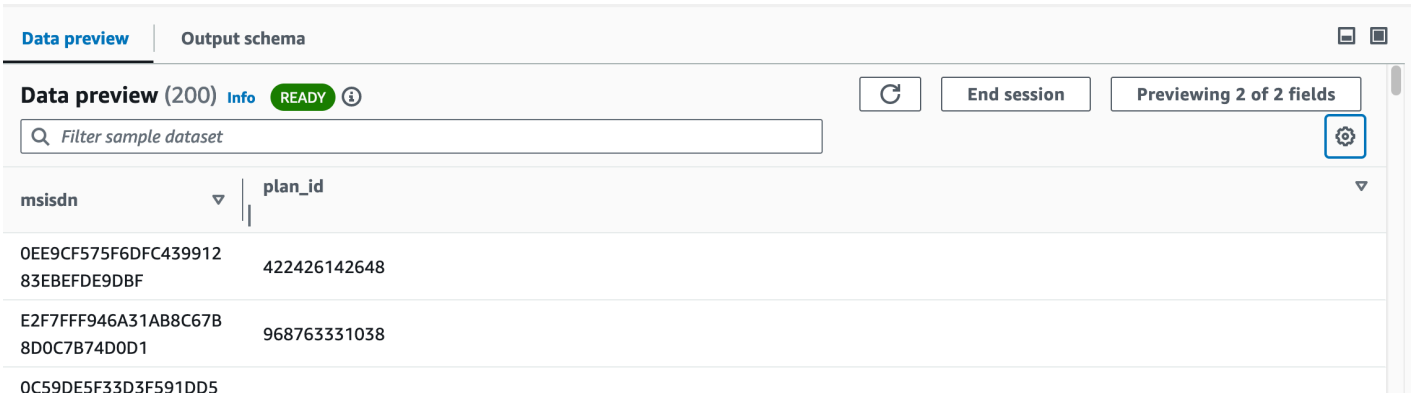

Para criar uma fórmula de preparação de dados no AWS Glue Studio:

1. Adicione a transformação da Fórmula de preparação de dados à sua tela de trabalho. Sua transformação deve estar conectada a um nó principal da fonte de dados. Ao adicionar o nó da Fórmula de preparação de dados, ele será reiniciado com as bibliotecas apropriadas e você verá o dataframe sendo preparado.

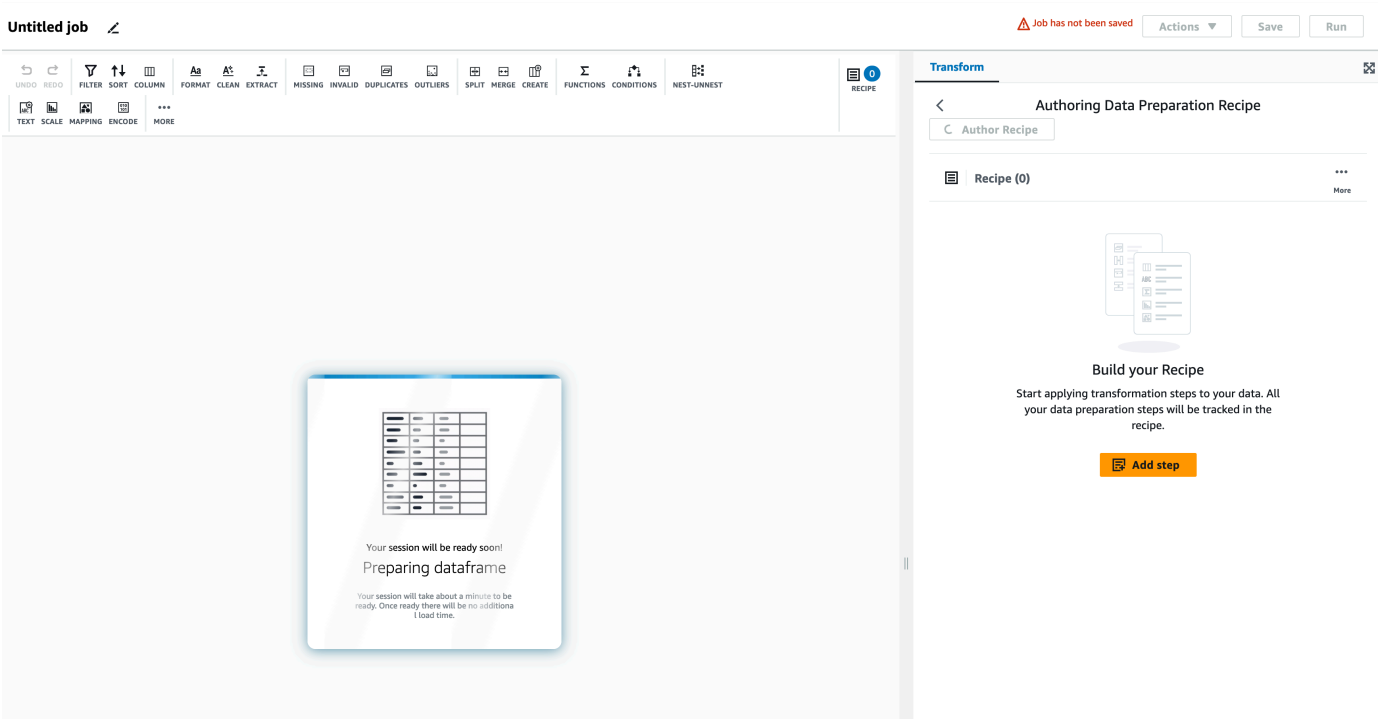

2. Quando a sessão de pré-visualização de dados estiver pronta, os dados com todas as etapas aplicadas anteriormente aparecerão na parte inferior da tela.
3. Escolha Criar fórmula. Essa opção permitirá que você inicie uma nova fórmula no AWS Glue Studio.

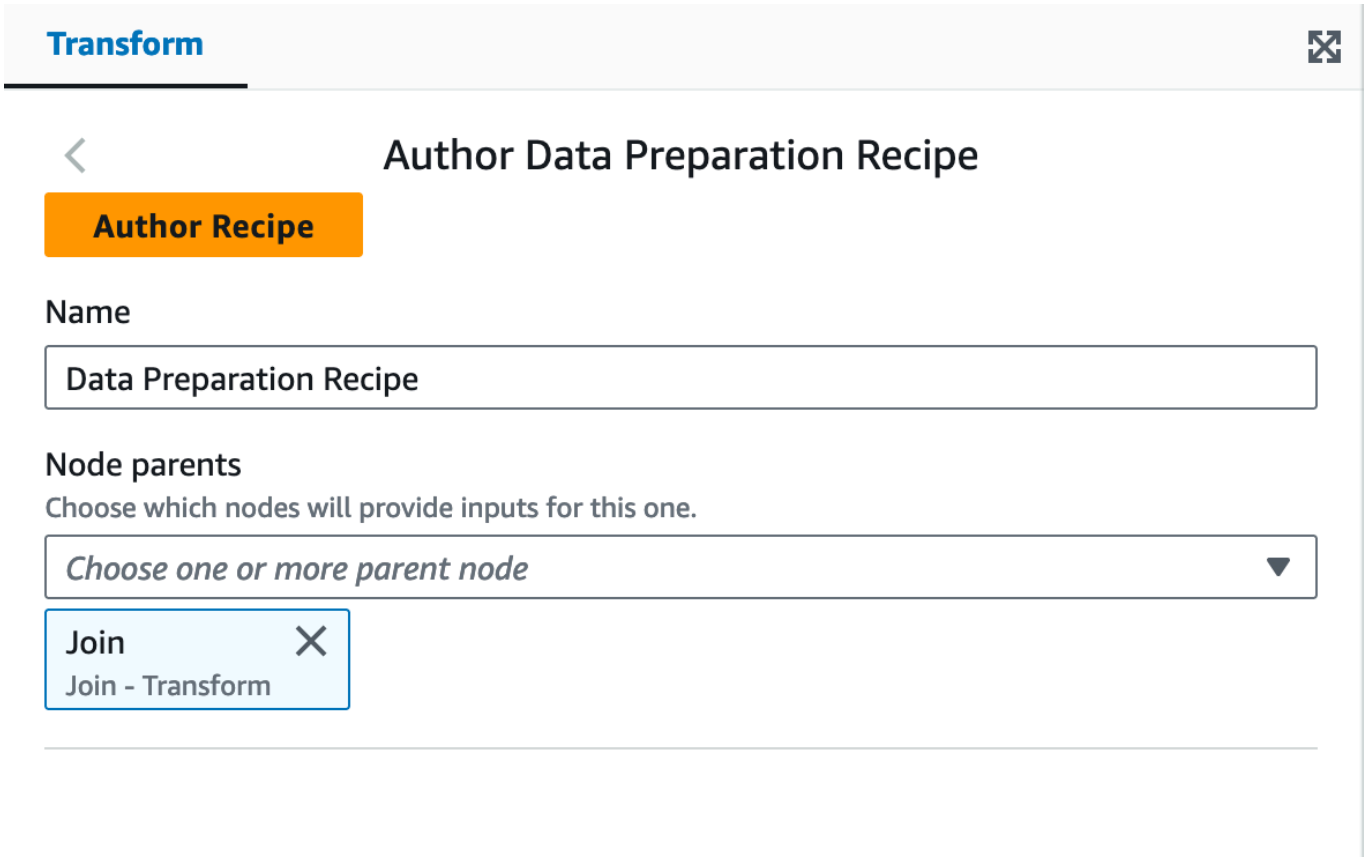

4. No painel Transformar à direita da tela de trabalho, insira um nome para sua fórmula de preparação de dados.
5. No lado esquerdo, a tela será substituída por uma visualização em grade dos seus dados. À direita, o painel Transformar mudará para mostrar as etapas da fórmula. Escolha Adicionar etapa para adicionar a primeira etapa em sua fórmula.

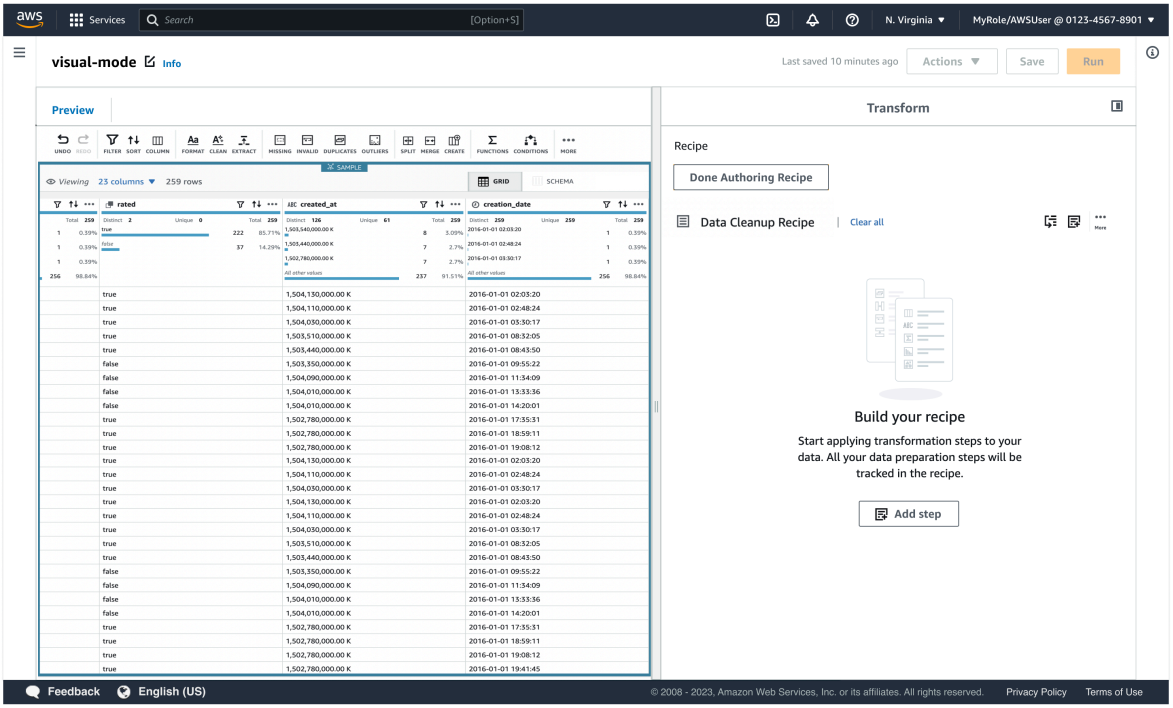

6. No painel Transformar, escolha classificar, executar uma ação na coluna e filtrar valores. Por exemplo, escolha Renomear coluna.

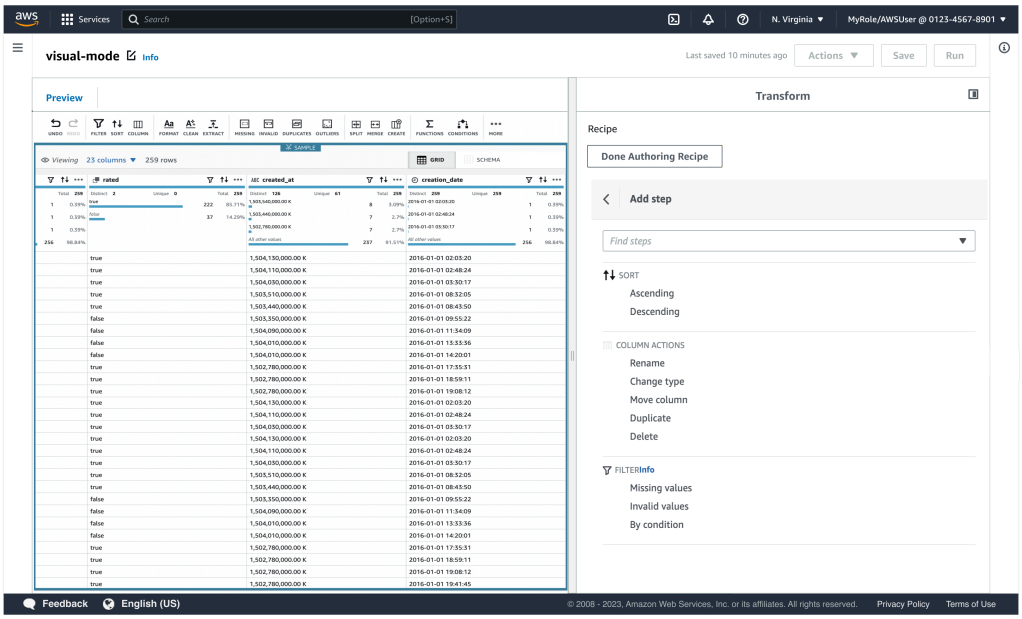

7. No painel Transformar no lado direito, as opções para renomear uma coluna permitem que você escolha a coluna de origem a ser renomeada e insira o novo nome da coluna. Depois de executar essa ação, escolha Aplicar.

   Você pode pré-visualizar cada etapa, desfazer uma etapa, reordenar etapas e usar qualquer um dos ícones de ação, como Filtrar, Classificar, Dividir, Mesclar etc. Quando você executa ações na grade de dados, as etapas são adicionadas à fórmula no painel Transformar.

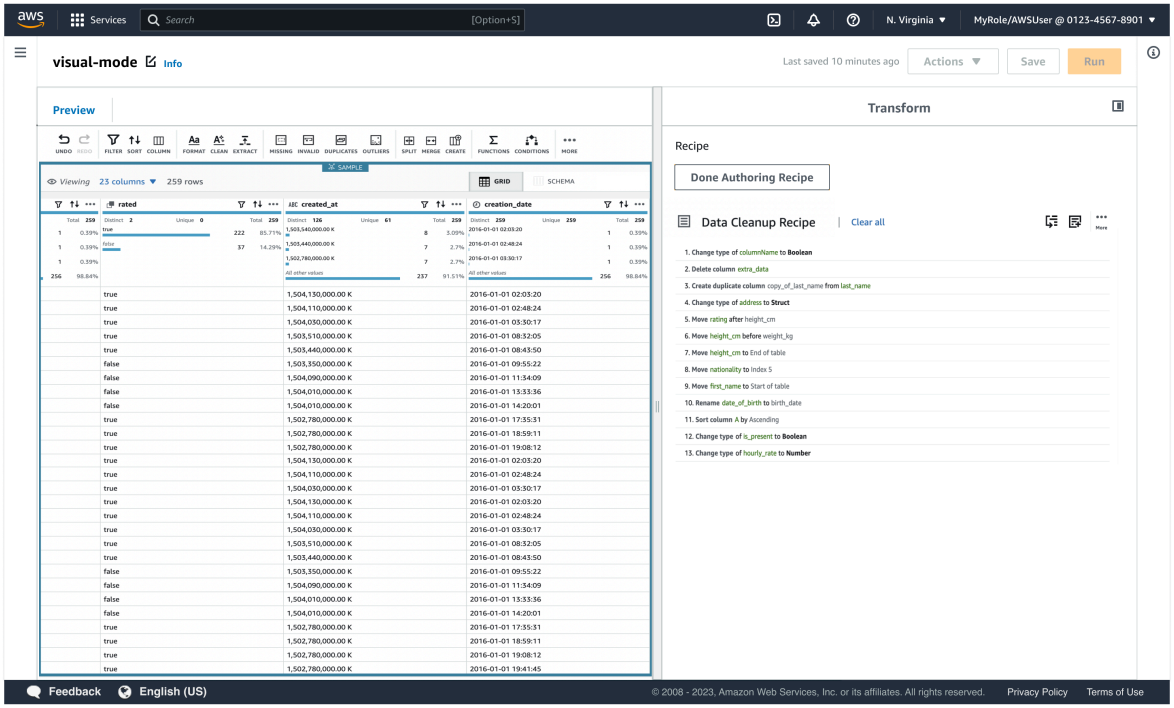

Caso precise fazer uma alteração, você poderá fazê-lo no painel Pré-visualizar ao pré-visualizar o resultado de cada etapa, desfazer uma etapa e reordenar as etapas. Por exemplo:

- Etapa de desfazer/refazer: desfaça uma etapa escolhendo o ícone de desfazer. Você pode repetir uma etapa escolhendo o ícone de refazer.

- Etapa de reordenação: quando você reordena uma etapa, o AWS Glue Studio valida cada etapa e informa se a etapa é inválida.

8. Depois de aplicar uma etapa, o painel Transformar mostrará todas as etapas da sua fórmula. Você pode limpar todas as etapas para recomeçar, adicionar mais etapas escolhendo o ícone de adicionar ou escolher Criação de fórmula concluída.

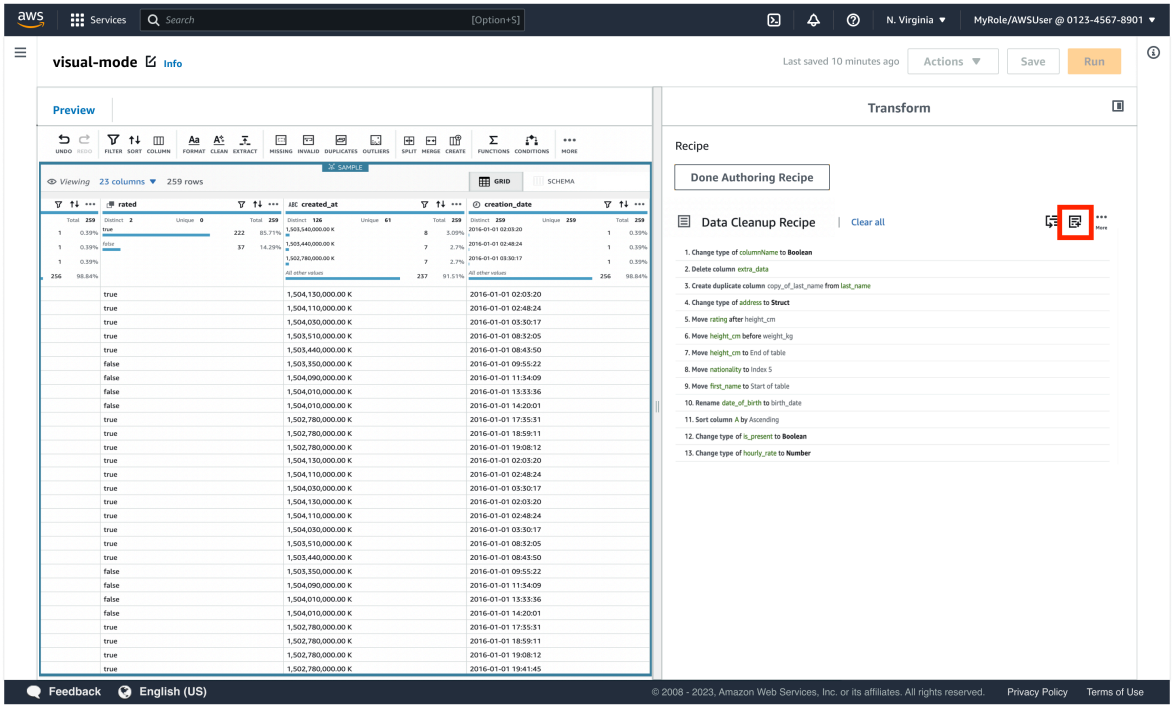

9. Escolha Salvar no canto superior direito da tela. As etapas da fórmula não serão salvas até você salvar seu trabalho.

Importar uma fórmula do AWS Glue DataBrew no AWS Glue Studio

No AWS Glue DataBrew, uma fórmula é um conjunto de etapas de transformação de dados. As fórmulas do AWS Glue DataBrew estabelecem como transformar dados que já foram lidos, mas não descrevem onde e como ler dados nem como e onde gravá-los. Isso é configurado nos nós de origem e de destino no AWS Glue Studio. Para obter mais informações sobre fórmulas, consulte Creating and using AWS Glue DataBrew recipes.

Para usar fórmulas do AWS Glue DataBrew no AWS Glue Studio, comece criando fórmulas no AWS Glue DataBrew. Se você já tiver fórmulas que deseja usar, pule esta etapa.

Permissões do IAM para o AWS Glue DataBrew

Este tópico fornece informações para ajudar você a entender as ações e os recursos que você, um administrador de IAM pode usar em uma política do AWS Identity and Access Management (IAM) para a transformação Data Preparation Recipe.

Para obter mais informações sobre segurança no AWS Glue, consulte Access Management.

> **Note**
>
> A tabela a seguir lista as permissões de que um usuário precisa para importar uma fórmula disponível do AWS Glue DataBrew.

Ações de transformação da fórmula de preparação de dados

Ação	Descrição
`databrew:ListRecipes`	Concede permissão para recuperar fórmulas do AWS Glue DataBrew.
`databrew:ListRecipeVersions`	Concede permissão para recuperar versões de fórmulas do AWS Glue DataBrew.
`databrew:DescribeRecipe`	Concede permissão para recuperar descrição de fórmula do AWS Glue DataBrew.

O perfil que você está usando para acessar essa funcionalidade deve ter uma política que permita várias ações AWS Glue DataBrew. Você pode fazer isso usando uma política `AWSGlueConsoleFullAccess` que inclua as ações necessárias ou adicionar a seguinte política em linha ao seu perfil:

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
```

```
                "databrew:ListRecipes",
                "databrew:ListRecipeVersions",
                "databrew:DescribeRecipe"
            ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Para usar a transformação Data Preparation Recipe, você deve adicionar a ação `IAM:PassRole` à política de permissões.

Permissões adicionais necessárias

Ação	Descrição
`iam:PassRole`	Concede permissão ao IAM para permitir que o usuário passe os perfis aprovados.

Sem essas permissões, ocorre o seguinte erro:

```
"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"
```

Importar uma fórmula do AWS Glue DataBrew

Para importar uma fórmula do AWS Glue DataBrew e usá-la no AWS Glue Studio:

Caso tenha um nó de Fórmula de preparação de dados disponível e queira editar as etapas da fórmula diretamente noAWS Glue Studio, você precisará importar as etapas da fórmula para o seu trabalho do AWS Glue Studio.

1. Comece um trabalho do AWS Glue no AWS Glue Studio com uma origem de dados.

2. Adicione o nó Fórmula de preparação de dados à sua tela de trabalho.

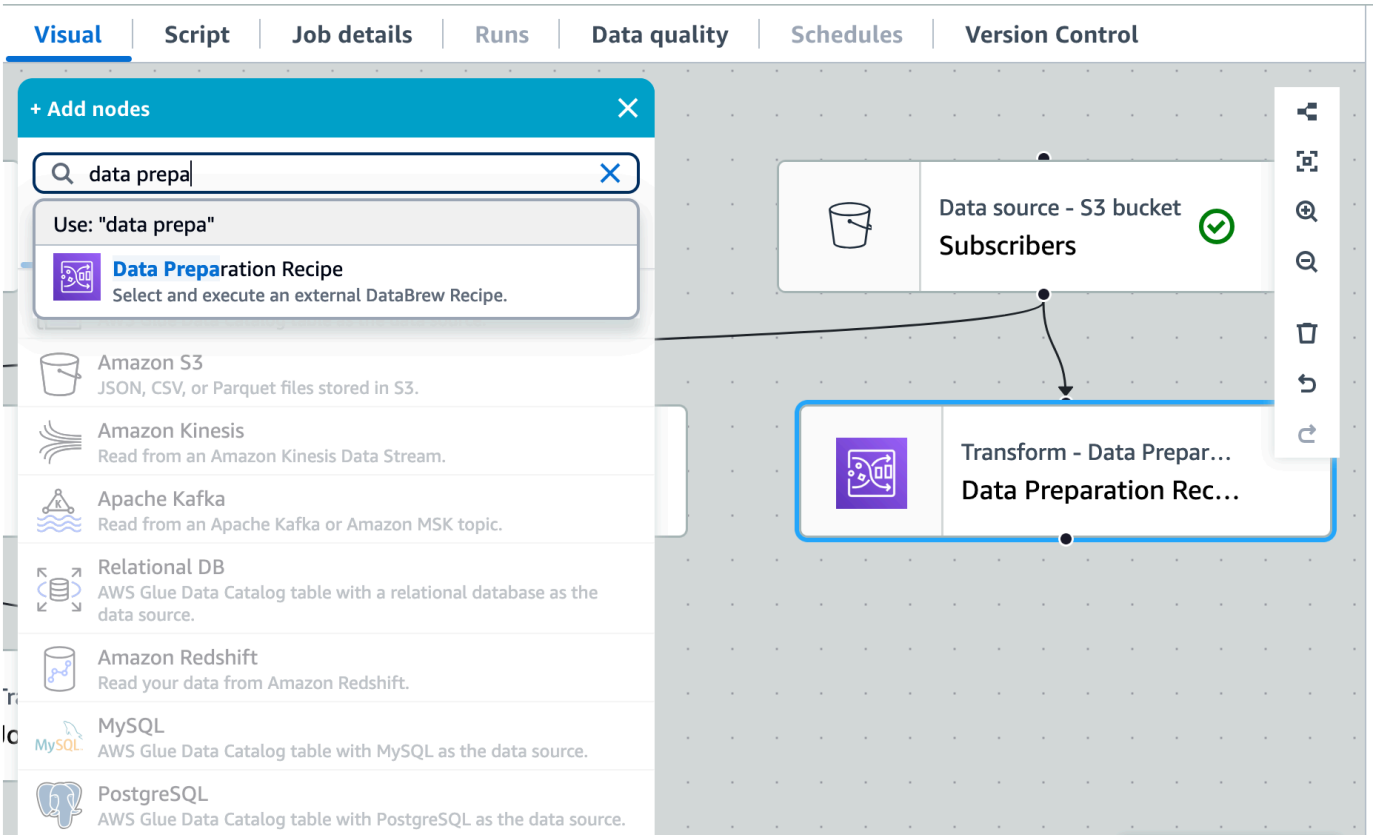

3. No painel Transformar, insira um nome para a fórmula.
4. Escolha um ou mais nós principais selecionando os nós disponíveis na tela na lista suspensa.
5. Escolha Criar fórmula. Se a Fórmula do autor estiver cinza, ela não estará disponível até que os pais do nó sejam selecionados e uma sessão de visualização de dados seja concluída.

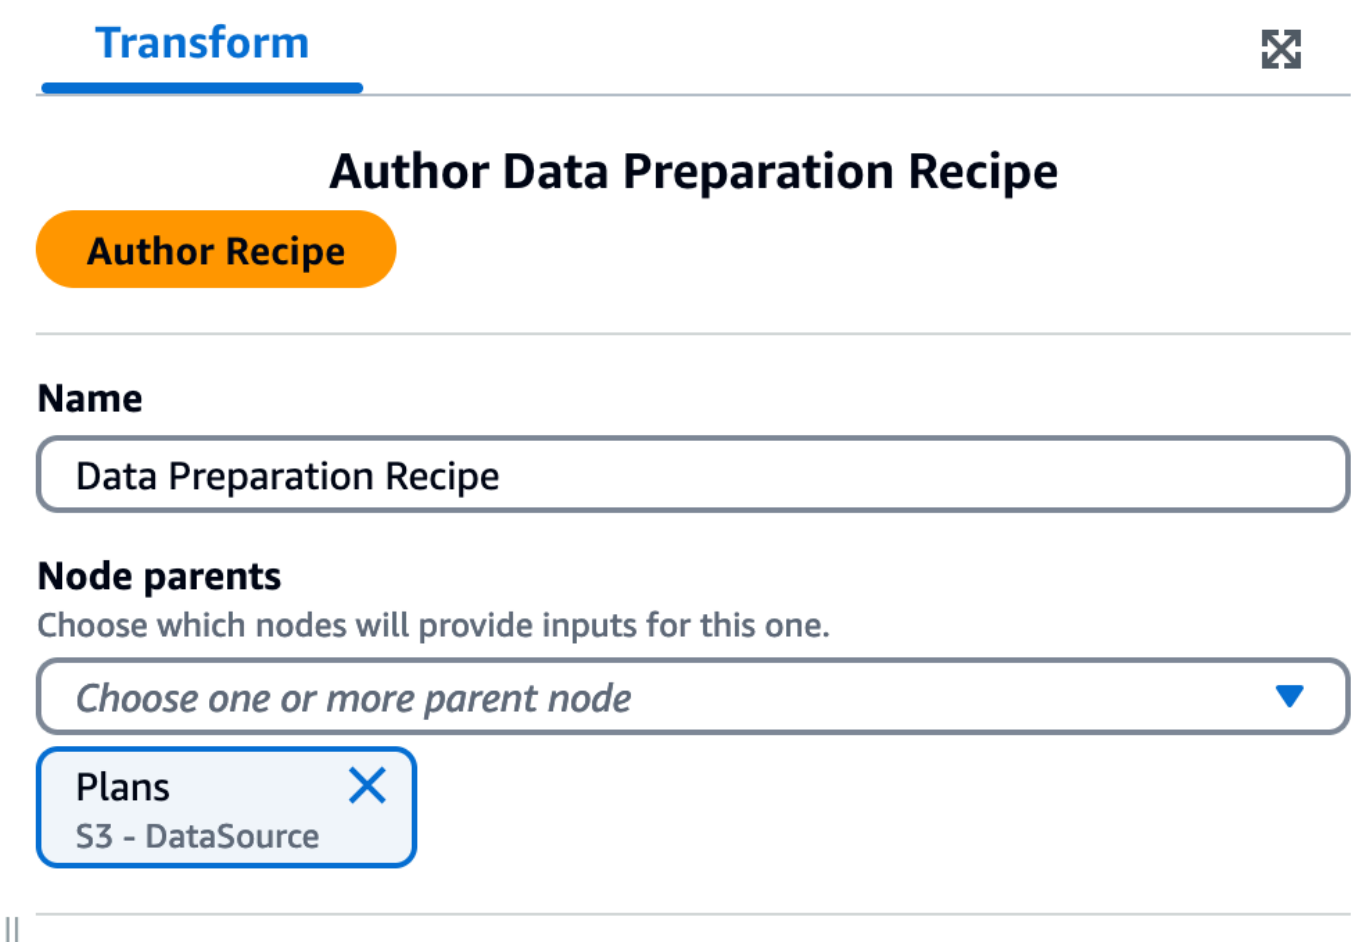

6. O quadro de dados carrega e mostra informações detalhadas sobre os dados de origem.

   Selecione o ícone de mais ações e escolha Importar fórmula.

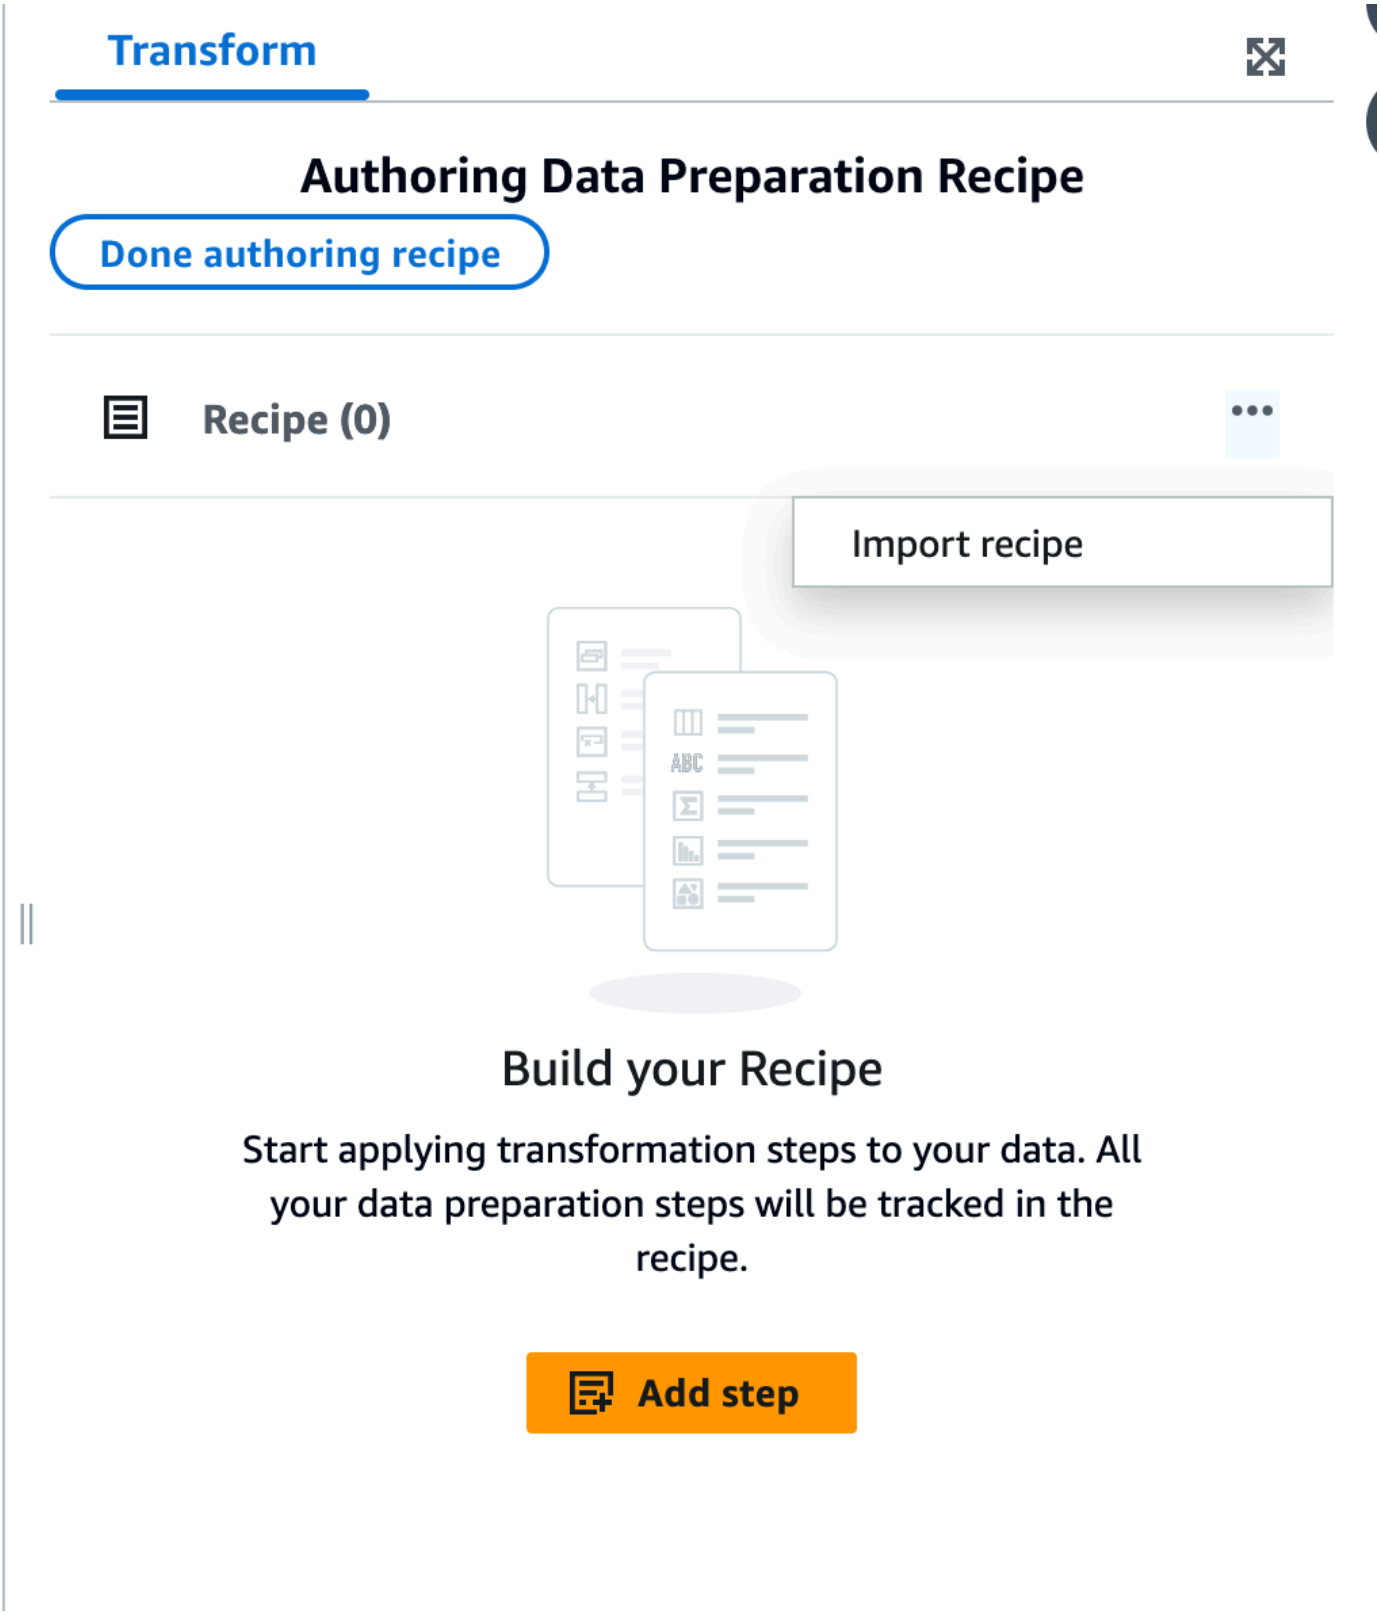

7. Use o assistente de importação de fórmulas para concluir as etapas. Na etapa 1, pesquise sua fórmula, selecione-a e escolha Avançar.

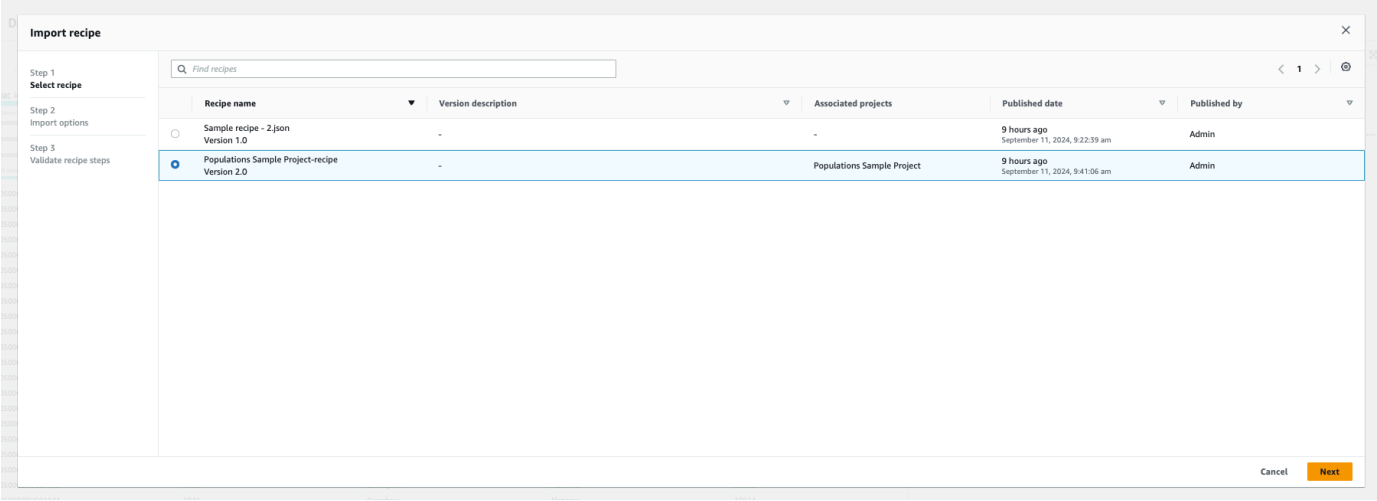

8. Na etapa 2, escolha as opções de importação. É possível optar por acrescentar uma nova fórmula a uma já existente ou substituir uma fórmula existente. Escolha Próximo.

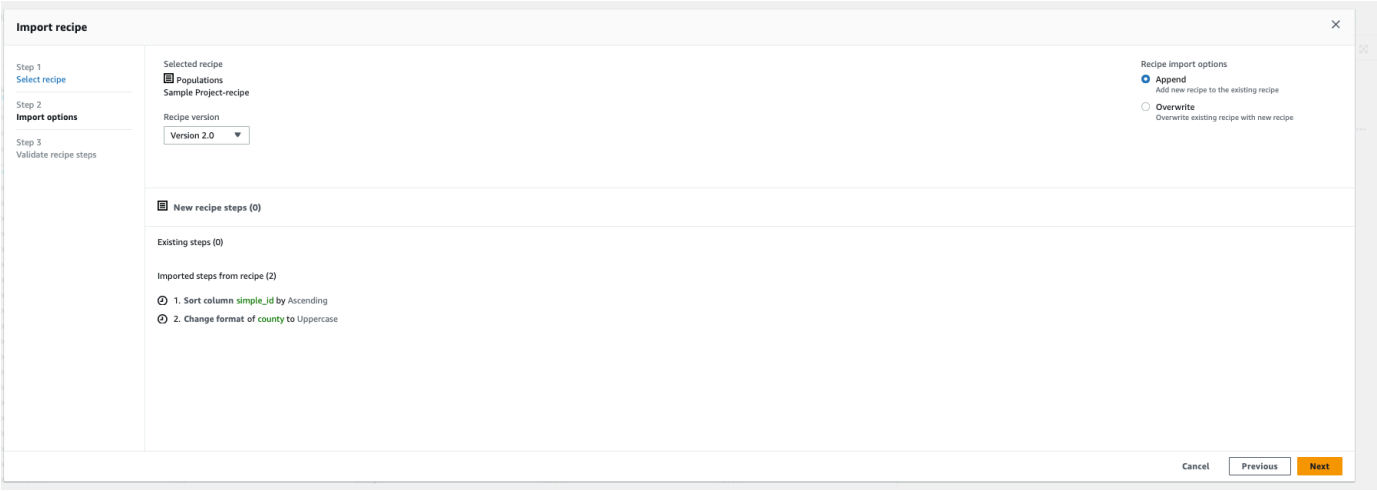

9. Na etapa 3, valide as etapas da fórmula. Depois de importar sua fórmula do AWS Glue DataBrew, você poderá editá-la diretamente no AWS Glue Studio.

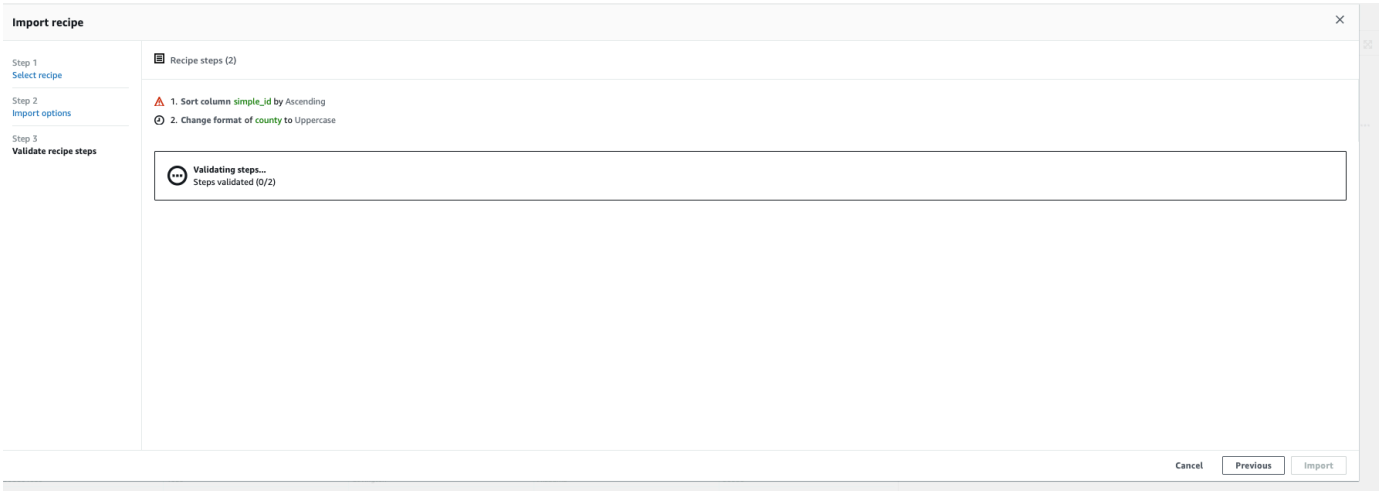

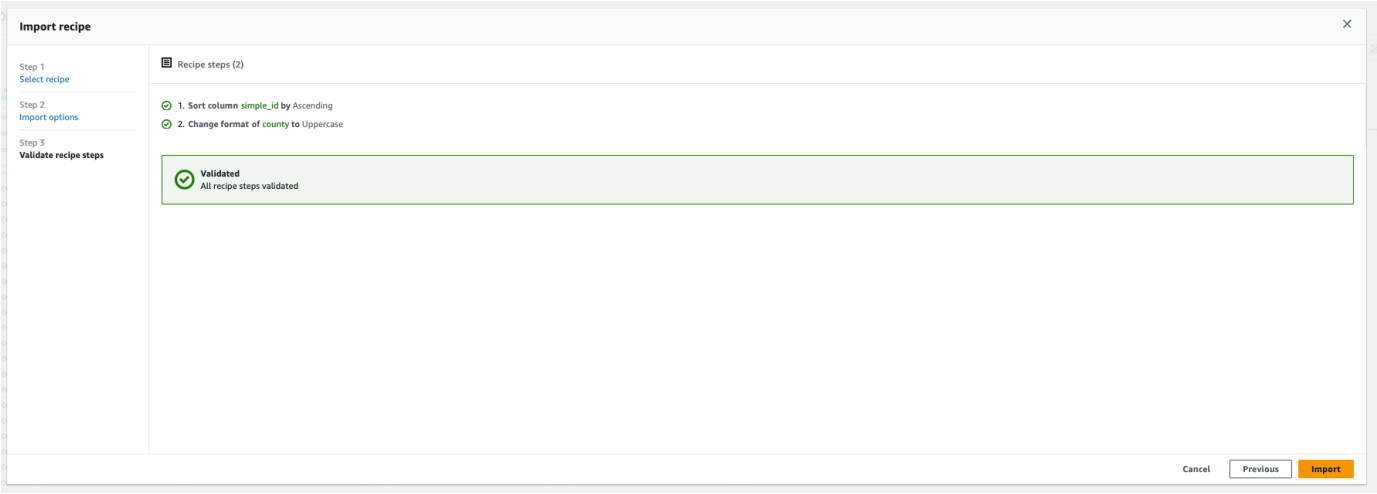

10. Depois disso, as etapas serão importadas como parte do seu trabalho do AWS Glue. Faça as alterações de configuração necessárias na guia Detalhes do trabalho, como nomear seu trabalho e ajustar a capacidade alocada, conforme necessário. Escolha Salvar para salvar seu trabalho e a fórmula.

    > **Note**
    >
    > JOIN, UNION, GROUP_BY, PIVOT, UNPIVOT, TRANSPOSE não são compatíveis com a importação de fórmulas nem estarão disponíveis no modo de criação de fórmulas.

11. Opcionalmente, você pode concluir a criação do trabalho adicionando outros nós de transformações, conforme necessário, e adicionar nós de destino de dados.

    Se você reordenar as etapas depois de importar uma fórmula, o AWS Glue executará a validação dessas etapas. Por exemplo, se você renomeou e depois excluiu uma coluna, e se moveu a etapa de exclusão para cima, a etapa de renomeação ficará inválida. Você pode então editar as etapas para corrigir o erro de validação.

Migração do AWS Glue DataBrew para o AWS Glue Studio

Se você tiver fórmulas no AWS Glue DataBrew, use a lista de verificação a seguir para migrá-las para o AWS Glue Studio.

Se você deseja…	Então faça isso
Permita que os usuários recuperem fórmulas do AWS Glue DataBrew, versões e descrições de fórmulas.	Adicione permissões do IAM a uma política que permite que sua função acesse as ações necessárias. Consulte Permissões do IAM para o AWS Glue DataBrew.
Importe uma fórmula do AWS Glue DataBrew existente para o AWS Glue Studio.	Siga as etapas em Importar uma fórmula do AWS Glue DataBrew.
Importe uma fórmula com JOIN e UNION.	Fórmulas com transformações UNION e JOIN não são suportadas. Use as transformações Join and Union no AWS Glue Studio antes ou depois de um nó de fórmula de preparação de dados.

Usando Alterar esquema para remapear as chaves de propriedade de dados

Uma transformação Alterar esquema remapeia as chaves de propriedade de dados de origem como as chaves desejadas configuradas para os dados de destino. Em um nó de transformação Alterar esquema, você pode:

- Alterar o nome de várias chaves de propriedade de dados.
- Alterar o tipo de dados das chaves de propriedade de dados, se o novo tipo de dados for suportado e houver um caminho de transformação entre os dois tipos de dados.
- Escolher um subconjunto de chaves de propriedade de dados indicando quais chaves de propriedade de dados você deseja descartar.

Conforme necessário, é possível adicionar mais nós Alterar esquema ao diagrama de trabalho, por exemplo, para modificar fontes de dados adicionais ou logo após uma transformação Join.

Usar Change Schema com tipo de dado decimal

Ao usar a transformação Alterar esquema com tipo de dado decimal, a transformação Alterar esquema modifica a precisão para o valor padrão de (10,2). Para modificar isso e definir a precisão do seu caso de uso, use a transformação de consulta do SQL e converta as colunas com uma precisão específica.

Por exemplo, se tiver uma coluna de entrada chamada "DecimalCol" do tipo Decimal e quiser remapeá-la para uma coluna de saída chamada "OutputDecimalCol" com uma precisão específica de (18,6), será preciso:

1. Adicionar uma transformação subsequente de consult do SQL após a transformação Alterar esquema.
2. Na transformação de consulta do SQL, use uma consulta do SQL para converter a coluna remapeada na precisão desejada. A consulta do SQL deve ser semelhante a esta:

   ```
   SELECT col1, col2, CAST(DecimalCol AS DECIMAL(18,6)) AS OutputDecimalCol
   FROM __THIS__
   ```

   Na consulta do SQL acima:

   - "col1" e "col2" são outras colunas em seus dados que você deseja passar sem modificação.
   - "DecimalCol" é o nome original da coluna dos dados de entrada.
   - "CAST(DecimalCol AS DECIMAL (18,6))" converte o "DecimalCol" em um tipo Decimal com uma precisão de 18 dígitos e 6 casas decimais.
   - "AS OutputDecimalCol" renomeia a coluna convertida para "OutputDecimalCol".

Usando a transformação de consulta do SQL, você pode substituir a precisão padrão definida pela transformação Alterar esquema e converter explicitamente as colunas decimais com a precisão desejada. Essa abordagem permite aproveitar a transformação Alterar esquema para renomear e reestruturar seus dados e, ao mesmo tempo, lidar com os requisitos de precisão das colunas decimais por meio da transformação subsequente de consulta do SQL.

Adicionar uma transformação Alterar esquema ao seu trabalho

> **Note**
>
> A transformação Alterar esquema não diferencia maiúsculas de minúsculas.

Para adicionar um nó de transformação Alterar esquema ao diagrama de trabalho

1. (Opcional) abra o painel Recurso e escolha Alterar esquema para adicionar uma nova transformação ao diagrama de trabalho, se necessário.

2. Na guia Propriedades do nó, insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transformar no painel de detalhes do nó.
4. Modifique o esquema de entrada:
   - Para renomear uma chave de propriedade de dados, insira o novo nome da chave no campo Target key (Chave de destino).
   - Para alterar o tipo de dados de uma chave de propriedade de dados, escolha o novo tipo de dados para a chave na lista Data type (Tipo de dados).
   - Para remover uma chave de propriedade de dados do esquema de destino, marque a caixa de seleção Drop (Descartar) da chave correspondente.
5. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
6. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Usando Drop Duplicates

A transformação Drop Duplicates remove linhas da sua fonte de dados, oferecendo duas opções. Você pode optar por remover a linha duplicada que é completamente igual ou escolher os campos a serem correspondentes e remover somente as linhas com base nos campos escolhidos.

Por exemplo, nesse conjunto de dados, você tem linhas duplicadas em que todos os valores em algumas linhas são exatamente iguais aos de outra linha e alguns dos valores nas linhas são iguais ou diferentes.

Linha	Nome	E-mail	Idade	State	Observação
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	esta é uma linha duplicada e corresponde completamente a todos os valores da linha #4
7	Rose	rose@gmail	23	NJ	Esta é uma linha duplicada e corresponde completamente a todos os valores da linha #5

Se você optar por combinar linhas inteiras, as linhas 6 e 7 serão removidas do conjunto de dados. O conjunto de dados agora é:

Linha	Nome	E-mail	Idade	State
1	Joy	joy@gmail	33	NY

Linha	Nome	E-mail	Idade	State
2	Tim	tim@gmail	45	OH
3	Rose	rose@gmail	23	NJ
4	Tim	tim@gmail	42	OH
5	Rose	rose@gmail	23	NJ

Se você optar por especificar as chaves, poderá optar por remover as linhas que coincidem em 'nome' e 'e-mail'. Isso oferece um controle mais preciso do que é uma “linha duplicada” para seu conjunto de dados. Ao especificar 'nome' e 'e-mail', o conjunto de dados agora é:

Linha	Nome	E-mail	Idade	State
1	Joy	joy@gmail	33	NY
2	Tim	tim@gmail	45	OH
3	Rose	rose@gmail	23	NJ

Tenha em mente que:

- Para que as linhas sejam reconhecidas como duplicadas, os valores diferenciam maiúsculas de minúsculas. Todos os valores nas linhas precisam ter a mesma letra maiúscula e minúscula - isso se aplica a qualquer opção escolhida (Combinar linhas inteiras ou Especificar chaves).
- Todos os valores são lidos como cadeias de caracteres.
- A transformação Drop Duplicates utiliza o comando dropDuplicates do Spark.
- Ao usar a transformação Drop Duplicates, a primeira linha é mantida e as outras linhas são descartadas.
- A transformação Drop Duplicates não altera o esquema do dataframe. Se você optar por especificar as chaves, todos os campos serão mantidos no dataframe resultante.

Usar SelectFields (Selecionar campos) para remover a maioria das chaves de propriedade de dados

Você pode criar um subconjunto de chaves de propriedade de dados a partir do conjunto de dados usando a transformação SelectFields (Selecionar campos). Você indica quais chaves de propriedade de dados deseja manter e o restante é removido do conjunto de dados.

> **Note**
>
> A transformação SelectFields (Selecionar campos) diferencia maiúsculas de minúsculas. Use ApplyMapping (Aplicar mapeamentos) se você precisar de uma maneira de selecionar campos que não diferencie maiúsculas de minúsculas.

Para adicionar um nó de transformação SelectFields ao diagrama de tarefas

1. (Opcional) abra o painel Recurso e escolha SelectFields) para adicionar uma nova transformação ao diagrama de trabalho, se necessário.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação) no painel de detalhes do nó.
4. No cabeçalho SelectFields (Selecionar campos), escolha as chaves de propriedade de dados no conjunto de dados que você deseja manter. Quaisquer chaves de propriedade de dados não selecionadas são descartadas do conjunto de dados.

   Você também pode marcar a caixa de seleção ao lado do cabeçalho de coluna Field (Campo) para escolher automaticamente todas as chaves de propriedade de dados do conjunto de dados. Em seguida, você pode desmarcar chaves de propriedade de dados individuais para removê-las do conjunto de dados.
5. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.

6. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Usar DropFields (Descartar campos) para manter a maioria das chaves de propriedade de dados

Você pode criar um subconjunto de chaves de propriedade de dados a partir do conjunto de dados usando a transformação DropFields (Descartar campos). Você indica quais chaves de propriedade de dados deseja remover e o restante é mantido no conjunto de dados.

> **Note**
>
> A transformação DropFields (Descartar campos) diferencia maiúsculas de minúsculas. Use ApplyMapping se você precisar de uma maneira de selecionar campos que não diferencie maiúsculas de minúsculas.

Para adicionar um nó de transformação DropFields (Descartar campos) ao diagrama de trabalho

1. (Opcional) abra o painel Recurso e escolha DropFields) para adicionar uma nova transformação ao diagrama de trabalho, se necessário.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação) no painel de detalhes do nó.
4. No cabeçalho DropFields (Descartar campos), escolha as chaves de propriedade de dados a serem descartadas da origem dos dados.

   Você também pode marcar a caixa de seleção ao lado do cabeçalho de coluna Field (Campo) para escolher automaticamente todas as chaves de propriedade de dados do conjunto de dados. Em seguida, você pode cancelar a seleção de chaves de propriedade de dados individuais para que elas sejam mantidas no conjunto de dados.

5. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
6. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Renomear um campo no conjunto de dados

Você pode usar a transformação RenameField (Renomear campo) para alterar o nome de uma chave de propriedade individual no conjunto de dados.

> **Note**
>
> A transformação RenameField (Renomear campo) diferencia maiúsculas de minúsculas. Use ApplyMapping (Aplicar mapeamento), se você precisar de uma transformação sem distinção entre maiúsculas e minúsculas.

> **Tip**
>
> Se você usar a transformação ApplyMapping, poderá renomear várias chaves de propriedade de dados no conjunto de dados com uma única transformação.

Para adicionar um nó de transformação RenameField (Renomear campo) ao diagrama de trabalho

1. (Opcional) abra o painel Recurso e escolha RenameField para adicionar uma nova transformação ao diagrama de trabalho, se necessário.

2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação).
4. No cabeçalho Data field (Campo de dados), escolha uma chave de propriedade nos dados de origem e, em seguida, insira um novo nome no campo New name field (Novo nome de campo).
5. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
6. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Usar Spigot (Torneira) para fazer uma amostra de seu conjunto de dados

Para testar as transformações executadas pelo trabalho, convém obter uma amostra dos dados para verificar se a transformação funciona como pretendido. A transformação Spigot (Torneira) grava um subconjunto de registros do conjunto de dados em um arquivo JSON, em um bucket do Amazon S3. O método de amostragem de dados pode ser um número especificado de registros desde o início do arquivo ou um fator de probabilidade usado para selecionar registros.

Para adicionar um nó de transformação Spigot (Torneira) ao diagrama de trabalho

1. (Opcional) abra o painel Recurso e escolha Spigot para adicionar uma nova transformação ao diagrama de trabalho, se necessário.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação) no painel de detalhes do nó.

4. Insira um caminho do Amazon S3 ou escolha Browse S3 (Procurar no S3) para escolher um local no Amazon S3. Esse é o local onde o trabalho grava o arquivo JSON que contém a amostra de dados.
5. Insira informações para o método de amostragem. É possível especificar um valor em Number of records (Número de registros) para gravar a partir do início do conjunto de dados e um Probability threshold (Limite de probabilidade, inserido como um valor decimal com um valor máximo de 1) de escolher qualquer registro dado.

   Por exemplo, para gravar os primeiros 50 registros do conjunto de dados, você definiria Number of records (Número de registros) como 50 e Probability threshold (Limite de probabilidade) como 1 (100%).

Unir conjuntos de dados

A transformação Join (Unir) permite combinar dois conjuntos de dados em um. Você especifica os nomes das chaves no esquema de cada conjunto de dados a ser comparado. O `DynamicFrame` de saída contém linhas em que as chaves atendem à condição de união. As linhas em cada conjunto de dados que atendem à condição de união são combinadas em uma única linha no `DynamicFrame` de saída que contém todas as colunas encontradas em qualquer um dos conjuntos de dados.

Para adicionar um nó de transformação Join (Unir) ao diagrama de trabalho

1. Se houver apenas uma fonte de dados disponível, você deverá adicionar um novo nó de origem dos dados ao diagrama de trabalho.
2. Escolha um dos nós de origem para a união. Abra o painel Recurso e escolha Unir para adicionar uma nova transformação ao diagrama do trabalho.
3. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho.
4. Na guia Node properties (Propriedades do nó), no cabeçalho Node parents (Nós pais), adicione um nó pai para que haja dois conjuntos de dados fornecendo entradas para a união. O pai pode ser um nó de origem dos dados ou um nó de transformação.

   > **Note**
   >
   > Uma união pode ter apenas dois nós pais.

5. Escolha a guia Transform (Transformação).

Se você vir uma mensagem indicando que existem nomes de chaves conflitantes, você pode:

- Escolher Resolve it (Resolver) para adicionar automaticamente um nó de transformação ApplyMapping (Aplicar mapeamento) em seu diagrama de trabalho. O nó ApplyMapping (Aplicar mapeamento) adiciona um prefixo a todas as chaves no conjunto de dados que tenham o mesmo nome de uma chave do outro conjunto de dados. Por exemplo, se você usar o valor padrão **`right`**, todas as chaves no conjunto de dados direito que tenham o mesmo nome de uma chave do conjunto de dados esquerdo serão renomeadas para `(right)`*`key name`*.
- Adicionar manualmente um nó de transformação anteriormente no diagrama de trabalho para remover ou renomear as chaves conflitantes.

6. Escolha o tipo de junção na lista Join type (Tipo de união).

   - Inner join (União interna): retorna uma linha com colunas de ambos os conjuntos de dados para cada correspondência com base na condição de união. As linhas que não satisfazem a condição de união não são retornadas.
   - Left join (União à esquerda): todas as linhas do conjunto de dados esquerdo e somente as linhas do conjunto de dados direito que satisfazem a condição de união.
   - Right join (União à direita): todas as linhas do conjunto de dados direito e somente as linhas do conjunto de dados esquerdo que satisfazem a condição de união.
   - Outer join (União externa): todas as linhas de ambos os conjuntos de dados.
   - Left semi join (semi à esquerda): todas as linhas do conjunto de dados esquerdo que têm uma correspondência no conjunto de dados direito com base na condição de união.
   - Left anti join (anti à esquerda): todas as linhas do conjunto de dados esquerdo que não têm uma correspondência no conjunto de dados direito com base na condição de união.

7. Na guia Transform (Transformação), no cabeçalho Join conditions (Condições de união), escolha Add condition (Adicionar condição). Escolha uma chave de propriedade de cada conjunto de dados para comparar. As chaves de propriedade no lado esquerdo do operador de comparação são referidas como o conjunto de dados esquerdo e as chaves de propriedade à direita são referidas como o conjunto de dados direito.

   Para condições de união mais complexas, você pode adicionar chaves correspondentes adicionais escolhendo Add condition (Adicionar condição) mais de uma vez. Se você adicionar uma condição acidentalmente, pode escolher o ícone de exclusão

(🗑)
para removê-la.

8. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
9. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Para obter um exemplo de esquema de saída de união, considere uma união entre dois conjuntos de dados com as seguintes chaves de propriedade:

```
Left: {id, dept, hire_date, salary, employment_status}
Right: {id, first_name, last_name, hire_date, title}
```

A união está configurada para corresponder nas chaves `id` e `hire_date` usando o operador de comparação =.

Como ambos os conjuntos de dados contêm as chaves `id` e `hire_date`, você escolhe Resolve it (Resolver) para adicionar automaticamente o prefixo **`right`** às chaves no conjunto de dados direito.

As chaves no esquema de saída seriam:

```
{id, dept, hire_date, salary, employment_status,
(right)id, first_name, last_name, (right)hire_date, title}
```

Usando Union para combinar linhas

Você usa o nó de transformação Union quando deseja combinar linhas de mais de uma fonte de dados que tenham o mesmo esquema.

Existem dois tipos de transformações Union:

1. ALL - ao aplicar ALL, a união resultante não remove linhas duplicadas.
2. DISTINCT: ao aplicar DISTINCT, a união resultante remove as linhas duplicadas.

Unions versus Joins

Você usa Union para combinar linhas. Você usa Join para combinar colunas.

Usando a transformação Union na tela Visual ETL

1. Adicione mais de uma fonte de dados para realizar uma transformação de união. Para adicionar uma fonte de dados, abra o painel Recurso e escolha a fonte de dados na guia Fontes. Antes de usar a transformação Union, você deve garantir que todas as fontes de dados envolvidas na união tenham o mesmo esquema e estrutura.
2. Quando você tem pelo menos duas fontes de dados que deseja combinar usando a transformação Union, crie a transformação Union adicionando-a à tela. Abra o painel Recurso na tela e pesquise “Union”. Você também pode escolher a guia Transformações no painel Recursos e rolar para baixo até encontrar a transformação Union e, em seguida, escolher Union.
3. Selecione o nó Union na tela de trabalho. Na janela Propriedades do nó, escolha os nós principais para se conectar à transformação Union.
4. O AWS Glue verifica a compatibilidade para garantir que a transformação Union possa ser aplicada a todas as fontes de dados. Se o esquema das fontes de dados for o mesmo, a operação será permitida. Se as fontes de dados não tiverem o mesmo esquema, uma mensagem de erro de inválido será exibida: “Os esquemas de entrada dessa união não são os mesmos. Considere usar o ApplyMapping para combinar os esquemas.” Para corrigir isso, escolha usar ApplyMapping.
5. Escolha o tipo de união.
    1. All: por padrão, o tipo de Union All é selecionado; isso resultará em linhas duplicadas, se houver alguma na combinação de dados.
    2. Distinct: escolha Distinct se quiser que as linhas duplicadas sejam removidas da combinação de dados resultante.

Usar SplitFields (Dividir campos) para dividir um conjunto de dados em dois

A transformação SplitFields (Dividir campos) permite que você escolha algumas das chaves de propriedade de dados no conjunto de dados de entrada, colocando-as em um conjunto de dados e

as chaves não selecionadas em um conjunto de dados separado. A saída dessa transformação é uma coleção de `DynamicFrames`.

> **Note**
>
> Você deve usar uma transformação SelectFromCollection (Selecionar da coleção) para converter a coleção de `DynamicFrames` em um único `DynamicFrame` antes que você possa enviar a saída para um local de destino.

A transformação SplitFields (Dividir campos) diferencia maiúsculas de minúsculas. Adicione uma transformação ApplyMapping (Aplicar mapeamento) como um nó pai, se você precisar de nomes de chave de propriedade sem distinção entre maiúsculas e minúsculas.

Para adicionar um nó de transformação SplitFields (Dividir campos) ao diagrama de trabalho

1. (Opcional) abra o painel Recurso e escolha Dividir campos para adicionar uma nova transformação ao diagrama de trabalho, se necessário.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação).
4. Escolha quais chaves de propriedade você deseja colocar no primeiro conjunto de dados. As chaves que você não escolher serão colocadas no segundo conjunto de dados.
5. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
6. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

7. Configure um nó de transformação SelectFromCollection (Selecionar da coleção) para processar os conjuntos de dados resultantes.

Visão geral da transformação SelectFromCollection

Determinadas transformações têm vários conjuntos de dados como saída, em vez de um único conjunto de dados, por exemplo, SplitFields (Dividir campos). A transformação SelectFromCollection (Selecionar da coleção) seleciona um conjunto de dados (`DynamicFrame`) em uma coleção de conjuntos de dados (uma matriz de `DynamicFrames`). A saída da transformação é o `DynamicFrame` selecionado.

Você deve usá-la após usar uma transformação que cria uma coleção de `DynamicFrames`, tais como:

- Transformações de código personalizado
- SplitFields

Se você não adicionar um nó de transformação SelectFromCollection (Selecionar da coleção) em seu diagrama de trabalho após qualquer uma dessas transformações, você receberá um erro em seu trabalho.

O nó pai para essa transformação deve ser um nó que retorna uma coleção de `DynamicFrames`. Se você escolher um pai para esse nó de transformação que retorne um único `DynamicFrame`, como uma transformação Join (Unir), seu trabalho retornará um erro.

Da mesma forma, se você usar um nó SelectFromCollection (Selecionar da coleção) em seu diagrama de trabalho como pai para uma transformação que espera um único `DynamicFrame` como entrada, o trabalho retornará um erro.

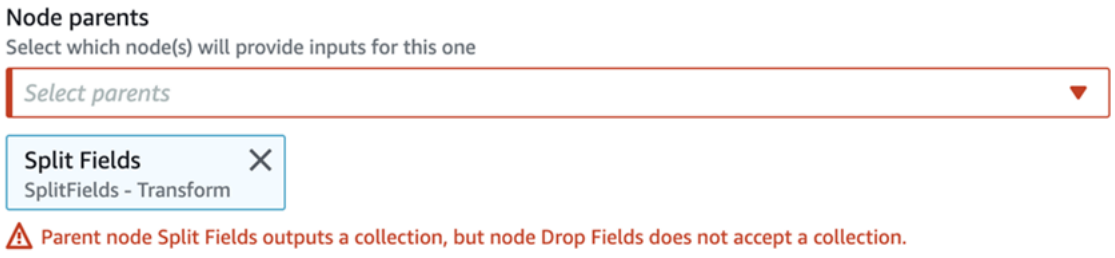

Usar SelectFromCollection (Selecionar da coleção) para escolher qual conjunto de dados manter

Use a transformação SelectFromCollection (Selecionar da coleção) para converter uma coleção de `DynamicFrames` em um único `DynamicFrame`.

Para adicionar um nó de transformação SelectFromCollection (Selecionar da coleção) ao diagrama de tarefas

1. (Opcional) Abra o painel Recurso e escolha SelectFromCollection) para adicionar uma nova transformação ao diagrama de trabalho, se necessário.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação).
4. No cabeçalho Frame index (Índice de quadros), escolha o número do índice da matriz que corresponde ao `DynamicFrame` que deseja selecionar na coleção de `DynamicFrames`.

   Por exemplo, se o nó pai para essa transformação for uma transformação SplitFields (Dividir campos), na guia Output schema (Esquema de saída) desse nó, você pode ver o esquema de cada `DynamicFrame`. Se quiser manter o `DynamicFrame` associado ao esquema de Output 2, você pode selecionar **1** para o valor de Frame index (Índice de quadros), que é o segundo valor na lista.

   Somente o `DynamicFrame` que você escolher será incluído na saída.
5. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
6. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Localizar e preencher valores ausentes em um conjunto de dados

Você pode usar a transformação FillMissingValues (Preencher valores ausentes) para localizar registros no conjunto de dados que têm valores ausentes e adicionar um novo campo com um valor determinado por imputação. O conjunto de dados de entrada é usado para treinar o modelo de machine learning (ML) que determina qual deve ser o valor ausente. Se você usar conjuntos de dados incrementais, cada conjunto incremental será usado como dados de treinamento para o modelo de ML, portanto, os resultados podem não ser tão precisos.

Para adicionar um nó de transformação FillMissingValues (Preencher valores ausentes) ao diagrama de trabalho

1. (Opcional) abra o painel Recurso e escolha FillMissingValues) para adicionar uma nova transformação ao diagrama de trabalho, se necessário.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação).
4. Em Data field (Campo de dados), escolha o nome da coluna ou do campo nos dados de origem que você deseja analisar quanto a valores ausentes.
5. (Opcional) no campo New field name (Nome do novo campo), insira um nome para o campo adicionado a cada registro que manterá o valor estimado de substituição para o campo analisado. Se o campo analisado não tiver um valor ausente, o valor no campo analisado será copiado para o novo campo.

   Se você não especificar um nome para o novo campo, o nome padrão será o nome da coluna analisada seguido de `_filled`. Por exemplo, se você inserir **`Age`** em Data field (Campo de dados) e não especificar um valor para New field name (Nome do novo campo), um novo campo chamado **`Age_filled`** será adicionado a cada registro.
6. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
7. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização

de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Filtrar chaves dentro de um conjunto de dados

Use a transformação Filter (Filtro) para criar um novo conjunto de dados filtrando registros do conjunto de dados de entrada com base em uma expressão regular. As linhas que não satisfaçam a condição do filtro são removidas da saída.

- Para tipos de dados de string, você pode filtrar linhas em que o valor da chave corresponde a uma string especificada.
- Para tipos de dados numéricos, você pode filtrar linhas comparando o valor da chave com um valor especificado usando os operadores de comparação <, >, =, !=, <= e >=.

Se você especificar várias condições de filtro, os resultados serão combinados usando um operador `AND` por padrão, mas você pode escolher `OR` em vez disso.

A transformação Filter (Filtro) diferencia maiúsculas de minúsculas. Adicione uma transformação ApplyMapping (Aplicar mapeamento) como um nó pai, se você precisar de nomes de chave de propriedade sem distinção entre maiúsculas e minúsculas.

Para adicionar um nó de transformação Filter (Filtro) ao diagrama de trabalho

1. (Opcional) Abra o painel Recurso e escolha Filtro para adicionar uma nova transformação ao diagrama de trabalho, se necessário.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Escolha a guia Transform (Transformação).
4. Escolha Global AND ou Global OR. Isso determina como várias condições de filtro são combinadas. Todas as condições são combinadas usando os operadores `AND` ou `OR`. Se você tiver apenas uma única condição de filtro, pode escolher qualquer uma.
5. Escolha o botão Add condition (Adicionar condição) na seção Filter condition (Condição de filtro) para adicionar uma condição de filtro.

No campo Key (Chave), escolha um nome de chave de propriedade do conjunto de dados. No campo Operation (Operação), escolha o operador de comparação. No campo Value (Valor), insira o valor de comparação. Estes são alguns exemplos de configurações de filtro:

- `year >= 2018`
- `State matches 'CA*'`

Ao filtrar valores de string, certifique-se de que o valor de comparação usa um formato de expressão regular que corresponda à linguagem de script selecionada nas propriedades do trabalho (Python ou Scala).

6. Adicione mais condições de filtro, conforme necessário.
7. (Opcional) depois de configurar as propriedades do nó de transformação, você pode visualizar o esquema modificado dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.
8. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Usar DropNullFields para remover campos com valores nulos

Use a transformação DropNullFields para remover campos do conjunto de dados se todos os valores no campo forem "null". Por padrão, o AWS Glue Studio reconhecerá objetos nulos, mas alguns valores como strings vazias, strings "null", inteiros -1 ou outros espaços reservados, como zeros, não são reconhecidos automaticamente como nulos.

Para usar DropNullFields

1. Adicione um nó DropNullFields ao diagrama do trabalho.

2. Na guia Node properties (Propriedades do nó), escolha valores adicionais que representem um valor nulo. Você pode optar por selecionar nenhum ou todos os valores:

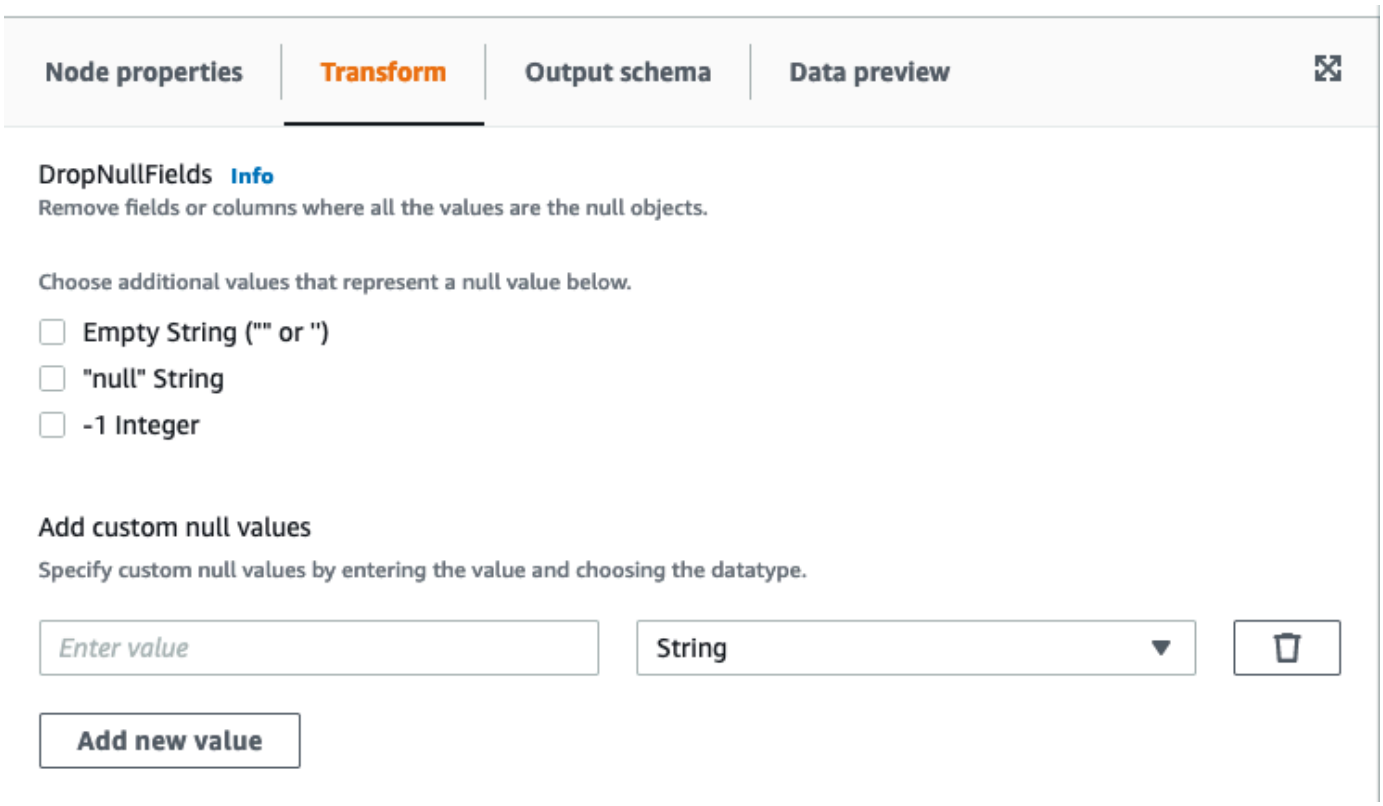

   - String vazia ("" ou ''): os campos que contiverem strings vazias serão removidos
   - "String null": os campos que contiverem a string com a palavra "null" serão removidos
   - Inteiro -1: os campos que contiverem um número inteiro -1 (menos um) serão removidos
3. Se necessário, você também poderá especificar valores nulos personalizados. Esses são valores nulos que podem ser exclusivos do seu conjunto de dados. Para adicionar um valor nulo personalizado, escolha Add new value (Adicionar novo valor).
4. Insira o valor nulo personalizado. Por exemplo, ele pode zero ou qualquer valor que esteja sendo usado para representar um nulo no conjunto de dados.
5. Escolha o tipo de dados no campo suspenso. Os tipos de dados podem ser String ou Integer.

> **Note**
>
> Os valores nulos personalizados e seus tipos de dados devem corresponder exatamente para que os campos sejam reconhecidos como valores nulos e os campos removidos.

Correspondências parciais em que apenas o valor nulo personalizado corresponde, mas o tipo de dados não resultará na remoção dos campos.

Usar uma consulta SQL para transformar dados

Você pode usar uma transformação SQL para escrever sua própria transformação na forma de uma consulta SQL.

Um nó de transformação SQL pode ter vários conjuntos de dados como entradas, mas produz apenas um único conjunto de dados como saída. Ele contém um campo de texto, onde você insere a consulta do Apache SparkSQL. Você pode atribuir aliases a cada conjunto de dados usado como entrada, para ajudar a simplificar a consulta SQL. Para obter mais informações sobre a sintaxe SQL, consulte a documentação do Spark SQL.

> **Note**
>
> Se você usar uma transformação do Spark SQL com uma origem dos dados localizada em uma VPC, adicione um endpoint da VPC do AWS Glue à VPC que contém a origem dos dados. Para obter mais informações sobre como configurar endpoints de desenvolvimento, consulte Adicionar um endpoint de desenvolvimento, Configurar seu ambiente para endpoints de desenvolvimento e Acessar o endpoint de desenvolvimento no Guia do desenvolvedor do AWS Glue.

Para usar um nó de transformação SQL no diagrama de trabalho

1. (Opcional) adicione um nó de transformação ao diagrama de trabalho, se necessário. Escolha Consulta SQL para o tipo de nó.

   > **Note**
   >
   > Se você usar uma sessão de visualização de dados e um SQL personalizado ou um nó de código personalizado, a sessão de visualização de dados executará o SQL ou o bloco de código no estado em que se encontra para todo o conjunto de dados.

2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se um nó pai ainda não estiver selecionado, ou se você quiser várias entradas para a

transformação SQL, escolha um nó na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação. Adicione nós pais conforme necessário.

3. Escolha a guia Transform (Transformação) no painel de detalhes do nó.
4. Os conjuntos de dados de origem para a consulta SQL são identificados pelos nomes especificados no campo Name (Nome) de cada nó. Se você não quiser usar esses nomes, ou se eles não forem adequados para uma consulta SQL, você pode associar um nome a cada conjunto de dados. O console fornece aliases padrão, como `MyDataSource`.

   Por exemplo, se um nó pai do nó de transformação SQL for nomeado como `Rename Org PK field`, você poderá associar o nome `org_table` com este conjunto de dados. Esse alias pode ser usado na consulta SQL no lugar do nome do nó.
5. No campo de entrada de texto, no cabeçalho Code block (Bloco de código), cole ou insira a consulta SQL. O campo de texto exibe o realce da sintaxe SQL e sugestões de palavra-chave.
6. Com o nó de transformação SQL selecionado, escolha a guia Output schema (Esquema de saída) e, em seguida, escolha Edit (Editar). Forneça as colunas e os tipos de dados que descrevem os campos de saída da consulta SQL.

   Especifique o esquema usando as seguintes ações na seção Output schema (Esquema de saída) da página:

   - Para renomear uma coluna, coloque o cursor na caixa de texto Key (Chave) da coluna (também conhecida como field (campo) ou property key [chave de propriedade]) e insira o novo nome.
   - Para alterar o tipo de dados de uma coluna, selecione o novo tipo de dados para a coluna na lista suspensa.
   - Para adicionar uma nova coluna de nível superior ao esquema, escolha o botão Overflow (excedente, ⋯) e, em seguida, escolha Add root key (Adicionar chave raiz). Novas colunas são adicionadas na parte superior do esquema.
   - Para remover uma coluna do esquema, escolha o ícone de exclusão (🗑) à extrema direita do nome da chave.
7. Quando terminar de especificar o esquema de saída, escolha Apply (Aplicar) para salvar suas alterações e saia do editor de esquema. Se não quiser salvar as alterações, escolha Cancel (Cancelar) para editar o editor de esquemas.

8. (Opcional) depois de configurar as propriedades do nó e da transformação, você pode previsualizar o conjunto de dados modificado escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Usar Aggregate para fazer cálculos resumidos em campos selecionados

Para usar a transformação Aggregate

1. Adicione o nó Aggregate ao diagrama do trabalho.
2. Na guia Node properties (Propriedades de nó), escolha campos para agrupar selecionando o campo suspenso (opcional). Você pode selecionar mais de um campo por vez ou procurar um nome de campo digitando na barra de pesquisa.

   Quando os campos são selecionados, o nome e o tipo de dados são mostrados. Para remover um campo, escolha "X" no campo.

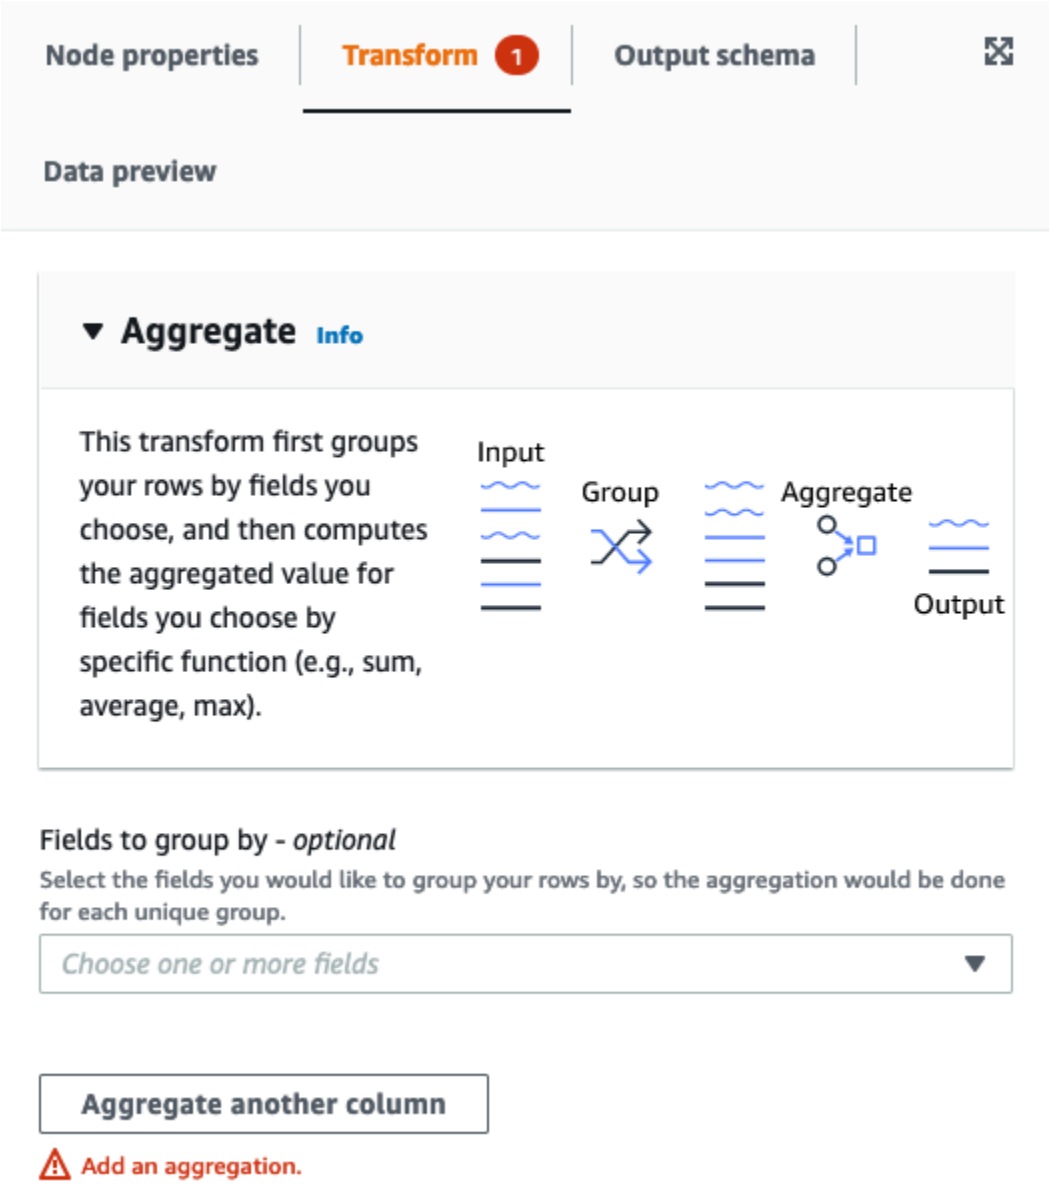

3. Selecione Aggregate another column (Agregar outra coluna). É necessário selecionar pelo menos um campo.

4. Escolha um campo na lista suspensa Field to aggregate (Campo a ser agregado).

5. Escolha a função de agregação a ser aplicada ao campo escolhido:

   - avg: calcula a média
   - CountDistinct: calcula o número de valores não nulos exclusivos
   - count: calcula o número de valores não nulos
   - first: retorna o primeiro valor que satisfaz os critérios "agrupar por"
   - last: retorna o último valor que satisfaz os critérios "agrupar por"
   - kurtosis: calcula a nitidez do pico de uma curva de distribuição de frequência
   - max: retorna o maior valor que satisfaz os critérios "agrupar por"
   - min: retorna o menor valor que satisfaz os critérios "agrupar por"
   - skewness: medida da assimetria da distribuição de probabilidade de uma distribuição normal
   - stddev_pop: calcula o desvio padrão da população e retorna a raiz quadrada da variância da população
   - sum: a soma de todos os valores no grupo
   - sumDistinct: a soma dos valores distintos no grupo
   - var_samp: a variância da amostra do grupo (ignora nulos)
   - var_pop: a variância da população do grupo (ignora nulos)

Nivelar structs aninhados

Nivele os campos de structs aninhados nos dados para transformá-los em campos de nível superior. Os novos campos são nomeados usando o nome do campo prefixado com os nomes dos campos de struct para alcançá-lo, separados por pontos.

Por exemplo, se os dados tiverem um campo do tipo Struct denominado “phone_numbers” que, entre outros campos, tenha um do tipo “Struct” denominado “home_phone” com dois campos: “country_code” e “number”. Depois de nivelados, esses dois campos se tornarão campos de nível superior denominados: “phone_numbers.home_phone.country_code” e “phone_numbers.home_phone.number”, respectivamente.

Para adicionar um nó de transformação Nivelar ao diagrama do trabalho

1. Abra o painel Recurso e escolha a guia Transformações e escolha Nivelar para adicionar uma nova transformação ao diagrama do trabalho. Você também pode usar a barra de pesquisa

digitando 'Flatten' e clicando no nó Nivelar. O nó selecionado no momento da adição do nó será o nó superior.

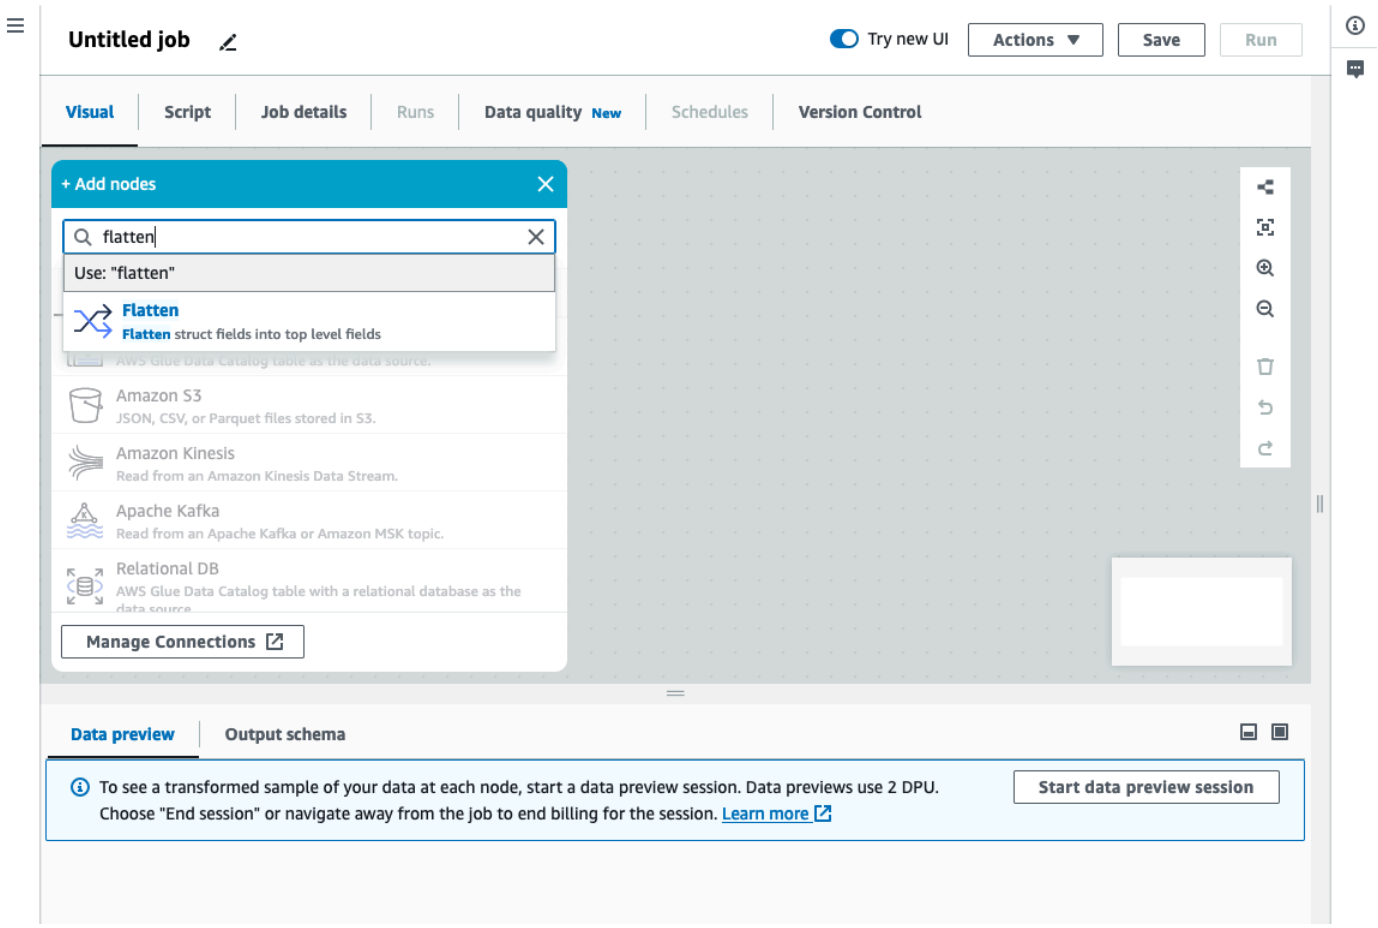

2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. (Opcional) Na guia Transformação, você pode limitar o nível máximo de aninhamento máximo a ser nivelado. Por exemplo, definir esse valor como 1 significa que somente structs de nível superior serão nivelados. Definir o máximo como 2 nivela o nível superior e os structs diretamente abaixo dele.

Adicionar uma coluna de UUID

Quando você adiciona uma coluna UUID (Universally Unique Identified), cada linha recebe uma string exclusiva de 36 caracteres.

Para adicionar um nó de transformação UUID ao diagrama do trabalho

1. Abra o painel Recurso e escolha UUID para adicionar uma nova transformação ao seu diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. (Opcional) Na guia Transformação, você pode personalizar o nome da nova coluna. Por padrão, ela será denominada "uuid".

Adicionar uma coluna de identificadores

Atribua um identificador numérico a cada linha no conjunto de dados.

Para adicionar um nó de transformação identificador ao diagrama do trabalho

1. Abra o painel Recurso e escolha Identificador para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. (Opcional) Na guia Transformação, você pode personalizar o nome da nova coluna. Por padrão, ela será denominada "id".
4. (Opcional) Se o trabalho processar e armazenar dados de forma incremental, será importante evitar que os mesmos IDs sejam reutilizados em diversas execuções do trabalho.

   Na guia Transformação, marque a opção exclusivo da caixa de seleção. Essa opção incluirá o timestamp do trabalho no identificador, tornando-o exclusivo entre as diversas execuções. Para permitir um número maior, a coluna em vez do tipo longo será um decimal.

Converter uma coluna no tipo timestamp

Você pode usar a transformação Em timestamp para alterar o tipo de dados de uma coluna de numérico ou string em timestamp, para que ela possa ser armazenada com esse tipo de dados ou aplicada a outras transformações que exijam um timestamp.

Para adicionar um nó de transformação Em timestamp ao diagrama do trabalho

1. Abra o painel Recurso e escolha Em Para timestamp para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformação, insira o nome da coluna a ser convertida.
4. Na guia Transformação, defina como analisar a coluna selecionada escolhendo o tipo.

   Se o valor for um número, ele poderá ser expresso em segundos (timestamp do Unix/Python), milissegundos ou microssegundos; escolha a opção correspondente.

   Se o valor for uma string formatada, escolha o tipo “iso”, e a string precisará estar conforme com uma das variantes do formato ISO, por exemplo: “2022-11-02T14:40:59.915Z“.

   Se não souber o tipo nesse momento ou se linhas diferentes usarem tipos diferentes, você poderá escolher ”detecção automática“ e o sistema fará sua melhor suposição, com um pequeno custo de desempenho.
5. (Opcional) Na guia Transformação, em vez de converter a coluna selecionada, você pode criar uma nova e manter a original inserindo um nome para a nova coluna.

Converter uma coluna de timestamp em uma string formatada

Formate uma coluna do tipo timestamp em uma do tipo string de acordo com um padrão. Você pode usar Formatar timestamp para obter a data e a hora como uma string com o formato desejado. Você pode definir o formato usando a sintaxe de data do Spark, bem como a maioria dos códigos de data do Python.

Por exemplo, se você quiser que a string de data seja formatada como “2023-01-01 00:00”, poderá definir esse formato usando a sintaxe do Spark como “aaaa-MM-dd HH:mm” ou os códigos de data equivalentes do Python como “%A-%m-%d %H: %M”

Para adicionar um nó de transformação Formatar timestamp ao diagrama do trabalho

1. Abra o painel Recurso e escolha Formatar timestamp para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.

2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformação, insira o nome da coluna a ser convertida.
4. Na guia Transformação, insira o padrão de Formato de timestamp a ser usado, expresso com a sintaxe de data do Spark ou os códigos de data do Python.
5. (Opcional) Na guia Transformação, em vez de converter a coluna selecionada, você pode criar uma nova e manter a original inserindo um nome para a nova coluna.

Criar uma transformação de roteador condicional

A transformação de roteador condicional permite que você aplique várias condições aos dados de entrada. Cada linha dos dados de entrada avaliada por uma condição de filtro de grupo e processada no grupo correspondente. Se uma linha atender a mais de uma condição de filtro de grupo, a transformação passará a linha para vários grupos. Se uma linha não atender a nenhuma condição, poderá ser descartada ou roteada para um grupo de saída padrão.

Essa transformação é semelhante à transformação de filtro, mas é útil para usuários que desejem testar os mesmos dados de entrada em várias condições.

Para adicionar uma transformação condicional de roteador:

1. Escolha um nó onde você realizará a transformação de roteador condicional. Esse pode ser um nó de origem ou outra transformação.
2. Escolha Ação e use a barra de pesquisa para localizar e escolher “Roteador condicional”. Uma transformação de roteador condicional é adicionada junto com dois nós de saída. Um único nó de saída, "Grupo padrão", contém os registros que não atendem a nenhuma das condições definidas nos outros nós de saída. O grupo padrão não pode ser editado.

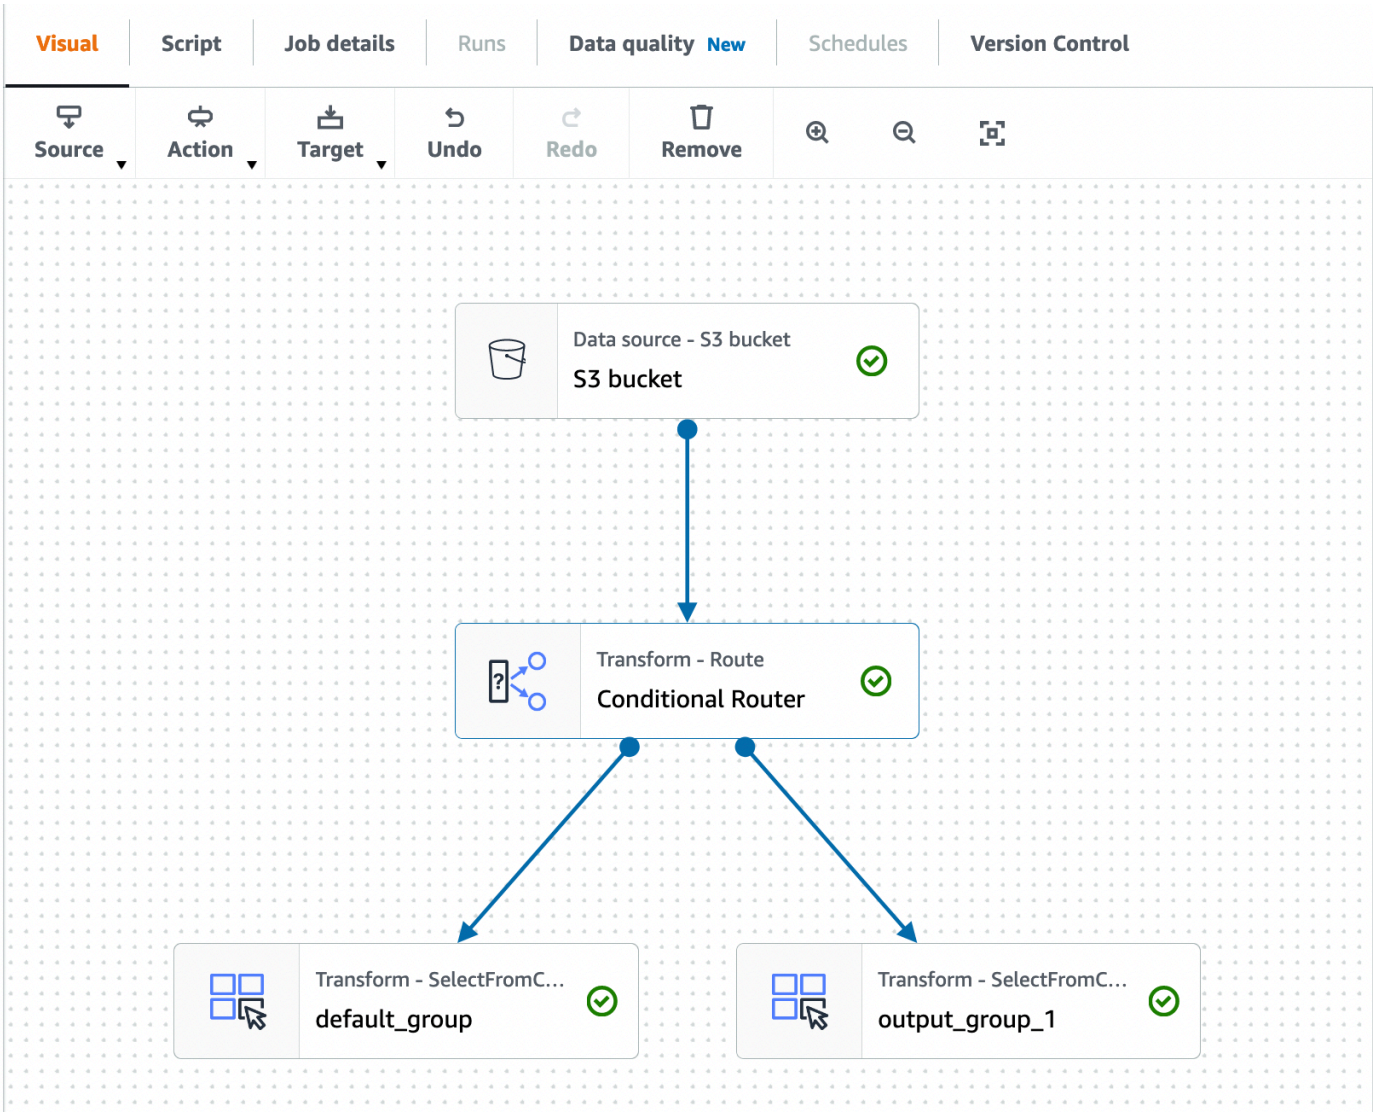

Você pode adicionar outros grupos de saída escolhendo Adicionar grupo. Para cada grupo de saída, você pode nomear o grupo e adicionar condições de filtro e um operador lógico.

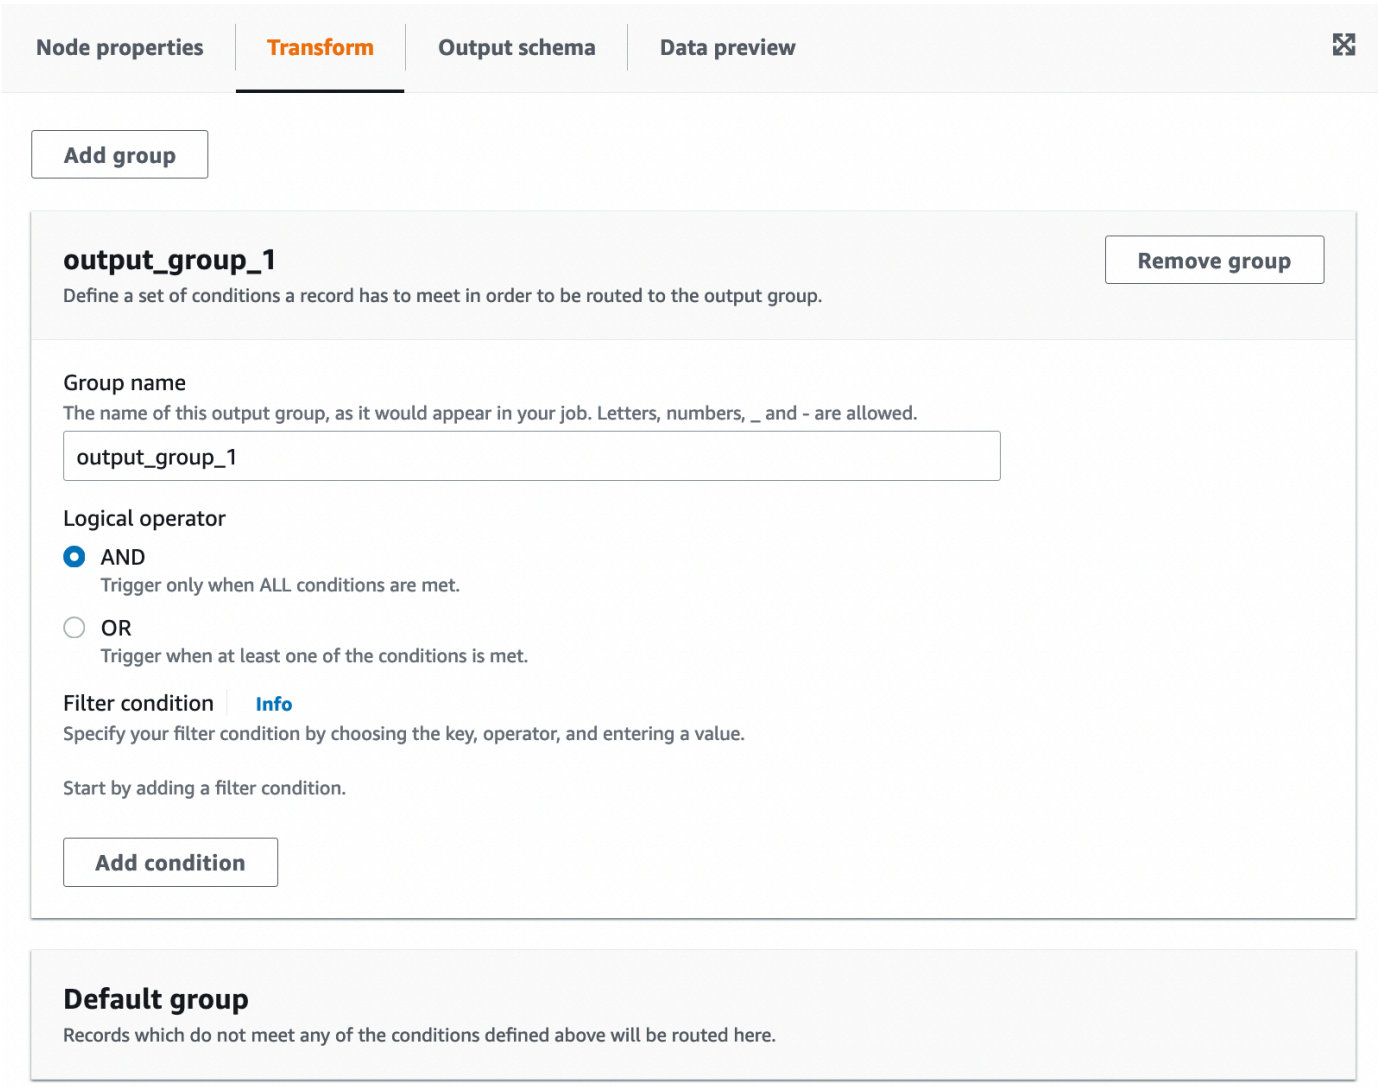

3. Dê outro nome ao grupo de saída inserindo um novo nome para o grupo. O AWS Glue Studio nomeará automaticamente os grupos para você (por exemplo, "output_group_1").
4. Escolha um operador lógico (AND, OR) e adicione uma condição de filtro especificando Chave, Operação e Valor. Os operadores lógicos permitem que você implemente mais de uma condição de filtro e aplique o operador lógico a cada condição de filtro especificada.

   Ao especificar a chave, você pode escolher entre as chaves disponíveis em seu esquema. Em seguida, escolha a operação disponível de acordo com o tipo de chave selecionada. Por exemplo, se o tipo de chave for "string", a operação disponível para você escolher é "matches".

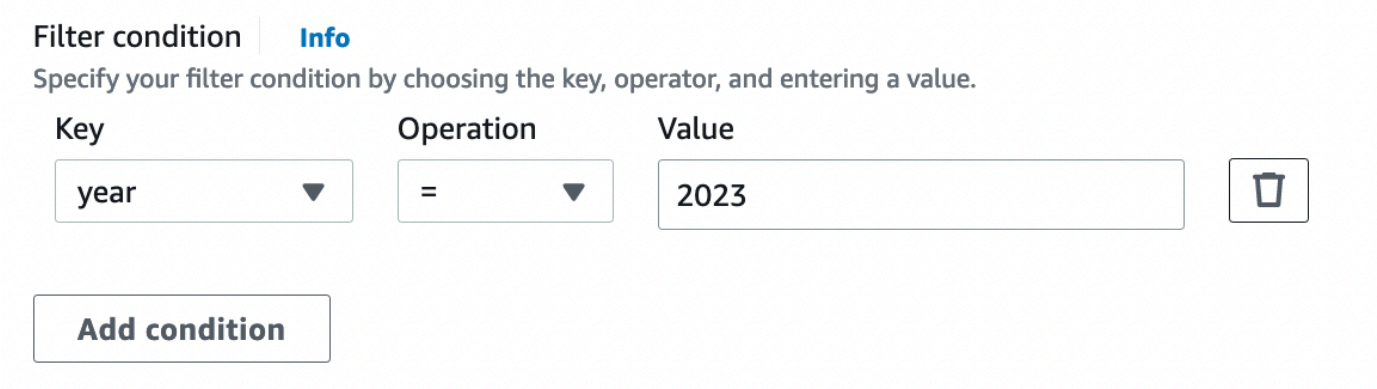

5. Insira o valor no campo Valor. Selecione Adicionar condição para adicionar mais condições. Para remover condições de filtro, selecione o ícone de lixeira.

Usando a transformação Concatenate Columns para acrescentar colunas

A transformação Concatenate permite que você crie uma nova coluna de strings usando os valores de outras colunas com um espaçador opcional. Por exemplo, se definirmos uma coluna concatenada “data” como a concatenação de “ano”, “mês” e “dia” (nessa ordem) com “-” como espaçador, obteríamos:

dia	mês	ano	date
01	01	2020	1/1/2020
02	01	2020	2/1/2020
03	01	2020	3/1/2020
04	01	2020	4/1/2020

Para adicionar uma transformação Concatenate:

1. Abra o painel Recurso. Em seguida, escolha Concatenate Columns para adicionar uma nova transformação ao diagrama de trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.

3. Na guia Transformar, insira o nome da coluna que conterá a string concatenada, bem como as colunas a serem concatenadas. A ordem na qual você marcar as colunas na lista suspensa será a ordem usada.

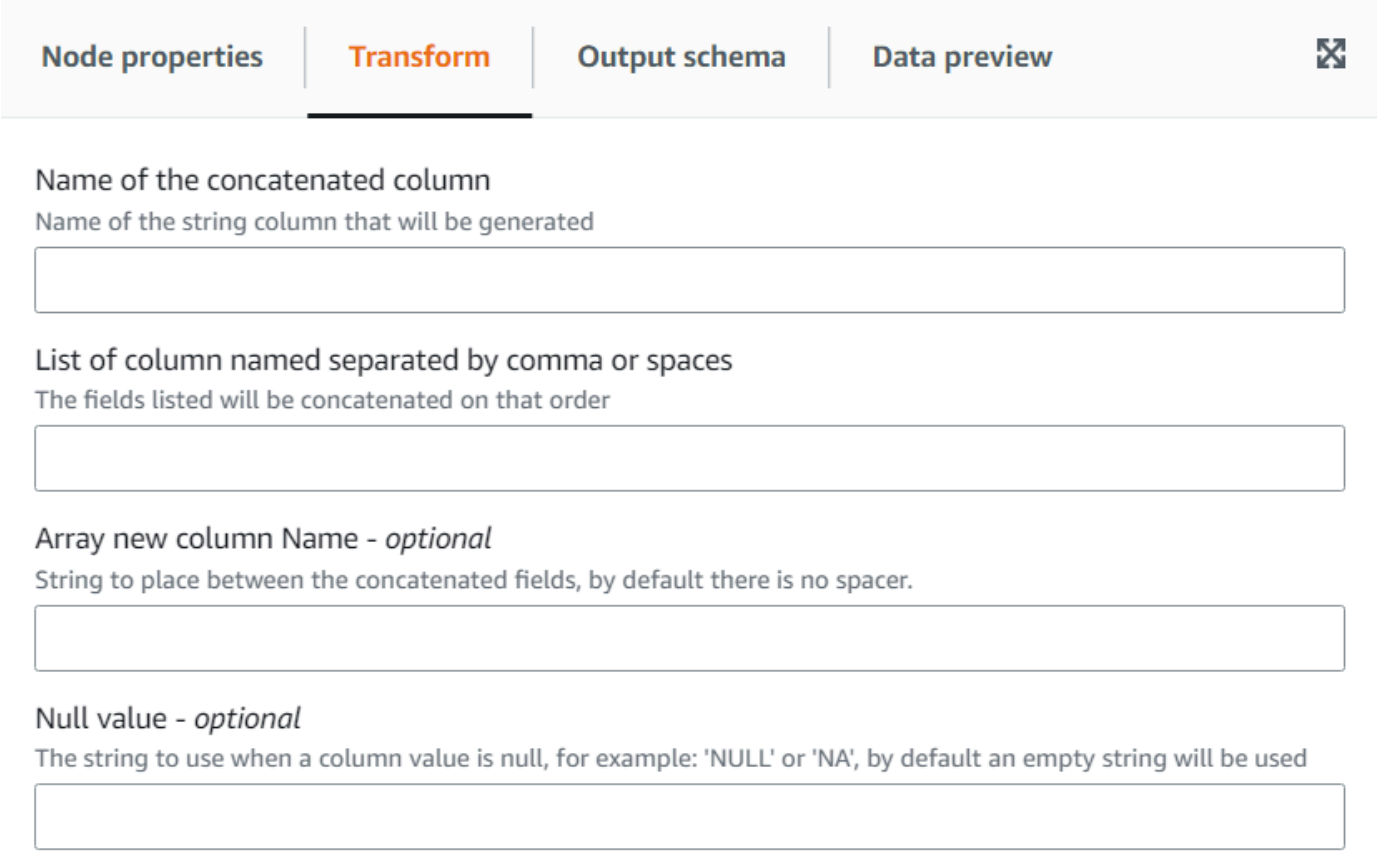

4. Espaçador - opcional - Insira uma string para colocar entre os campos concatenados. Por padrão, não há espaçador.
5. Valor nulo - opcional: insira uma string a ser usada quando o valor de uma coluna for nulo. Por padrão, nos casos em que as colunas têm o valor 'NULL' ou 'NA', é usada uma string vazia.

Usar a transformação Split String para dividir uma coluna de string

A transformação Split String permite que você divida uma string em uma matriz de tokens usando uma expressão regular para definir como a divisão é feita. Em seguida, você pode manter a coluna como um tipo de matriz ou aplicar uma transformação Array To Columns após esta, para extrair os valores da matriz nos campos de nível superior, supondo que cada token tenha um significado que conhecemos de antemão. Além disso, se a ordem dos tokens for irrelevante (por exemplo, um conjunto de categorias), você poderá usar a transformação Explode para gerar uma linha separada para cada valor.

Por exemplo, você pode dividir a coluna “categories” usando uma vírgula como padrão para adicionar uma coluna “categories_arr”.

product_id	categories	categories_arr
1	esportes, inverno	[esportes, inverno]
2	jardim, ferramentas	[jardim, ferramentas]
3	videogames	[videogames]
4	jogo, jogo de tabuleiro, social	[jogo, jogo de tabuleiro, social]

Para adicionar uma transformação Split String:

1. Abra o painel Recurso e escolha Split String para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, escolha a coluna a ser dividida e insira o padrão a ser usado para dividir a string. Na maioria dos casos, você pode simplesmente inserir o(s) caractere(s), a menos que tenha um significado especial como expressão regular e precise de escape. Os caracteres que precisam de escape são: `\.[]{}()<>*+-=!?^$|` adicionando uma barra invertida na frente do caractere. Por exemplo, se você quiser separar por um ponto ('.'), você precisa inserir `\.`. No entanto, uma vírgula não tem um significado especial e só pode ser especificada como está: `,`.

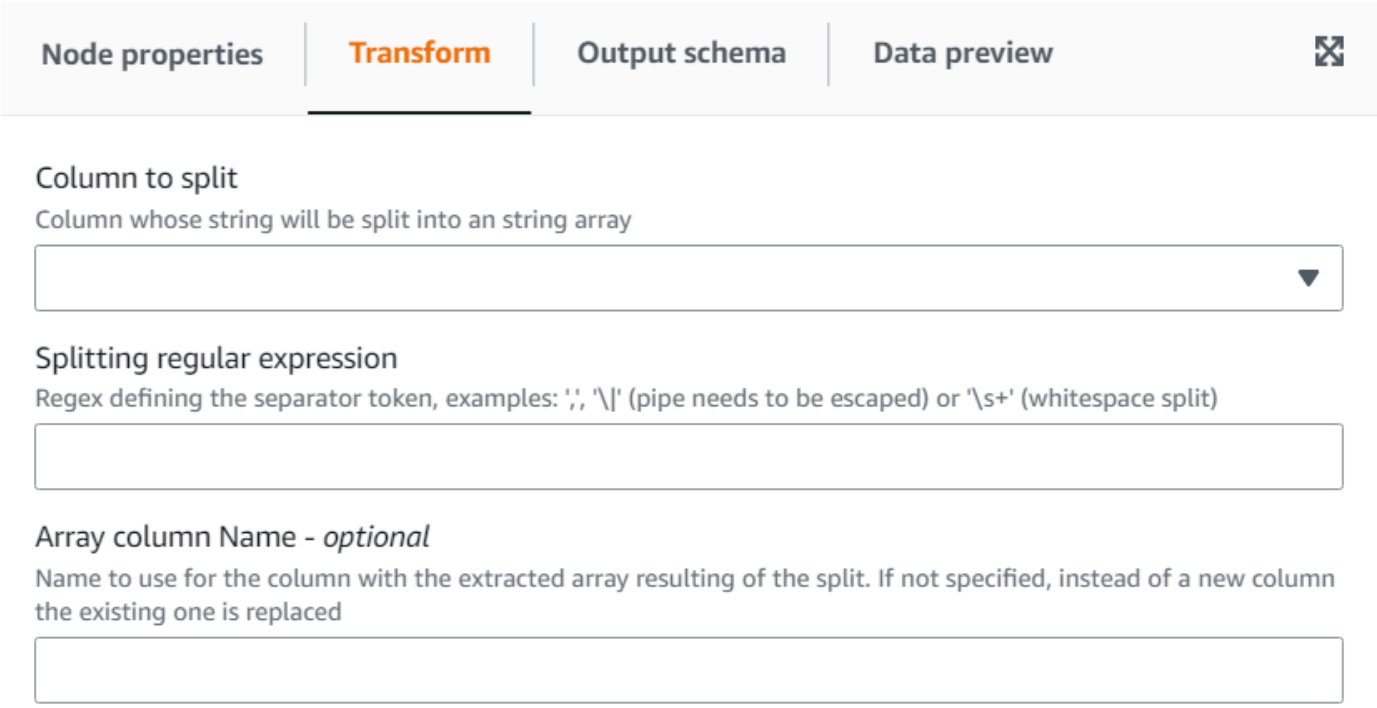

4. (Opcional) Se você quiser manter a coluna de string original, poderá inserir um nome para uma nova coluna de matriz, mantendo assim a coluna de string original e a nova coluna de matriz tokenizada.

Usando a transformação Array To Columns para extrair os elementos de uma matriz para colunas de nível superior

A transformação Array To Columns permite extrair alguns ou todos os elementos de uma coluna do tipo matriz para novas colunas. A transformação preencherá as novas colunas o máximo possível se a matriz tiver valores suficientes para extrair, opcionalmente usando os elementos nas posições especificadas.

Por exemplo, se você tiver uma coluna de matriz “sub-rede”, que foi o resultado da aplicação da transformação “Split String” em uma sub-rede ip v4, você pode extrair a primeira e a quarta posições para as novas colunas “primeiro_octeto” e “quarto_octeto”. A saída da transformação neste exemplo seria (observe que as duas últimas linhas têm matrizes mais curtas do que o esperado):

sub-rede	primeiro_octeto	quarto_octeto
[54, 240, 197, 238]	54	238

sub-rede	primeiro_octeto	quarto_octeto
[192, 168, 0, 1]	192	1
[192, 168]	192	
[]		

Para adicionar uma transformação Array To Columns:

1. Abra o painel Recurso e escolha Array To Columns para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, escolha a coluna da matriz a ser extraída e insira a lista de novas colunas para os tokens extraídos.

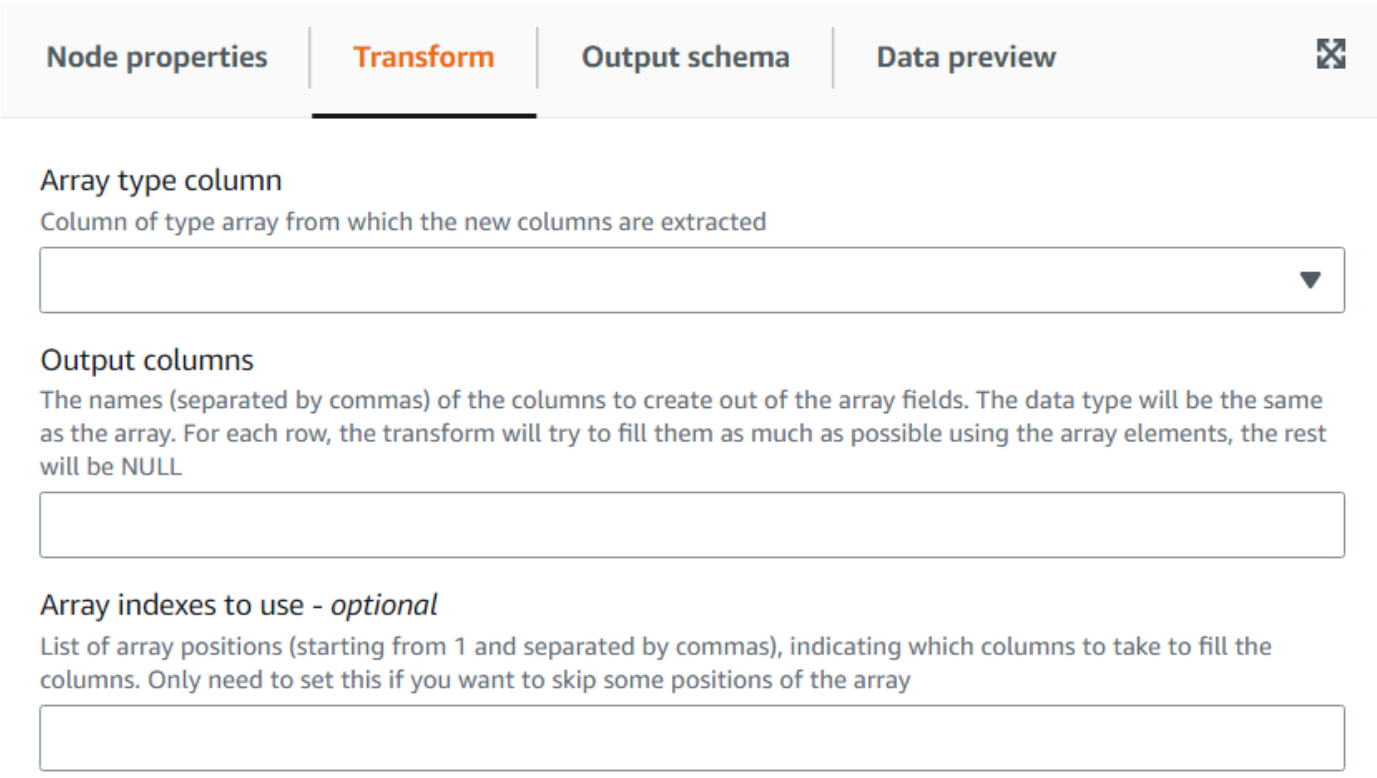

4. (Opcional) Se não quiser usar os tokens da matriz para atribuir às colunas, você pode especificar os índices a serem obtidos, que serão atribuídos à lista de colunas na mesma ordem

especificada. Por exemplo, se as colunas de saída forem “coluna1, coluna2, coluna3” e os índices “4, 1, 3”, o quarto elemento da matriz irá para a coluna1, o primeiro para a coluna2 e o terceiro para a coluna3 (se a matriz for menor que o número do índice, será atribuído um valor NULL).

Usar a transformação Add Current Timestamp

A transformação Add Current Timestamp permite marcar as linhas com a hora em que os dados foram processados. Isso é útil para fins de auditoria ou para rastrear a latência no pipeline de dados. Você pode adicionar essa nova coluna como um tipo de dados de carimbo de data/hora ou como string formatada.

Para adicionar uma transformação Add Current Timestamp:

1. Abra o painel Recurso e escolha Add Current Timestamp para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.

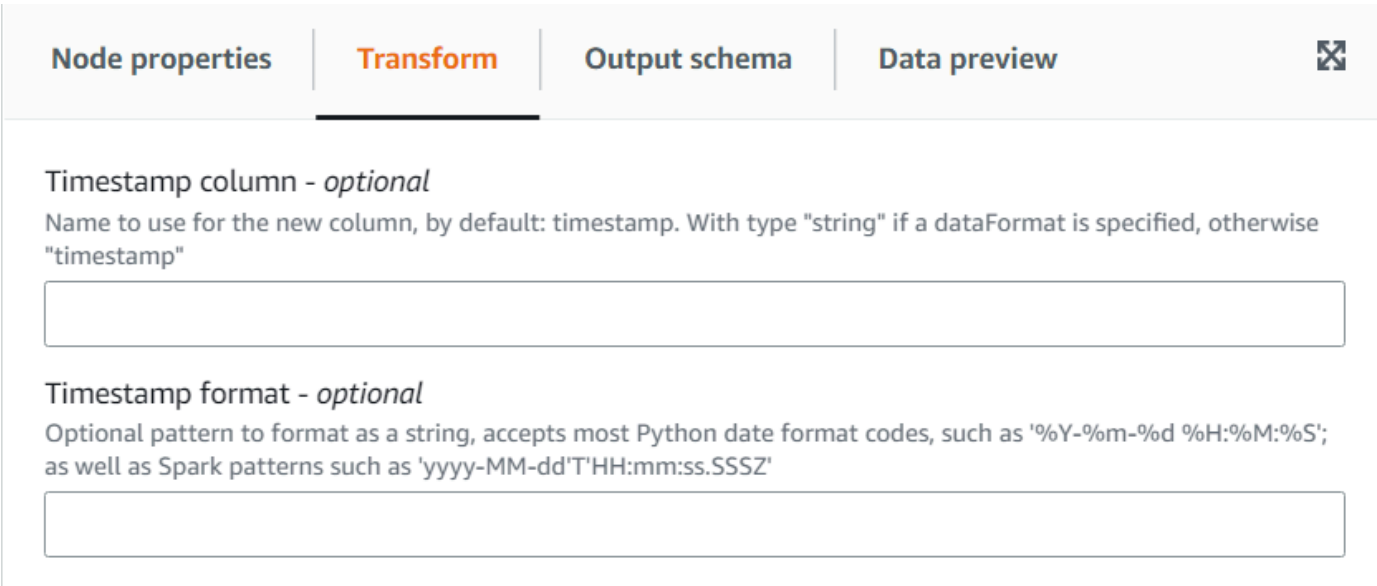

3. (Opcional) Na guia Transformar, insira um nome personalizado para a nova coluna e um formato se você preferir que a coluna seja uma string de data formatada.

Usar a transformação Pivot Rows to Columns

A transformação Pivot Rows to Columns permite agregar uma coluna numérica girando valores exclusivos nas colunas selecionadas que se tornam novas colunas (se várias colunas forem selecionadas, os valores serão concatenados para nomear as novas colunas). Dessa forma, as linhas são consolidadas e têm mais colunas com agregações parciais para cada valor exclusivo. Por exemplo, se você tiver esse conjunto de dados de vendas por mês e país (classificado para ser mais fácil de ilustrar):

ano	mês	país	valor
2020	Jan	uk	32
2020	Jan	de	42
2020	Jan	us	64
2020	Fev	uk	67
2020	Fev	de	4
2020	Fev	de	7
2020	Fev	us	6
2020	Fev	us	12
2020	Jan	us	90

Se você utilizar valor e país como as colunas de agregação, novas colunas serão criadas a partir da coluna país original. Na tabela abaixo, você tem novas colunas para de, uk e us em vez da coluna país.

ano	mês	de	uk	us
2020	Jan	42	32	64
2020	Jan	11	67	18

ano	mês	de	uk	us
2021	Jan			90

Se, em vez disso, você quiser dinamizar o mês e o país, obterá uma coluna para cada combinação dos valores dessas colunas:

ano	Jan_de	Jan_uk	Jan_us	Fev_de	Fev_uk	Fev_us
2020	42	32	64	11	67	18
2021			90			

Para adicionar uma transformação Pivot Rows Ro Columns:

1. Abra o painel Recurso e escolha Pivot Rows To Columns para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, escolha a coluna numérica que será agregada para produzir os valores para as novas colunas, a função de agregação a ser aplicada e a(s) coluna(s) cujos valores exclusivos serão convertidos em novas colunas.

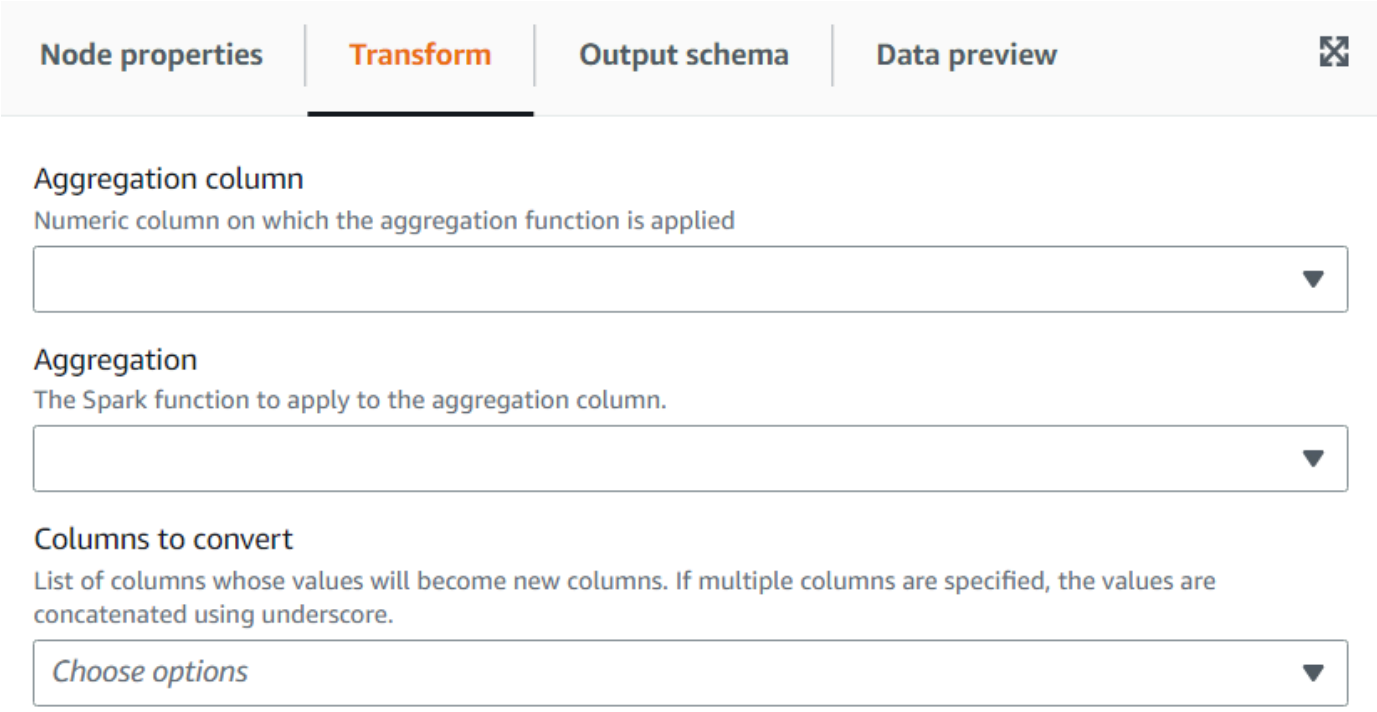

Usar a transformação Unpivot Columns To Rows

A transformação Unpivot permite converter colunas em valores de novas colunas, gerando uma linha para cada valor exclusivo. É o oposto de pivot, mas observe que não é equivalente, pois não pode separar linhas com valores idênticos que eram agregados ou dividir combinações nas colunas originais (você pode fazer isso posteriormente usando uma transformação Split). Por exemplo, se tiver a seguinte tabela:

ano	mês	de	uk	us
2020	Jan	42	32	64
2020	Fev	11	67	18
2021	Jan			90

Você pode despivotar as colunas: “de”, “uk” e “us” em uma coluna “país” com o valor “quantidade” e obter o seguinte (classificado aqui para fins de ilustração):

ano	mês	país	valor
2020	Jan	uk	32
2020	Jan	de	42
2020	Jan	us	64
2020	Fev	uk	67
2020	Fev	de	11
2020	Fev	us	18
2021	Jan	us	90

Observe que as colunas que têm um valor NULL (“de” e “uk” de jan 2021) não são geradas por padrão. Você pode ativar essa opção para obter:

ano	mês	país	valor
2020	Jan	uk	32
2020	Jan	de	42
2020	Jan	us	64
2020	Fev	uk	67
2020	Fev	de	11
2020	Fev	us	18
2021	Jan	us	90
2021	Jan	de	
2021	Jan	uk	

Para adicionar uma transformação Unpivot Columns to Rows:

1. Abra o painel Recurso e escolha Unpivot Rows To Columns para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, insira as novas colunas a serem criadas para conter os nomes e valores das colunas escolhidas para despivotar.

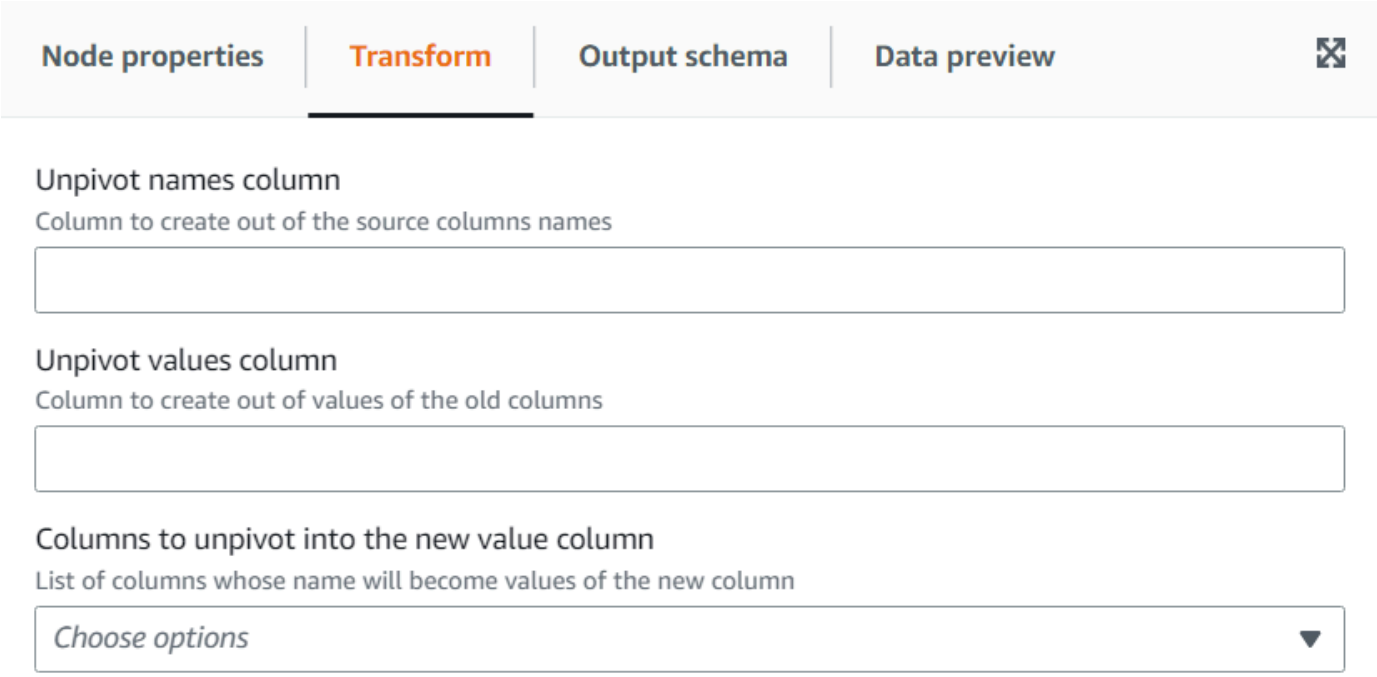

Usando a transformação Autobalance Processing para otimizar seu runtime

A transformação Autobalance Processing redistribui os dados entre os operadores para melhorar a performance. Isso ajuda nos casos em que os dados estão desbalanceados ou, como vêm da fonte, não permitem processamento paralelo suficiente. Isso é comum quando a fonte é compactada com gzip ou é JDBC. A redistribuição de dados tem um custo de performance módico, portanto, a otimização nem sempre compensará esse esforço se os dados já estiverem bem balanceados. Por baixo, a transformação usa a repartição do Apache Spark para reatribuir dados aleatoriamente entre um número de partições ideal para a capacidade do cluster. Para usuários avançados, é possível inserir um número de partições manualmente. Além disso, ele pode ser usado para otimizar

a gravação de tabelas particionadas reorganizando os dados com base em colunas especificadas. Isso resulta em arquivos de saída mais consolidados.

1. Abra o painel Recurso e escolha Autobalance Processing para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. (Opcional) Na guia Transformação, você pode inserir um número de partições. Em geral, é recomendável que você deixe o sistema decidir esse valor, mas pode ajustar o multiplicador ou inserir um valor específico se precisar controlar isso. Se você for salvar os dados particionados por colunas, poderá escolher as mesmas colunas que as colunas de repartição. Dessa forma, minimizará o número de arquivos em cada partição e evitará muitos arquivos por partição, o que prejudicaria a performance das ferramentas que consultam esses dados.

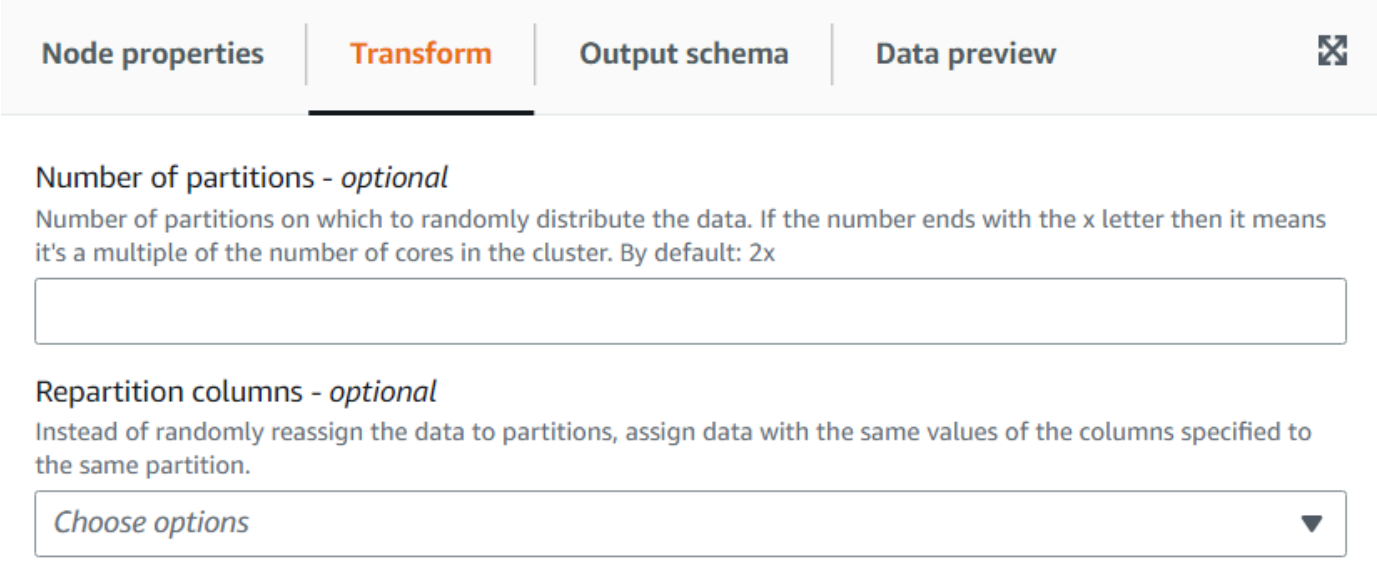

Usando a transformação Derived Column para combinar outras colunas

A transformação Derived Column permite definir uma nova coluna com base em uma fórmula matemática ou expressão SQL na qual você pode usar outras colunas nos dados, além de constantes e literais. Por exemplo, para derivar uma coluna de “porcentagem” das colunas “success” e “count”, você pode inserir a expressão SQL: “success * 100/count || '%'”.

Exemplo de resultado:

success	contagem	percentage
14	100	14%
6	20	3%
3	40	7,5%

Para adicionar uma transformação Derived Column:

1. Abra o painel Recurso e escolha Derived Column para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transform, insira o nome da coluna e a expressão do conteúdo.

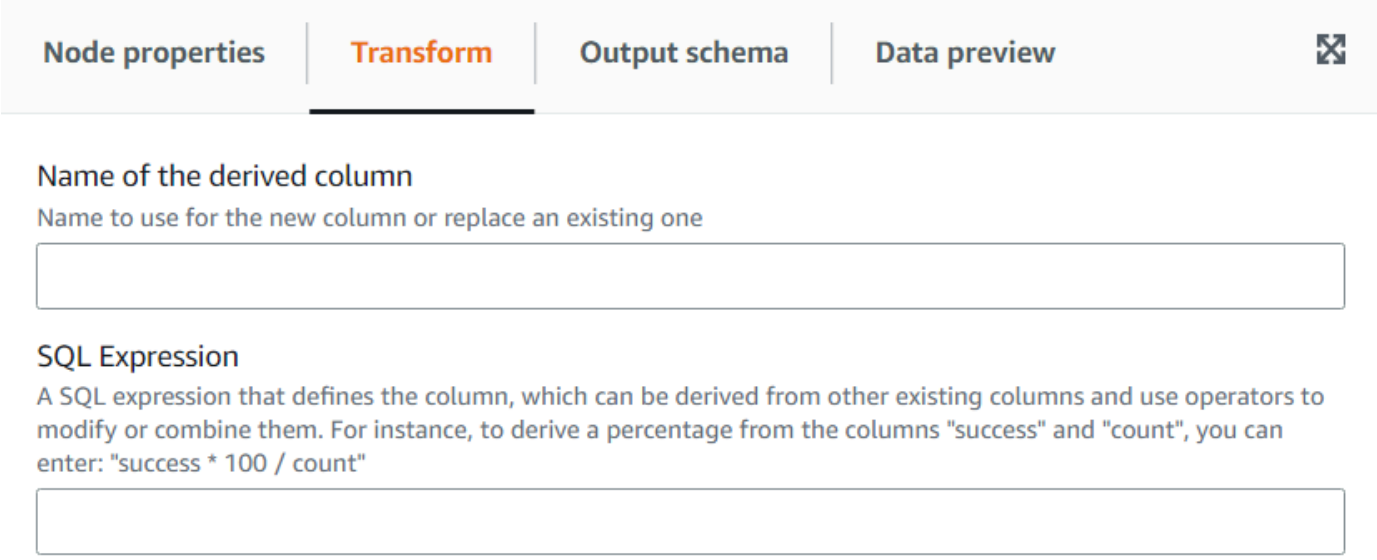

Usar a transformação Lookup para adicionar dados correspondentes de uma tabela de catálogo

A transformação Lookup permite adicionar colunas de uma tabela de catálogo definida quando as chaves correspondem às colunas de pesquisa definidas nos dados. Isso equivale a fazer uma junção externa esquerda entre os dados e a tabela de pesquisa usando como condição as colunas correspondentes.

Para adicionar uma transformação Lookup:

1. Abra o painel Recurso e escolha Lookup para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, insira o nome totalmente qualificado da tabela de catálogo a ser usado para realizar as pesquisas. Por exemplo, se seu banco de dados for “mydb” e sua tabela “mytable”, digite “mydb.mytable”. Em seguida, insira os critérios para encontrar uma correspondência na tabela de pesquisa, se a chave de pesquisa for composta. Insira a lista de colunas de chave separadas por vírgulas. Se uma ou mais das colunas de chave não tiverem o mesmo nome, você precisará definir o mapeamento de correspondência.

   Por exemplo, se as colunas de dados forem “user_id” e “region” e na tabela de usuários as colunas correspondentes forem denominadas “id” e “region”, no campo Colunas a serem correspondidas, digite: "user_id=id, region". Você poderia fazer region=region, mas não é necessário, pois são iguais.
4. Por fim, insira as colunas a serem extraídas da linha correspondente na tabela de pesquisa para incorporá-las aos dados. Se nenhuma correspondência for encontrada, essas colunas serão definidas como NULL.

> **Note**
>
> Abaixo da transformação Lookup, está sendo usada uma junção à esquerda para ser eficiente. Se a tabela de pesquisa tiver uma chave composta, certifique-se de que as colunas correspondentes estejam configuradas para corresponder a todas as colunas-chave, de forma que somente uma correspondência possa ocorrer. Caso contrário, várias linhas de pesquisa corresponderão e isso resultará na adição de linhas extras para cada uma dessas correspondências.

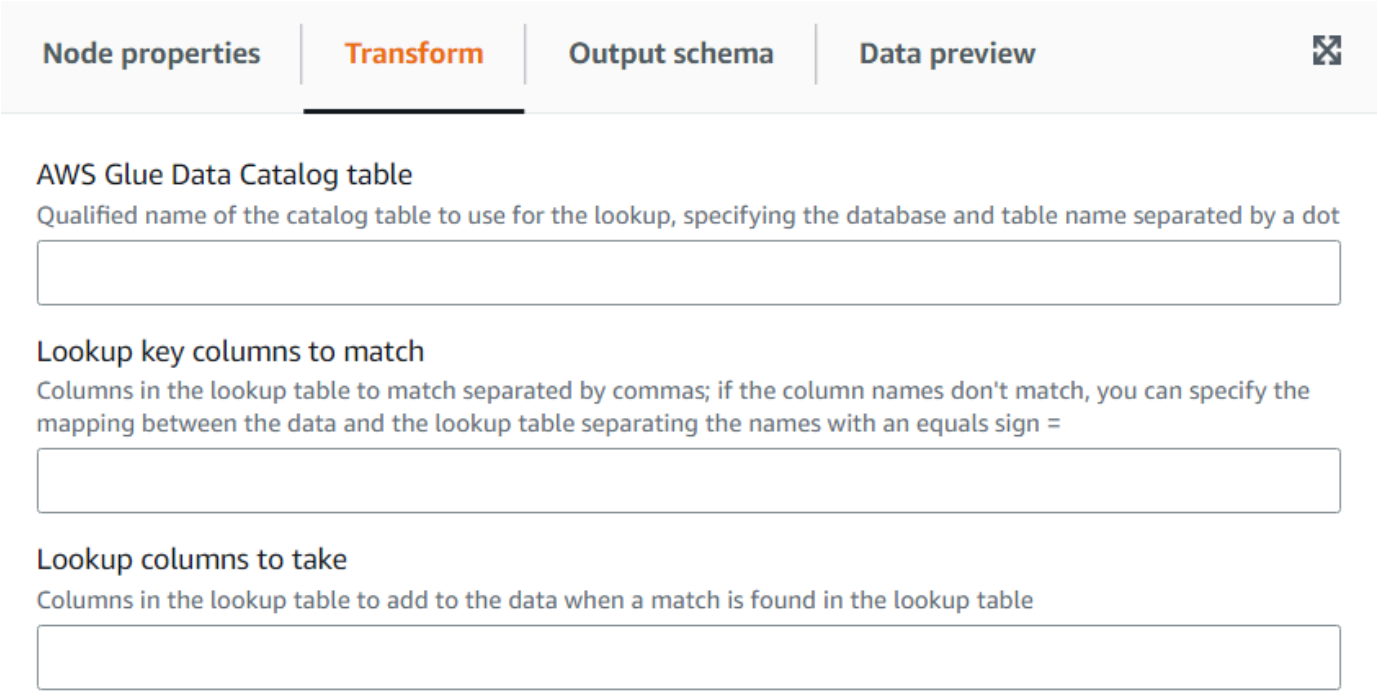

Usando a transformação Explode Array ou Map Into Rows

A transformação Explode permite extrair valores de uma estrutura aninhada em linhas individuais que são mais fáceis de manipular. No caso de uma matriz, a transformação gerará uma linha para cada valor da matriz, replicando os valores para as outras colunas na linha. No caso de um mapa, a transformação gerará uma linha para cada entrada com a chave e o valor como colunas, além de quaisquer outras colunas na linha.

Por exemplo, se tivermos esse conjunto de dados que tem uma coluna de matriz “categoria” com vários valores.

product_id	category
1	[esportes, inverno]
2	[jardim, ferramentas]
3	[videogames]
4	[jogo, jogo de tabuleiro, social]

product_id	category
5	[]

Se você explodir a coluna “categoria” em uma coluna com o mesmo nome, você substituirá a coluna. Você pode selecionar que deseja que os NULLs sejam incluídos para obter o seguinte (ordenado para fins ilustrativos):

product_id	category
1	esportes
1	inverno
2	jardim
2	ferramenta
3	videogames
4	jogo
4	jogo de tabuleiro
4	social
5	

Para adicionar uma transformação Explode Array ou Map Into Rows:

1. Abra o painel Recurso e escolha Explode Array Or Map Into Rows para adicionar uma nova transformação ao diagrama do seu trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. (Opcional) Na guia Propriedades do nó, insira um nome para o nó no diagrama do trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.

3. Na guia Transformar, escolha a coluna a ser explodida (ela deve ser um tipo de matriz ou mapa). Em seguida, insira um nome para a coluna para os itens da matriz ou os nomes das colunas para as chaves e valores se você estiver explodindo um mapa.
4. (Opcional) Na guia Transformar, por padrão, se a coluna a ser explodida for NULL ou tiver uma estrutura vazia, ela será omitida no conjunto de dados explodido. Se você quiser manter a linha (com as novas colunas como NULL), marque “Incluir NULLs”.

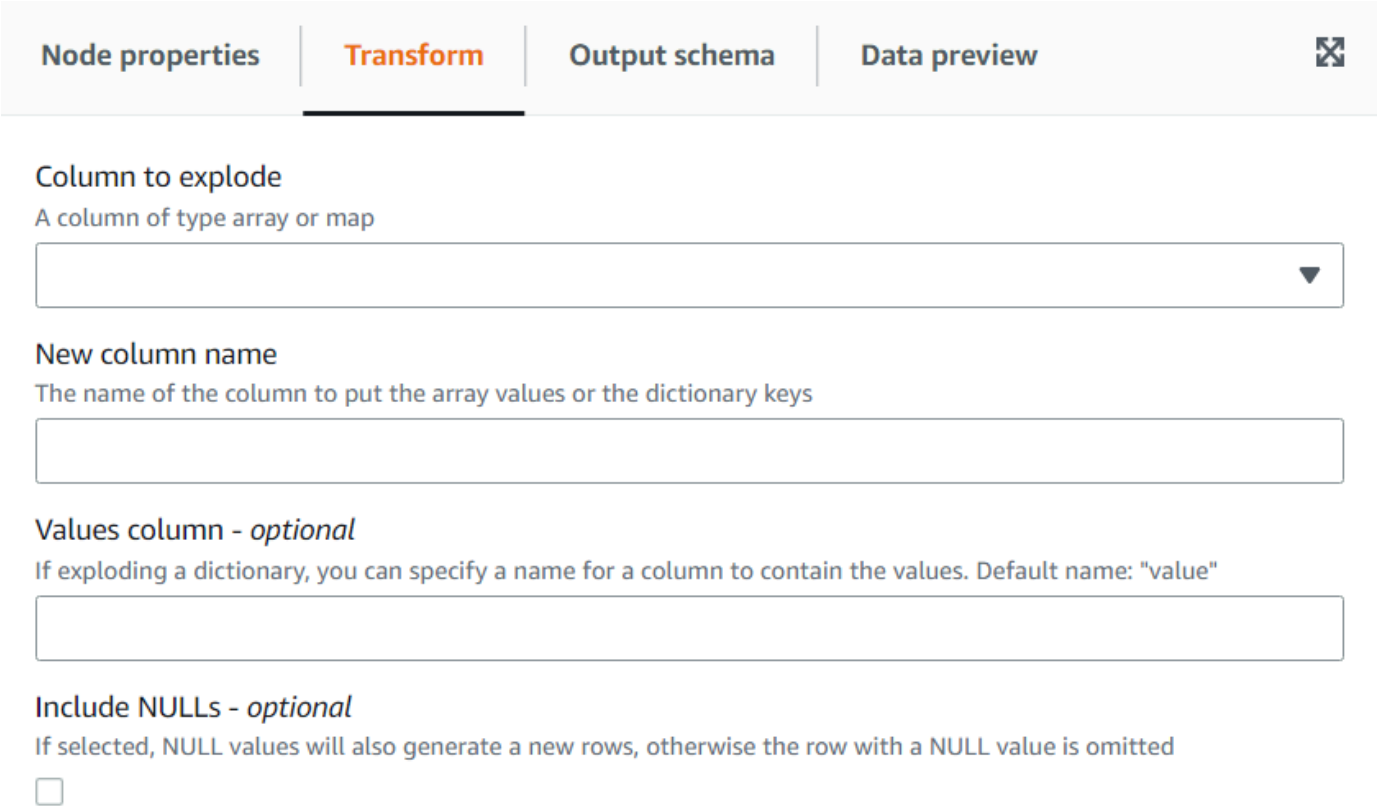

Usar a transformação Record Matching para invocar uma transformação de classificação de dados existentes

Usar a transformação invoca uma transformação de classificação de dados de machine learning Record Matching existente.

A transformação avalia os dados atuais em relação ao modelo treinado com base em rótulos. Uma coluna “match_id” é adicionada para atribuir cada linha a um grupo de itens considerados equivalentes com base no treinamento do algoritmo. Para obter mais informações, consulte Correspondência de registros com Lake Formation FindMatches.

> **Note**
>
> A versão do AWS Glue usada pelo trabalho visual deve corresponder à versão que o AWS Glue usou para criar a transformação Record Matching.

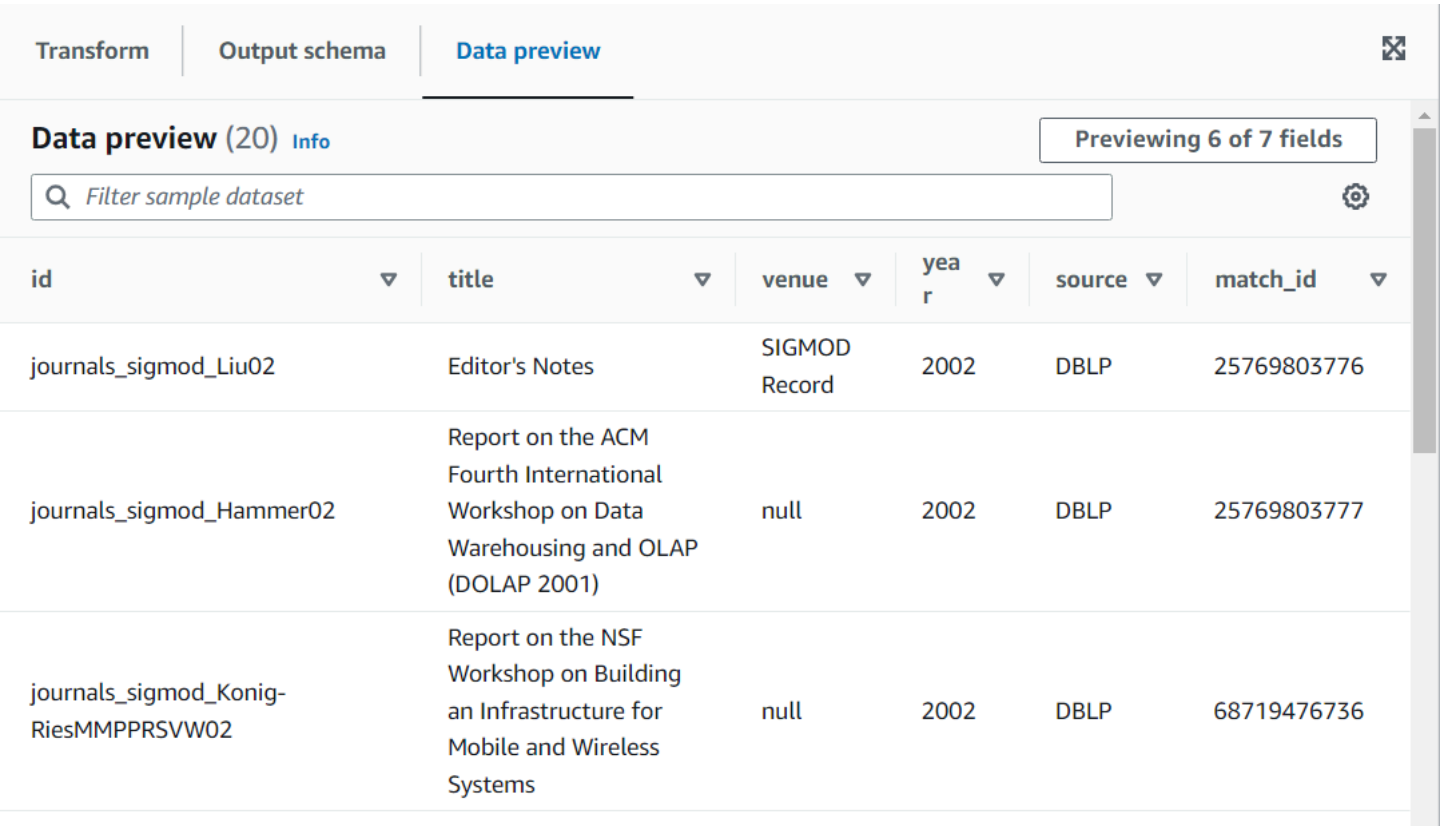

Para adicionar um nó de transformação Record Matching ao diagrama de trabalho

1. Abra o painel Recurso e escolha Record Matching para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. No painel propriedades do nó, insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, insira a ID retirada da página Transformações de machine learning:

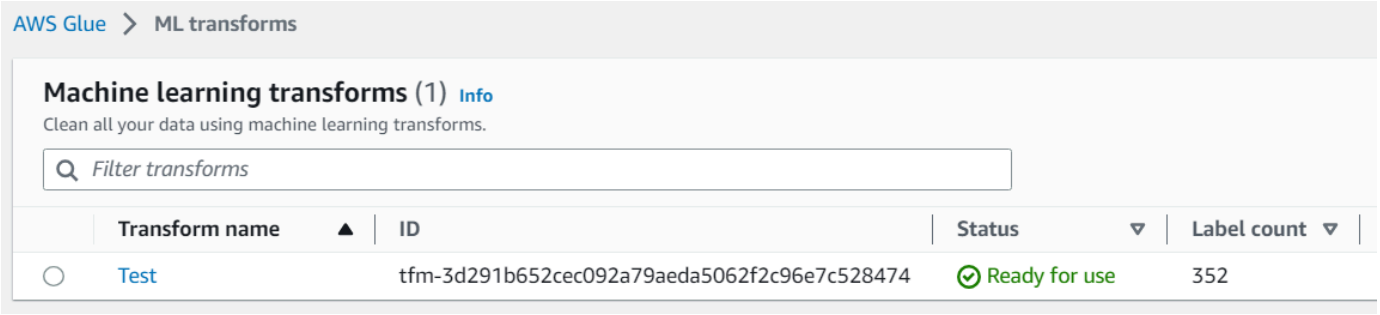

4. (Opcional) Na guia Transformação, você pode marcar a opção de adicionar as pontuações de confiança. Ao custo de computação extra, o modelo estimará uma pontuação de confiança para cada correspondência como uma coluna adicional.

Remoção de linhas nulas

Essa transformação remove do conjunto de dados as linhas que têm todas as colunas como nulas. Além disso, você pode estender esses critérios para incluir campos vazios, de modo a manter as linhas em que pelo menos uma coluna não esteja vazia.

Para adicionar um nó de transformação Remove Null Rows ao diagrama de trabalho

1. Abra o painel Recurso e escolha Remove Null Rows para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. No painel propriedades do nó, insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. (Opcional) Na guia Transformar, marque a opção Estendido se quiser exigir que as linhas não apenas não sejam nulas, mas também não estejam vazias. Dessa forma, cadeias de caracteres, matrizes ou mapas vazios serão considerados nulos para o propósito dessa transformação.

Analisar uma coluna de string contendo dados JSON

Essa transformação analisa uma coluna de string contendo dados JSON e a converte em uma estrutura ou coluna de matriz, dependendo se o JSON é um objeto ou uma matriz, respectivamente. Opcionalmente, você pode manter a coluna analisada e a original.

O esquema JSON pode ser fornecido ou inferido (no caso de objetos JSON), com amostragem opcional.

Para adicionar um nó de transformação de Parse JSON Column ao diagrama de trabalho

1. Abra o painel Recurso e escolha Parse JSON Column para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. No painel propriedades do nó, insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, selecione a coluna que contém a string JSON.
4. (Opcional) Na guia Transformar, insira o esquema que os dados JSON seguem usando a sintaxe SQL, por exemplo: “campo1 STRING, campo2 INT” no caso de um objeto ou “ARRAY<STRING>” no caso de uma matriz.

   No caso de uma matriz, o esquema é obrigatório, mas no caso de um objeto, se o esquema não for especificado, ele será inferido usando os dados. Para reduzir o impacto da inferência do esquema (especialmente em um conjunto de dados grande), você pode evitar ler os dados inteiros duas vezes inserindo uma proporção de amostras a serem usadas para inferir o esquema. Se o valor for menor que 1, a proporção correspondente de amostras aleatórias será usada para inferir o esquema. Se os dados forem confiáveis e o objeto for consistente entre as linhas, você poderá usar uma proporção pequena, como 0,1, para melhorar a performance.
5. (Opcional) Na guia Transformar, você pode inserir um novo nome de coluna se quiser manter a coluna de string original e a coluna analisada.

Extraindo um caminho JSON

Essa transformação extrai novas colunas de uma coluna de string JSON. Essa transformação é útil quando você precisa apenas de alguns elementos de dados e não quer importar todo o conteúdo do JSON para o esquema da tabela.

Para adicionar um nó de transformação Extract JSON Path ao diagrama do trabalho

1. Abra o painel Recurso e escolha Extract JSON Path para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. No painel propriedades do nó, insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, selecione a coluna que contém a string JSON. Insira uma ou mais expressões de caminho JSON separadas por vírgulas, cada uma fazendo referência a como

extrair um valor da matriz ou objeto JSON. Por exemplo, se a coluna JSON contivesse objetos com as propriedades “prop_1" e “prop2", você poderia extrair ambas especificando seus nomes “prop_1, prop_2".

Se o campo JSON tiver caracteres especiais, por exemplo, para extrair a propriedade desse JSON `{"a. a": 1}` você poderá usar o caminho `$['a. a']`. A exceção é a vírgula porque ela é reservada para caminhos separados. Em seguida, insira os nomes das colunas correspondentes para cada caminho, separados por vírgulas.

4. (Opcional) Na guia Transformar, você pode marcar a opção de descartar a coluna JSON depois de extraída. Isso faz sentido quando você não precisa do restante dos dados JSON depois de extrair as partes necessárias.

Extrair fragmentos de string usando uma expressão regular

Essa transformação extrai fragmentos de string usando uma expressão regular e cria uma nova coluna a partir dela, ou várias colunas se estiver usando grupos regex.

Para adicionar um nó de transformação Regex Extractor ao diagrama de trabalho

1. Abra o painel Recurso e escolha Regex Extractor para adicionar uma nova transformação ao diagrama do trabalho. O nó selecionado no momento da adição do nó será o nó superior.
2. No painel propriedades do nó, insira um nome para o nó no diagrama de trabalho. Se ainda não houver um nó pai selecionado, escolha um na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.
3. Na guia Transformar, insira a expressão regular e a coluna na qual ela precisa ser aplicada. Em seguida, insira o nome da nova coluna na qual armazenar a string correspondente. A nova coluna será nula somente se a coluna de origem for nula; se a regex não corresponder, a coluna ficará vazia.

   Se a regex usar grupos, haverá um nome de coluna correspondente separado por vírgula, mas você pode pular grupos deixando o nome da coluna vazio.

   Por exemplo, se você tiver uma coluna “purchase_date” com uma string usando formatos de data ISO longo e curto, convém extrair o ano, mês, dia e hora, quando disponível. Observe que o grupo de horas é opcional, caso contrário, nas linhas em que não estiverem disponíveis, todos os grupos extraídos seriam strings vazias (porque o regex não correspondia). Nesse caso, não

queremos que o grupo torne a hora opcional, mas a interna, então deixamos o nome vazio e ele não é extraído (esse grupo incluiria o caractere T).

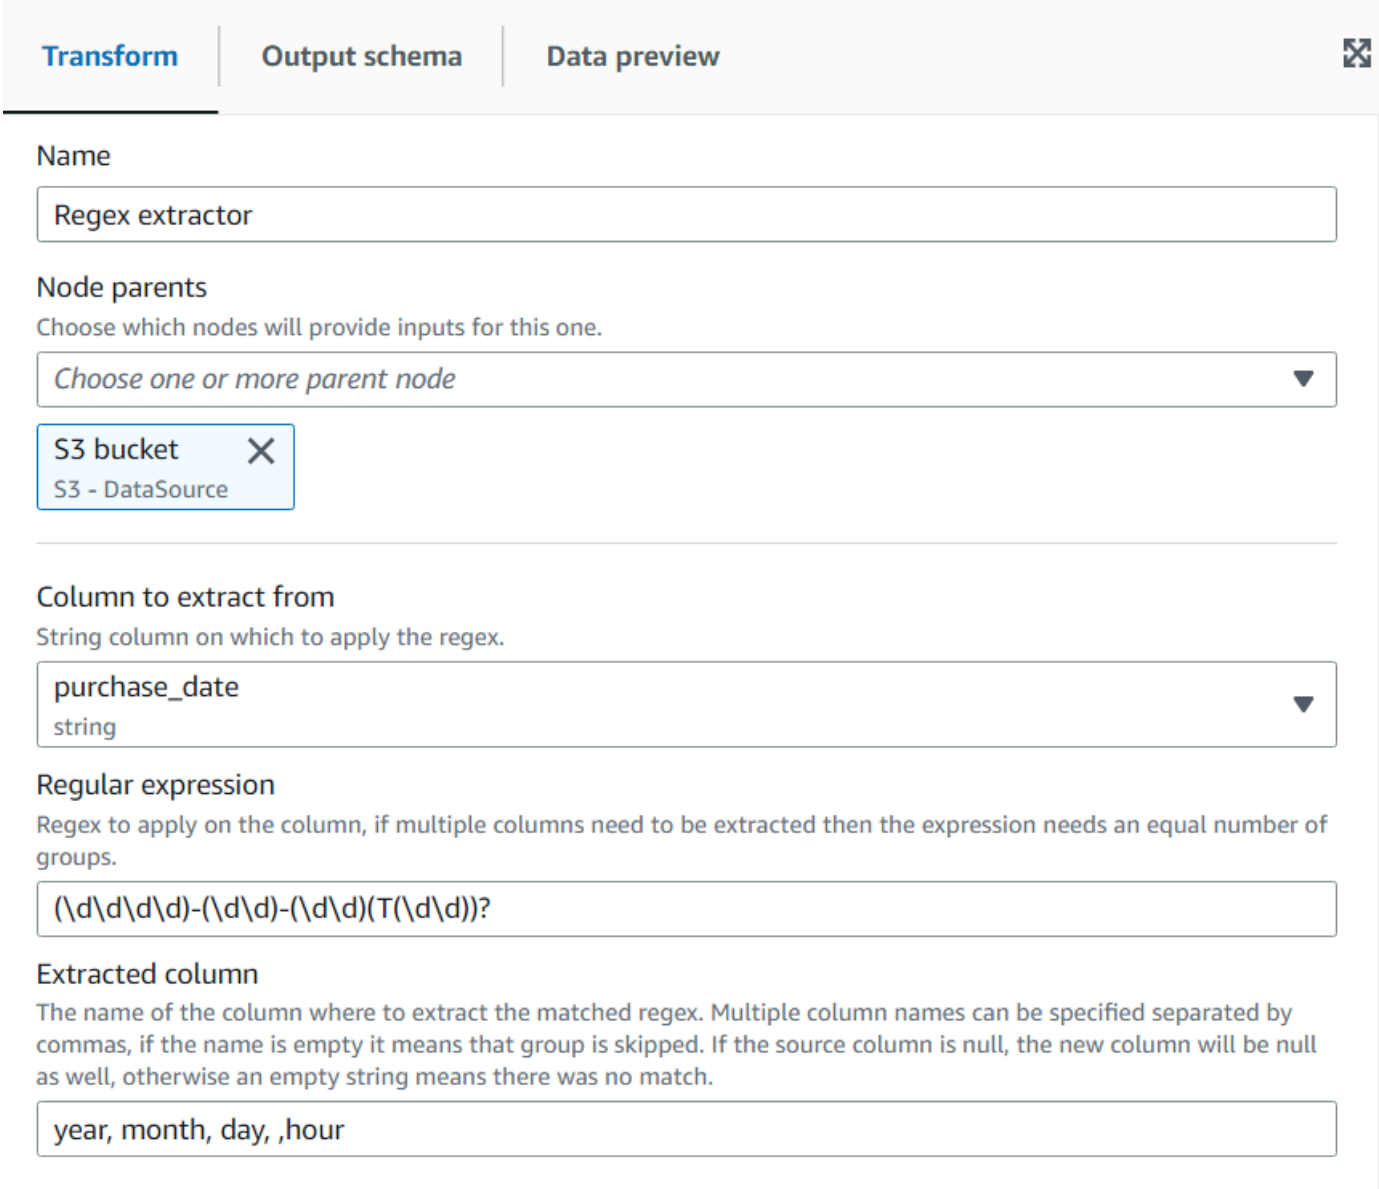

Resultando na visualização prévia dos dados:

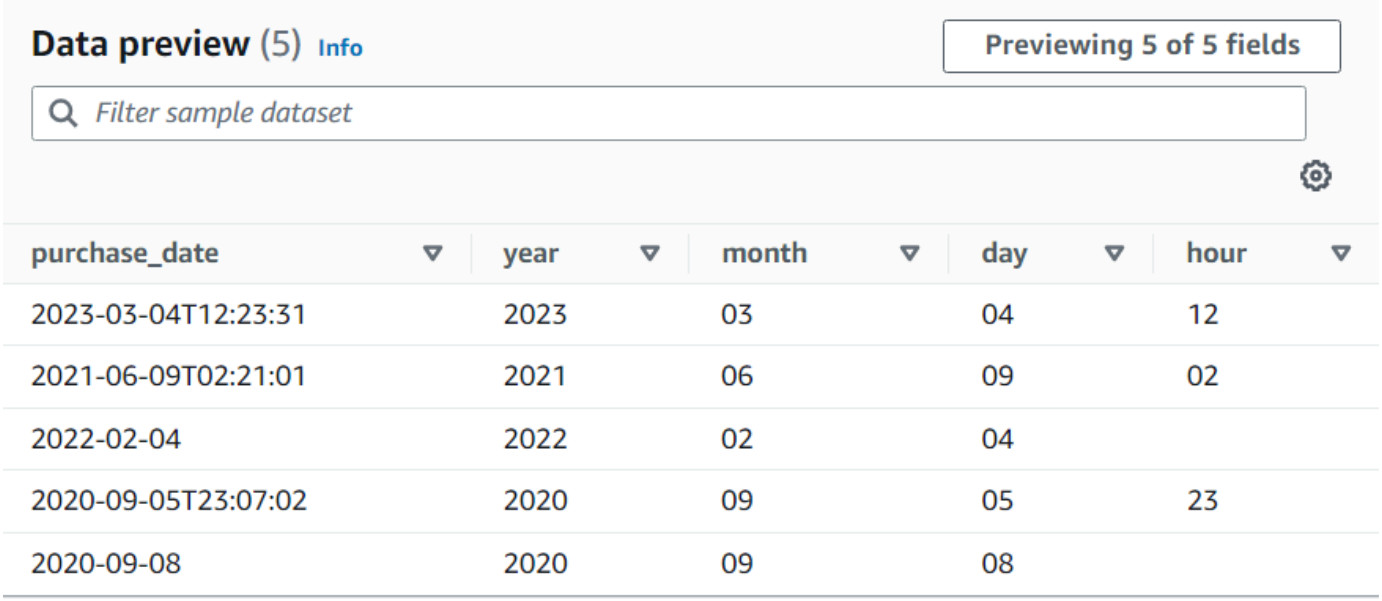

Criar uma transformação personalizada

Se precisar executar transformações mais complicadas em seus dados ou quiser adicionar chaves de propriedade de dados ao conjunto de dados, você pode adicionar uma transformação Custom code (Código personalizado) em seu diagrama de trabalho. O nó Custom code (Código personalizado) permite inserir um script que executa a transformação.

Ao usar código personalizado, você deve usar um editor de esquema para indicar as alterações feitas na saída por meio do código personalizado. Ao editar o esquema, você pode executar as seguintes ações:

- Adicionar ou remover chaves de propriedade de dados
- Alterar o tipo de dados das chaves de propriedade de dados
- Alterar o nome das chaves de propriedade de dados
- Reestruturar uma chave de propriedade aninhada

Você deve usar uma transformação SelectFromCollection (Selecionar da coleção) para escolher um único `DynamicFrame` do resultado do nó de transformação personalizada antes de enviar a saída para um local de destino.

Use as seguintes tarefas para adicionar um nó de transformação personalizada ao diagrama de trabalho.

Adicionar um nó de transformação de código personalizado ao diagrama de trabalho

Para adicionar um nó de transformação personalizado ao diagrama de trabalho

1. (Opcional) abra o painel Recurso e escolha Transformação personalizada para adicionar uma nova transformação ao diagrama de trabalho.
2. Na guia Node properties (Propriedades do nó), insira um nome para o nó no diagrama de trabalho. Se um nó pai ainda não estiver selecionado, ou se você quiser várias entradas para a transformação personalizada, escolha um nó na lista Node parents (Nós pais) para usar como fonte de entrada para a transformação.

Inserir código para o nó de transformação personalizada

Você pode digitar ou copiar código em um campo de entrada. O trabalho usa esse código para executar a transformação de dados. Você pode fornecer um trecho de código em Python ou Scala. O código deve aceitar um ou mais `DynamicFrames` como entrada e retornar uma coleção de `DynamicFrames`.

Para inserir o script para um nó de transformação personalizada

1. Com o nó de transformação personalizada selecionado no diagrama de trabalho, escolha a guia Transform (Transformação).
2. No campo de entrada de texto, no cabeçalho Code block (Bloco de código), cole ou insira o código da transformação. O código que você usa deve corresponder à linguagem especificada para o trabalho na guia Job details (Detalhes do trabalho).

   Ao fazer referência aos nós de entrada em seu código, o AWS Glue Studio nomeia o `DynamicFrames` retornado pelos nós do diagrama de trabalho sequencialmente com base na ordem de criação. Use um dos seguintes métodos de atribuição de nomes no código:

   - Geração de código clássico: use nomes funcionais para se referir aos nós no diagrama do trabalho.
     - Nós da origem dos dados: `DataSource0`, `DataSource1`, `DataSource2` e assim por diante.
     - Nós de transformação: `Transform0`, `Transform1`, `Transform2` e assim por diante.
   - Geração de novo código: use o nome especificado na guia Node properties (Propriedades do nó), seguida por um "`_node1`", "`_node2`" anexao e assim por

diante. Por exemplo, `S3bucket_node1`, `ApplyMapping_node2`, `S3bucket_node2`, `MyCustomNodeName_node1`.

Para obter mais informações sobre o gerador de novo código, consulte Geração de código de script.

Os exemplos a seguir mostram o formato do código a ser inserido na caixa de código:

Python

O exemplo a seguir pega o primeiro `DynamicFrame` recebido, converte-o em um `DataFrame` para aplicar o método de filtro nativo (mantendo somente registros que têm mais de 1.000 votos) e, em seguida, converte-o novamente em um `DynamicFrame` antes de devolvê-lo.

```
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

O exemplo a seguir pega o primeiro `DynamicFrame` recebido, converte-o em um `DataFrame` para aplicar o método de filtro nativo (mantendo somente registros que têm mais de 1.000 votos) e, em seguida, converte-o novamente em um `DynamicFrame` antes de devolvê-lo.

```
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)
  }
}
```

Editar o esquema de um nó de transformação personalizada

Quando você usa um nó de transformação personalizada, o AWS Glue Studio não pode inferir automaticamente os esquemas de saída criados pela transformação. Use o editor de esquema para descrever as alterações de esquema implantadas pelo código de transformação personalizada.

Um nó de código personalizado pode ter qualquer número de nós pais, cada um fornecendo um `DynamicFrame` como entrada para o seu código personalizado. Um nó de código personalizado retorna uma coleção de `DynamicFrames`. Cada `DynamicFrame` usado como entrada tem um esquema associado. Você deve adicionar um esquema que descreva cada `DynamicFrame` retornado pelo nó de código personalizado.

> **Note**
>
> Quando você define seu próprio esquema em uma transformação personalizada, o AWS Glue Studio não herda esquemas de nós anteriores. Para atualizar o esquema, selecione o nó Custom transform (Transformação personalizada) e escolha a guia Data preview (Visualização de dados). Depois que a visualização for gerada, escolha “Use Preview Schema” (Usar esquema de visualização). O esquema será substituído pelo esquema usando os dados de visualização.

Para editar os esquemas de um nó de transformação personalizada

1. Com o nó de transformação personalizada selecionado no diagrama de trabalho, no painel de detalhes do nó, escolha a guia Outpu schema (Esquema de saída).
2. Escolha Edit (Editar) para fazer alterações no esquema.

   Se você tiver chaves de propriedade de dados aninhadas, como uma matriz ou objeto, pode escolher o ícone Expand-Rows (Expandir linhas,) no canto superior direito de cada painel de esquema, para expandir a lista de chaves de propriedade de dados filhas. Depois de escolher esse ícone, ele muda para o ícone Collapse-Rows (Recolher linhas,), que você pode usar para recolher a lista de chaves de propriedade filhas.
3. Modifique o esquema usando as seguintes ações na seção no lado direito da página:

- Para renomear uma chave de propriedade, coloque o cursor na caixa de texto Key (Chave) da chave de propriedade e insira o novo nome.
- Para alterar o tipo de dados de uma chave de propriedade de dados, use a lista para escolher o novo tipo de dados da chave de propriedade.
- Para adicionar uma nova propriedade de nível superior ao esquema, escolha o botão Overflow (excedente,

)
  à esquerda do botão Cancel (Cancelar) e, em seguida, escolha Add root key (Adicionar chave raiz).
- Para adicionar uma chave de propriedade filha ao esquema, escolha o ícone Add-Key (Adicionar chave,

)
  associado à chave pai. Insira um nome para a chave filha e escolha o tipo de dados.
- Para remover uma chave de propriedade do esquema, escolha o ícone Remove (Excluir,

)
  à extrema direita do nome da chave.

4. Se o código de transformação personalizada usar vários `DynamicFrames`, você poderá adicionar esquemas de saída adicionais.

   - Para adicionar um esquema novo e vazio, escolha o ícone Overflow (Excedente,

)
     e, em seguida, escolha Add output schema (Adicionar esquema de saída).
   - Para copiar um esquema existente em um novo esquema de saída, certifique-se de que aquele que você deseja copiar seja exibido no seletor de esquemas. Selecione o ícone Overflow (Excedente,

)
     e, em seguida, escolha Duplicate (Duplicar).

   Se você quiser remover um esquema de saída, certifique-se de que o esquema que deseja copiar seja exibido no seletor de esquemas. Escolha o ícone Overflow (Excedente,

)
   e, em seguida, escolha Delete (Excluir).

5. Adicione novas chaves raiz ao novo esquema ou edite as chaves duplicadas.

6. Quando estiver modificando os esquemas de saída, escolha o botão Apply (Aplicar) para salvar suas alterações e saia do editor de esquemas.

   Se não quiser salvar as alterações, escolha o botão Cancel (Cancelar).

Configurar a saída da transformação personalizada

Uma transformação de código personalizado retorna uma coleção de `DynamicFrames`, mesmo que haja somente um `DynamicFrame` no conjunto de resultados.

Para processar a saída de um nó de transformação personalizada

1. Adicione um nó de transformação SelectFromCollection (Selecionar da coleção) que tem o nó de transformação personalizada como nó pai. Atualize esta transformação para indicar qual conjunto de dados você deseja usar. Consulte Usar SelectFromCollection (Selecionar da coleção) para escolher qual conjunto de dados manter Para mais informações.
2. Adicione mais transformações SelectFromCollection (Selecionar da coleção) para o diagrama de trabalho se você quiser usar `DynamicFrames` adionais produzidos pelo nó de transformação personalizada.

   Considere um cenário no qual você adiciona um nó de transformação personalizada para dividir um conjunto de dados de voo em vários conjuntos de dados, mas duplica algumas das chaves de propriedade de identificação em cada esquema de saída, como a data ou o número do voo. Adicione um nó de transformação SelectFromCollection (Selecionar da coleção) para cada esquema de saída, com o nó de transformação personalizada como nó pai.
3. (Opcional) em seguida, você pode usar cada nó de transformação SelectFromCollection (Selecionar da coleção) como entrada para outros nós no trabalho ou como pai para um nó de destino de dados.

Transformar dados com transformações visuais personalizadas

As transformações visuais personalizadas permitem que você crie transformações e as disponibilize para uso em trabalhos do AWS Glue Studio. As transformações visuais personalizadas permitem que os desenvolvedores de ETL, que talvez não estejam familiarizados com a codificação, pesquisem e usem uma biblioteca crescente de transformações usando a interface do AWS Glue Studio.

Você pode criar uma transformação visual personalizada e, em seguida, fazer o upload para o Amazon S3 para disponibilizá-la para uso por meio do editor visual no AWS Glue Studio para trabalhar com esses trabalhos.

Tópicos

- Conceitos básicos de transformações visuais personalizadas
- Etapa 1. Crie um arquivo de configuração JSON
- Etapa 2. Implemente a lógica da transformação
- Etapa 3. Validar e solucionar problemas de transformações visuais personalizadas no AWS Glue Studio
- Etapa 4. Atualize transformações visuais personalizadas conforme necessário
- Etapa 5. Use a transformações visuais personalizadas no AWS Glue Studio
- Exemplos de uso
- Exemplos de scripts visuais personalizados
- Vídeo

Conceitos básicos de transformações visuais personalizadas

Para criar uma transformação visual personalizada, siga estas etapas.

- Etapa 1. Crie um arquivo de configuração JSON
- Etapa 2. Implemente a lógica da transformação
- Etapa 3. Valide a transformação visual personalizada
- Etapa 4. Atualize a transformação visual personalizada conforme necessário
- Etapa 5. Use a transformação visual personalizada no AWS Glue Studio

Comece configurando o bucket do Amazon S3 e continue com a Etapa 1. Crie um arquivo de configuração JSON.

Pré-requisitos

As transformações fornecidas pelo cliente residem em uma conta AWS do cliente. Essa conta é proprietária das transformações e, portanto, tem todas as permissões para visualizá-las (pesquisar e usar), editá-las ou excluí-las.

Para usar uma transformação personalizada no AWS Glue Studio, você precisará criar e fazer upload de dois arquivos para o bucket de ativos do Amazon S3 nessa conta AWS:

- Arquivo Python: contém a função de transformação
- Arquivo JSON: descreve a transformação. Isso também é conhecido como o arquivo de configuração que é necessário para definir a transformação.

Para emparelhar os arquivos, use o mesmo nome para ambos. Por exemplo:

- myTransform.json
- myTransform.py

Opcionalmente, você pode dar à sua transformação visual personalizada um ícone personalizado fornecendo um arquivo SVG contendo o ícone. Para emparelhar os arquivos, use o mesmo nome para o ícone:

- myTransform.svg

O AWS Glue Studio os combinará automaticamente usando seus respectivos nomes de arquivo. Os nomes dos arquivos não podem ser os mesmos para nenhum módulo existente.

Convenção recomendada para nome de arquivo de transformação

O AWS Glue Studio importará seu arquivo como módulo (por exemplo, `import myTransform`) em seu script de trabalho. Portanto, o nome do seu arquivo deve seguir as mesmas regras de nomenclatura definidas para nomes de variáveis (identificadores) do Python. Especificamente, eles devem começar com uma letra ou um sublinhado e, em seguida, ser compostos inteiramente por letras, dígitos e/ou sublinhados.

> **Note**
>
> Certifique-se de que o nome do arquivo de transformação não esteja em conflito com os módulos python carregados existentes (por exemplo, `sys, array, copy` etc.) para evitar problemas inesperados de runtime.

Configurar um bucket do Amazon S3

As transformações que você cria são armazenadas no Amazon S3 e pertencem à sua conta AWS. Você cria novas transformações visuais personalizadas simplesmente carregando arquivos (json e py) para a pasta de ativos do Amazon S3, onde todos os scripts de trabalho estão armazenados atualmente (por exemplo, `s3://aws-glue-assets-<accountid>-<region>/transforms`). Se estiver usando um ícone personalizado, carregue-o também. Por padrão, o AWS Glue Studio lerá todos os arquivos .json da pasta /transforms no mesmo bucket do S3.

Etapa 1. Crie um arquivo de configuração JSON

É necessário um arquivo de configuração JSON para definir e descrever sua transformação visual personalizada. O esquema para o arquivo de configuração é como se segue.

Estrutura de arquivo JSON

Campos

- `name: string`: (obrigatório) o nome do sistema de transformação usado para identificar as transformações. Siga as mesmas regras de nomenclatura definidas para nomes de variáveis (identificadores) do Python. Especificamente, eles devem começar com uma letra ou um sublinhado e, em seguida, ser compostos inteiramente por letras, dígitos e/ou sublinhados.
- `displayName: string`: (opcional) o nome da transformação exibida no editor visual de trabalhos do AWS Glue Studio. Se não for especificado nenhum `displayName`, o `name` será usado como o nome da transformação no AWS Glue Studio.
- `description: string`: (opcional) a descrição da transformação é exibida no AWS Glue Studio e pode ser pesquisada.
- `functionName: string`: (obrigatório) o nome da função do Python é usado para identificar a função a ser chamada no script do Python.
- `path: string`: (opcional) o caminho completo do Amazon S3 para o arquivo fonte do Python. Se não for especificado, o AWS Glue usará a correspondência de nomes de arquivo para emparelhar os arquivos .json e .py. Por exemplo, o nome do arquivo JSON, `myTransform.json`, será emparelhado com o arquivo Python, `myTransform.py`, no mesmo local do Amazon S3.
- `parameters: Array of TransformParameter object`: (opcional) a lista de parâmetros a serem exibidos quando você os configura no editor visual do AWS Glue Studio.

Campos TransformParameter

- `name: string`: (obrigatório) o nome do parâmetro que será passado para a função do Python como um argumento nomeado no script do trabalho. Siga as mesmas regras de nomenclatura definidas para nomes de variáveis (identificadores) do Python. Especificamente, eles devem começar com uma letra ou um sublinhado e, em seguida, ser compostos inteiramente por letras, dígitos e/ou sublinhados.
- `displayName: string`: (opcional) o nome da transformação exibida no editor visual de trabalhos do AWS Glue Studio. Se não for especificado nenhum `displayName`, o `name` será usado como o nome da transformação no AWS Glue Studio.
- `type: string`: (obrigatório) o tipo de parâmetro que aceita tipos de dados comuns do Python. Valores válidos: 'str' | 'int' | 'float' | 'list' | 'bool'.
- `isOptional: boolean`: (opcional) determina se o parâmetro é opcional. Por padrão, todos os parâmetros são obrigatórios.
- `description: string`: (opcional) a descrição é exibida no AWS Glue Studio para ajudar o usuário a configurar o parâmetro de transformação.
- `validationType: string`: (opcional) define a forma como esse parâmetro é validado. Atualmente, só aceita expressões regulares. Por padrão, o tipo de validação é definido como `RegularExpression`.
- `validationRule: string`: (opcional) expressão regular usada para validar a entrada do formulário antes do envio, quando `validationType` está definido como `RegularExpression`. A sintaxe da expressão regular deve ser compatível com as especificações RegExp do Ecmascript.
- `validationMessage: string`: (opcional) a mensagem a ser exibida quando a validação falhar.
- `listOptions: An array of TransformParameterListOption object` OU um `string` ou o valor da string 'coluna': (opcional) opções a serem exibidas no controle de interface de usuário de seleção ou seleção múltipla. Aceitar uma lista de valores separados por vírgula ou um objeto JSON do tipo `TransformParameterListOption`. Ele também pode preencher dinamicamente a lista de colunas do esquema do nó pai especificando o valor da string “coluna”.
- `listType: string`: (opcional) defina os tipos de opções como tipo = “list”. Valores válidos: 'str' | 'int' | 'float' | 'list' | 'bool'. Tipo de parâmetro que aceita tipos de dados comuns do Python.

Campos TransformParameterListOption

- `value: string | int | float | bool`: (obrigatório) valor da opção.
- `label: string`: (opcional) rótulo da opção exibida na lista suspensa de seleção.

Transformar parâmetros em AWS Glue Studio

Por padrão, os parâmetros são obrigatórios, a menos que sejam marcados como `isOptional` no arquivo .json. No AWS Glue Studio, os parâmetros são exibidos na guia Transform (Transformar). O exemplo mostra parâmetros definidos pelo usuário, como endereço de e-mail, número de telefone, idade, sexo e país de origem.

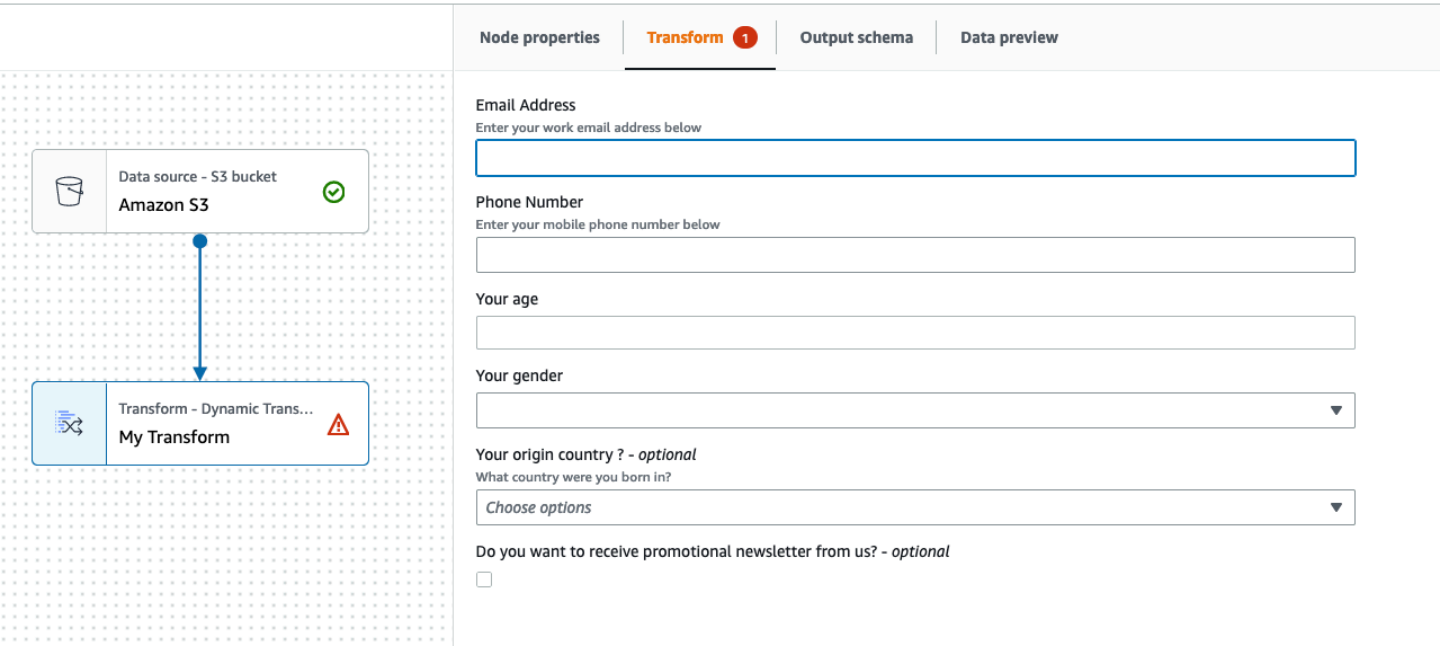

Você pode impor algumas validações no AWS Glue Studio usando expressões regulares no arquivo json especificando o parâmetro `validationRule` e especificando uma mensagem de validação em `validationMessage`.

```
    "validationRule": "^\\(?(\\d{3})\\)?[- ]?(\\d{3})[- ]?(\\d{4})$",
    "validationMessage": "Please enter a valid US number"
```

> **Note**
>
> Como a validação ocorre no navegador, a sintaxe da expressão regular deve ser compatível com as especificações RegExp do Ecmascript. A sintaxe do Python não é compatível com essas expressões regulares.

Adicionar validação evitará que o usuário salve o trabalho com a entrada incorreta do usuário. O AWS Glue Studio exibe a mensagem de validação como a exibida no exemplo:

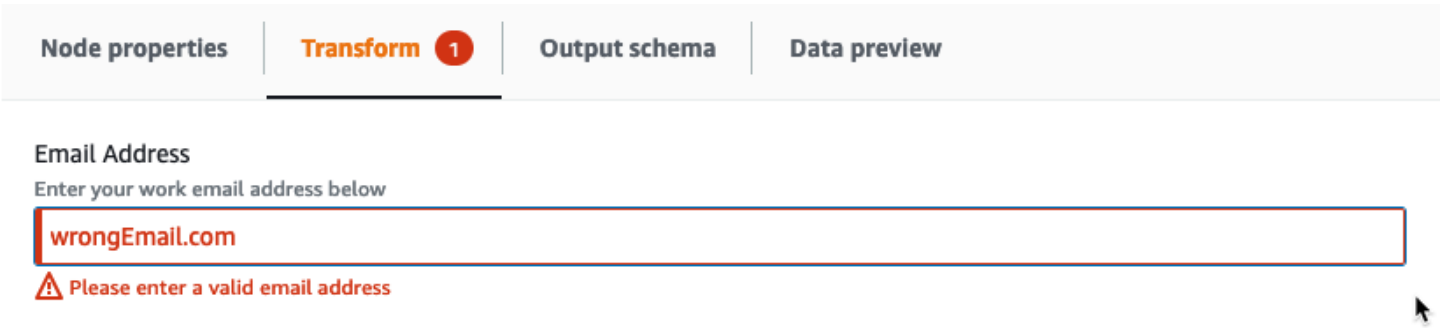

Os parâmetros são exibidos no AWS Glue Studio com base na configuração do parâmetro.

- Quando o `type` é qualquer um dos seguintes: `str`, `int` ou `float`, um campo de entrada de texto é exibido. Por exemplo, a exibição de tela mostra campos de entrada para os parâmetros 'Endereço de e-mail' e 'Sua idade'.

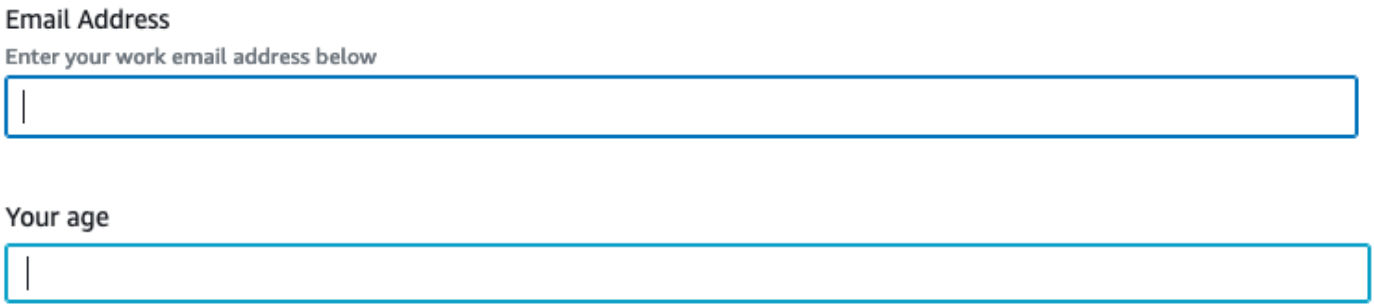

- Quando `type` é `bool`, uma caixa de seleção é exibida.

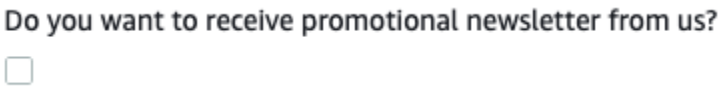

- Quando `type` é `str` e `listOptions` é fornecida, é exibida uma única lista de seleção.

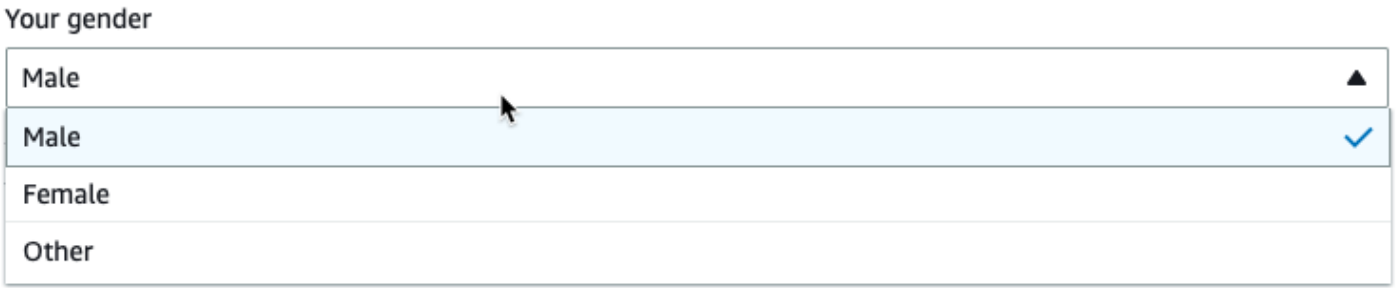

- Quando são fornecidos `type`, `list`, `listOptions` e `listType`, é exibida uma lista de seleção múltipla.

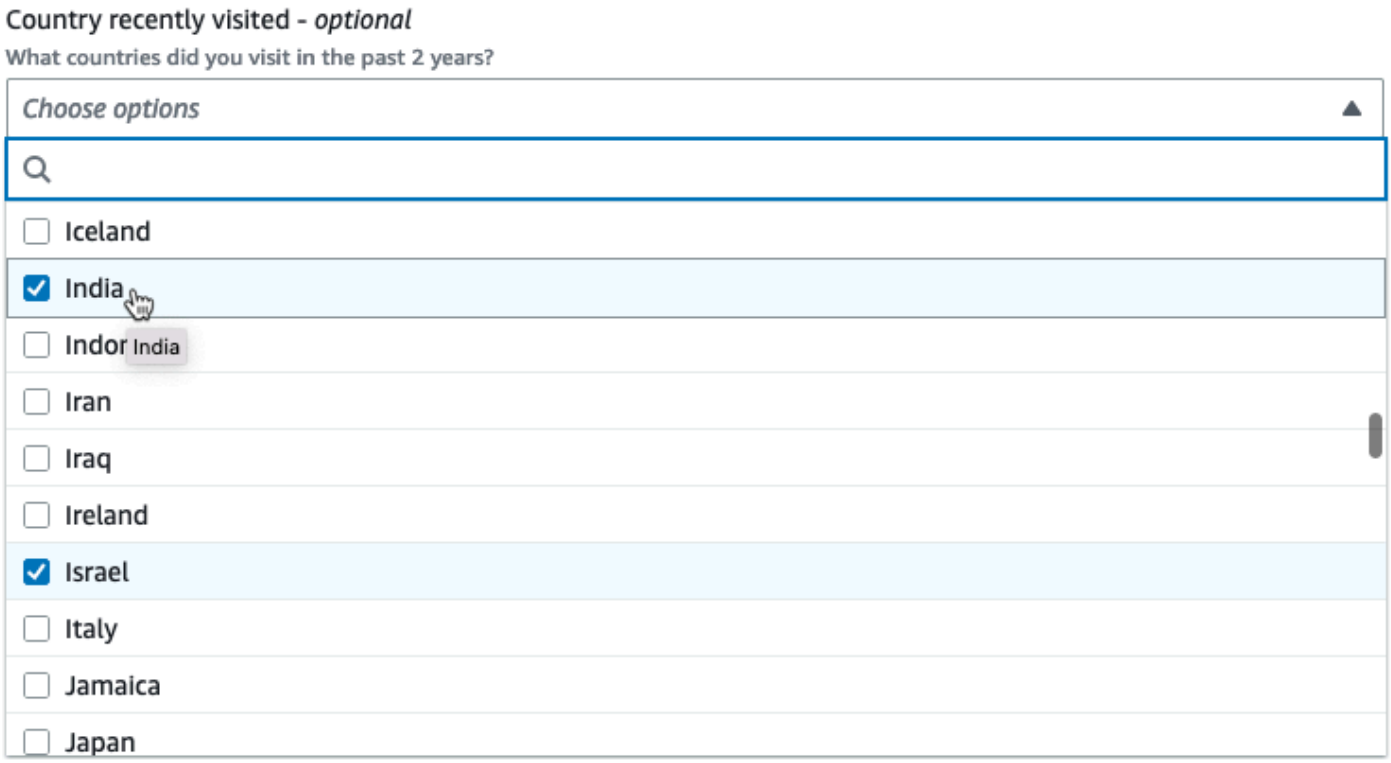

Exibir um seletor de coluna como parâmetro

Se a configuração exigir que o usuário escolha uma coluna do esquema, você poderá exibir um seletor de coluna para que o usuário não precise digitar o nome da coluna. Ao definir o campo `listOptions` como “coluna”, o AWS Glue Studio exibe dinamicamente um seletor de coluna com base no esquema de saída do nó pai. O AWS Glue Studio pode exibir um seletor de coluna única ou múltipla.

O exemplo a seguir usa o esquema:

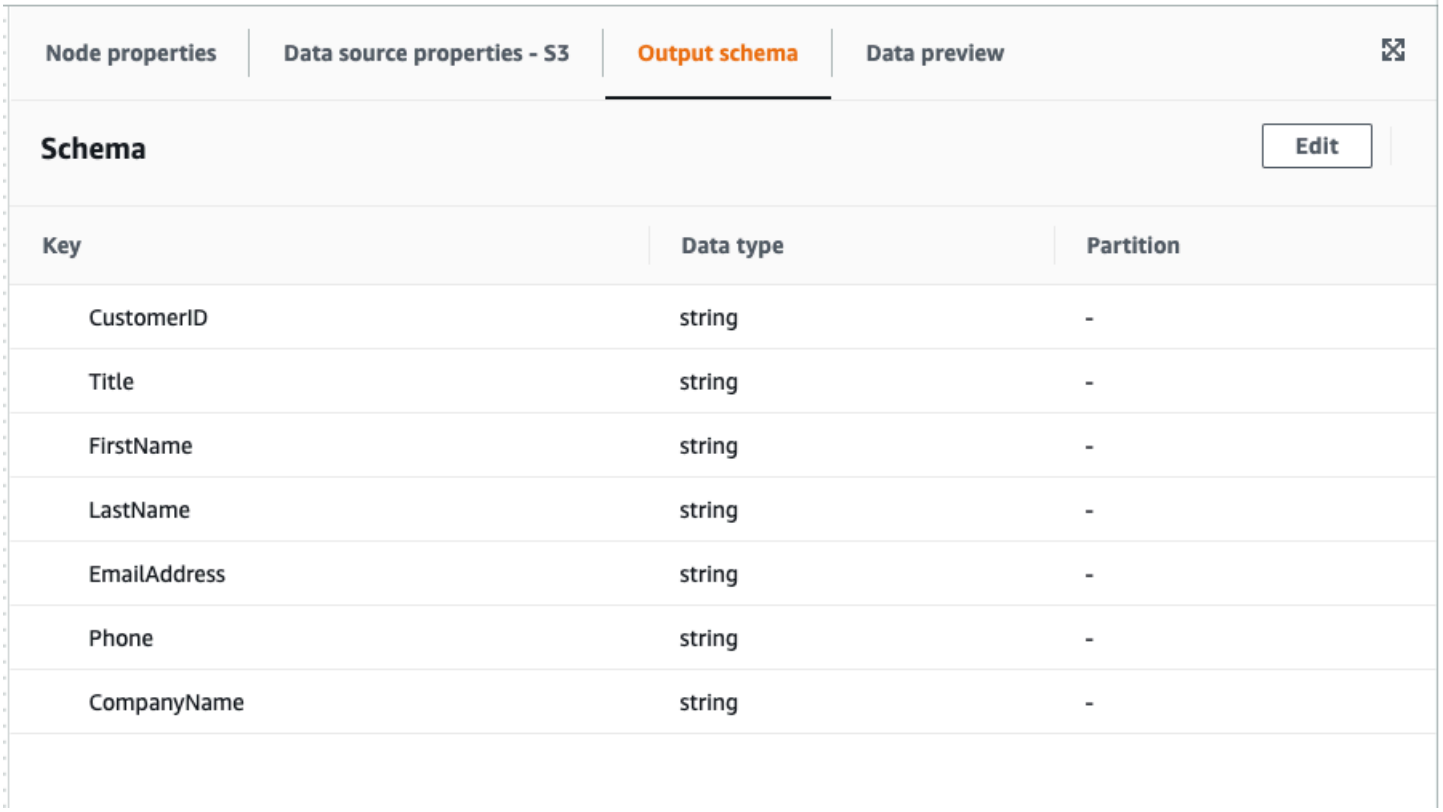

Para definir seu parâmetro Transformação visual personalizada para exibir uma única coluna:

1. No seu arquivo JSON, para o objeto `parameters`, defina o valor de `listOptions` como "coluna". Isso permite que o usuário escolha uma coluna em uma lista de seleção no AWS Glue Studio.

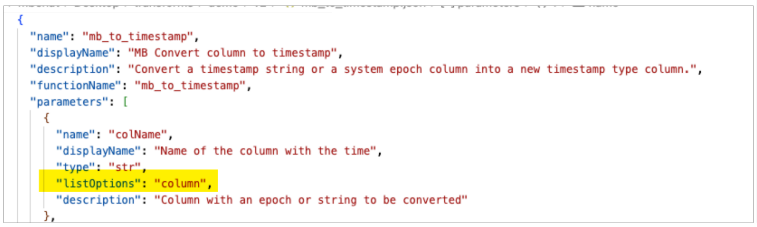

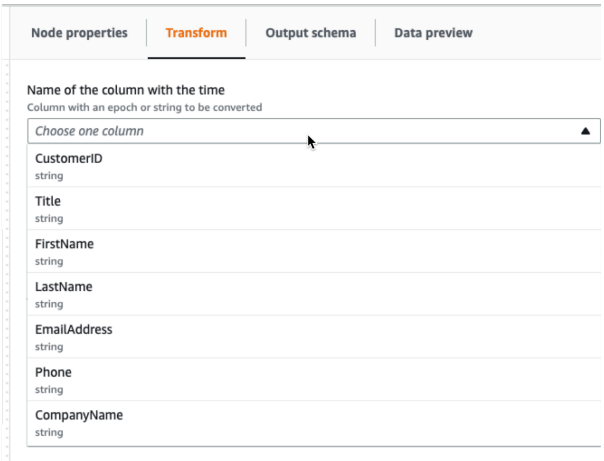

2. Você também pode permitir a seleção de várias colunas definindo o parâmetro como:

   - `listOptions: "column"`
   - `type: "list"`

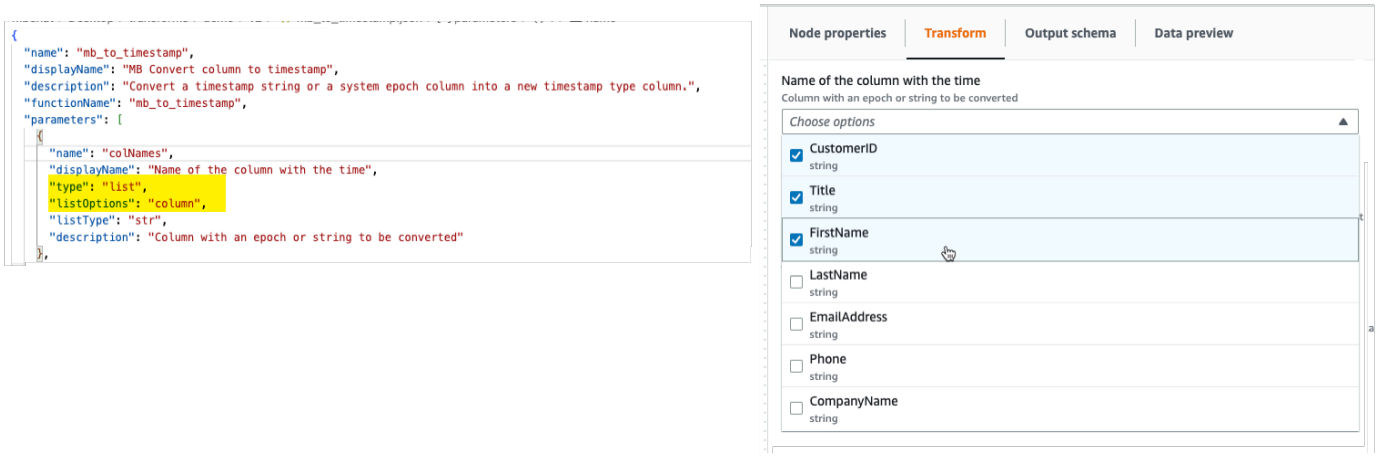

Etapa 2. Implemente a lógica da transformação

> **Note**
>
> As transformações visuais personalizadas são compatíveis apenas scripts Python. O Scala não é compatível.

Para adicionar o código que implementa a função definida pelo arquivo de configuração .json, é recomendável colocar o arquivo Python no mesmo local do arquivo .json, com o mesmo nome, mas com a extensão ".py". O AWS Glue Studioemparelha automaticamente os arquivos .json e .py para que você não precise especificar o caminho do arquivo Python no arquivo de configuração.

No arquivo Python, adicione a função declarada, com os parâmetros nomeados configurados e registre-a para ser usada no `DynamicFrame`. Este é um exemplo de um arquivo 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
```

É recomendável usar um caderno AWS Glue para obter a maneira mais rápida de desenvolver e testar o código python. Consulte Conceitos básicos de cadernos no AWS Glue Studio.

Para ilustrar como implementar a lógica de transformação, a transformação visual personalizada no exemplo abaixo é uma transformação para filtrar os dados recebidos para manter somente os dados relacionados a um estado específico dos EUA. O arquivo .json contém o parâmetro para `functionName` como `custom_filter_state` e dois argumentos (“state” e “colName” com o tipo “str”).

O exemplo de arquivo config .json é:

```
{
"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"
   }
  ]
}
```

Para implementar o script complementar no Python

1. Inicie um caderno do AWS Glue e execute a célula inicial fornecida para o início da sessão. A execução da célula inicial cria os componentes básicos necessários.
2. Crie uma função que execute a filtragem conforme descrito no exemplo e registre-a no `DynamicFrame`. Copie o código abaixo e cole em uma célula do caderno do AWS Glue.

```
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. Crie ou carregue dados de amostra para testar o código na mesma célula ou em uma nova célula. Se você adicionar os dados de exemplo em uma nova célula, não se esqueça de executar a célula. Por exemplo:

```
# 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. Teste para validar o "custom_filter_state" com argumentos diferentes:

```
[14]: dynf1.custom_filter_state("state", "NY").show()
      {"count": 2, "state": "NY"}
```

5. Depois de executar vários testes, salve o código com a extensão .py e nomeie o arquivo .py com um nome que espelhe o nome do arquivo .json. Os arquivos.py e .json devem estar na mesma pasta de transformação.

   Copie o código a seguir e cole-o em um arquivo e renomeie-o com uma extensão de arquivo .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. No AWS Glue Studio, abra uma tarefa visual e adicione a transformação à tarefa selecionando-a na lista de Transformações disponíveis.

   Para reutilizar essa transformação em um código de script Python, adicione o caminho do Amazon S3 ao arquivo .py nno trabalho, em “Referenced files path” (Caminho de arquivos referenciados) e, no script, importe o nome do arquivo python (sem a extensão) adicionando-o à parte superior do arquivo. Por exemplo: `import` <nome do arquivo (sem a extensão)>

Etapa 3. Validar e solucionar problemas de transformações visuais personalizadas no AWS Glue Studio

O AWS Glue Studio valida o arquivo de configuração JSON antes que as transformações visuais personalizadas sejam carregadas no AWS Glue Studio. A validação inclui:

- Presença de campos obrigatórios
- Validação do formato JSON
- Parâmetros incorretos ou inválidos
- Presença dos arquivos .py e .json no mesmo caminho do Amazon S3
- Nomes de arquivo correspondentes para o.py e .json

Se a validação for bem-sucedida, a transformação será listada na lista de ações disponíveis no editor visual. Se um ícone personalizado tiver sido fornecido, ele deve estar visível ao lado da Ação.

Se a validação falhar, o AWS Glue Studio não carrega a transformação visual personalizada.

Etapa 4. Atualize transformações visuais personalizadas conforme necessário

Depois de criado e usado, o script de transformação pode ser atualizado desde que a transformação siga a definição json correspondente:

- O nome usado ao atribuir ao DynamicFrame deve corresponder ao `functionName` json.
- Os argumentos da função devem ser definidos no arquivo json conforme descrito em Etapa 1. Crie um arquivo de configuração JSON .
- O caminho do arquivo Python no Amazon S3 não pode mudar, pois os trabalhos dependem diretamente dele.

> **Note**
>
> Se alguma atualização precisar ser feita, certifique-se de que o script e o arquivo .json sejam atualizados de forma consistente e que todas as tarefas visuais sejam salvas corretamente novamente com a nova transformação. Se os trabalhos visuais não forem salvos depois que as atualizações forem feitas, as atualizações não serão aplicadas e validadas. Se o arquivo de script Python for renomeado ou não for colocado ao lado do arquivo .json, será necessário especificar o caminho completo no arquivo .json.

Ícone personalizado

Se você determinar que o ícone padrão de sua Ação não a distingue visualmente como parte de seus fluxos de trabalho, você poderá fornecer um ícone personalizado, conforme descrito em the section called “ Conceitos básicos de transformações visuais personalizadas ”. Você pode atualizar o ícone atualizando o SVG correspondente hospedado no Amazon S3.

Para obter melhores resultados, crie sua imagem para ser visualizada em 32x32px seguindo as diretrizes do Cloudscape Design System. Para obter mais informações sobre o uso do CloudWatch, consulte a documentação do Cloudscape

Etapa 5. Use a transformações visuais personalizadas no AWS Glue Studio

Para usar uma transformação visual personalizada no AWS Glue Studio, você carrega os arquivos de configuração e de origem e seleciona a transformação no menu Action (Ação). Todos os parâmetros que precisem de valores ou entradas estão disponíveis para você na guia Transform (Transformar).

1. Faça o upload dos dois arquivos (arquivo fonte do Python e arquivo de configuração JSON) para a pasta de ativos do Amazon S3, onde os scripts de trabalho são armazenados. Por padrão, o AWS Glue lerá todos os arquivos .json da pasta /transforms no mesmo bucket do Amazon S3.
2. No menu Action (Ação), escolha a transformação visual personalizada. Ela é nomeada com a transformação `displayName` ou o nome que você especificou no arquivo de configuração .json.
3. Insira valores para os parâmetros que foram configurados no arquivo de configuração.

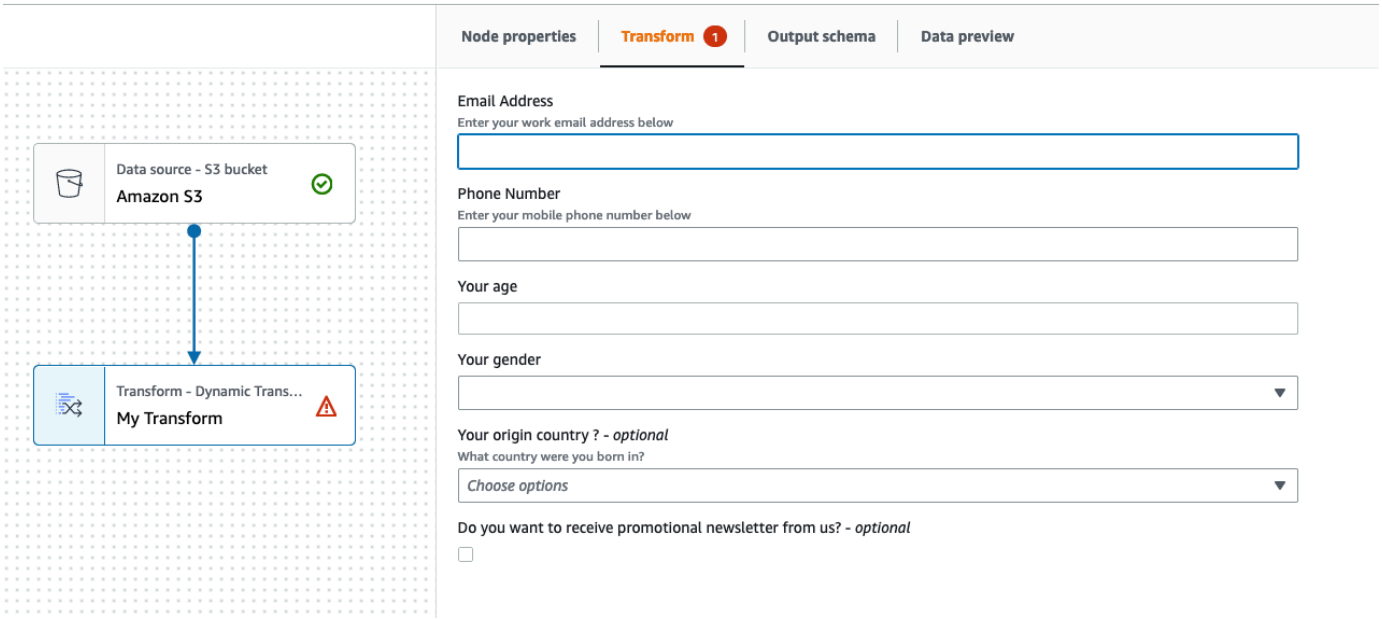

Exemplos de uso

A seguir está um exemplo de todos os parâmetros possíveis em um arquivo de configuração .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,Barbad
 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,G
Bissau,Guyana,Haiti,Heard and McDonald Islands,Honduras,Hong
 Kong,Hungary,Iceland,India,Indonesia,Iran,Iraq,Ireland,Israel,Italy,Jamaica,Japan,Jordan,Kazak
 (North),Korea
 (South),Kuwait,Kyrgyzstan,Laos,Latvia,Lebanon,Lesotho,Liberia,Libya,Liechtenstein,Lithuania,Lu
 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
    }
  ]
}
```

Exemplos de scripts visuais personalizados

Os exemplos a seguir realizam transformações equivalentes. No entanto, o segundo exemplo (SparkSQL) é o mais limpo e eficiente, seguido pela UDF do pandas e, finalmente, pelo mapeamento de baixo nível no primeiro exemplo. O exemplo a seguir é um exemplo completo de uma transformação simples para somar duas colunas:

```
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
```

O exemplo a seguir é uma transformação equivalente usando a API do 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
```

O exemplo a seguir usa as mesmas transformações, mas usando uma UDF do pandas, que é mais eficiente do que usar uma UDF simples. Para obter mais informações sobre como escrever UDFs panda, consulte a documentação do Apache Spark SQL.

```
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
```

Vídeo

O vídeo a seguir fornece uma introdução às transformações visuais personalizadas e demonstra como usá-las.

Usar estruturas do Data Lake com o AWS Glue Studio

Visão geral

As estruturas de data lake de código aberto simplificam o processamento incremental de dados para os arquivos armazenados em data lakes criados no Amazon S3. O AWS Glue 3.0 e posteriores são compatíveis com as seguintes estruturas de armazenamento em data lake de código aberto:

- Apache Hudi
- Linux Foundation Delta Lake
- Apache Iceberg

A partir do AWS Glue 4.0, o AWS Glue fornece suporte nativo para essas estruturas para que você possa ler e gravar os dados que armazenar no Amazon S3 de maneira consistente em termos de transações. Não é necessário instalar um conector separado nem realizar etapas adicionais de configuração para usar essas estruturas em trabalhos do AWS Glue.

As estruturas do Data Lake podem ser usadas como fonte ou destino no AWS Glue Studio por meio de trabalhos do editor de scripts do Spark. Para obter mais informações sobre o uso do Apache Hudi, do Apache Iceberg e do Delta Lake, consulte: Usar estruturas de data lake com trabalhos do AWS Glue ETL.

Criação de formatos de tabela abertos a partir de uma fonte de streaming do AWS Glue

As tarefas de ETL de streaming do AWS Glue consomem continuamente dados de fontes de streaming, limpam e transformam os dados em andamento e os disponibilizam para análise em questão de segundos.

A AWS oferece uma ampla seleção de serviços para atender às suas necessidades. Um serviço de replicação de banco de dados, como o AWS Database Migration Service, pode replicar os dados de seus sistemas de origem para o Amazon S3, que normalmente hospeda a camada de armazenamento do data lake. Embora seja fácil aplicar atualizações em um sistema de gerenciamento de banco de dados relacional (RDBMS) que oferece suporte a uma aplicação de origem online, é difícil aplicar esse processo de CDC em seus data lakes. As estruturas de gerenciamento de dados de código aberto simplificam o processamento incremental de dados e o desenvolvimento de pipelines de dados e são uma boa opção para resolver esse problema.

Para obter mais informações, consulte:

- Criar um data lake transacional quase em tempo real baseado em Apache HUDI usando streaming do AWS Glue
- Crie um data lake Apache Iceberg em tempo real alinhado ao GDPR

Usar a estrutura do Hudi no AWS Glue Studio

Ao criar ou editar um trabalho, o AWS Glue Studio adiciona automaticamente as bibliotecas do Hudi correspondentes, dependendo da versão do AWS Glue que você esteja usando. Para obter mais informações, consulte Usar a estrutura Hudi no AWS Glue.

Usar a estrutura do Apache Hudi em fontes de dados do Data Catalog

Para adicionar um formato de fonte de dados Hudi a um trabalho:

1. No menu Fonte, escolha AWS Glue Studio Data Catalog.

2. Na guia Propriedades da fonte de dados, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o tipo de formato como Apache Hudi e o URL do Amazon S3.

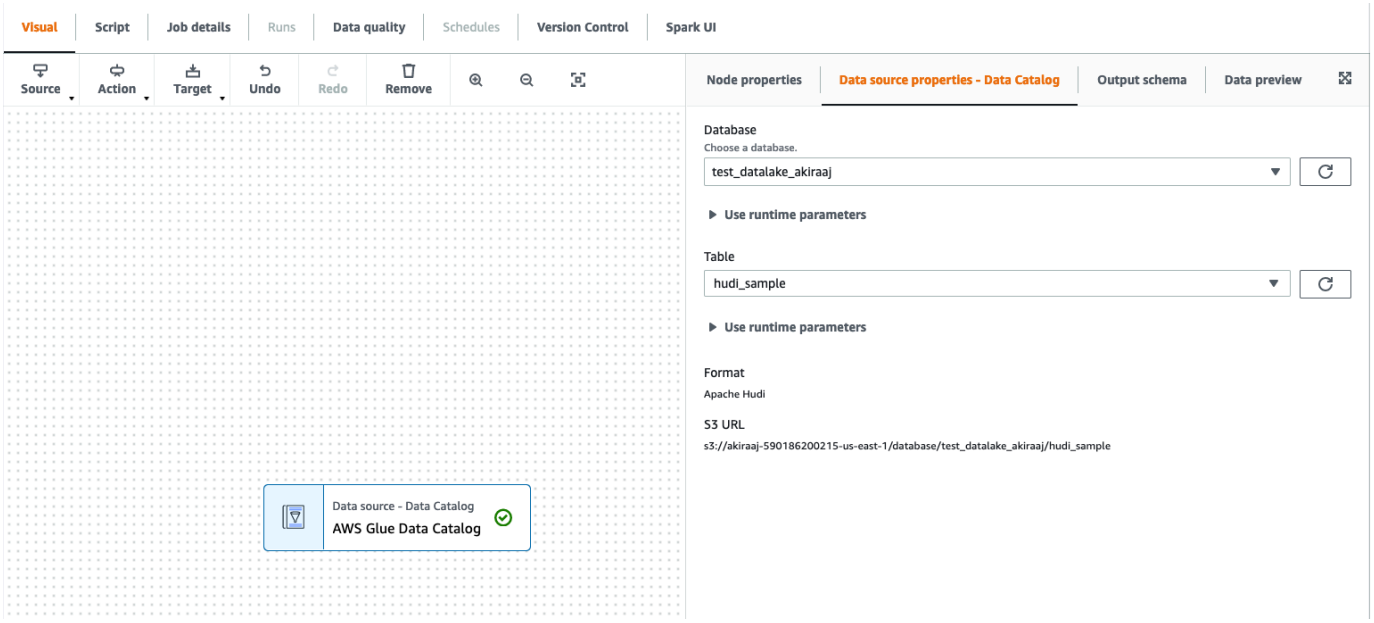

Usar a estrutura do Hudi em fontes de dados do Amazon S3

1. No menu Fonte, selecione Amazon S3.
2. Se você escolher a tabela do Data Catalog como o tipo de fonte do Amazon S3, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o formato como Apache Hudi e o URL do Amazon S3.
4. Se você escolher o local do Amazon S3 como o tipo de fonte do Amazon S3, escolha a URL do S3 clicando em Procurar o Amazon S3.
5. Em Formato de dados, selecione Apache Hudi.

> **Note**
>
> Se o AWS Glue Studio não conseguir inferir o esquema da pasta ou arquivo do Amazon S3 selecionado, escolha Opções adicionais para selecionar uma nova pasta ou arquivo. Em Opções adicionais, escolha entre as seguintes opções em Inferência de esquema:
>
> - Deixe o AWS Glue Studio escolher automaticamente um arquivo de amostra. O AWS Glue Studio escolherá um arquivo de amostra no local do Amazon S3 para que o esquema possa ser inferido. No campo Arquivo amostrado automaticamente, você pode visualizar o arquivo que foi selecionado automaticamente.

- Escolha um arquivo de amostra do Amazon S3. Escolha o arquivo do Amazon S3 a ser usado clicando em Procurar no Amazon S3.

6. Clique em Inferir esquema. Depois, você poderá visualizar o esquema de saída clicando na guia Esquema de saída.
7. Escolha Opções adicionais para inserir um par de chave-valor.

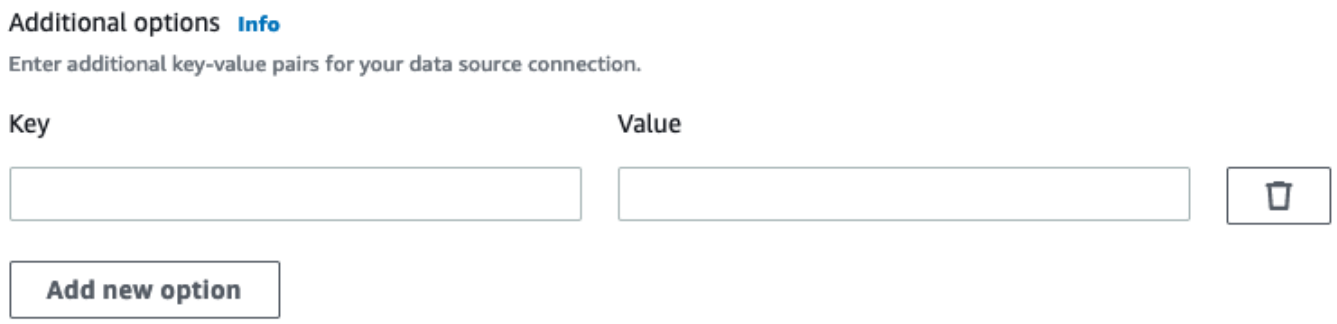

Usar a estrutura do Apache Hudi em destinos de dados

Usar a estrutura do Apache Hudi em destinos de dados do Data Catalog

1. No menu Destino, escolha AWS Glue Studio Data Catalog.
2. Na guia Propriedades da fonte de dados, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o tipo de formato como Apache Hudi e o URL do Amazon S3.

Usar a estrutura do Apache Hudi em destinos de dados do Amazon S3

Insira os valores ou selecione-os entre as opções disponíveis para configurar o formato do Apache Hudi. Para obter mais informações sobre o Apache Hudi, consulte a documentação do Apache Hudi.

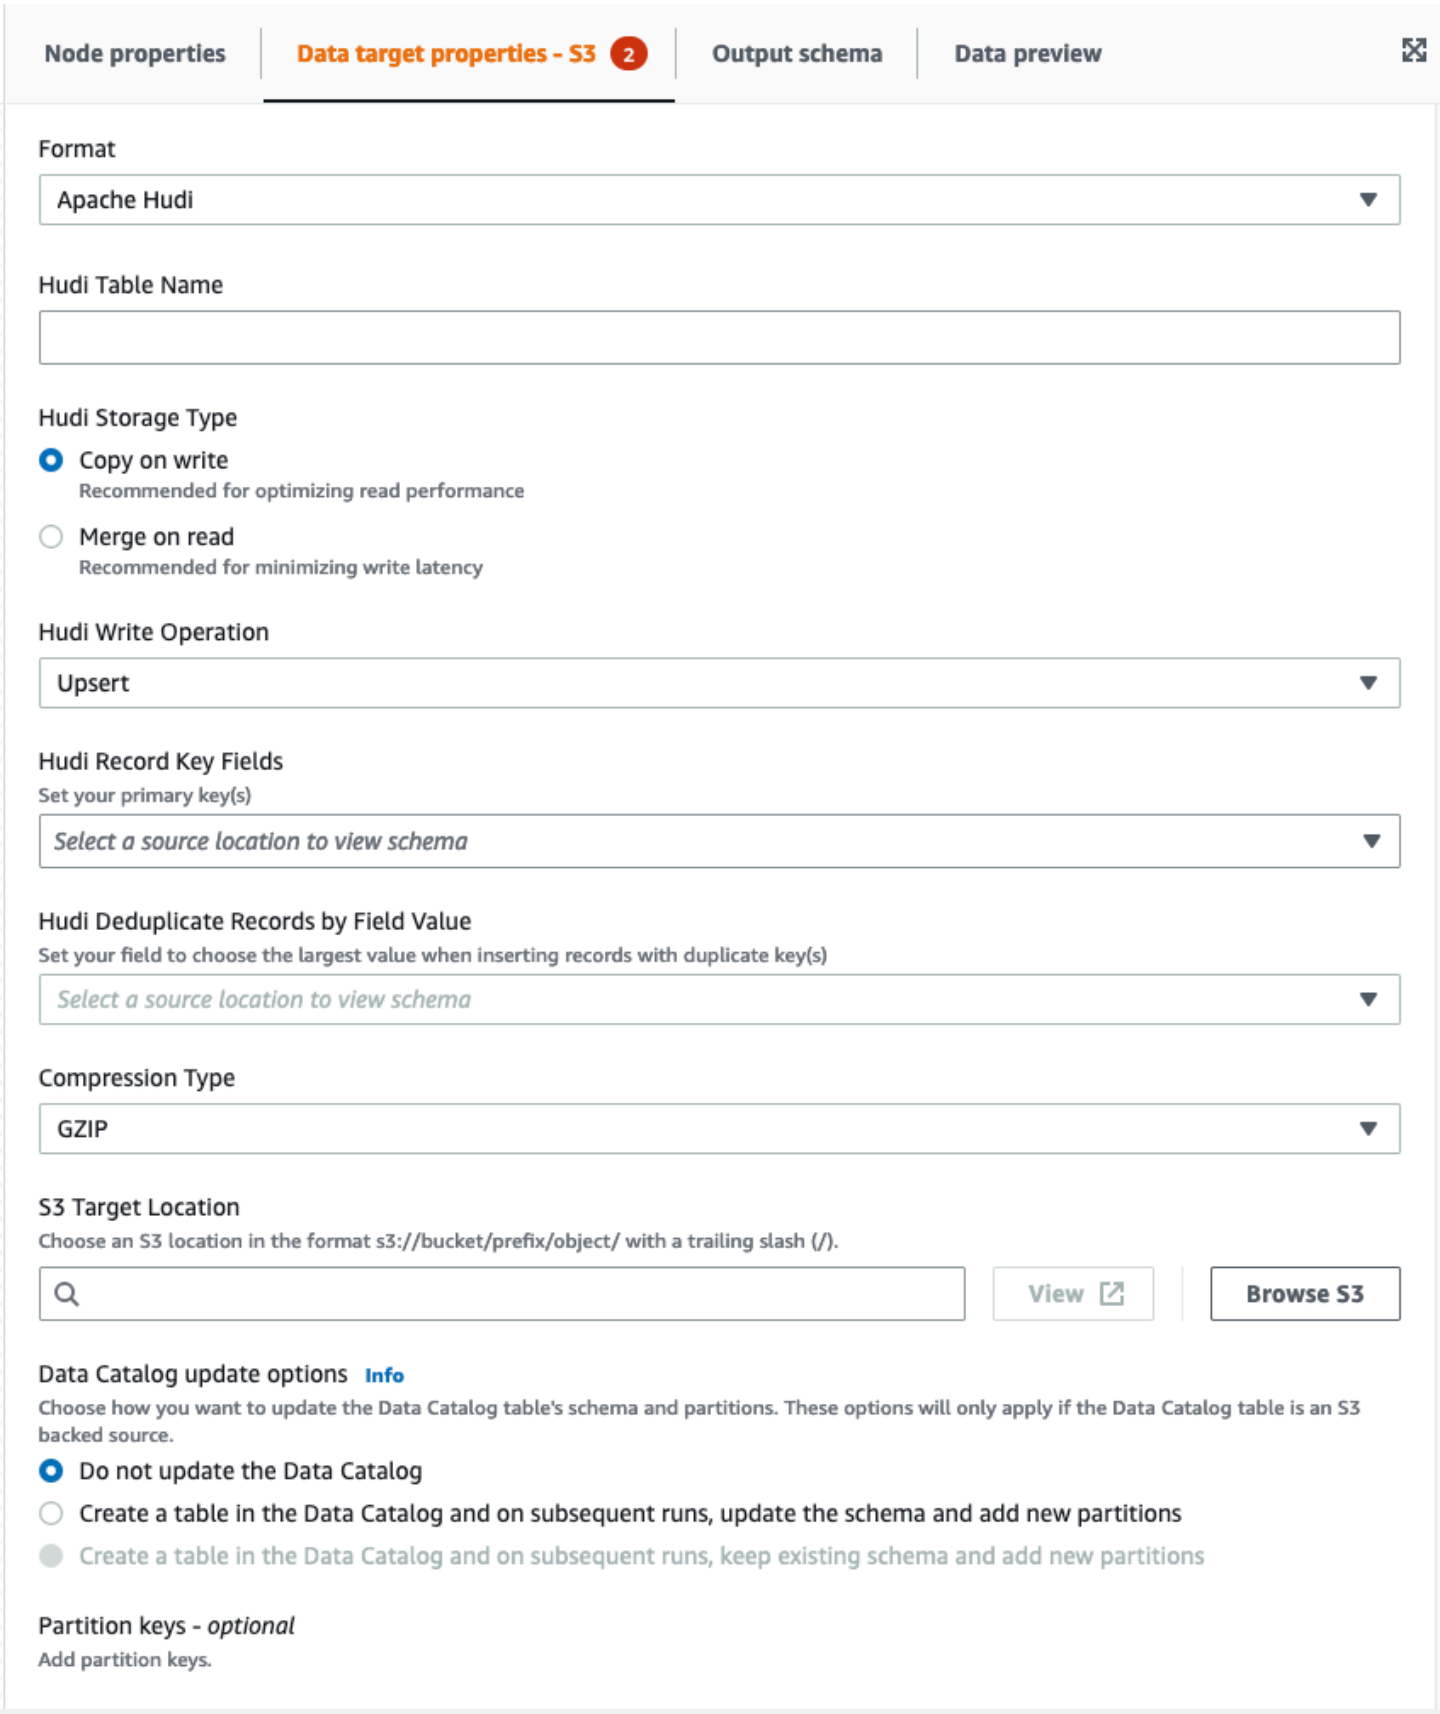
Node properties
Data target properties - S3 2
Output schema
Data preview
Format
Apache Hudi
Hudi Table Name
Hudi Storage Type
Copy on write
Recommended for optimizing read performance
Merge on read
Recommended for minimizing write latency
Hudi Write Operation
Upsert
Hudi Record Key Fields
Set your primary 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.

- Nome da tabela do Hudi: esse é o nome da tabela do Hudi.
- Tipo de armazenamento do Hudi: escolha entre duas opções:
  - Copiar e gravar: recomendado para otimizar o desempenho de leitura. Esse é o tipo de armazenamento padrão do Hudi. Cada atualização cria uma nova versão dos arquivos durante uma gravação.
  - Mesclar na leitura: recomendado para minimizar a latência de gravação. As atualizações são registradas em arquivos delta baseados em linha e são compactadas conforme necessário para criar novas versões dos arquivos colunares.
- Operação de gravação do Hudi: escolha uma das seguintes opções:
  - Upsert: essa é a operação padrão, na qual os registros de entrada são marcados primeiro como inserções ou atualizações consultando o índice. Recomendado quando você está atualizando dados existentes.
  - Inserir: essa opção insere registros, mas não verifica os registros existentes e pode resultar em duplicatas.
  - Inserção em massa: essa opção insere registros e é recomendado para grandes volumes de dados.
- Campos de chave de registro do Hudi: use a barra de pesquisa para pesquisar e escolher chaves de registro primárias. Os registros no Hudi são identificados por uma chave primária, que é um par de chave de registro e o caminho da partição ao qual o registro pertence.
- Campo de combinação prévia do Hudi: esse é o campo usado para a combinação prévia antes da gravação real. Quando dois registros tiverem o mesmo valor de chave, o AWS Glue Studio selecionará o de maior valor para o campo de combinação prévia. Defina um campo com o valor incremental (por exemplo, updated_at) pertence a.
- Tipo de compactação: escolha uma das opções de tipo de compactação: não compactado, GZIP, LZO ou Snappy.
- Local de destino do Amazon S3: escolha o local de destino do Amazon S3 clicando em Procurar no S3.
- Opções de atualização do Data Catalog: escolha uma das seguintes opções:
  - Do not update the Data Catalog (Não atualizar o Data Log): (padrão) escolha essa opção se você não quiser que o trabalho atualize o Data Catalog, mesmo que o esquema seja alterado ou novas partições sejam adicionadas.
  - Criar uma tabela no Data Catalog e em execuções subsequentes, atualizar o esquema e adicionar novas partições: se você escolher essa opção, o trabalho criará a tabela no Data Catalog quando for executado pela primeira vez. Em execuções de trabalho subsequentes,

ele atualizará a tabela do Data Catalog, se o esquema for alterado ou novas partições forem adicionadas.

Você também deve selecionar um banco de dados no Data Catalog e inserir um nome de tabela.

- Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions (Criar uma tabela no Data Catalog e em execuções subsequentes, manter o esquema atual e adicionar novas partições): se você escolher essa opção, o trabalho criará a tabela no Data Catalog na sua primeira execução. Em execuções de trabalho subsequentes, ele atualizará a tabela do Data Catalog, mas apenas para adicionar novas partições.

  Você também deve selecionar um banco de dados no Data Catalog e inserir um nome de tabela.

- Partition keys (Chaves de partição): escolha quais colunas usar como chaves de particionamento na saída. Para adicionar mais chaves de partição, escolha Add a partition key (Adicionar uma chave de partição.
- Opções adicionais: insira um par de valor-chave conforme necessário.

Gerar código por meio do AWS Glue Studio

Quando o trabalho é salvo, os seguintes parâmetros de trabalho são adicionados a ele se uma fonte ou um destino Hudi forem detectados:

- `--datalake-formats`: uma lista distinta de formatos de data lake detectados no trabalho visual (diretamente escolhendo um “formato” ou indiretamente selecionando uma tabela de catálogo com suporte de um data lake).
- `--conf` : gerado com base no valor de `--datalake-formats`. Por exemplo, se o valor de `--datalake-formats` for "hudi", o AWS Glue gerará um valor `spark.serializer=org.apache.spark.serializer.KryoSerializer –conf spark.sql.hive.convertMetastoreParquet=false` para esse parâmetro.

Substituir as bibliotecas fornecidas pelo AWS Glue

Para usar uma versão do Hudi que não seja compatível com o AWS Glue, você pode especificar seus próprios arquivos JAR de biblioteca do Hudi. Para usar seu próprio arquivo JAR:

- use o parâmetro de trabalho `--extra-jars`. Por exemplo, `'--extra-jars': 's3pathtojarfile.jar'`. Para obter mais informações, consulte parâmetros de trabalho do AWS Glue.

- não inclua `hudi` como um valor para o parâmetro de trabalho `--datalake-formats`. Inserir uma string em branco como um valor garante que nenhuma biblioteca de data lake seja fornecida a você automaticamente pelo AWS Glue. Para obter mais informações, consulte Usar a estrutura Hudi no AWS Glue.

Usar a estrutura do Delta Lake no AWS Glue Studio Glue

Usar a estrutura do Delta Lake em fontes de dados

Usar a estrutura do Delta Lake em fontes de dados do Amazon S3

1. No menu Fonte, selecione Amazon S3.
2. Se você escolher a tabela do Data Catalog como o tipo de fonte do Amazon S3, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o formato como Data Lake e o URL do Amazon S3.
4. Escolha Opções adicionais para inserir um par de chave-valor. Por exemplo, um par de chave-valor pode ser: chave: timestampAsOf e valor: 2023-02-24 14:16:18.

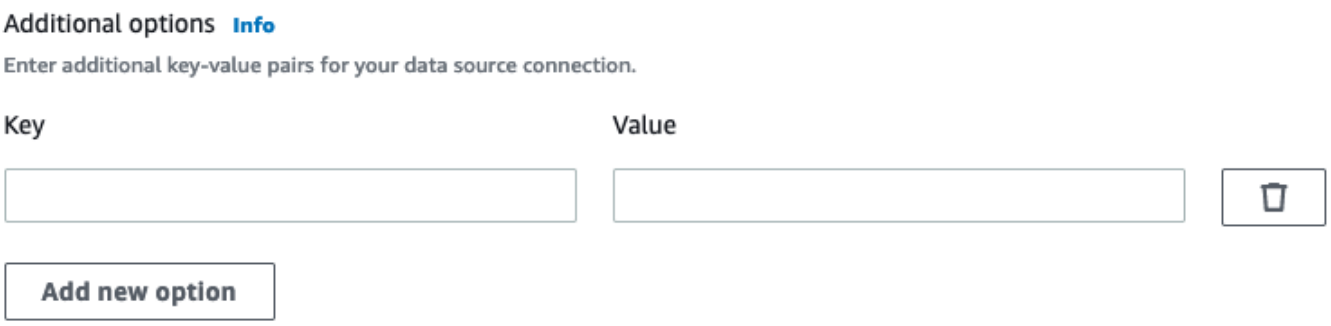

5. Se você escolher o local do Amazon S3 como o tipo de fonte do Amazon S3, escolha a URL do S3 clicando em Procurar o Amazon S3.
6. Em Formato de dados, escolha Delta Lake.

> **Note**
>
> Se o AWS Glue Studio não conseguir inferir o esquema da pasta ou arquivo do Amazon S3 selecionado, escolha Opções adicionais para selecionar uma nova pasta ou arquivo. Em Opções adicionais, escolha entre as seguintes opções em Inferência de esquema:

- Deixe o AWS Glue Studio escolher automaticamente um arquivo de amostra. O AWS Glue Studio escolherá um arquivo de amostra no local do Amazon S3 para que o esquema possa ser inferido. No campo Arquivo amostrado automaticamente, você pode visualizar o arquivo que foi selecionado automaticamente.
- Escolha um arquivo de amostra do Amazon S3. Escolha o arquivo do Amazon S3 a ser usado clicando em Procurar no Amazon S3.

7. Clique em Inferir esquema. Depois, você poderá visualizar o esquema de saída clicando na guia Esquema de saída.

Usar a estrutura do Delta Lake em fontes de dados do Data Catalog

1. No menu Fonte, escolha AWS Glue Studio Data Catalog.
2. Na guia Propriedades da fonte de dados, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o tipo de formato como Data Lake e o URL do Amazon S3.

> **Note**
>
> Se sua fonte Delta Lake ainda não estiver registrada na tabela do AWS Glue Data Catalog, você tem duas opções:
>
> 1. Crie um crawler do AWS Glue para o armazenamento de dados Delta Lake. Para obter mais informações, consulte Como especificar opções de configuração para um armazenamento de dados do Delta Lake.
> 2. Use uma fonte de dados do Amazon S3 para selecionar sua fonte de dados Delta Lake. Consulte Usar a estrutura do Delta Lake em fontes de dados do Amazon S3 .

Usar formatos do Delta Lake em destinos de dados

Usar formatos do Delta Lake em destinos de dados do Data Catalog

1. No menu Destino, escolha AWS Glue Studio Data Catalog.
2. Na guia Propriedades da fonte de dados, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o tipo de formato como Data Lake e o URL do Amazon S3.

Usar formatos do Delta Lake em fontes de dados do Amazon S3

Insira os valores ou selecione-os entre as opções disponíveis para configurar o formato do Delta Lake.

- Tipo de compactação: escolha uma das opções de tipo de compactação: não compactado ou Snappy.
- Local de destino do Amazon S3: escolha o local de destino do Amazon S3 clicando em Procurar no S3.
- Opções de atualização do Data Catalog: atualizar o Data Catalog não é compatível com esse formato no editor visual do Glue Studio.
  - Do not update the Data Catalog (Não atualizar o Data Log): (padrão) escolha essa opção se você não quiser que o trabalho atualize o Data Catalog, mesmo que o esquema seja alterado ou novas partições sejam adicionadas.
  - Para atualizar o catálogo de dados após a execução do trabalho do AWS Glue, execute ou agende um crawler do AWS Glue. Para obter mais informações, consulte Como especificar opções de configuração para um armazenamento de dados do Delta Lake.
- Chaves de partição: escolha quais colunas serão usadas como chaves de particionamento na saída. Para adicionar mais chaves de partição, escolha Adicionar uma chave de partição.
- Opcionalmente, escolha Opções adicionais para inserir um par chave-valor. Por exemplo, um par de chave-valor pode ser: chave: timestampAsOf e valor: 2023-02-24 14:16:18.

Usar a estrutura do Apache Iceberg no AWS Glue Studio

Usar a estrutura do Apache Iceberg em destinos de dados

Usar a estrutura do Apache Iceberg em destinos de dados do Data Catalog

1. No menu Destino, escolha AWS Glue Studio Data Catalog.
2. Na guia Propriedades da fonte de dados, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o tipo de formato como Apache Iceberg e o URL do Amazon S3.

Usar a estrutura do Apache Hudi em destinos de dados do Amazon S3

Insira os valores ou selecione-os entre as opções disponíveis para configurar o formato do Apache Iceberg.

- Formatar: escolha Apache Iceberg no menu suspenso.
- Local de destino do Amazon S3: escolha o local de destino do Amazon S3 clicando em Procurar no S3.
- Opções de atualização do catálogo de dados:Criar uma tabela no catálogo de dados e em execuções subsequentes, manter o esquema existente e adicionar novas partições deve ser selecionado para continuar. Escrever uma nova tabela do Iceberg usando o AWS Glue requer que o Data Catalog seja configurado como o catálogo para a tabela do Iceberg. Para atualizar uma tabela do Iceberg existente que tenha sido registrada no Data Catalog, escolha Data Catalog como alvo.
  - Banco de dados: escolha o banco de dados do Data Catalog.
  - Nome da tabela: insira o valor para o nome da tabela. Os nomes das tabelas do Apache Iceberg devem estar em letras minúsculas. Use sublinhas se necessário, pois espaços não são permitidos. Por exemplo, "data_lake_format_tables".

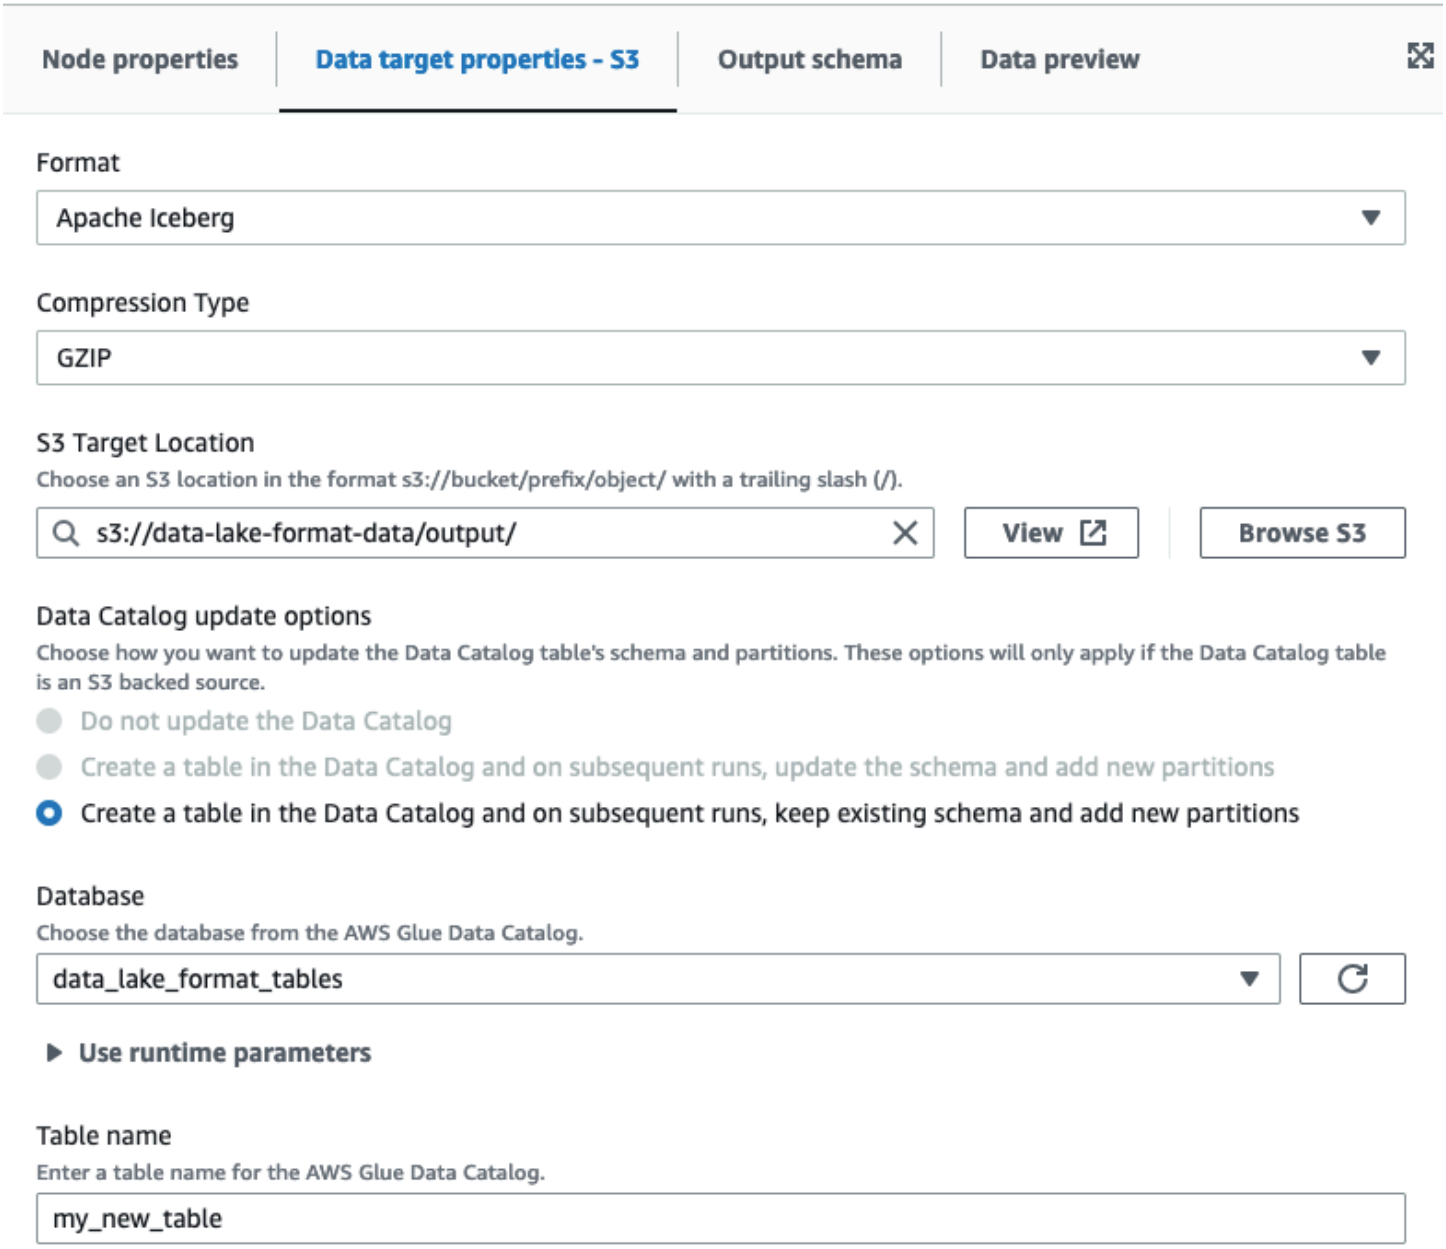

Usar a estrutura do Apache Iceberg em fontes de dados do Amazon S3

Usar a estrutura do Apache Iceberg em fontes de dados do Data Catalog

1. No menu Fonte, escolha AWS Glue Studio Data Catalog.
2. Na guia Propriedades da fonte de dados, escolha um banco de dados e uma tabela.
3. O AWS Glue Studio exibe o tipo de formato como Apache Iceberg e o URL do Amazon S3.

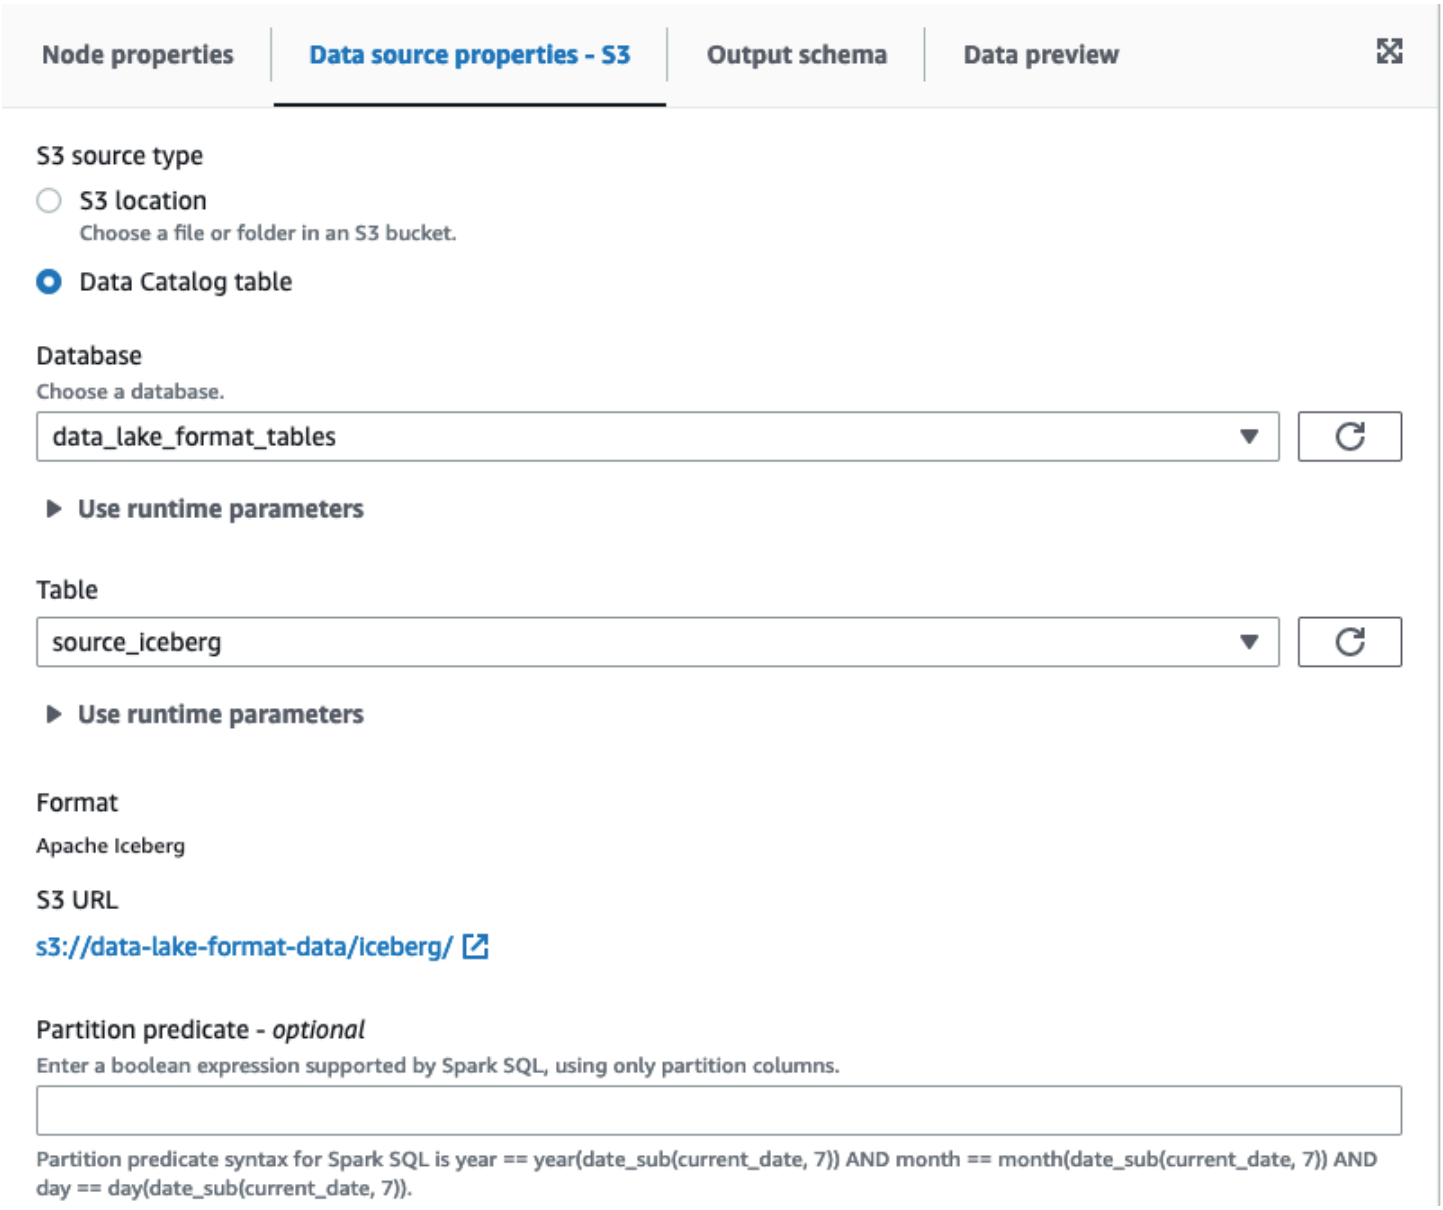

Usar a estrutura do Apache Iceberg em fontes de dados do Amazon S3

O Apache Iceberg não está disponível como opção de dados para os nós de origem do Amazon S3 no AWS Glue Studio.

Conectar a fontes de dados usando trabalhos do Visual ETL

Ao criar um novo trabalho, você pode usar conexões para conectar aos dados ao editar trabalhos visuais de ETL no AWS Glue. Você pode fazer isso adicionando nós de origem que usam conectores para ler dados e nós de destino para especificar o local para gravação dos dados.

Tópicos

- Modificar as propriedades de um nó da fonte dos dados
- Usar as tabelas do Data Catalog para a origem dos dados
- Usar um conector para a origem dos dados
- Usar arquivos no Amazon S3 para a origem dos dados
- Usar uma fonte de dados de transmissão
- Referências

Modificar as propriedades de um nó da fonte dos dados

Para especificar as propriedades da origem dos dados, escolha primeiro um nó de origem dos dados no diagrama de trabalho. Em seguida, no lado direito do painel de detalhes do nó, configure as propriedades do nó.

Para modificar as propriedades de um nó de origem dos dados

1. Vá para o editor visual para um trabalho novo ou salvo.
2. Escolha um nó de origem dos dados no diagrama de trabalho.
3. Selecione a guia Node properties (Propriedades do nó) no painel de detalhes do nó e insira as seguintes informações:
   - Name (Nome): (opcional) insira um nome a ser associado ao nó no diagrama de trabalho. Esse nome deve ser exclusivo entre todos os nós para esse trabalho.
   - Node type (Tipo de nó): o tipo de nó determina a ação que é executada pelo nó. Na lista de opções de Node type (Tipo de nó), escolha um dos valores listados no cabeçalho Data source (Origem dos dados).
4. Configure as informações de Data source properties (Propriedades da origem dos dados). Para obter mais informações, consulte as seções a seguir:
   - Usar as tabelas do Data Catalog para a origem dos dados
   - Usar um conector para a origem dos dados
   - Usar arquivos no Amazon S3 para a origem dos dados
   - Usar uma fonte de dados de transmissão
5. (Opcional) depois de configurar as propriedades do nó e da origem dos dados, você pode exibir o esquema de sua origem dos dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em

seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.

6. (Opcional) depois de configurar as propriedades do nó e da origem dos dados, você poderá previsualizar o conjunto de dados de sua origem dos dados escolhendo a guia Data preview (Previsualização de dados) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar os dados. Há um custo associado ao uso desse recurso e o a cobrança começa assim que você fornece uma função do IAM.

Usar as tabelas do Data Catalog para a origem dos dados

Para todas as origens dos dados, exceto o Amazon S3 e os conectores, uma tabela deve existir noAWS Glue Data Catalog para o tipo de origem que você escolher. O AWS Glue não cria a tabela do Data Catalog.

Para configurar um nó de origem dos dados com base em uma tabela do Data Catalog

1. Vá para o editor visual para um trabalho novo ou salvo.
2. Escolha um nó de origem dos dados no diagrama de trabalho.
3. Escolha a guia Data source properties (Propriedades da origem dos dados) e insira as seguintes informações:

   - S3 source type (Tipo de origem do S3): (somente para origens de dados do Amazon S3) escolha a opção Select a Catalog table (Selecionar uma tabela do catálogo) para usar uma tabela do AWS Glue Data Catalog existente.
   - Database (Banco de dados): escolha o banco de dados no Data Catalog que contém a tabela de origem que você deseja usar para esse trabalho. É possível usar o campo de pesquisa para procurar um banco de dados pelo nome.
   - Table (Tabela): escolha a tabela associada aos dados de origem na lista. Essa tabela já deve existir no AWS Glue Data Catalog. É possível usar o campo de pesquisa para procurar uma tabela pelo nome.
   - Partition predicate (Predicado de partição): (somente para origens de dados do Amazon S3) insira uma expressão booleana baseada no Spark SQL que inclua apenas as colunas de particionamento. Por exemplo: `"(year=='2020' and month=='04')"`

- Temporary directory (Diretório temporário): (somente para origens de dados do Amazon RedShift) insira um caminho para o local de um diretório funcional no Amazon S3, onde seu trabalho de ETL possa gravar resultados intermediários temporários.
- Role associated with the cluster (Função associada ao cluster): (somente para origens de dados do Amazon RedShift) insira uma função para o seu trabalho de ETL usar que contenha permissões para clusters do Amazon Redshift. Para ter mais informações, consulte the section called “Permissões de origem e destino dos dados”.

Usar um conector para a origem dos dados

Se você selecionar um conector para Node type (Tipo de nó), siga as instruções em Criação de trabalhos com conectores personalizados para concluir a configuração das propriedades da origem dos dados.

Usar arquivos no Amazon S3 para a origem dos dados

Se você escolher o Amazon S3 como sua origem dos dados, poderá escolher:

- Um banco de dados e tabela do Data Catalog.
- Um bucket, pasta ou arquivo no Amazon S3.

Se você usar um bucket do Amazon S3 como origem dos dados, o AWS Glue detectará o esquema dos dados no local especificado a partir de um dos arquivos ou usando o arquivo especificado como um arquivo de exemplo. A detecção de esquema ocorre quando você usa o botão Infer schema (Inferir esquema). Se você alterar o local do Amazon S3 ou o arquivo de exemplo, escolha Infer schema (Inferir esquema) novamente para realizar a detecção de esquema usando as novas informações.

Para configurar um nó de origem dos dados que lê diretamente de arquivos no Amazon S3

1. Vá para o editor visual para um trabalho novo ou salvo.
2. Escolha um nó de origem dos dados no diagrama de trabalho para uma origem do Amazon S3.
3. Escolha a guia Data source properties (Propriedades da origem dos dados) e insira as seguintes informações:

   - S3 source type (Tipo de origem do S3): (somente para origens de dados do Amazon S3) escolha a opção S3 location (Localização do S3).

- S3 URL (URL do S3): insira o caminho para o bucket, pasta ou arquivo do Amazon S3 que contém os dados do seu trabalho. Você pode escolher Browse S3 (Procurar no S3) para selecionar o caminho a partir dos locais disponíveis para sua conta.
- Recursive (Recursivo): escolha essa opção se desejar que o AWS Glue leia dados de arquivos em pastas filhas no local do S3.

  Se as pastas filhas contiverem dados particionados, o AWS Glue não adicionará ao Data Catalog nenhuma informação de partição especificada nos nomes de pastas. Por exemplo, considere as seguintes pastas no Amazon S3:

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

  Se você escolher Recursive (Recursivo) e selecionar a pasta `sales` como a sua localização do S3, o AWS Glue lerá os dados em todas as pastas filhas, mas não criará partições para o ano, mês ou dia.
- Data format (Formato de dados): escolha o formato no qual os dados são armazenados. Você pode escolher JSON, CSV ou Parquet. O valor selecionado informa ao trabalho do AWS Glue como ler os dados do arquivo de origem.

  > **Note**
  >
  > Se você não selecionar o formato correto para os seus dados, O AWS Glue poderá inferir o esquema corretamente, mas o trabalho não poderá analisar corretamente os dados do arquivo de origem.

  Você pode inserir opções de configuração adicionais, dependendo do formato escolhido.

  - JSON (JavaScript Object Notation)
    - JsonPath (Caminho Json): insira um caminho JSON que aponta para um objeto usado para definir um esquema de tabela. Expressões de caminho JSON sempre se referem a uma estrutura JSON da mesma forma como expressões XPath são usadas em combinação com um documento XML. O “objeto de membro raiz” no caminho JSON é sempre referido como $, mesmo que seja um objeto ou matriz. O caminho JSON pode ser escrito na notação de pontos ou de colchetes.

Para obter mais informações sobre operadores do caminho JSON, consulte JsonPath no site do GitHub.

- Records in source files can span multiple lines (Registros em arquivos de origem podem abranger várias linhas): escolha essa opção se um único registro puder abranger várias linhas no arquivo CSV.

- CSV (comma-separated values)
  - Delimiter (Delimitador): insira um caractere para indicar o que separa cada entrada de coluna na linha, por exemplo, `;` ou `,`.
  - Escape character (Caractere de escape): insira um caractere usado como caractere de escape. Ele indica que o caractere que segue imediatamente o caractere de escape deve ser entendido literalmente e não deve ser interpretado como um delimitador.
  - Quote character (Caractere de aspas): insira o caractere usado para agrupar strings separadas em um único valor. Por exemplo, você escolheria aspas duplas (") se tiver valores como `"This is a single value"` em seu arquivo CSV.
  - Records in source files can span multiple lines (Registros em arquivos de origem podem abranger várias linhas): escolha essa opção se um único registro puder abranger várias linhas no arquivo CSV.
  - First line of source file contains column headers (A primeira linha do arquivo de origem contém cabeçalhos de coluna): escolha essa opção se a primeira linha do arquivo CSV contiver cabeçalhos de coluna em vez de dados.
- Parquet (Apache Parquet columnar storage)

  Não há configurações adicionais a configurar para dados armazenados no formato Parquet.
- Apache Hudi

  Não há configurações adicionais a definir para dados armazenados no formato Apache Hudi.
- Delta Lake

  Não há configurações adicionais a definir para dados armazenados no formato Delta Lake.
- Excel

  Não há configurações adicionais a definir para dados armazenados no formato Excel.

- Partition predicate (Predicato de partição): para particionar os dados que são lidos a partir da origem dos dados, introduza uma expressão booliana baseada no Spark SQL

que inclua apenas as colunas de particionamento. Por exemplo: `"(year=='2020' and month=='04')"`

- Advanced options (Opções avançadas): expanda essa seção se desejar que AWS Glue detecte o esquema de seus dados com base em um arquivo específico.
  - Schema inference (Inferência do esquema): escolha a opção Choose a sample file from S3(Escolher um arquivo de exemplo no S3), se desejar usar um arquivo específico em vez de deixar que o AWS Glue escolha um por você. A inferência de esquema não está disponível para a fonte Excel.
  - Auto-sampled file (Arquivo amostrado automaticamente): insira o caminho para o arquivo no Amazon S3 a ser usado para inferir o esquema.

  Se estiver editando um nó de origem dos dados e alterando o arquivo de exemplo selecionado, escolha Reload schema (Recarregar esquema) para detectar o esquema usando o novo arquivo de exemplo.

4. Selecione o botão Infer schema (Inferir esquema) para detectar o esquema dos arquivos de origem no Amazon S3. Se você alterar o local do Amazon S3 ou o arquivo de exemplo, deve escolher Infer schema (Inferir esquema) novamente para realizar a detecção do esquema usando as novas informações.

Usar uma fonte de dados de transmissão

É possível criar trabalhos de extração, transformação e carregamento (ETL) de transmissão que sejam executados continuamente e que consumam dados de fontes de transmissão, como o Amazon Kinesis Data Streams, Apache Kafka e Amazon Managed Streaming for Apache Kafka (Amazon MSK).

Para configurar propriedades de uma fonte de dados de transmissão

1. Vá para o editor visual de um trabalho novo ou salvo.
2. Escolha um nó de origem dos dados no gráfico para fluxos de dados do Kafka ou do Kinesis.
3. Escolha a guia Data source properties (Propriedades da origem dos dados) e insira as seguintes informações:

Kinesis

- Kinesis source type (Tipo de origem do Kinesis): escolha a opção Stream details (Detalhes do fluxo) para usar o acesso direto à fonte de transmissão ou escolha Data Catalog Table(Tabela do Data Catalog) para usar as informações nele armazenadas.

  Se você escolher Stream details (Detalhes do fluxo), especifique as informações adicionais a seguir.

  - Local do fluxo de dados: escolha se o fluxo está associado ao usuário atual ou a outro usuário.
  - Region (Região): escolha a Região da AWS onde o fluxo existe. Essas informações são usadas para construir o ARN para acesso ao fluxo de dados.
  - Stream ARN (ARN do fluxo): o nome do recurso da Amazon (ARN) do fluxos de dados do Kinesis. Se o fluxo estiver localizado na conta atual, você poderá escolher o nome do fluxo na lista suspensa. É possível usar o campo de pesquisa para procurar um fluxo de dados por seu nome ou ARN.
  - Data format (Formato de dados): escolha na lista o formato usado pelo fluxo de dados.

    O AWS Glue detecta automaticamente o esquema dos dados da transmissão.

  Se você escolher Data Catalog table (Tabela do Data Catalog), especifique as informações adicionais a seguir.

  - Database (Banco de dados): (opcional) escolha o banco de dados no AWS Glue Data Catalog que contém a tabela associada à sua fonte de dados de transmissão. É possível usar o campo de pesquisa para procurar um banco de dados pelo nome.
  - Table (Tabela): (opcional) escolha a tabela associada aos dados de origem na lista. Essa tabela já deve existir no AWS Glue Data Catalog. É possível usar o campo de pesquisa para procurar uma tabela pelo nome.
  - Detect schema (Detectar esquema): escolha essa opção para que o AWS Glue detecte o esquema dos dados da transmissão, em vez de usar as informações do esquema em uma tabela do Data Catalog. Essa opção é habilitada automaticamente quando a opção Stream details (Detalhes do fluxo) é escolhida.
- Starting position (Posição inicial): por padrão, o trabalho de ETL usa a opção Earliest (Mais antiga), o que significa que ele lê dados começando com o registro mais antigo disponível no fluxo. Em vez disso, você pode escolher Latest (Mais recente), o que indica que o trabalho de ETL deve começar a leitura logo após o registro mais recente no fluxo.

- Window size (Tamanho da janela): por padrão, o trabalho de ETL processa e grava dados em janelas de 100 segundos. Isso permite que os dados sejam processados de forma eficiente e que as agregações sejam realizadas em dados que chegam mais tarde do que o esperado. É possível modificar esse tamanho da janela para aumentar a pontualidade ou a precisão da agregação.

  Os trabalhos de transmissão do AWS Glue usam pontos de verificação em vez de marcadores de trabalho para rastrear os dados que foram lidos.
- Connection options (Opções de conexão): expanda essa seção para adicionar pares de chave-valor a fim de especificar opções de conexão adicionais. Para obter informações sobre quais opções você pode especificar aqui, consulte "connectionType": "kinesis" no Guia do desenvolvedor do AWS Glue.

Kafka

- Apache Kafka source (Origem do Apache Kafka): escolha a opção Stream details (Detalhes do fluxo) para usar o acesso direto à fonte de transmissão ou escolha Data Catalog Table(Tabela do Data Catalog) para usar as informações nele armazenadas.

  Se você escolher Data Catalog table (Tabela do Data Catalog), especifique as informações adicionais a seguir.

  - Database (Banco de dados): (opcional) escolha o banco de dados no AWS Glue Data Catalog que contém a tabela associada à sua fonte de dados de transmissão. É possível usar o campo de pesquisa para procurar um banco de dados pelo nome.
  - Table (Tabela): (opcional) escolha a tabela associada aos dados de origem na lista. Essa tabela já deve existir no AWS Glue Data Catalog. É possível usar o campo de pesquisa para procurar uma tabela pelo nome.
  - Detect schema (Detectar esquema): escolha essa opção para que o AWS Glue detecte o esquema dos dados de transmissão, em vez de armazenar as informações do esquema em uma tabela do Data Catalog. Essa opção é habilitada automaticamente quando a opção Stream details (Detalhes do fluxo) é escolhida.

  Se você escolher Stream details (Detalhes do fluxo), especifique as informações adicionais a seguir.

  - Connection name (Nome da conexão): escolha a conexão do AWS Glue que contém as informações de acesso e autenticação para o fluxo de dados do Kafka. Você deve

usar uma conexão com origens de dados de streaming do Kafka. Se uma conexão não existe, é possível usar o console do AWS Glue para criar uma conexão para o fluxo de dados do Kafka.

- Topic name (Nome do tópico): insira o nome do tópico do qual a leitura será feita.
- Data format (Formato dos dados): escolha o formato a ser usado ao ler dados da sequência de eventos do Kafka.

- Starting position (Posição inicial): por padrão, o trabalho de ETL usa a opção Earliest (Mais antiga), o que significa que ele lê dados começando com o registro mais antigo disponível no fluxo. Em vez disso, você pode escolher Latest (Mais recente), o que indica que o trabalho de ETL deve começar a leitura logo após o registro mais recente no fluxo.
- Window size (Tamanho da janela): por padrão, o trabalho de ETL processa e grava dados em janelas de 100 segundos. Isso permite que os dados sejam processados de forma eficiente e que as agregações sejam realizadas em dados que chegam mais tarde do que o esperado. É possível modificar esse tamanho da janela para aumentar a pontualidade ou a precisão da agregação.

  Os trabalhos de transmissão do AWS Glue usam pontos de verificação em vez de marcadores de trabalho para rastrear os dados que foram lidos.
- Connection options (Opções de conexão): expanda essa seção para adicionar pares de chave-valor a fim de especificar opções de conexão adicionais. Para obter informações sobre quais opções você pode especificar aqui, consulte "connectionType": "kafka" no Guia do desenvolvedor do AWS Glue.

> **Note**
>
> As previsualizações de dados não são suportadas atualmente para fontes de dados de transmissão.

Referências

Melhores práticas

- Criar um pipeline de serviços de ETL para carregar dados incrementalmente do Amazon S3 ao Amazon Redshift usando AWS Glue

Programação ETL

- Tipos de conexão e opções para ETL no AWS Glue
- Valores de connectionType de JDBC
- Opções avançadas para mover dados de e para o Amazon Redshift

Configurar nós de destino de dados

O destino de dados é onde o trabalho grava os dados transformados.

Visão geral das opções de destino de dados

Seu destino de dados (também chamado de coletor de dados) pode ser:

- S3: o trabalho grava os dados em um arquivo no local do Amazon S3 escolhido e no formato especificado.

  Se você configurar colunas de partição para o destino de dados, o trabalho grava o conjunto de dados no Amazon S3 em diretórios com base na chave de partição.
- AWS Glue Data Catalog: o trabalho usa as informações associadas à tabela no Data Catalog para gravar os dados de saída em um local de destino.

  É possível criar a tabela manualmente ou com o crawler. Você também pode usar modelos do AWS CloudFormation para criar tabelas no Data Catalog.
- Um conector: um conector é um pedaço de código que facilita a comunicação entre o armazenamento de dados e o AWS Glue. O trabalho usa o conector e a conexão associada para gravar os dados de saída em um local de destino. Você pode assinar um conector oferecido no AWS Marketplace ou pode criar seu próprio conector personalizado. Para obter mais informações, consulte Adição de conectores ao AWS Glue Studio

Você pode optar por atualizar o Data Catalog quando seu trabalho grava em um destino de dados do Amazon S3. Em vez de exigir que um crawler atualize o Data Catalog quando o esquema ou as partições mudam, essa opção facilita a manutenção das tabelas atualizadas. Essa opção simplifica o processo de disponibilização de dados para analytics, adicionando opcionalmente novas tabelas ao Data Catalog e atualizando partições de tabela e o esquema de tabelas diretamente a partir do trabalho.

Editar o nó de destino de dados

O destino de dados é onde o trabalho grava os dados transformados.

Para adicionar ou configurar um nó de destino de dados em seu diagrama de trabalho

1. (Opcional) se você precisar adicionar um nó de destino, escolha Target (Destino) na barra de ferramentas no topo do editor visual e escolha S3 ou Glue Data Catalog.

   - Se escolher S3 para o destino, o trabalho grava o conjunto de dados em um ou mais arquivos no local do Amazon S3 especificado.
   - Se escolher AWS Glue Data Catalog para o destino, o trabalho grava em um local descrito pela tabela selecionada no Data Catalog.
2. Escolha um nó de destino dos dados no diagrama de trabalho. Quando você escolhe um nó, o painel de detalhes do nó aparece no lado direito da página.
3. Escolha a guia Node properties (Propriedades do nó) e insira as seguintes informações:

   - Name (Nome): insira um nome a ser associado ao nó no diagrama de trabalho.
   - Node type (Tipo de nó): um valor já deve estar selecionado, mas você pode alterá-lo conforme necessário.
   - Node parents (Nós pais): o nó pai é o nó no diagrama de trabalho que fornece os dados de saída que você deseja gravar no local de destino. Para um diagrama de trabalho pré-preenchido, o nó de destino já deve ter o nó pai selecionado. Se não houver nenhum nó pai exibido, escolha um nó pai na lista.

     Um nó de destino tem um único nó pai.
4. Configure as informações de Data target properties (Propriedades do destino dos dados). Para obter mais informações, consulte as seções a seguir:

   - Uso do Amazon S3 para o destino de dados
   - Usar as tabelas do Data Catalog para o destino dos dados
   - Usar um conector para o destino de dados
5. (Opcional) depois de configurar as propriedades do nó de destino, você pode visualizar o esquema de saída para seus dados escolhendo a guia Output schema (Esquema de saída) no painel de detalhes do nó. Na primeira vez que você escolher essa guia para qualquer nó em seu trabalho, você receberá uma solicitação para fornecer uma função do IAM para acessar

os dados. Se você não tiver especificado uma função do IAM na guia Job details (Detalhes do trabalho), você receberá uma solicitação para inserir uma função do IAM aqui.

Uso do Amazon S3 para o destino de dados

Para todas as origens dos dados, exceto o Amazon S3 e os conectores, uma tabela deve existir noAWS Glue Data Catalog para o tipo de origem que você escolher. O AWS Glue Studio não cria a tabela do Data Catalog.

Para configurar um nó de destino de dados que grava no Amazon S3

1. Vá para o editor visual para um trabalho novo ou salvo.
2. Escolha um nó de origem dos dados no diagrama de trabalho.
3. Escolha a guia Data source properties (Propriedades da origem dos dados) e insira as seguintes informações:

   - Format (Formato): escolha um formato na lista. Os tipos de formato disponíveis para os resultados dos dados são:
     - JSON: JavaScript Object Notation.
     - CSV: Comma-separated values (valores separados por vírgula).
     - Avro: JSON binário do Apache Avro.
     - Parquet: um tipo de gravador Parquet personalizado, otimizado como o formato de dados para `DynamicFrames`. Em vez de exigir um esquema pré-calculado para os dados, ele calcula e modifica o esquema dinamicamente.
     - ORC: formato colunar de linha otimizado (ORC) do Apache.
     - Apache Hudi: é uma estrutura de armazenamento de data lake de código aberto que simplifica o processamento incremental de dados e o desenvolvimento de pipelines de dados.
     - Apache Iceberg: um formato de tabela de alta performance que funciona exatamente como uma tabela SQL.
     - Delta Lake: uma estrutura de armazenamento de data lake de código aberto que ajuda você a realizar transações ACID, escalar o tratamento de metadados e unificar o streaming e o processamento de dados em lote.
     - XML: Linguagem de Marcação Extensível (XML).
     - Tableau Hyper: a tecnologia de mecanismo de dados em memória do Tableau.

Para saber mais sobre essas opções de formato, consulte Opções de formato para entradas e saídas de ETL no AWS Glue no Guia do desenvolvedor do AWS Glue.

- Tipo de compactação: você pode optar por compactar os dados opcionalmente usando os tipos de arquivos `CSV`, `JSON` ou `Parquet`. O padrão é sem compactação, ou None (Nenhum).

Tipo de arquivo	Compactações
JSON/CSV/XML	GZIP, BZIP2, BROTLI, DEFLATE, LZ4, Snappy
Parquet	Snappy, LZ4, LZO, BROTLI, GZIP
ORC	Snappy, ZLIB, Não compactado, LZO
Avro	GZIP, BZIP2, BROTLI, DEFLATE, LZ4, Snappy
Delta Lake	GZIP, BZIP2, BROTLI, DEFLATE, LZ4, Snappy
Apache Hudi	GZIP, LZO, Snappy
Apache Iceberg	GZIP, LZO, Snappy
Tableau Hyper	Nenhum

- S3 Target Location (Local de destino do S3): o bucket do Amazon S3 e o local para a saída de dados. Você pode selecionar o botão Browse S3 (Procurar no S3) para ver os buckets do Amazon S3 aos quais você tem acesso e escolher um como destino.
- Opções de atualização do Data Catalog
  - Do not update the Data Catalog (Não atualizar o Data Log): (padrão) escolha essa opção se você não quiser que o trabalho atualize o Data Catalog, mesmo que o esquema seja alterado ou novas partições sejam adicionadas.
  - Create a table in the Data Catalog and on subsequent runs, update the schema and add new partitions (Criar uma tabela no Data Catalog e em execuções subsequentes, atualizar o esquema e adicionar novas partições): se você escolher essa opção, o trabalho criará a tabela no Data Catalog na sua primeira execução. Em execuções de trabalho

subsequentes, ele atualizará a tabela do Data Catalog, se o esquema for alterado ou novas partições forem adicionadas.

Você também deve selecionar um banco de dados no Data Catalog e inserir um nome de tabela.

- Create a table in the Data Catalog and on subsequent runs, keep existing schema and add new partitions (Criar uma tabela no Data Catalog e em execuções subsequentes, manter o esquema atual e adicionar novas partições): se você escolher essa opção, o trabalho criará a tabela no Data Catalog na sua primeira execução. Em execuções de trabalho subsequentes, ele atualizará a tabela do Data Catalog, mas apenas para adicionar novas partições.

  Você também deve selecionar um banco de dados no Data Catalog e inserir um nome de tabela.

- Particionamento de arquivos: escolha qual tipo de particionamento você deseja usar para salvar a saída.
  - Geração automática de arquivos (recomendado): este é o valor padrão para o número de arquivos gerados.
  - Saída de vários arquivos: especifique o número de saídas de arquivos que você deseja. Para uma performance ideal, use o valor padrão do número de arquivos gerados automaticamente.
- Partition keys (Chaves de partição): escolha quais colunas usar como chaves de particionamento na saída. Para adicionar mais chaves de partição, escolha Add a partition key (Adicionar uma chave de partição.

O particionamento de arquivos não é compatível com o Tableau Hyper como formato de destino.

Usar as tabelas do Data Catalog para o destino dos dados

Para todas as origens dos dados, exceto o Amazon S3 e os conectores, uma tabela deve existir noAWS Glue Data Catalog para o tipo de destino que você escolher. O AWS Glue Studio não cria a tabela do Data Catalog.

Para configurar as propriedades de dados para um destino que usa uma tabela do Data Catalog

1. Vá para o editor visual para um trabalho novo ou salvo.

2. Escolha um nó de destino dos dados no diagrama de trabalho.
3. Selecione a guia Data target properties (Propriedades do destino de dados) e insira as seguintes informações:

   - Database (Banco de dados): escolha na lista o banco de dados que contém a tabela que você deseja usar como destino. Esse banco de dados já deve existir no Data Catalog.
   - Table (Tabela): escolha na lista a tabela que define o esquema de dados de saída. Essa tabela já deve existir no Data Catalog.

     Uma tabela no Data Catalog consiste em nomes de colunas, definições de tipos de dados, informações de partição e outros metadados relacionados a um conjunto de dados de destino. O trabalho grava em um local descrito por essa tabela no Data Catalog.

     Para obter mais informações sobre como criar tabelas no Data Catalog, consulte Definir tabelas no Data Catalog no Guia do desenvolvedor do AWS Glue.
   - Opções de atualização do Data Catalog
     - Do not change table definition (Não alterar a definição da tabela): (padrão) escolha essa opção se não quiser que o trabalho atualize o Data Catalog, mesmo que o esquema seja alterado ou novas partições sejam adicionadas.
     - Update schema and add new partitions (Atualizar esquema e adicionar novas partições): se você escolher essa opção, o trabalho atualizará a tabela do Data Catalog, se o esquema for alterado ou novas partições forem adicionadas.
     - Keep schema and add new partitions (Manter o esquema e adicionar novas partições): se você escolher essa opção, o trabalho atualizará a tabela do Data Catalog, mas apenas para adicionar novas partições.
     - Partition keys (Chaves de partição): escolha quais colunas usar como chaves de particionamento na saída. Para adicionar mais chaves de partição, escolha Add a partition key (Adicionar uma chave de partição.

Usar um conector para o destino de dados

Se você selecionar um conector como Node type (Tipo de nó), siga as instruções em Criação de trabalhos com conectores personalizados para concluir a configuração das propriedades do destino dos dados.

Editar ou carregar um script de trabalho

Use o editor visual do AWS Glue Studio para editar o script de trabalho ou carregar seu próprio script.

É possível usar o editor visual para editar os nós do trabalho somente quando os trabalhos foram criados com o AWS Glue Studio. Se o trabalho foi criado usando o console do AWS Glue, por meio de comandos de API, ou com a command line interface (CLI), você pode usar o editor de scripts no AWS Glue Studio para editar o script de trabalho, os parâmetros e a programação. Você também pode editar o script para um trabalho criado no AWS Glue Studio convertendo o trabalho para o modo somente script.

Para editar o script de trabalho ou carregar seu próprio script

1. Se estiver criando um novo trabalho, na página Jobs (Trabalhos), escolha a opção Spark script editor (Editor de scripts do Spark) para criar um trabalho do Spark ou escolha Pythin Shell script editor (Editor de scripts de shell do Python) para criar um trabalho de shell do Python. Você pode escrever um novo script ou carregar um existente. Se escolher Spark script editor (Editor de scripts do Spark), você pode escrever ou carregar um script em Scala ou Python. Se escolher Python Shell script editor (Editor de scripts de shell do Python), você só pode escrever ou carregar um script em Python.

   Depois de escolher a opção para criar um novo trabalho, na seção Options (Opções) que aparece, você pode optar por iniciar com um script inicial (Create a new script with boilerplate code [Criar um novo script com o código clichê]) ou pode carregar um arquivo local para usar como script de trabalho.

   Se escolher Spark script editor (Editor de scripts do Spark), poderá carregar arquivos de script em Scala ou Python. Os scripts em Scala devem ter a extensão de arquivo `.scala`. Os scripts em Python devem ser reconhecidos como arquivos do tipo Python. Se escolher Python Shell script editor (Editor de scripts de shell do Python), só poderá carregar arquivos de script em Python.

   Quando terminar de fazer suas escolhas, selecione Create (Criar) para criar o trabalho e abrir o editor visual.
2. Vá para o editor de trabalho visual para o trabalho novo ou salvo e escolha a guia Script.
3. Se você não tiver criado um novo trabalho usando uma das opções do editor de scripts e jamais tiver editado o script para um trabalho existente, a guia Script exibe o cabeçalho Script (Locked)

(Script [bloqueado]). Isso significa que o editor de scripts está em modo somente leitura. Escolha Edit script (Editar script) para desbloquear o script para edição.

Para tornar o script editável, o AWS Glue Studio converte seu trabalho de um trabalho visual para um trabalho somente de script. Se você desbloquear o script para edição, não poderá mais usar o editor visual para esse trabalho depois de salvá-lo.

Na janela de confirmação, escolha Confirm (Confirmar) para continuar ou Cancel (Cancelar) para manter o trabalho disponível para edição visual.

Se escolher Confirm (Confirme), a guia Visual não aparecerá mais no editor. Você pode usar o AWS Glue Studio para modificar o script usando o editor de scripts, modificar os detalhes ou programação do trabalho ou exibir execuções de trabalho.

> **Note**
>
> Até que você salve o trabalho, a conversão para um trabalho somente de script não é permanente. Se você atualizar a página da Web do console ou fechar o trabalho antes de salvá-lo e reabri-lo no editor visual, ainda poderá editar os nós individuais no editor visual.

4. Edite o script, conforme necessário.

   Quando terminar de editar o script, escolha Save (Salvar) para salvar o trabalho e convertê-lo permanentemente de visual para somente script.

5. (Opcional) você pode baixar o script no console do AWS Glue Studio escolhendo o botão Download (Baixar) na guia Script. Quando você escolhe esse botão, uma nova janela do navegador é aberta, exibindo o script em sua localização no Amazon S3. Os parâmetros de trabalho Script filename (Nome de arquivo do script) e Script path (Caminho do script) na guia Job details (Detalhes do trabalho) determinam o nome e a localização do arquivo de script no Amazon S3.

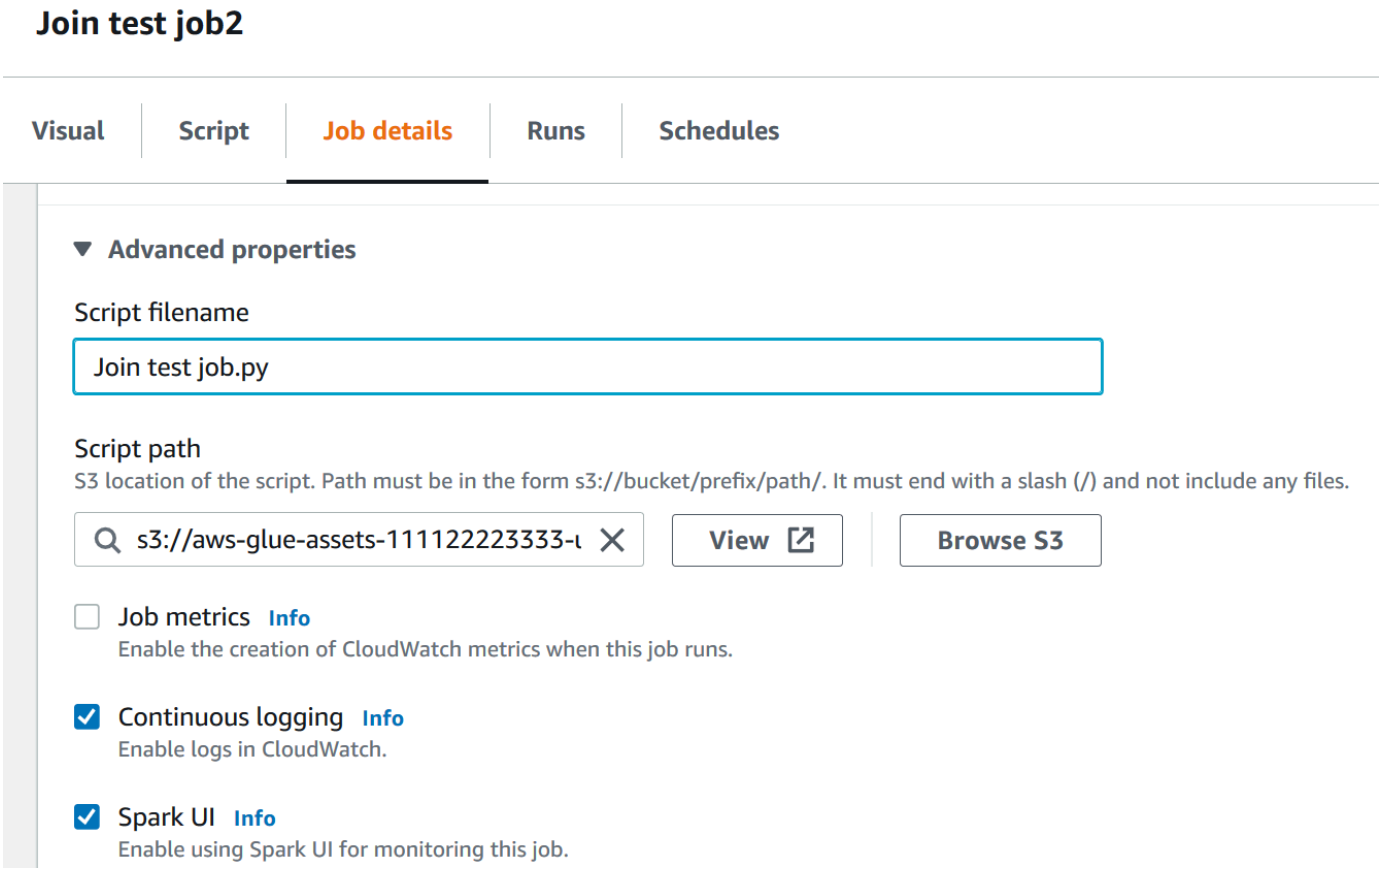

Quando você salva o trabalho, o AWS Glue salva o script de trabalho no local especificado por esses campos. Se você modificar o arquivo de script nesse local no Amazon S3, o AWS Glue Studio carregará o script modificado na próxima vez que você editar o trabalho.

Criar e editar scripts em Scala no AWS Glue Studio

Quando você escolhe o editor de scripts para criar um trabalho, por padrão, a linguagem de programação de trabalho é definida como `Python 3`. Se você optar por escrever um novo script em vez de carregar um, o AWS Glue Studio iniciará um novo script com texto boilerplate escrito em Python. Se em vez disso, você quiser escrever um script em Scala, deverá primeiro configurar o editor de scripts para usar o Scala.

> **Note**
>
> Se você escolher o Scala como a linguagem de programação para o trabalho e usar o editor visual para projetar seu trabalho, o script de trabalho gerado será escrito em Scala e nenhuma outra ação será necessária.

Para escrever um novo script em Scala no AWS Glue Studio

1. Crie um novo trabalho escolhendo a opção Spark script editor (Editor de scripts do Spark).
2. Em Options (Opções), escolha Create a new script with boilerplate code (Criar um novo script com o código clichê).
3. Escolha a guia Job details (Detalhes do trabalho) e defina Language (Linguagem) como `Scala` (em vez de `Python 3`).

> **Note**
>
> A propriedade Type (Tipo) do trabalho é automaticamente definida como `Spark` quando você escolhe a opção Spark script editor (Editor de scripts do Spark) para criar um trabalho.

4. Escolha a guia Script.
5. Remova o texto clichê em Python. Você pode substituí-lo com o seguinte texto clichê em Scala.

```
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. Escreva seu script de trabalho em Scala no editor. Adicione mais declarações `import`, conforme necessário.

Criar e editr trabalhos de shell do Python no AWS Glue Studio

Quando você escolhe o editor de scripts de shell do Python para criar um trabalho, pode carregar um script em Python existente ou escrever um novo. Se você optar por escrever um novo script, o código clichê será adicionado ao novo script de trabalho em Python.

Para criar um novo trabalho de shell do Python

Consulte as instruções em Iniciar trabalhos no AWS Glue Studio.

As propriedades de trabalho que são suportadas para trabalhos de shell do Python não são as mesmas que as suportadas para trabalhos do Spark. A lista a seguir descreve as alterações nos parâmetros de trabalho disponíveis para trabalhos de shell do Python na guia Job details (Detalhes do trabalho).

- A propriedade Type (Tipo) para o trabalho é automaticamente definida como `Python Shell` e não pode ser alterada.
- Em vez deLanguage (Linguagem), há uma propriedade Python version (Versão do Python) para o trabalho. No momento, os trabalhos de shell do Python criados no AWS Glue Studio usam o Python 3.6.
- A propriedade Glue version (Versão do Glue) não está disponível, porque não se aplica a trabalhos de shell do Python.
- Em vez de Worker type (Tipo de operador) e Number of workers (Número de operadores), uma propriedade Data processing units (Unidades de processamento de dados) é mostrada. Essa propriedade de trabalho determina quantas unidades de processamento de dados (DPUs) são consumidas pelo shell do Python ao executar o trabalho.
- A propriedade Job bookmark (Marcador de trabalho) não está disponível, porque não é suportado para trabalhos de shell do Python.
- Em Advanced properties (Propriedades avançadas), as propriedades a seguir não estão disponíveis para trabalhos de shell do Python.
  - Métricas de trabalho
  - Registro em log contínuo
  - Spark UI (IU do Spark) e Spark UI logs path (Caminho de logs de IU do Spark)
  - Dependent jars path (Caminho de arquivos jar dependentes), no cabeçalho Libraries (Bibliotecas)

Alterar os nós pais de um nó no diagrama de trabalho

Você pode alterar os pais de um nó para mover nós dentro do diagrama de trabalho ou para alterar uma origem dos dados de um nó.

Para alterar o nó pai

1. Escolha o nó no diagrama de trabalho que você deseja modificar.
2. No painel de detalhes do nó, na guia Node properties (Propriedades do nó) no cabeçalho Node parents (Nós pais), remova o pai atual do nó.
3. Escolha um novo nó pai na lista.
4. Modifique as outras propriedades do nó conforme necessário para corresponder ao nó pai recém-selecionado.

Se você modificou um nó por engano, pode usar o botão Undo (Desfazer) na barra de ferramentas para reverter a ação.

Excluir nós do diagrama de trabalho

Ao trabalhar com trabalhos de ETL visuais, é possível remover nós da tela sem precisar adicionar novamente ou reestruturar nenhum nó conectado ao nó removido.

No exemplo abaixo, acompanhe escolhendo Trabalhos de ETL > ETL visual e, em Exemplos de trabalhos, escolhendo Trabalho de ETL visual para unir várias fontes. Escolha Criar trabalho de exemplo para criar um trabalho e siga as etapas abaixo.

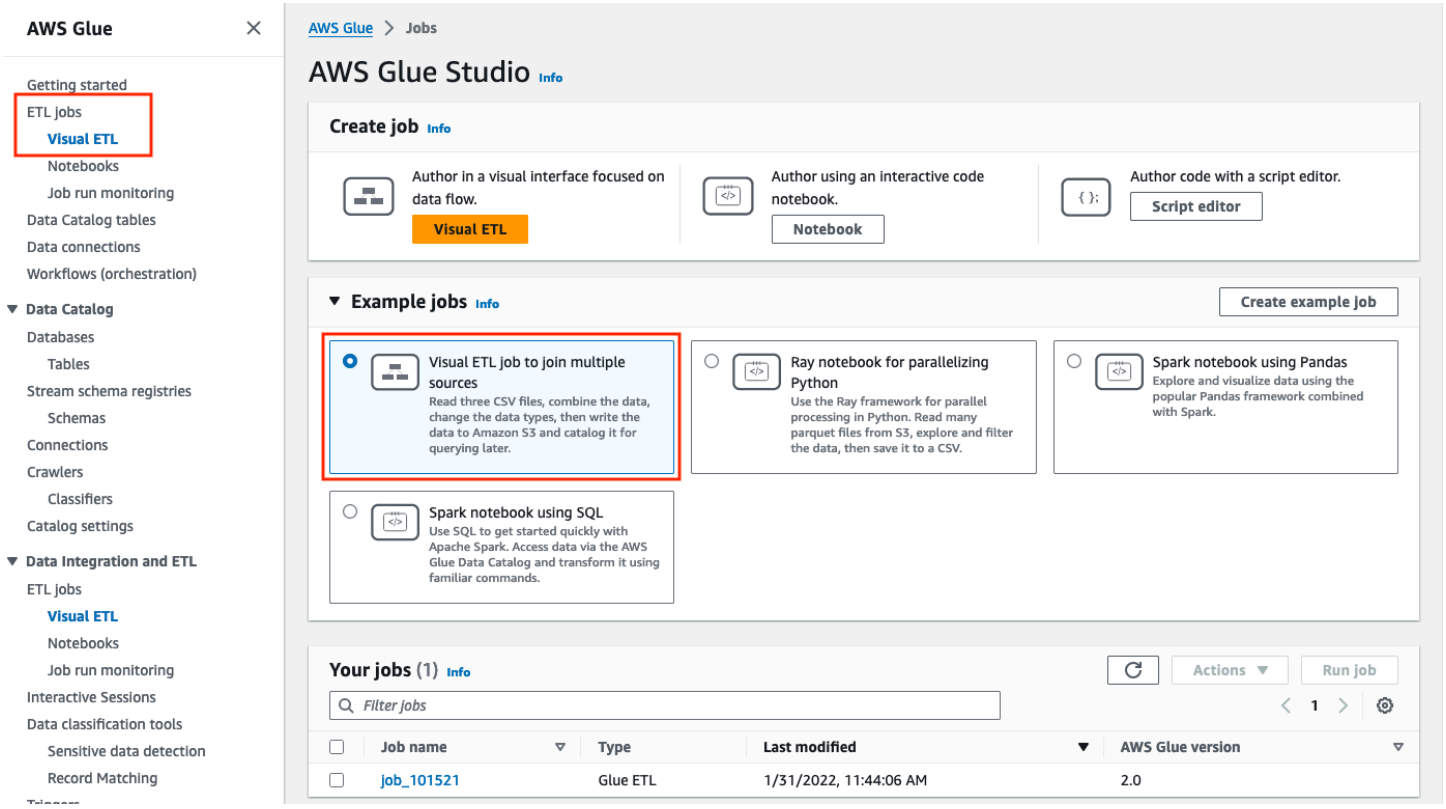

Para remover um nó da tela

1. No console do AWS Glue, escolha ETL visual no menu de navegação e escolha uma tarefa existente. A tela de trabalho exibe o trabalho de exemplo conforme ilustrado abaixo.

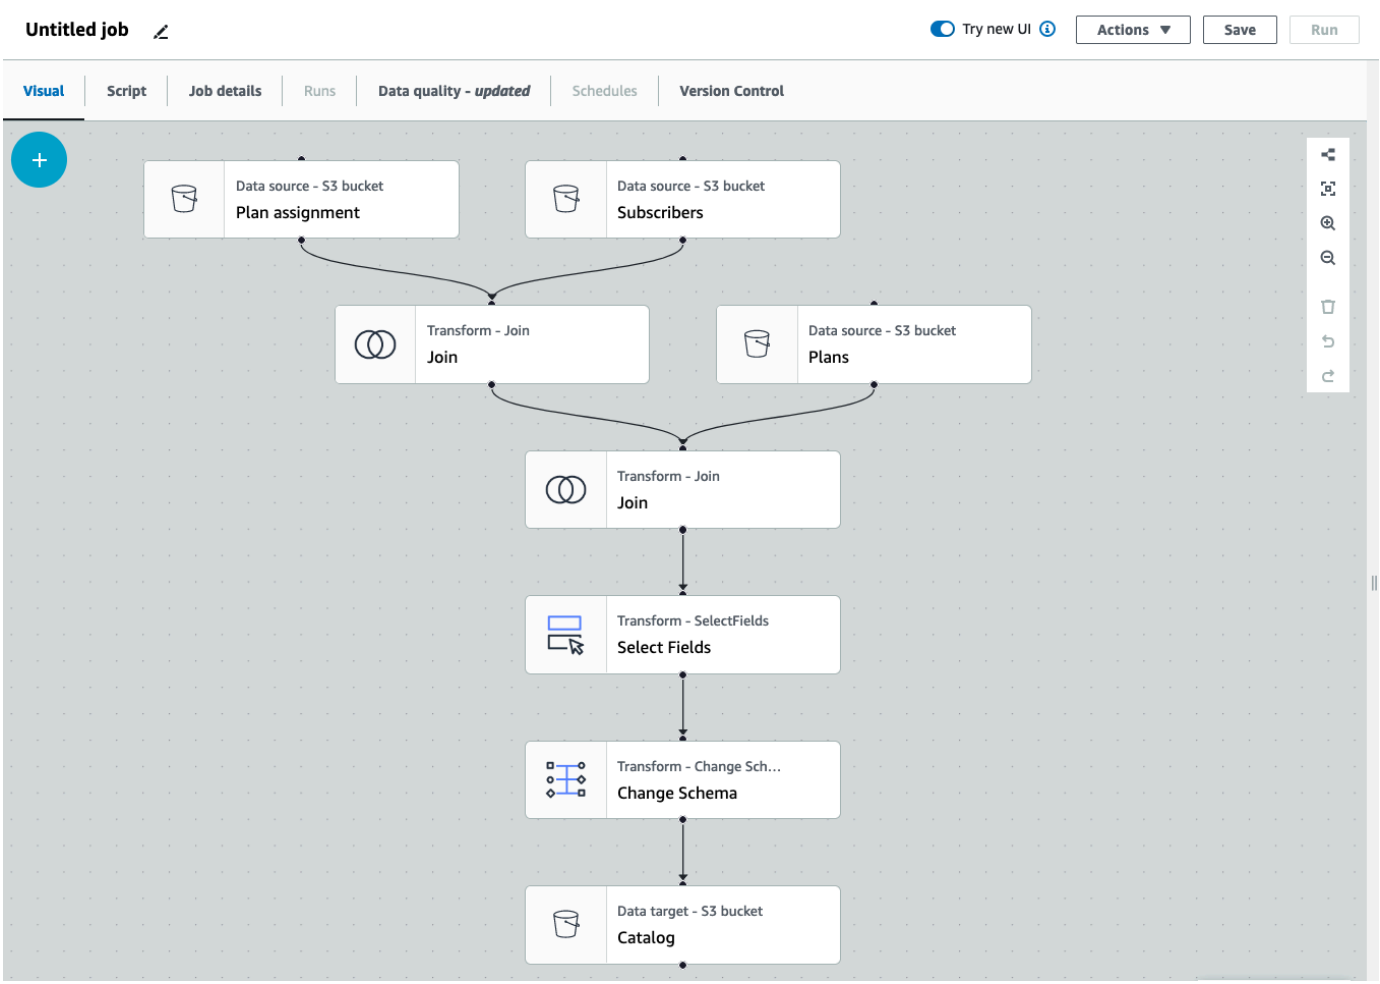

2. Escolha o nó que deseja remover. A tela ampliará o zoom no nó. Na barra de ferramentas no lado direito da tela, escolha o ícone Lixeira. Isso removerá o nó, e qualquer nó conectado ao nó será movido para ocupar seu lugar no fluxo de trabalho. Neste exemplo, o primeiro nó Join foi excluído da tela.

   Se você excluir um nó no fluxo de trabalho, o AWS Glue reorganizará os nós de uma forma que não resulte em um fluxo de trabalho inválido. Talvez você ainda precise corrigir a configuração de um nó.

   No exemplo, o nó Join abaixo do nó Subscribers foi removido. Como resultado, o nó de origem Plans foi movido para o nível superior e ainda está conectado ao nó secundário Join. O nó Join agora requer configuração adicional, pois Join requer dois nós de origem pais com tabelas

selecionadas. A guia Transformar à direita da tela exibe o requisito ausente em Condições de união.

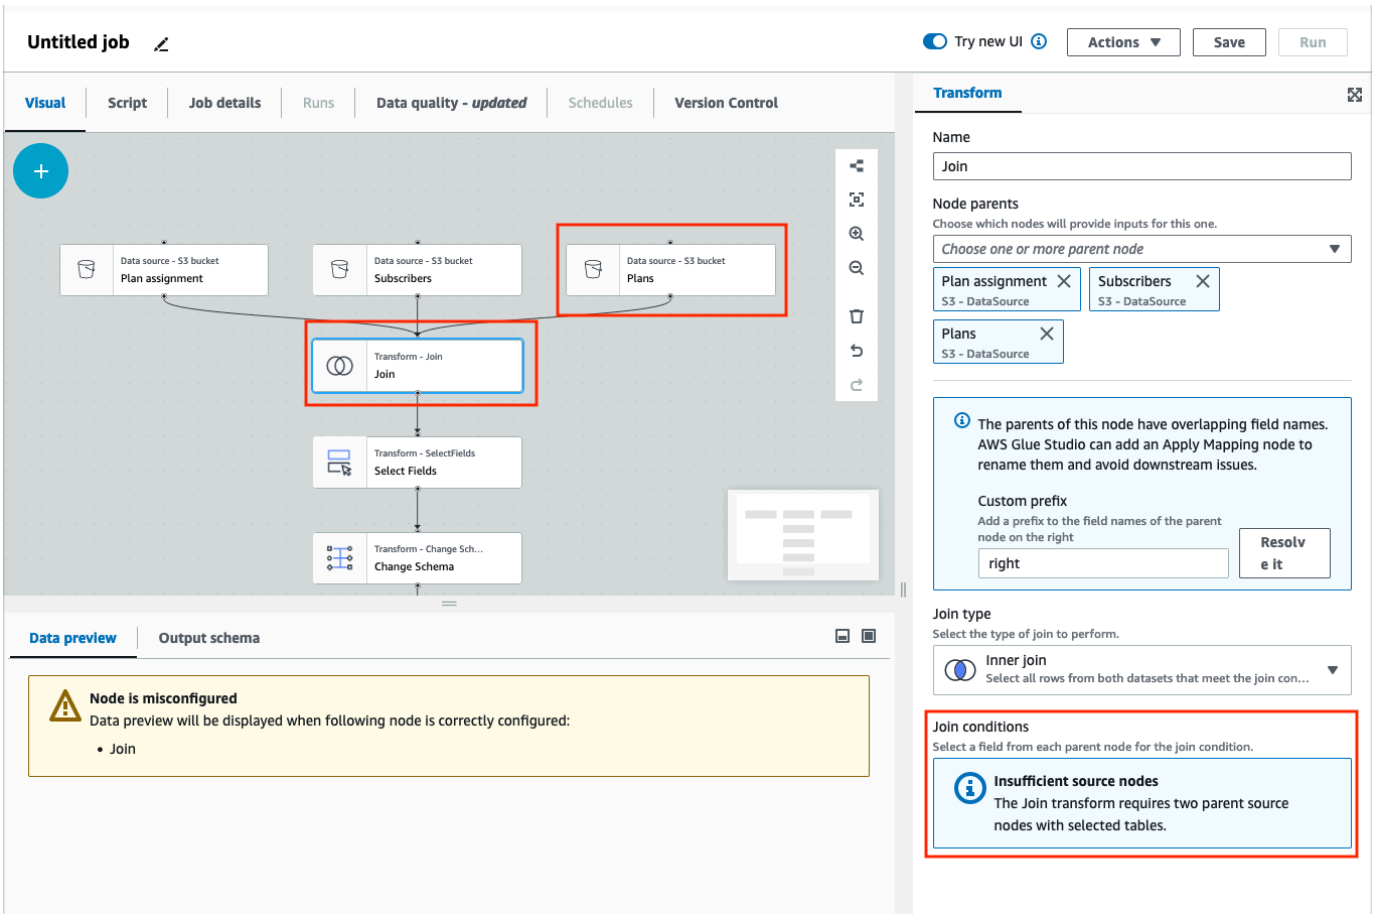

3. Exclua o segundo nó Join e o nó Select Fields. Quando os nós forem excluídos, o fluxo de trabalho será semelhante ao exemplo abaixo.

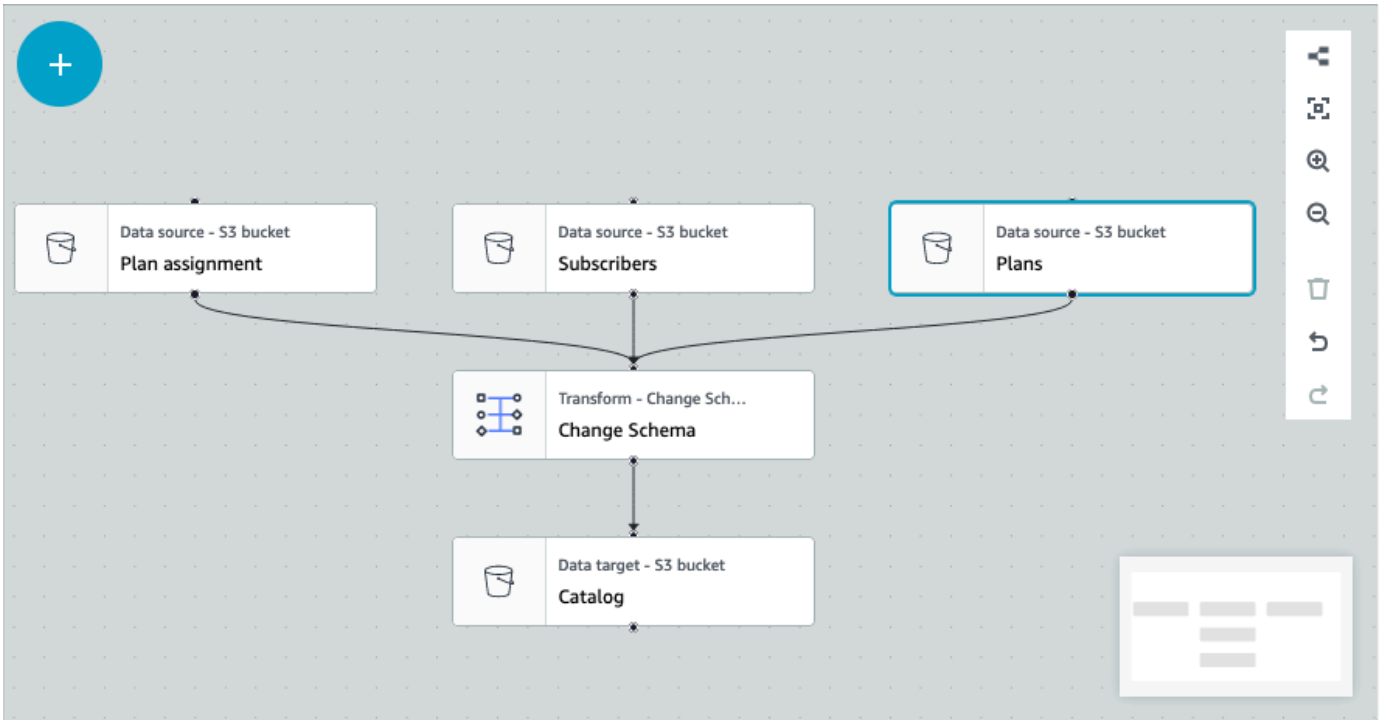

4. Para modificar as conexões do nó, clique na alça do nó e arraste a conexão para um novo nó. Isso permitirá a você excluir os nós e reorganizá-los em um fluxo lógico. No exemplo, uma nova conexão está sendo feita com um clique na alça no nó Plans e arrastando-se a conexão até o nó Join, conforme ilustrado pela seta vermelha.

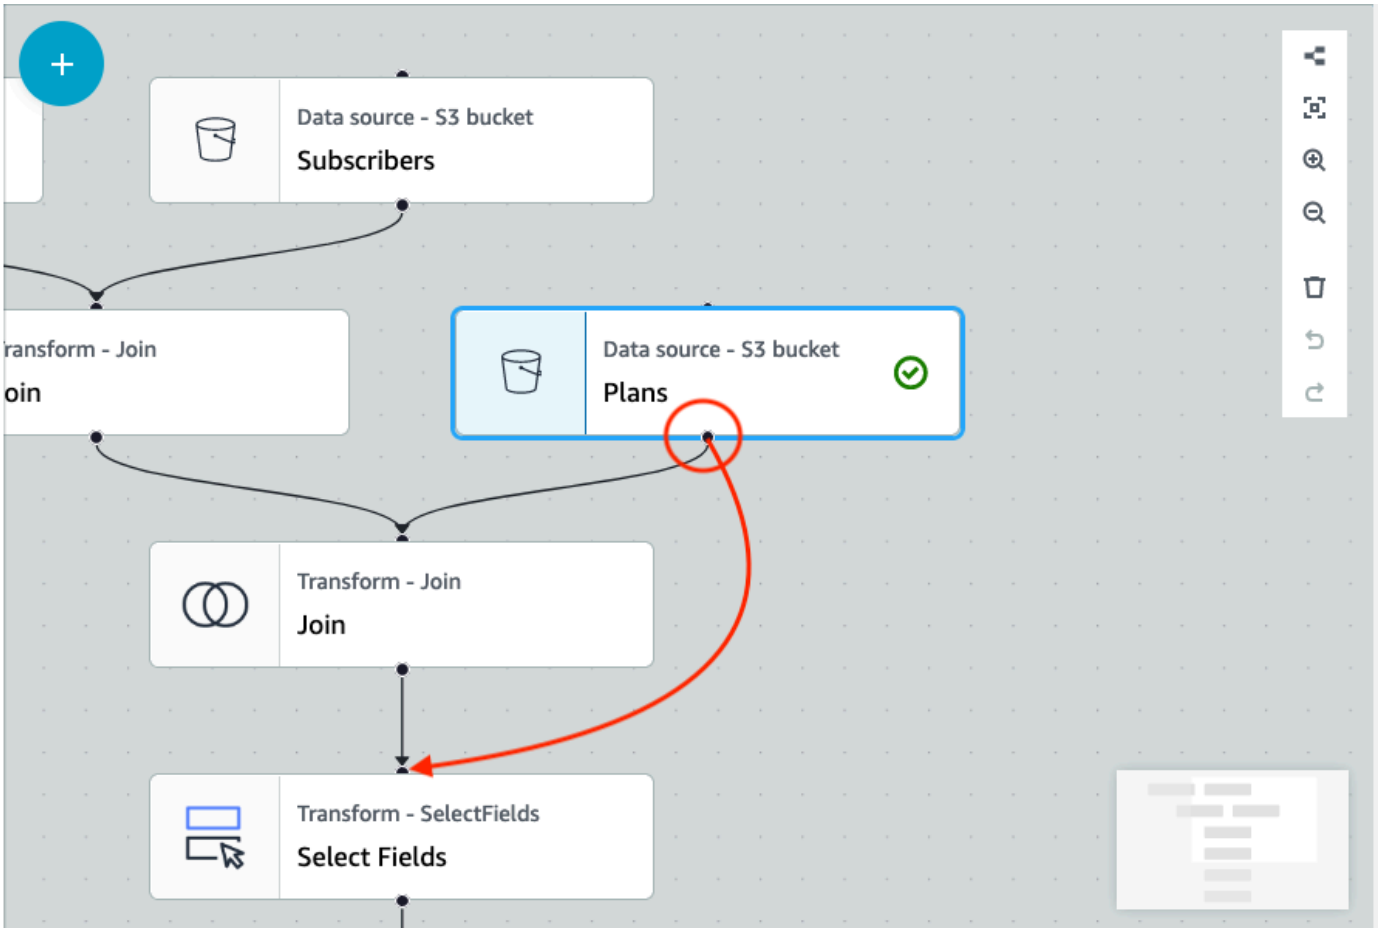

5. Se precisar desfazer alguma ação, escolha o ícone Desfazer diretamente abaixo do ícone Lixeira na barra de ferramentas no lado direito da tela.

Adicionar parâmetros de origem e destino ao nó do AWS Glue Data Catalog

O AWS Glue Studio permite que você parametrize trabalhos visuais. Como os nomes das tabelas de catálogo no ambiente de produção e desenvolvimento podem ser diferentes, você pode definir e selecionar parâmetros de runtime para bancos de dados e tabelas que serão executados quando seu trabalho for executado.

A parametrização de trabalhos permite parametrizar origens e destinos e salvar estes parâmetros no trabalho ao usar o nó do AWS Glue Data Catalog. Ao especificar origens e destinos como parâmetros, você está permitindo a reutilização de trabalhos, principalmente quando usa o mesmo trabalho em vários ambientes. Isso é útil para promover código em ambientes de implantação, economizando tempo e esforços no gerenciamento das suas origens e dos seus destinos. Além

disso, os parâmetros personalizados que você especificar substituirão os argumentos padrão para execuções específicas de trabalhos do AWS Glue.

Para adicionar parâmetros de origem e destino

Se você estiver usando o nó do AWS Glue Data Catalog como origem ou destino, poderá definir parâmetros de runtime na seção Advanced properties (Propriedades avançadas) na guia Job details (Detalhes do trabalho).

1. Escolha o nó do AWS Glue Data Catalog como nó de origem ou nó de destino.
2. Escolha a guia Job details (Detalhes do trabalho).
3. Escolha Advanced properties (Propriedades avançadas).
4. Na seção Job parameters (Parâmetros do trabalho), insira um valor de chave. Por exemplo, `--db.source` seria o parâmetro para uma origem de banco de dados. Você pode inserir qualquer nome para a chave, desde que o nome da chave seja seguido pelo “traço traço”.

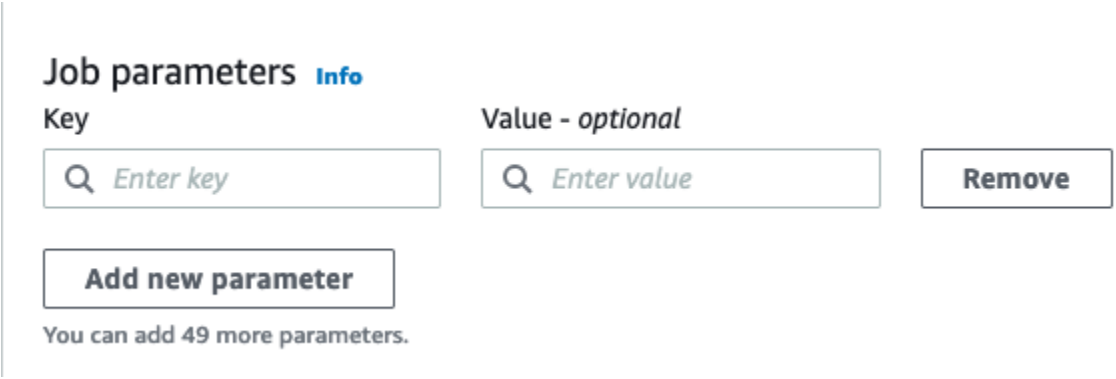

5. Insira o valor. Por exemplo, `databasename` seria o valor para um banco de dados sendo parametrizado.
6. Escolha Add new parameter (Adicionar novo parâmetro) se quiser adicionar parâmetros. O máximo de 50 parâmetros é permitido. Depois que o par de chave-valor tiver sido definido, você poderá usar o parâmetro no nó do AWS Glue Data Catalog.

Para selecionar um parâmetro de runtime

> **Note**
>
> O processo para selecionar parâmetros de runtime para bancos de dados e tabelas é o mesmo, não importando se o nó do AWS Glue Data Catalog é a origem ou o destino.

1. Escolha o nó do AWS Glue Data Catalog como nó de origem ou nó de destino.
2. Na guia Data source properties - Data Catalog (Propriedades da fonte de dados - Data Catalog) em Database (Banco de dados), escolha Use runtime parameters (Usar parâmetros de runtime).

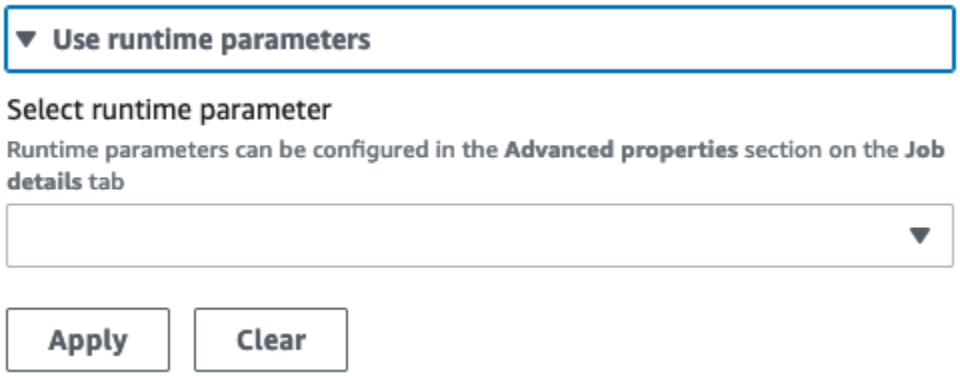

3. No menu suspenso, escolha um parâmetro. Por exemplo, quando você selecionar um parâmetro definido para um banco de dados de origem, o banco de dados será preenchido automaticamente no menu suspenso de banco de dados quando você escolher Apply (Aplicar).
4. Na seção Table (Tabela), escolha um parâmetro que você já definiu como tabela de origem. Quando você escolhe Apply (Aplicar), a tabela é automaticamente preenchida como a tabela a ser usada.
5. Quando você salvar e executar o trabalho, o AWS Glue Studio fará referência aos parâmetros selecionados durante a execução do trabalho.

Usando sistemas de controle de versão do Git no AWS Glue

> **Note**
>
> Atualmente, os notebooks não são compatíveis com o controle de versão noAWS Glue Studio. No entanto, há suporte para controle de versão para scripts de AWS Glue tarefas e tarefas ETL visuais.

Se houver repositórios remotos e você quiser gerenciar seus trabalhos do AWS Glue usando seus repositórios, poderá usar o AWS Glue Studio ou a AWS CLI para sincronizar as alterações nos seus repositórios e seus trabalhos no AWS Glue. Quando sincroniza as alterações dessa forma, você está transferindo o trabalho do AWS Glue Studio para seu repositório ou transferindo do repositório para o AWS Glue Studio.

Com a integração do Git no AWS Glue Studio, você pode:

- Fazer a integração com sistemas de controle de versão do Git, como AWS CodeCommit, GitHub e Bitbucket
- Editar trabalhos do AWS Glue no AWS Glue Studio se você usa trabalhos visuais ou de script e os sincroniza com um repositório
- Parametrizar origens e destinos nos trabalhos
- Extrair trabalhos de um repositório e editá-los no AWS Glue Studio
- Testar trabalhos extraindo-os de ramificações e/ou transferindo-os para ramificações usando fluxos de trabalho em várias ramificações no AWS Glue Studio
- Baixar arquivos de um repositório e carregar trabalhos para o AWS Glue Studio para a criação de trabalhos entre contas
- Usar sua ferramenta de automação preferencial (por exemplo, Jenkins, AWS CodeDeploy etc.)

Este vídeo demonstra como você pode integrar o AWS ao Glue com Git e criar um pipeline de código contínuo e colaborativo.

Permissões do IAM

Certifique-se de que o trabalho tenha uma das seguintes permissões do IAM. Para obter mais informações sobre como configurar permissões do IAM, consulte Configurar permissões do IAM para o AWS Glue Studio.

- `AWSGlueServiceRole`
- `AWSGlueConsoleFullAccess`

No mínimo, as seguintes ações são necessárias para a integração com o Git:

- `glue:UpdateJobFromSourceControl`: para poder atualizar o AWS Glue com um trabalho presente em um sistema de controle de versão
- `glue:UpdateSourceControlFromJob`: para poder atualizar o sistema de controle de versão com um trabalho armazenado no AWS Glue
- `s3:GetObject`: para poder recuperar o script do trabalho durante a transferência para o sistema de controle de versão
- `s3:PutObject`: para poder atualizar o script ao extrair um trabalho de um sistema de controle de origem

Pré-requisitos

Para enviar trabalhos para um repositório de controle de origem, você precisará:

- um repositório que já foi criado pelo seu administrador
- uma ramificação no repositório
- um token de acesso pessoal (para o Bitbucket, esse é o token de acesso ao repositório)
- o nome de usuário do proprietário do repositório
- definir permissões no repositório para permitir AWS Glue Studio a leitura e gravação no repositório
  - GitLab — defina os escopos do token para api, read_repository e write_repository
  - Bitbucket — defina permissões para:
    - Associação ao Workspace — leia, escreva
    - Projetos — escrever, administrar ler
    - Repositórios — leitura, gravação, administração, exclusão

> **Note**
>
> Ao usar AWS CodeCommit, o token de acesso pessoal e o proprietário do repositório não são necessários. Consulte Conceitos básicos do Git e do AWS CodeCommit.

Usando trabalhos do seu repositório de controle de origem no AWS Glue Studio

Para extrair um trabalho do seu repositório de controle de origem que não está no AWS Glue Studio e usar esse trabalho no AWS Glue Studio, os pré-requisitos dependerão do tipo de trabalho.

Para um trabalho visual:

- você precisa de uma pasta e de um arquivo JSON da definição do trabalho que correspondam ao nome do trabalho

  Por exemplo, veja a definição de trabalho abaixo. A ramificação no seu repositório deve conter um caminho `my-visual-job/my-visual-job.json`, em que a pasta e o arquivo JSON correspondam ao nome do trabalho

```
{
  "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\":\"quote\",\"Recurse\":true,\"Separator\":\"comma\",\"WithHeader
\":true}}}"
}
```

Para um trabalho de script:

- você precisa de uma pasta, de um arquivo JSON da definição do trabalho e do script
- a pasta e o arquivo JSON devem corresponder ao nome do trabalho. O nome do script precisa corresponder ao `scriptLocation` da definição do trabalho junto com a extensão do arquivo

  Por exemplo, na definição do trabalho abaixo, a ramificação no seu repositório deve conter um caminho `my-script-job/my-script-job.json` e `my-script-job/my-script-job.py`. O nome do script deve corresponder ao nome na `scriptLocation`, incluindo a extensão do 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"
```

```
  }
}
```

Limitações

- No momento, o AWS Glue não oferece suporte a push/pull do GitLab-Groups.

Conectar repositórios de controle de versão com o AWS Glue

Você pode inserir os detalhes do seu repositório de controle de versão e gerenciá-los na guia Version Control (Controle de versão) no editor de trabalhos do AWS Glue Studio. Para se integrar ao seu repositório Git, deverá se conectar a ele para cada vez que fizer login no AWS Glue Studio.

Para conectar um sistema de controle de versão Git:

1. No AWS Glue Studio, comece um novo trabalho e escolha guia Version Control (Controle de versão).

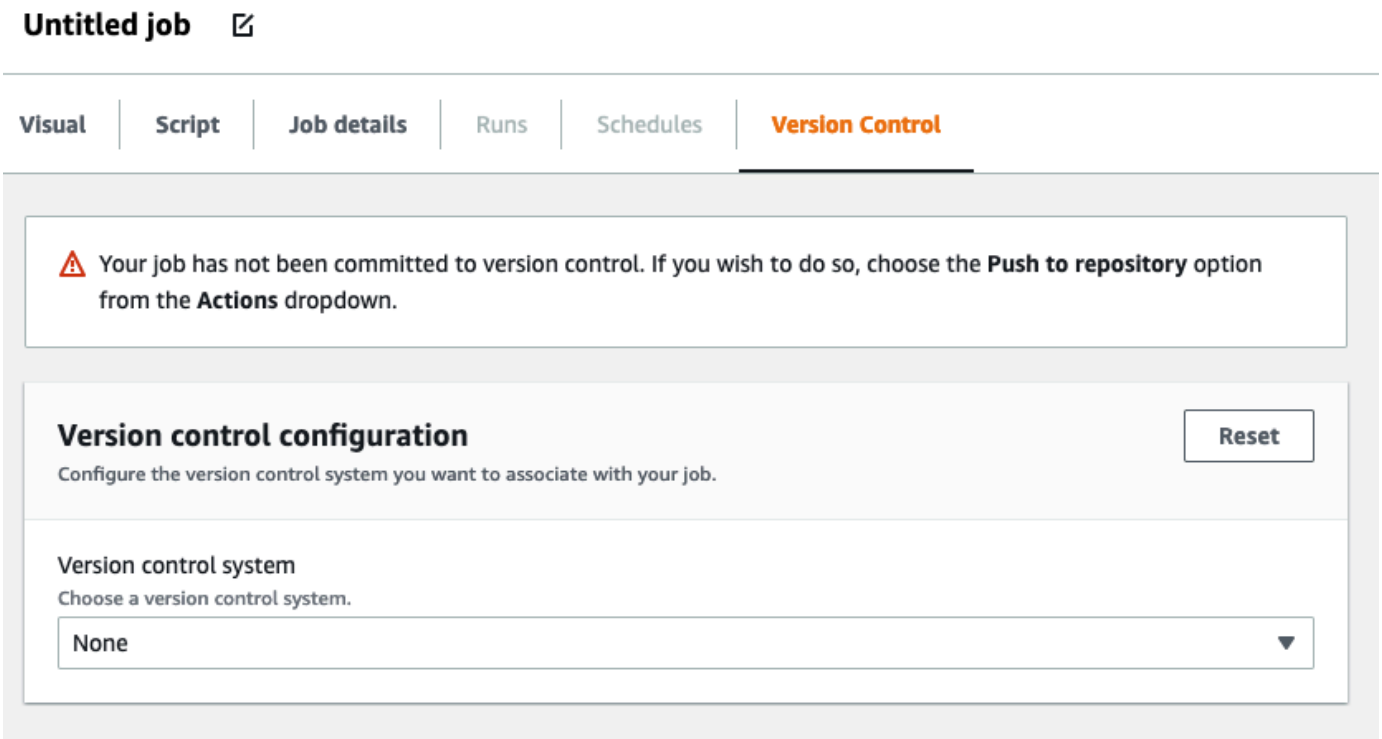

2. Em Version control system (Sistema de controle de versão), escolha o serviço Git entre as opções disponíveis clicando no menu suspenso.

- AWS CodeCommit
- GitHub
- GitLab
- Bitbucket

3. Dependendo do sistema de controle de versão Git escolhido, você terá campos diferentes para preencher.

   para AWS CodeCommit:

   Conclua a configuração do repositório selecionando o repositório e a ramificação para seu trabalho:

   - Repositório: se você tiver configurado repositórios no AWS CodeCommit, selecione o repositório no menu suspenso. Seus repositórios serão preenchidos automaticamente na lista
   - Ramificação: selecione a ramificação no menu suspenso
   - Pasta: opcional - insira o nome da pasta na qual deseja salvar seu trabalho. Se o campo for deixado vazio, uma pasta será criada automaticamente. O nome da pasta assume o nome do trabalho como padrão.

   Para o GitHub:

   Conclua a configuração do GitHub preenchendo os campos:

   - Personal access token (Token de acesso pessoal): esse é o token fornecido pelo repositório do GitHub. Para obter mais informações sobre tokens de acesso pessoal, consulte GitHub Docs (Documentos do GitHub)
   - Repository owner (Proprietário do repositório): este é o proprietário do repositório do GitHub.

   Conclua a configuração do repositório selecionando o repositório e a ramificação no GitHub.

   - Repository (Repositório): se você tiver configurado repositórios no GitHub, selecione o repositório no menu suspenso. Seus repositórios serão preenchidos automaticamente na lista
   - Ramificação: selecione a ramificação no menu suspenso

- Pasta: opcional - insira o nome da pasta na qual deseja salvar seu trabalho. Se o campo for deixado vazio, uma pasta será criada automaticamente. O nome da pasta assume o nome do trabalho como padrão.

Para o GitLab:

> **Note**
>
> No momento, o AWS Glue não oferece suporte a push/pull do GitLab-Groups.

- Personal access token (Token de acesso pessoal): esse é o token fornecido pelo repositório do GitLab. Para obter mais informações sobre tokens de acesso pessoal, consulte Tokens de acesso pessoal do GitLab
- Repository owner (Proprietário do repositório): este é o proprietário do repositório do GitLab.

Conclua a configuração do repositório selecionando o repositório e a ramificação no GitLab.

- Repository (Repositório): se você tiver configurado repositórios no GitLab, selecione o repositório no menu suspenso. Seus repositórios serão preenchidos automaticamente na lista
- Ramificação: selecione a ramificação no menu suspenso
- Pasta: opcional - insira o nome da pasta na qual deseja salvar seu trabalho. Se o campo for deixado vazio, uma pasta será criada automaticamente. O nome da pasta assume o nome do trabalho como padrão.

Para Bitbucket:

- Senha de aplicações: o Bitbucket usa senhas de aplicações, e não tokens de acesso ao repositório. Para obter mais informações sobre senhas de aplicações, consulte Senhas de aplicações.
- Repository owner (Proprietário do repositório): este é o proprietário do repositório do Bitbucket. No Bitbucket, o proprietário é o criador do repositório.

Conclua a configuração do repositório selecionando o espaço de trabalho, repositório, ramificação e pasta do Bitbucket.

- Espaço de trabalho - se você tiver espaços de trabalho configurados no Bitbucket, selecione o espaço de trabalho no menu suspenso. Seus espaços de trabalho são preenchidos automaticamente
- Repository (Repositório) - se você tiver configurado repositórios no , selecione o repositório no menu suspenso. Seus repositórios são preenchidos automaticamente
- Ramificação: selecione a ramificação no menu suspenso. Suas filiais são preenchidas automaticamente
- Pasta: opcional - insira o nome da pasta na qual deseja salvar seu trabalho. Se deixado em branco, uma pasta será criada automaticamente com o nome do trabalho.

4. Escolha Save (Salvar) na parte superior do trabalho do AWS Glue Studio

Transferir trabalhos do AWS Glue para o repositório de origem

Depois de inserir os detalhes do seu sistema de controle de versão, você pode editar trabalhos no AWS Glue Studio e enviá-los para seu repositório de origem. Se você não estiver familiarizado com os conceitos do Git, como push e pull, consulte esse tutorial em Conceitos básicos do Git e do AWS CodeCommit.

Para transferir seu trabalho para um repositório, você precisa inserir os detalhes do seu sistema de controle de versão e salvar o trabalho.

1. No trabalho do AWS Glue Studio, escolha Actions (Ações). Opções adicionais de menu serão abertas.

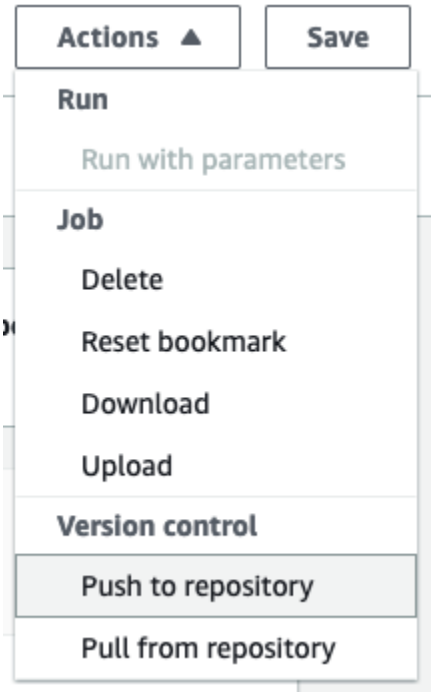

2. Escolha Push to repository (Transferir para o repositório).

   Essa ação salvará o trabalho. Quando você transfere para o repositório, o AWS Glue Studio transfere a alteração mais recente salva. Se o trabalho no repositório tiver sido modificado por você ou por outro usuário e estiver fora de sincronia com o trabalho no AWS Glue Studio, o trabalho no repositório será substituído pelo trabalho salvo no AWS Glue Studio quando você transferir o trabalho do AWS Glue Studio.

3. Escolha Confirm (Confirmar) para concluir a ação. Uma nova confirmação será criada no repositório. Se você estiver usando o AWS CodeCommit, uma mensagem de confirmação exibirá um link para a confirmação mais recente no AWS CodeCommit.

Extrair trabalhos do AWS Glue do repositório de origem

Depois de inserir os detalhes do seu repositório do Git na guia Version control (Controle de versão), você também pode extrair trabalhos do seu repositório e editá-los no AWS Glue Studio.

1. No trabalho do AWS Glue Studio, escolha Actions (Ações). Opções adicionais de menu serão abertas.

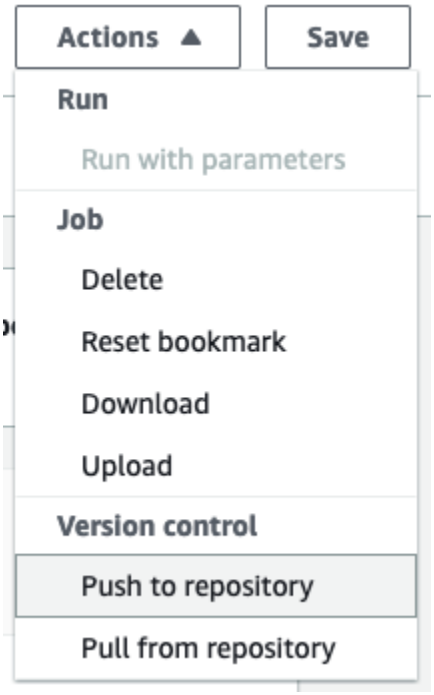

2. Escolha Pull from repository (Extrair do repositório).
3. Selecione a opção Confirmar. Essa opção captura a confirmação mais recente do repositório e atualiza seu trabalho no AWS Glue Studio.
4. Edite seu trabalho no AWS Glue Studio. Se você fizer alterações, poderá sincronizar o trabalho com o repositório escolhendo Push to repository (Transferir para o repositório) no menu suspenso Actions (Ações).

Criação de código com notebooks AWS Glue Studio

Os engenheiros de dados podem criar trabalhos do AWS Glue de forma mais fácil e rápida do que antes usando a interface de caderno interativo no AWS Glue Studio ou sessões interativas no AWS Glue.

Limitações

- Cadernos do AWS Glue Studio não são compatíveis com Scala.

Tópicos

- Visão geral do uso de cadernos
- Criar um trabalho de ETL usando cadernos no AWS Glue Studio

- Componentes do editor de cadernos
- Salvar o caderno e o script do trabalho
- Gerenciar sessões de cadernos
- Usar o Amazon Q Developer com cadernos do AWS Glue Studio

Visão geral do uso de cadernos

O AWS Glue Studio permite criar trabalhos interativamente em uma interface de caderno baseada no Jupyter Notebooks. Com os cadernos no AWS Glue Studio, você pode editar scripts de trabalho e visualizar a saída sem ter que executar um trabalho completo. Da mesma forma, é possível editar o código de integração de dados e visualizar a saída precisar executar um trabalho completo. Além disso, você pode adicionar markdowns e salvar cadernos como arquivos .ipynb e scripts de trabalho. É possível iniciar um caderno sem instalar software localmente nem gerenciar servidores. Quando estiver satisfeito com seu código, o AWS Glue Studio poderá converter seu caderno em um trabalho do Glue com o clique de um botão.

Alguns dos benefícios de usar cadernos incluem:

- Nenhum cluster para provisionar ou gerenciar
- Nenhum cluster ocioso para pagar
- Não é necessária nenhuma configuração inicial
- Não é necessário realizar a instalação de cadernos do Jupyter
- O mesmo runtime/plataforma que o ETL do AWS Glue.

Ao começar um caderno via AWS Glue Studio, todas as etapas de configuração são feitas para você, para que você possa explorar seus dados e começar a desenvolver seu script de trabalho após apenas alguns segundos. O AWS Glue Studio configura um caderno do Jupyter com o kernel Jupyter do AWS Glue. Não é necessário configurar VPCs, conexões de rede nem endpoints de desenvolvimento para usar esse caderno.

Para criar trabalhos usando a interface de caderno:

- configure as permissões do IAM necessárias.
- inicie uma sessão de caderno para criar um trabalho
- escreva código nas células do caderno
- execute e teste o código para visualizar a saída

- salve o trabalho

Depois que o caderno for salvo, ele será um trabalho do AWS Glue completo. Você pode gerenciar todos os aspectos do trabalho, como agendar trabalhos de execução, definir parâmetros de trabalho e exibir o histórico de execução do trabalho ao lado do seu caderno.

Criar um trabalho de ETL usando cadernos no AWS Glue Studio

Para começar a usar cadernos no console do AWS Glue Studio

1. Anexe políticas do AWS Identity and Access Management ao usuário AWS Glue Studio e crie um perfil do IAM para seu trabalho de ETL e bloco de anotações.
2. Configure a segurança adicional do IAM para cadernos, conforme descrito em Conceder permissões para a função do IAM.
3. Abra o console do AWS Glue Studio em https://console.aws.amazon.com/gluestudio/.

   > **Note**
   >
   > Verifique se o navegador não bloqueia cookies de terceiros. Qualquer navegador que bloqueie cookies de terceiros por padrão ou graças a uma configuração habilitada pelo usuário impedirá a inicialização dos cadernos. Para mais informações sobre o gerenciamento de cookies, consulte:

   - Chrome
   - Firefox
   - Safari
4. Escolha o link Jobs (Trabalhos) no menu de navegação do lado esquerdo.
5. Escolha Jupyter Notebook (Caderno do Jupyter) e, em seguida, escolha Create (Criar) para iniciar uma nova sessão de caderno.
6. Na página Create job in Jupyter notebook (Criar trabalho em caderno do Jupyter), forneça o nome do trabalho e escolha a função do IAM a ser usada. Escolha Criar trabalho.

   Após um curto período de tempo, o editor de caderno é mostrado.
7. Após adicionar o código, execute a célula para iniciar uma sessão. Há várias maneiras de executar a célula:

- Pressione o botão play (reproduzir).
- Use o atalho de teclado:
  - No macOS, Command+Enter para executar a célula.
  - No Windows, Shift+Enter para executar a célula.

Para obter informações sobre como escrever código usando uma interface do caderno do Jupyter, consulte a Documentação do usuário do Jupyter Notebook.

8. Para testar seu script, execute o script inteiro ou células individuais. Qualquer saída de comando será exibida na área abaixo da célula.
9. Após concluir o desenvolvimento de seu caderno, você poderá salvar o trabalho e executá-lo. Você encontrará o script na guia Script. Qualquer mágica adicionada ao caderno será removida e não será salva como parte do script do trabalho gerado do AWS Glue. O AWS Glue Studio adicionará automaticamente um `job.commit()` ao final do script gerado com base no conteúdo do caderno.

   Para obter mais informações sobre como executar trabalhos, consulte Iniciar uma execução de trabalho.

Componentes do editor de cadernos

A interface do editor de cadernos oferece as seguintes seções principais.

- Interface do caderno (painel principal) e barra de ferramentas
- Guias de edição de trabalhos

O editor de cadernos

O editor de cadernos do AWS Glue Studio é baseado na aplicação Jupyter Notebook. A interface de cadernos do AWS Glue Studio é semelhante à fornecida pelo Juypter Notebooks e é descrita na seção Interface de usuário de cadernos. O caderno usado por sessões interativas é um Jupyter Notebook.

Embora o caderno do AWS Glue Studio seja semelhante ao Juptyer Notebooks, ele apresenta algumas diferenças importantes:

- no momento, o caderno do AWS Glue Studio não pode instalar extensões
- não é possível usar várias guias; há uma relação 1:1 entre um trabalho e um caderno
- o caderno do AWS Glue Studio não tem o mesmo menu de arquivos superior que existe no Jupyter Notebooks
- no momento, o caderno do AWS Glue Studio só funciona com o kernel do AWS Glue. Observe que você não pode atualizar o kernel por conta própria.

Guias de edição de trabalhos do AWS Glue Studio

As guias que você usa para interagir com o trabalho ETL estão na parte superior da página do caderno. Elas são semelhantes às guias que aparecem no editor de trabalhos visual do AWS Glue Studio e executam as mesmas ações.

- Notebook (caderno): use essa guia para visualizar o script do trabalho usando a interface do caderno.
- Job details (Detalhes do trabalho): configure o ambiente e as propriedades para as execuções de trabalhos.
- Runs (Execuções): visualize informações sobre execuções anteriores deste trabalho.
- Schedules (Programações): configure uma programação para executar seu trabalho em horários específicos.

Salvar o caderno e o script do trabalho

Você pode salvar seu caderno e o script do trabalho que você está criando a qualquer momento. Basta escolher o botão Save (Salvar) no canto superior direito, o mesmo que você faria se estivesse usando o editor visual ou de script.

Quando você escolhe Save (Salvar), o arquivo do caderno é salvo nos locais padrão.

- Por padrão, o script do trabalho é salvo no local do Amazon S3 indicado na guia Job Details (Detalhes do trabalho), em Advanced properties (Propriedades avançadas), na propriedade dos detalhes do trabalho Script path (Caminho do script). Os scripts de trabalho são salvos em uma subpasta denominada `Scripts`.
- Por padrão, o arquivo do caderno (`.ipynb`) é salvo no local do Amazon S3 indicado na guia Job Details (Detalhes do trabalho), em Advanced properties (Propriedades avançadas), no Script

path (Caminho do script) dos detalhes do trabalho. Os arquivos de cadernos são salvos em uma subpasta denominada `Notebooks`.

> **Note**
>
> Quando você salva o trabalho, o script de trabalho contém apenas as células de código do caderno. As células e magics do Markdown não estão incluídas no script de trabalho. Porém, o arquivo `.ipynb` conterá todas as remarcações e magics.

Após salvar o trabalho, você poderá executar o trabalho usando o script criado no caderno.

Gerenciar sessões de cadernos

Os cadernos no AWS Glue Studio são baseados no recurso de sessões interativas do AWS Glue. Há um custo para usar sessões interativas. Para ajudar a gerenciar seus custos, você pode monitorar as sessões criadas para sua conta e definir as configurações padrão para todas as sessões.

Alterar o tempo limite padrão para todas as sessões do caderno

Por padrão, o caderno provisionado do AWS Glue Studio expira após 12 horas se o caderno tiver sido iniciado e nenhuma célula executada. Não há custo associado a ele e o tempo-limite não é configurável.

Após executar uma célula, isso iniciará uma sessão interativa. Essa sessão tem um tempo limite padrão de 48 horas. Esse tempo limite pode ser configurado mediante a transmissão de uma mágica de `%idle_timeout` antes de executar uma célula.

Para modificar o tempo limite de sessão padrão para cadernos no AWS Glue Studio

1. No caderno, insira o magic `%idle_timeout` em uma célula e especifique o valor do tempo limite em minutos.
2. Por exemplo: `%idle_timeout 15` mudará o tempo limite padrão para 15 minutos. Se a sessão não for usada em 15 minutos, ela será interrompida automaticamente.

Instalar módulos Python adicionais

Se desejar instalar módulos adicionais em sua sessão usando pip, você poderá fazê-lo usando `%additional_python_modules`para adicioná-los à sua sessão:

```
%additional_python_modules awswrangler, s3://amzn-s3-demo-bucket/mymodule.whl
```

Todos os argumentos para additional_python_modules são passados para `pip3 install -m <>`

Para visualizar uma lista de módulos Python disponíveis, consulte Usar bibliotecas Python com o AWS Glue.

Alterar a configuração do AWS Glue

É possível usar mágicas para controlar valores de configuração de trabalho do AWS Glue. Se quiser alterar um valor de configuração de trabalho, use a mágica adequada no caderno. Consulte Mágicas compatíveis com sessões interativas do AWS Glue para Jupyter.

> **Note**
>
> As propriedades de substituição de uma sessão em execução não estão mais disponíveis. Para alterar as configurações da sessão, você pode interromper a sessão, definir as novas configurações e, em seguida, iniciar uma nova sessão.

O AWS Glue oferece suporte a vários tipos de operadores. Você pode definir o tipo do operador com `%worker_type`. Por exemplo: `%worker_type G.2X` . O padrão é G.1X.

Também é possível especificar o número de operadores com `%number_of_workers`. Por exemplo, para especificar 40 operadores: `%number_of_workers 40`.

Para obter mais informações, consulte Definir as propriedades do trabalho

Interromper uma sessão de caderno

Para interromper uma sessão de caderno, use o magic `%stop_session`.

Se você navegar para longe do caderno no console do AWS, receberá uma mensagem de aviso onde poderá optar por interromper a sessão.

Usar o Amazon Q Developer com cadernos do AWS Glue Studio

O AWS Glue Studio permite criar trabalhos interativamente em uma interface de caderno baseada no Jupyter Notebooks. O uso do Amazon Q Developer melhora a experiência de criação em cadernos do AWS Glue Studio.

A extensão do Amazon Q Developer oferece suporte à escrita de código gerando recomendações de código e sugerindo melhorias relacionadas a problemas de código. O Amazon Q Developer é compatível com Python e Scala, as duas linguagens usadas para codificar scripts ETL para trabalhos do Spark em cardenos do AWS Glue Studio.

O que é o Amazon Q Developer?

O Amazon Q Developer é um serviço baseado em machine learning que ajuda a melhorar a produtividade do desenvolvedor. O Amazon Q Developer faz isso gerando recomendações de código com base nos comentários dos desenvolvedores em linguagem natural e no código criado por eles no IDE. O serviço se integra ao JupyterLab, Amazon SageMaker AI Studio, instâncias de caderno do Amazon SageMaker AI e outros ambientes de desenvolvimento integrados (IDEs).

Para obter mais informações, consulte Usar o Amazon Q Developer com o AWS Glue Studio.

Status de execução de trabalhos do AWS Glue no console

Você pode visualizar o status de um trabalho de extração, transformação e carregamento (ETL) do AWS Glue enquanto ele está em execução ou após a interrupção. É possível visualizar o status usando o console do AWS Glue. Para obter mais informações sobre o status de execução de trabalhos, consulte the section called “Status de execução de trabalho”.

Acessar o painel de monitoramento de trabalhos

Acesse o painel de monitoramento de trabalhos escolhendo o link Monitoramento de execuções de trabalho no painel de navegação em Trabalhos de ETL.

Visão geral do painel de monitoramento de trabalhos

O painel de monitoramento de trabalhos fornece um resumo geral das execuções de trabalho, com totais para os trabalhos com um status Running (Executando), Canceled (Cancelado), Success (Bem-sucedido) ou Failed (Com falha). Os blocos adicionais fornecem a taxa geral de sucesso da execução do trabalho, o uso estimado de DPU para trabalhos, uma divisão das contagens de status de trabalhos por tipo de trabalho, tipo de operador e dia.

Os gráficos nos blocos são interativos. Você pode escolher qualquer bloco em um gráfico para executar um filtro que exiba apenas esses trabalhos na tabela Job runs (Execuções do trabalho) na parte inferior da página.

Você pode alterar o intervalo de datas para as informações exibidas nessa página usando o seletor Data range (Intervalo de datas). Quando você altera o intervalo de datas, os blocos de informações são ajustados a fim de exibir os valores para o número especificado de dias antes da data atual. Você também pode usar um intervalo de datas específico se escolher Custom (Personalizado) no seletor de intervalo de datas.

Visualizar execuções do trabalho

> **Note**
>
> O histórico de execução de trabalhos pode ser acessado por 90 dias para seu fluxo de trabalho e execução de trabalhos.

O recurso Job runs (Execuções do trabalho) exibe os trabalhos para o intervalo de datas e filtros especificados.

Você pode filtrar os trabalhos em critérios adicionais, como status, tipo de operador, tipo de trabalho e nome do trabalho. Na caixa de filtro na parte superior da tabela, você pode inserir o texto a ser usado como filtro. Os resultados da tabela são atualizados com linhas que contêm correspondências à medida que você digita o texto.

Você pode exibir um subconjunto dos trabalhos escolhendo elementos nos gráficos no painel de monitoramento de trabalho. Por exemplo, se você escolher o número de trabalhos em execução no bloco Job runs summary (Resumo de execuções do trabalho), a lista Job runs (Execuções do trabalho) exibe apenas os trabalhos que têm atualmente o status `Running`. Se você escolher uma das barras no gráfico de barras Worker type breakdown (Detalhamento do tipo de operador), somente as execuções de trabalho com o tipo de operador e status correspondentes serão mostrados na lista Job runs (Execuções do trabalho).

O recurso Job runs (Execuções do trabalho) exibe os detalhes das execuções do trabalho. É possível classificar as linhas na tabela escolhendo um cabeçalho de coluna. A tabela contém as seguintes informações:

Propriedade	Descrição
Nome do trabalho	O nome do trabalho do .
Tipo	O tipo de ambiente do trabalho: • Glue ETL (ETL do Glue): execuções em um ambiente Apache Spark gerenciado pelo AWS Glue. • Glue Streaming (Transmissão do Glue): executa em um ambiente Apache Spark e realiza ETL em fluxos de dados. • Python shell: executa scripts do Python como um shell.
Horário de início	A data e a hora em que a execução deste trabalho foi iniciada.
End time (Horário de término)	A data e a hora em que a execução desse trabalho foi concluída.
Run status (Status da execução)	O estado atual da execução do trabalho. Os valores podem ser: • `STARTING` • `RUNNING` • `STOPPING` • `STOPPED` • `SUCCEEDED` • `FAILED` • `TIMEOUT`
Run time (runtime)	A quantidade de tempo em que a execução de trabalho consumiu recursos.
Capacity	O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para

Propriedade	Descrição
	essa execução de trabalho. Para obter mais informações sobre planejamento de capacidade, consulte Monitoramento de planejamento de capacidade de DPU no Guia do desenvolvedor do AWS Glue.

Propriedade	Descrição
Tipo de operador	O tipo de operador predefinido que é alocado quando um trabalho é executado. Os valores podem ser `G.1X`, `G.2X`, `G.4X` ou `G.8X`. • **`G.1X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia para 1 DPU (4 vCPUs, 16 GB de memória) com 84 GB de disco (aproxima damente 34 GB livres). Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória. Esse é o Worker type (Tipo de operador) padrão para trabalhos do AWS Glue versão 2.0 ou posterior. • **`G.2X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia para 2 DPU (8 vCPUs, 32 GB de memória) com 128 GB de disco (aproxima damente 77 GB livres). Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória e trabalhos que executem transformações de machine learning. • **`G.4X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia para 4 DPU (16 vCPUs, 64 GB de memória) com 256 GB de disco (aproxima damente 235 GB livres). Recomenda mos esse tipo de operador para trabalhos cujas workloads contêm as transform ações, agregações, uniões e consultas mais exigentes. Esse tipo de operador

Propriedade	Descrição
	está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Singapura), Ásia-Pacífico (Sydney), Ásia-Pacífico (Tóquio), Canadá (Central) , Europa (Frankfurt), Europa (Irlanda) e Europa (Estocolmo). • **`G.8X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia para 8 DPU (32 vCPUs, 128 GB de memória) com 512 GB de disco (aproxima damente 487 GB livres). Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível apenas para trabalhos ETL do Spark do AWS Glue versão 3.0 ou posterior , nas mesmas regiões da AWS compatíveis com o tipo de operador `G.4X`.
DPU hours (Horas de DPU)	O número estimado de DPUs usadas para a execução de trabalho. Uma DPU é uma medida relativa do poder de processamento. As DPUs são usadas para determinar o custo da execução de trabalho. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

É possível escolher qualquer execução de trabalho na lista e visualizar informações adicionais. Escolha uma execução de trabalho e realize uma das seguintes ações:

- Selecione o menu Actions (Ações) e a opção View job (Visualizar trabalho) para visualizar o trabalho no editor visual.
- Selecione o menu Actions (Ações) e a opção Stop run (Interromper execução) para interromper a execução atual do trabalho.
- Escolha o botão View CloudWatch logs (Visualizar logs do CloudWatch) para exibir os logs de execução do trabalho.
- Escolha Visualizar detalhes para visualizar a página de detalhes da execução do trabalho.

Visualizar os logs de execuções de trabalho

Você pode visualizar os logs de trabalhos de várias maneiras:

- Na página Monitoring (Monitoramento), na tabela Job runs (Execuções do trabalho), escolha uma execução de trabalho e selecione View CloudWatch logs (Visualizar logs do CloudWatch).
- No editor visual de trabalhos, na guia Runs (Execuções) de um trabalho, escolha os hiperlinks para exibir os logs:
  - Logs: links para os logs de trabalho do Apache Spark gravados quando o registro em log contínuo é habilitado para uma execução de trabalho. Quando você escolhe esse link, ele leva você para os logs do Amazon CloudWatch no grupo de logs `/aws-glue/jobs/logs-v2`. Por padrão, os logs excluem a pulsação do Apache Hadoop YARN e as mensagens de log do driver ou do executor do Apache Spark desnecessárias. Para obter mais informações sobre registro em log contínuo, consulte Registro em log contínuo para trabalhos do AWS Glue no Guia do desenvolvedor do AWS Glue.
  - Error logs (Logs de erro): vinculam-se aos logs gravados em `stderr` para a execução de trabalho. Quando você escolhe esse link, ele leva você para os logs do Amazon CloudWatch no grupo de logs `/aws-glue/jobs/error`. Você pode usar esses logs para exibir detalhes sobre os erros que foram encontrados durante a execução de trabalho.
  - Output logs (Logs de saída): links para os logs gravados em `stdout` para a execução de trabalho. Quando você escolhe esse link, ele leva você para os logs do Amazon CloudWatch no grupo de logs `/aws-glue/jobs/output`. Você pode usar esses logs para ver todos os detalhes sobre as tabelas que foram criadas no AWS Glue Data Catalog e os erros que foram encontrados.

Visualizar os detalhes de uma execução de trabalho

Você pode escolher um trabalho na lista Job runs (Execuções do trabalho) na página Monitoring (Monitoramento) e, em seguida, escolher View run details (Visualizar detalhes da execução) para ver informações detalhadas sobre a execução de trabalho.

As informações exibidas na página de detalhes da execução de trabalho incluem:

Propriedade	Descrição
Nome do trabalho	O nome do trabalho do .
Run status (Status da execução)	O estado atual da execução do trabalho. Os valores podem ser: • `STARTING` • `RUNNING` • `STOPPING` • `STOPPED` • `SUCCEEDED` • `FAILED` • `TIMEOUT`
Versão do Glue	A versão do AWS Glue usada pela execução de trabalho.
Recent attempt (Tentativa recente)	O número de tentativas automáticas de repetição da execução deste trabalho.
Horário de início	A data e a hora em que a execução deste trabalho foi iniciada.
End time (Horário de término)	A data e a hora em que a execução desse trabalho foi concluída.
Start-up time (Horário de início)	A quantidade de tempo gasta preparando para executar o trabalho.

Propriedade	Descrição
Tempo de execução	A quantidade de tempo gasta executando o script do trabalho.
Nome do gatilho	O nome do acionador associado ao trabalho.
Modificação mais recente	A data em que o trabalho foi modificado pela última vez.
Configuração de segurança	A configuração de segurança do trabalho, que inclui criptografia do Amazon S3, criptografia do CloudWatch e configurações de criptografia de marcadores de trabalho.
Timeout (Tempo limite)	O valor do tempo limite da execução de trabalho.
Allocated capacity (Capacidade alocada)	O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para essa execução de trabalho. Para obter mais informações sobre planejamento de capacidade, consulte Monitoramento de planejamento de capacidade de DPU no Guia do desenvolvedor do AWS Glue.
Max capacity (Capacidade máxima)	A capacidade máxima disponível para a execução de trabalho.
Número de operadores	O número de operadores usados para a execução de trabalho.

Propriedade	Descrição
Tipo de operador	O tipo de operadores predefinidos alocados para a execução de trabalho. Os valores podem ser `G.1X` ou `G.2X`. • **`G.1X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador é mapeado para 1 DPU (4 vCPUs, 16 GB de memória, disco de 64 GB), e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória. Esse é o Worker type (Tipo de operador) padrão para trabalhos do AWS Glue versão 2.0 ou posterior. • **`G.2X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador é mapeado para 2 DPUs (8 vCPUs, 32 GB de memória, disco de 128 GB), e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória e trabalhos que executem transformações de machine learning.
Logs	Um link para os logs de trabalho para registro em log contínuo (`/aws-glue/jobs/logs-v2`).
Output Logs (Logs de saída)	Um link para os arquivos de log de saída do trabalho (`/aws-glue/jobs/output`).
Logs de erro	Um link para os arquivos de log de erros do trabalho (`/aws-glue/jobs/error`).

Você também pode visualizar os seguintes itens adicionais, os quais se tornam disponíveis ao visualizar informações sobre execuções de trabalhos recentes. Para ter mais informações, consulte the section called “Exibir informações para execuções de trabalho recentes”.

- Argumentos de entrada
- Logs contínuos
- Métricas: é possível ver visualizações de métricas básicas. Para obter ter mais informações sobre as métricas incluídas, consulte the section called “Visualizar métricas do Amazon CloudWatch para uma execução de trabalho do Spark”.
- Interface do usuário do Spark: é possível visualizar os logs do Spark do seu trabalho na interface do usuário do Spark. Para obter mais informações sobre o uso da interface do usuário Web do spark , consulte o the section called “Monitorar com a interface do usuário do Spark”. Habilite esse recurso seguindo o procedimento em the section called “Habilitar a interface do usuário do Spark para trabalhos”.

Visualizar métricas do Amazon CloudWatch para uma execução de trabalho do Spark

Na página de detalhes de uma execução de trabalho, abaixo da seção Run details (Detalhes da execução), você pode visualizar as métricas do trabalho. O AWS Glue Studio envia métricas de trabalho para o Amazon CloudWatch para cada trabalho executado.

O AWS Glue relata as métricas ao Amazon CloudWatch a cada 30 segundos. As métricas do AWS Glue representam valores do delta a partir dos valores relatados anteriormente. Quando apropriado, os painéis de métricas agregam (somam) os valores de 30 segundos para obter um valor para o último minuto inteiro. No entanto, as métricas do Apache Spark que o AWS Glue transfere para o Amazon CloudWatch são geralmente valores absolutos que representam o estado atual no momento em que são relatadas.

> **Note**
>
> Você deve configurar sua conta para acessar o Amazon CloudWatch.

As métricas fornecem informações sobre a execução de trabalho, como:

- ETL Data Movement (Movimentação de dados de ETL): o número de bytes lidos ou gravados no Amazon S3.
- Memory Profile: Heap used (Perfil de memória: heap usado): o número de bytes de memória usados pelo heap da máquina virtual Java (JVM).
- Memory Profile: heap usage (Perfil de memória: uso do heap): a fração da memória (escala: 0 a 1) usada pelo heap da JVM.
- CPU Load (Carga da CPU): a fração da carga do sistema da CPU usada (escala: 0 a 1), exibida em porcentagem.

Visualizar métricas do Amazon CloudWatch para uma execução de trabalho do Ray

Na página de detalhes de uma execução de trabalho, abaixo da seção Run details (Detalhes da execução), você pode visualizar as métricas do trabalho. O AWS Glue Studio envia métricas de trabalho para o Amazon CloudWatch para cada trabalho executado.

O AWS Glue relata as métricas ao Amazon CloudWatch a cada 30 segundos. As métricas do AWS Glue representam valores do delta a partir dos valores relatados anteriormente. Quando apropriado, os painéis de métricas agregam (somam) os valores de 30 segundos para obter um valor para o último minuto inteiro. No entanto, as métricas do Apache Spark que o AWS Glue transfere para o Amazon CloudWatch são geralmente valores absolutos que representam o estado atual no momento em que são relatadas.

> **Note**
>
> Você deve configurar sua conta para acessar o Amazon CloudWatch, conforme descrito em .

Nas trabalhos do Ray, você pode visualizar os seguintes gráficos de métrica agregados. Com elas, você pode criar um perfil do cluster e das tarefas, e pode acessar informações detalhadas sobre cada nó. Os dados de séries temporais que sustentam esses gráficos estão disponíveis no CloudWatch para análise posterior.

Perfil da tarefa: estado da tarefa

Mostra o número de tarefas do Ray no sistema. Cada ciclo de vida da tarefa tem sua própria série temporal.

Perfil da tarefa: Nome da tarefa

Mostra o número de tarefas do Ray no sistema. Somente tarefas pendentes e ativas são mostradas. Cada tipo de tarefa (por nome) recebe sua própria série temporal.

Perfil de cluster: CPUs em uso

Mostra o número de núcleos de CPU usados. Cada nó recebe sua própria série temporal. Os nós são identificados por endereços IP, que são efêmeros e usados apenas para identificação.

Perfil do cluster: uso da memória de armazenamento de objetos

Mostra o uso de memória pelo cache de objetos do Ray. Cada localização da memória (memória física, armazenada em cache no disco e distribuída no Amazon S3) tem sua própria série temporal. O armazenamento de objetos gerencia o armazenamento de dados em todos os nós do cluster. Para obter mais informações, consulte Objects na documentação do Ray.

Perfil do cluster: número de nós

Mostra o número de nós provisionados para o cluster.

Detalhe do nó: uso da CPU

Mostra a utilização da CPU em cada nó como uma porcentagem. Cada série mostra uma porcentagem agregada do uso da CPU em todos os núcleos do nó.

Detalhe do nó: uso de memória

Mostra o uso da memória em cada nó em GB. Cada série mostra a memória agregada entre todos os processos no nó, incluindo tarefas do Ray e o processo de armazenamento do Plasma. Isso não refletirá objetos armazenados em disco ou derramados no Amazon S3.

Detalhe do nó: uso de disco

Mostra o uso de disco em cada nó em GB.

Detalhe do nó: velocidade de E/S do disco

Mostra a E/S de disco em cada nó em KB/s.

Detalhe do nó: throughput de E/S da rede

Mostra a E/S de rede em cada nó em KB/s.

Detalhe do nó: uso da CPU pelo componente do Ray

Mostra o uso da CPU em frações de um núcleo. Cada componente do Ray em cada nó recebe sua própria série temporal.

Detalhe do nó: uso da memória pelo componente do Ray

Mostra o uso da memória em GiB. Cada componente do Ray em cada nó recebe sua própria série temporal.

Detectar e processar dados sigilosos

A transformação Detect PII identifica informações de identificação pessoal (PII) em sua origem dos dados. Você escolhe a entidade de PII para identificar, como deseja que os dados sejam verificados e o que fazer com a entidade de PII identificada pela transformação Detect PII.

A transformação Detect PII permite detectar, mascarar ou remover entidades que você define ou que são predefinidas pela AWS. Isso permite aumentar a conformidade e reduzir a responsabilidade. Por exemplo, talvez você queira garantir a exclusão de informações de identificação pessoal passíveis de leitura em seus dados e deseje mascarar números de previdência social com uma string fixa (por exemplo, xxx-xx-xxxx), números de telefone ou endereços.

Para trabalhar com dados confidenciais fora do AWS Glue Studio, consulte Usar detecção de dados confidenciais fora do AWS Glue Studio

Tópicos

- Como escolher a forma como os dados serão lidos
- Escolha das entidades de PII para detecção
- Especificar o nível da sensibilidade de detecção
- Como escolher o que fazer com dados de PII identificados
- Adicionar substituições de ações refinadas

Como escolher a forma como os dados serão lidos

Ao examinar seu conjunto de dados em busca de dados confidenciais, como informações de identificação pessoal (PII), é possível optar por detectar PII em cada linha ou detectar as colunas que contêm dados de PII.

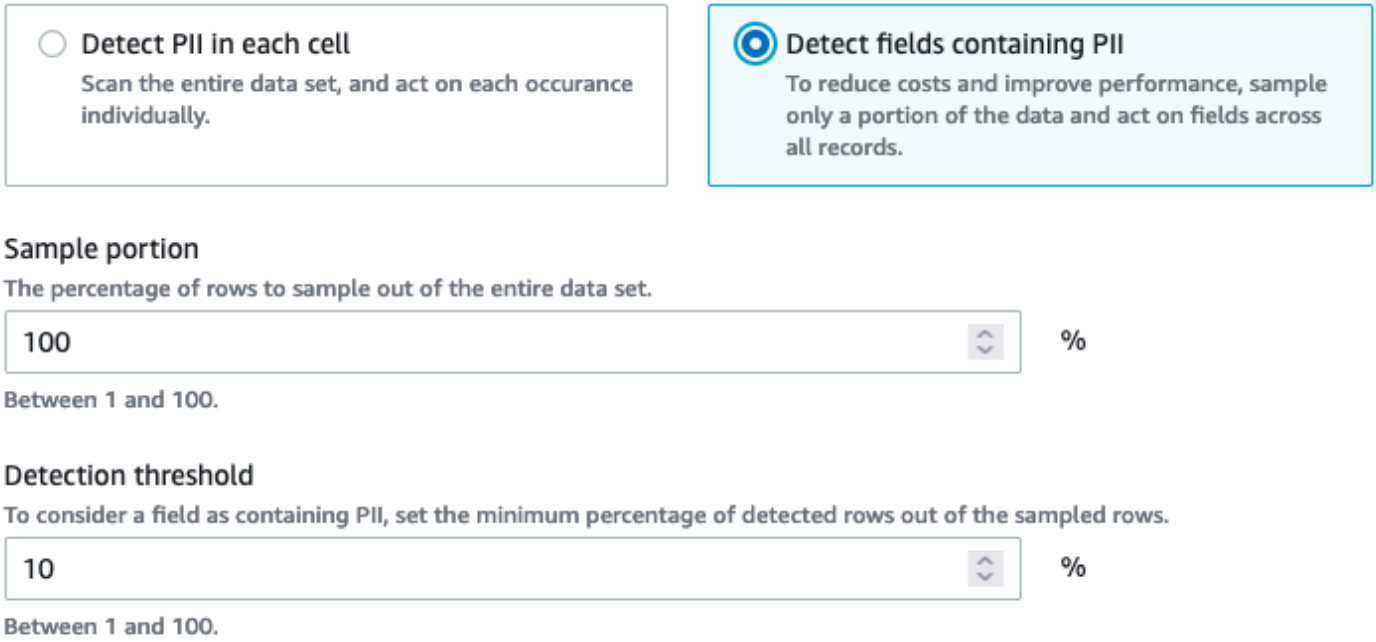

Ao escolher a opção Detect PII in each cell (Detectar PII em cada célula), você está escolhendo verificar todas as linhas na origem dos dados. Esta é uma leitura abrangente para garantir que as entidades de PII sejam identificadas.

Ao escolher a opção Detect fields containing PII (Detectar campos contendo PII), você está optando por ler uma amostra de linhas para entidades de PII. Essa é uma maneira de manter os custos e os recursos baixos e, ao mesmo tempo, identificar os campos em que as entidades de PII são encontradas.

Ao optar por detectar campos que contêm PII, você pode reduzir custos e melhorar a performance por meio da amostragem de uma parte das linhas. Escolher essa opção permitirá que você especifique opções adicionais:

- Sample portion (Porção da amostra): permite especificar a porcentagem de linhas que serão amostradas. Por exemplo, ao inserir "50", estará especificando que deseja 50% das linhas lidas para a entidade PII.
- Detection threshold (Limite de detecção): permite que você especifique a porcentagem de linhas que contêm a entidade PII para que toda a coluna seja identificada como tendo a entidade PII. Por exemplo, ao digitar "10", você estará especificando que o número da entidade de PII, US Phone, nas linhas lidas deve ser 10% ou maior para que o campo seja identificado como tendo a entidade de PII US Phone. Se a porcentagem de linhas que contêm a entidade de PII for inferior a 10%, esse campo não será rotulado como tendo a entidade PII US Phone nele.

Escolha das entidades de PII para detecção

Se optou por Detect PII in each cell (Detectar PII em cada célula), escolha entre uma de três opções:

- Todos os padrões de PII disponíveis: isso inclui entidades da AWS.
- Selecionar categorias: quando você selecionar categorias, os padrões de PII incluirão automaticamente os padrões nas categorias selecionadas.
- Selecionar padrões específicos: somente os padrões selecionados serão detectados.

Para obter uma lista dos tipos de dados confidenciais gerenciados, consulte Tipos de dados gerenciados.

Escolher entre todos os padrões de PII disponíveis

Se você escolher All available PII patterns (Todos os padrões de PII disponíveis), selecione entidades predefinidas pela AWS. É possível selecionar uma, mais de uma ou todas as entidades.

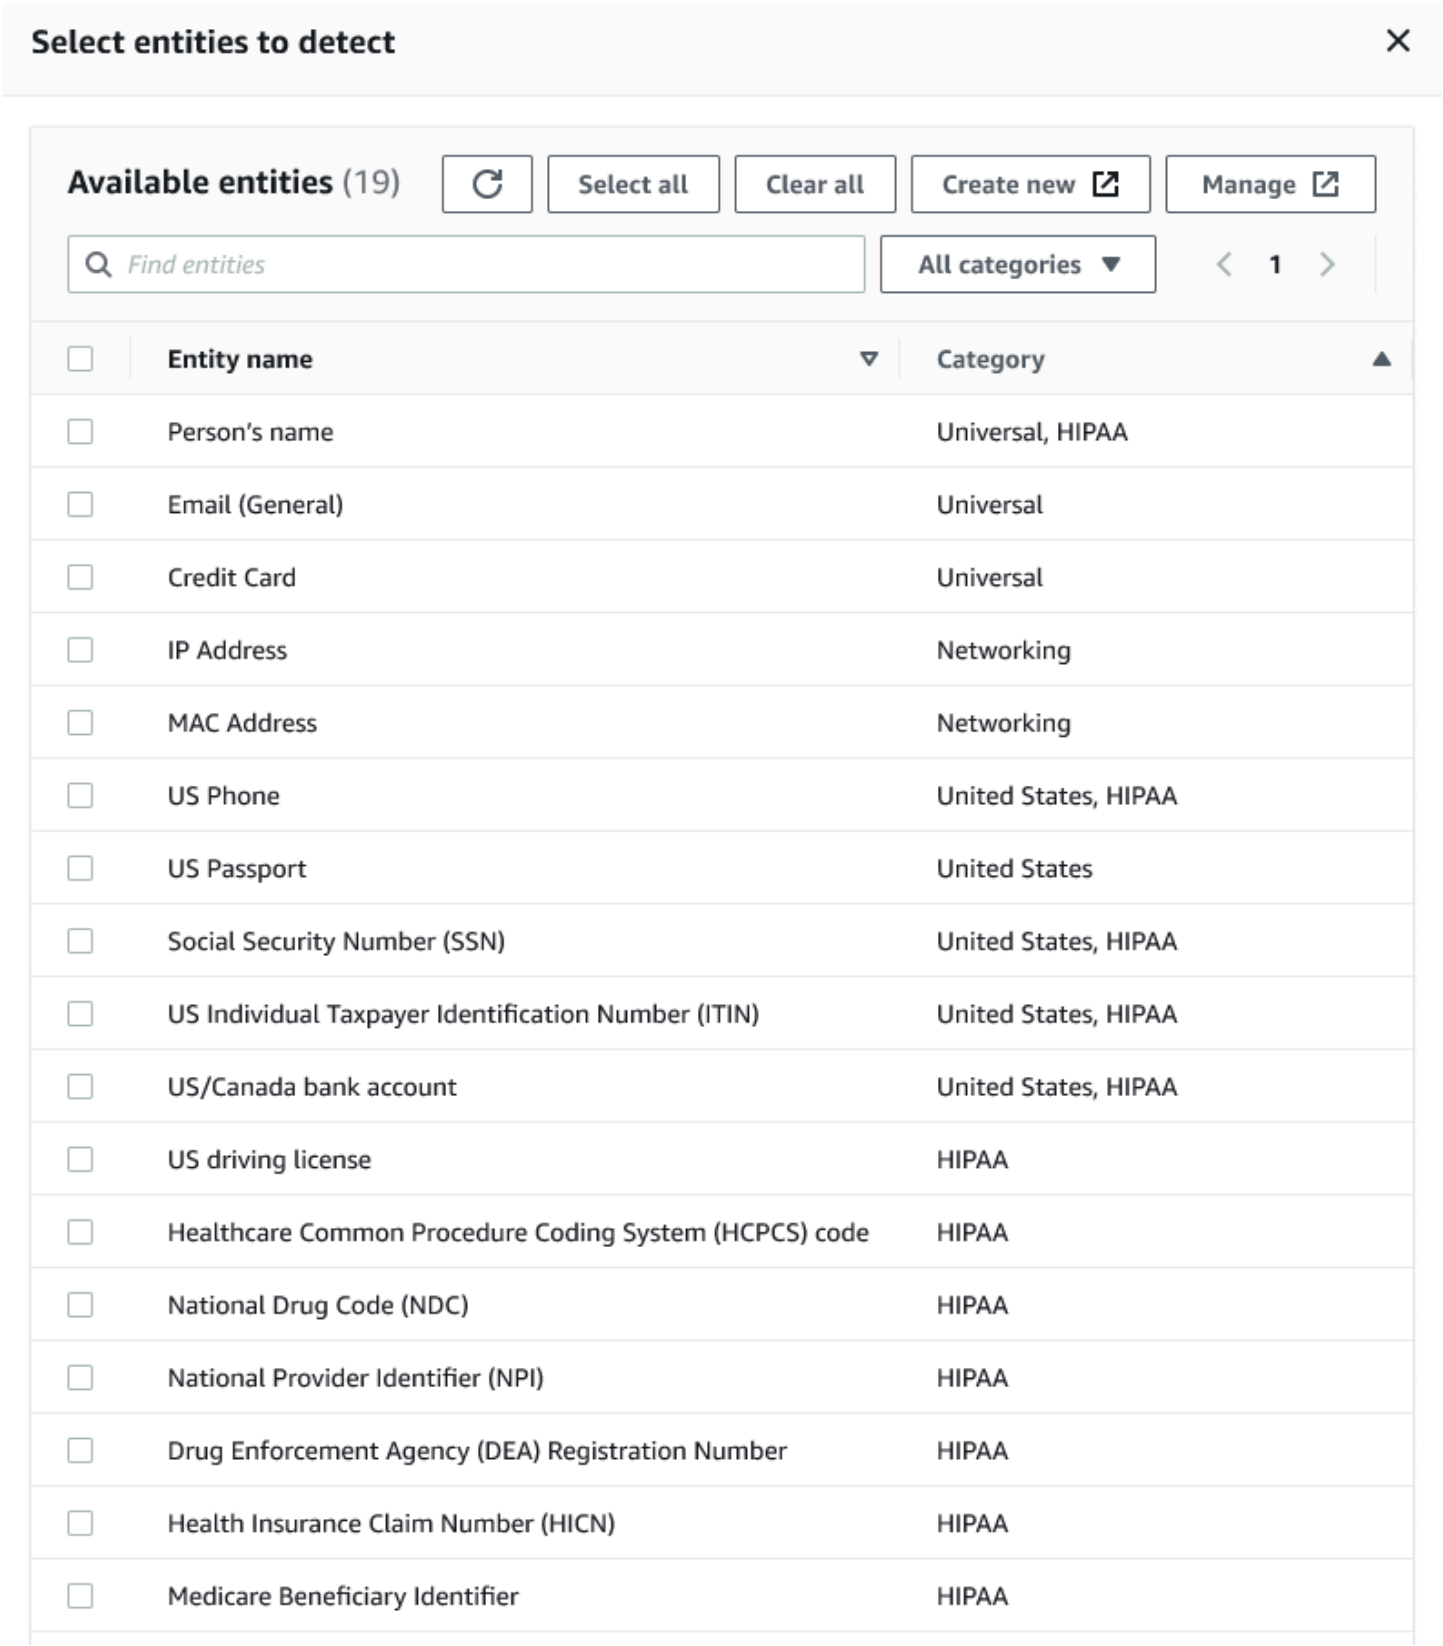
Select entities to detect
Available entities (19)
Select all
Clear all
Create new
Manage
Find entities
All categories
1
Entity name
Category
Person's name
Universal, HIPAA
Email (General)
Universal
Credit Card
Universal
IP Address
Networking
MAC Address
Networking
US Phone
United States, HIPAA
US Passport
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

Selecionar categorias

Se escolheu Select categories (Selecionar categorias) como os padrões de PII a serem detectados, selecione entre as opções no menu suspenso. Observe que algumas entidades podem pertencer a mais de uma categoria. Por exemplo, Person's name (Nome do indivíduo) é uma entidade que pertence às categorias Universal e HIPAA.

- Universal (exemplos: e-mail, cartão de crédito)
- HIPAA (exemplos: carteira de habilitação dos EUA, código do Healthcare Common Procedure Coding System [HCPCS – Sistema de Codificação de Procedimentos Comuns de Saúde])
- Redes (exemplos: endereço IP, endereço MAC)
- Argentina
- Austrália
- Áustria
- Bélgica
- Bósnia
- Bulgária
- Canadá
- Chile
- Colômbia
- Croácia
- Chipre
- Tchéquia
- Dinamarca
- Estônia
- Finlândia
- França
- Alemanha
- Grécia
- Hungria
- Irlanda

- Coreia
- Japão
- México
- Holanda
- Nova Zelândia
- Noruega
- Portugal
- Romênia
- Cingapura
- Eslováquia
- Eslovênia
- Espanha
- Suécia
- Suíça
- Turquia
- Ucrânia
- Estados Unidos
- Reino Unido
- Venezuela

Selecionar padrões específicos

Se escolher Select specific patterns (Selecionar padrões específicos) como os padrões de PII a serem detectados, você pode pesquisar ou navegar em uma lista de padrões que já criou, ou criar um novo padrão de entidade de detecção.

As etapas abaixo descrevem como criar um novo padrão personalizado para detectar dados sigilosos. Você criará o padrão personalizado inserindo um nome para o padrão personalizado, adicionará uma expressão regular e, opcionalmente, definirá palavras de contexto.

1. Para criar um novo padrão, clique no botão Create new (Criar novo)

2. Na página Create detection entity (Criar entidade de detecção), insira o nome da entidade e uma expressão regular. A expressão regular (Regex) é o que o AWS Glue usará para fazer a correspondência de entidades.
3. Clique em Validate (Validar). Se a validação for bem-sucedida, você verá uma mensagem de confirmação informando que a string é uma expressão regular válida. Se a validação não for bem-sucedida, você verá uma mensagem informando que a string não está em conformidade com a formatação adequada e com os caracteres, operadores ou construções aceitos.
4. Você pode optar por adicionar palavras de contexto além da expressão regular. Palavras de contexto podem aumentar a probabilidade de uma correspondência. Elas podem ser úteis em casos nos quais os nomes de campo não descrevem a entidade. Por exemplo, os números da previdência social dos EUA podem ser nomeados “SSN” ou “SS”. A adição dessas palavras de contexto pode ajudar na correspondência da entidade.
5. Clique em Create (Criar) para criar a entidade de detecção. Qualquer entidade criada fica visível no console do AWS Glue Studio. Clique em Detection entities (Entidades de detecção) no menu de navegação à esquerda.

   Você pode editar, excluir ou criar entidades de detecção na página Detection entities (Entidades de detecção). Você também pode pesquisar por um padrão usando o campo de pesquisa.

Especificar o nível da sensibilidade de detecção

É possível definir o nível de sensibilidade ao usar a detecção de dados confidenciais.

- Alto (padrão): detecta mais entidades para casos de uso que exigem um nível mais alto de sensibilidade. Todos os trabalhos do AWS Glue criados após novembro de 2023 são habilitados automaticamente com essa configuração.
- Baixo: detecta menos entidades e reduz os falsos positivos.

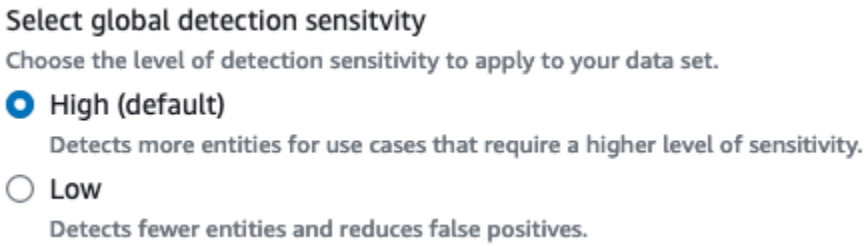

Como escolher o que fazer com dados de PII identificados

Se você optar por detectar PII em toda a fonte de dados, poderá selecionar uma ação global para aplicar:

- Enrich data with detection results (Enriquecer dados com resultados da detecção): se você escolher Detect PII em cada célula, poderá armazenar as entidades detectadas em uma nova coluna.
- Redact detected text (Editar o texto detectado): é possível substituir o valor de PII detectado por uma string especificada no campo opcional de entrada de texto Replacing text (Substituindo texto). Se nenhuma string for especificada, a entidade de PII detectada será substituída por "*******".
- Editar o texto detectado: é possível substituir parte das PII detectadas por uma string especificada por você. Há duas opções possíveis: deixar as extremidades desmascaradas ou mascarar fornecendo um padrão de regex explícito. Este recurso ainda não está disponível no AWS Glue 2.0.
- Aplicar hash criptográfico: você pode passar o valor de PII detectado para uma função de hash criptográfico SHA-256 e substituir o valor pela saída da função.

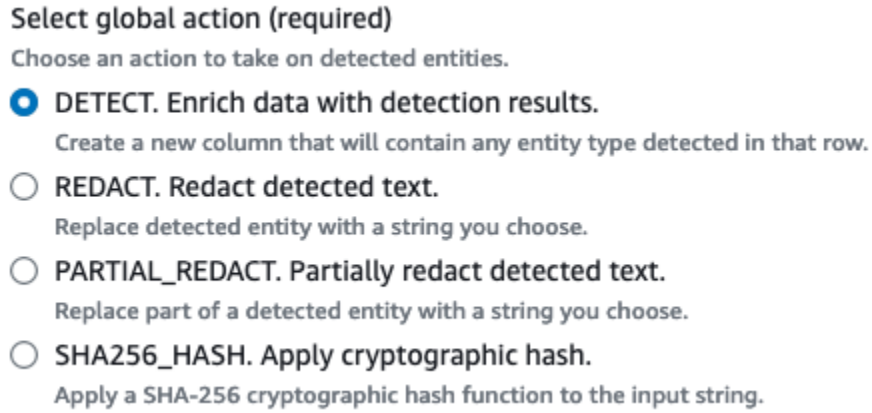

Diferenças entre o AWS Glue versões 2.0 e 3.0+

Os trabalhos do AWS Glue 2.0 retornarão um novo DataFrame com as informações de PII detectadas para cada coluna em uma coluna suplementar. Qualquer redação ou trabalho de hash é visível no script AWS Glue na guia visual.

Os trabalhos do AWS Glue 3.0 e 4.0 retornarão um novo DataFrame com essa mesma coluna suplementar. Uma nova chave para "actionUsed" está presente e pode ser uma de `DETECT`, `REDACT`, `PARTIAL_REDACT` ou `SHA256_HASH`. Se uma ação de mascaramento for selecionada, o DataFrame retornará dados com dados confidenciais mascarados.

Adicionar substituições de ações refinadas

Configurações adicionais de detecção e ação podem ser adicionadas à tabela de substituições de ações refinadas. Isso permite a você:

- Incluir ou excluir determinadas colunas da detecção: um esquema inferido na fonte de dados preencherá a tabela com as colunas disponíveis.
- Especificar configurações específicas que sejam mais refinadas do que usar ações globais: por exemplo, você pode especificar diferentes configurações de redação de texto para diferentes tipos de entidade.
- Especificar uma ação diferente da ação global: se uma ação diferente precisar ser aplicada em um tipo de dados confidenciais diferente, isso pode ser feito aqui. Observe que duas ações diferentes de edição no local (redação e hash) não podem ser usadas na mesma coluna, mas a detecção sempre pode ser usada.

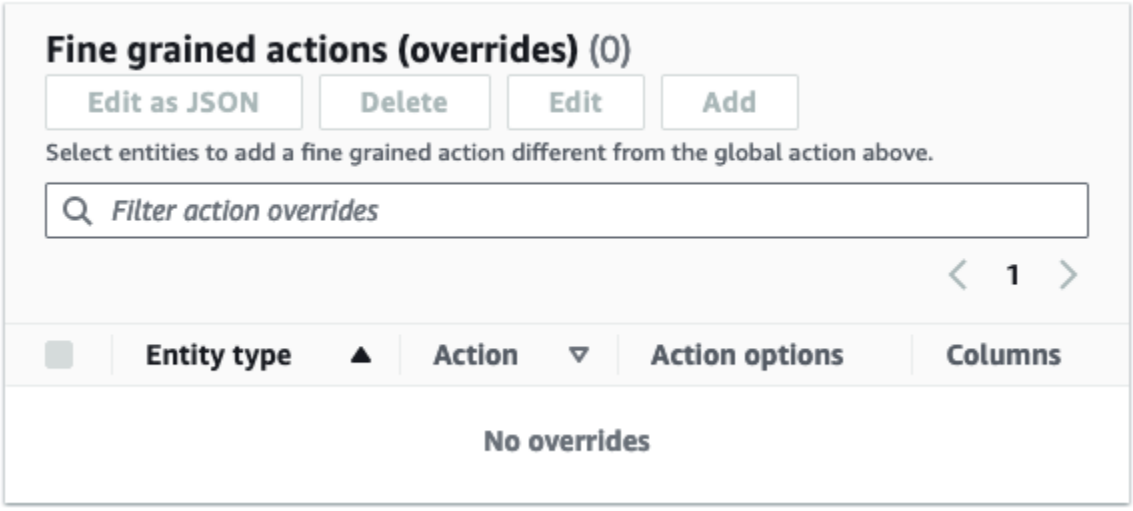

Gerenciar trabalhos de ETL com o AWS Glue Studio

Você pode usar a interface gráfica simples no AWS Glue Studio para gerenciar seus trabalhos de ETL. Usando o menu de navegação, escolhar Jobs (Trabalhos) para visualizar a página Jobs (Trabalhos). Nessa página, você pode ver todos os trabalhos que criou com o AWS Glue Studio ou com o console do AWS Glue. Você pode exibir, gerenciar e executar seus trabalhos nessa página.

Você também pode executar as seguintes tarefas nessa página:

- Iniciar uma execução de trabalho
- Programar execuções de trabalho
- Gerenciar programações de trabalho
- Interromper execuções de trabalho
- Visualizar os trabalhos
- Exibir informações para execuções de trabalho recentes
- Visualizar o script de trabalho
- Modificar as propriedades do trabalho
- Salvar o trabalho
- Clonar um trabalho
- Excluir trabalhos

Iniciar uma execução de trabalho

No AWS Glue Studio, você pode executar seus trabalhos sob demanda. Um trabalho pode ser executado várias vezes, e cada vez que você o executa, o AWS Glue coleta informações sobre as atividades e a performance do trabalho. Essa informação é referida como uma execução de trabalho e é identificada por um ID de execução de trabalho.

Você pode iniciar uma execução de trabalho no AWS Glue Studio das seguintes formas:

- Na página Jobs (Trabalhos), escolha o trabalho que você deseja iniciar e, em seguida, escolha o botão Run job (Executar trabalho).
- Se você estiver visualizando um trabalho no editor visual e ele estiver salvo, você pode escolher o botão Run (Executar) para iniciar uma execução de trabalho.

Para obter mais informações sobre execuções de trabalhos, consulte Trabalhar com trabalhos no console do AWS Glue no Guia do desenvolvedor do AWS Glue.

Programar execuções de trabalho

No AWS Glue Studio, você pode criar uma programação para que seus trabalhos sejam executados em horários específicos. Você pode especificar restrições, como a quantidade de vezes que os trabalhos são executados. Essas restrições são feitas com base no `cron` e têm as mesmas limitações que o `cron`. Por exemplo, se você optar por executar seu trabalho no dia 31 de cada mês, lembre-se de que alguns meses não têm 31 dias. Para obter mais informações sobre o `cron`, consulte Expressões do Cron no Guia do desenvolvedor do AWS Glue.

Para executar trabalhos de acordo com uma programação

1. Crie uma programação de trabalho usando um dos seguintes métodos:
   - Na página Jobs (Trabalhos), escolha o trabalho para o qual você deseja criar uma programação, escolha Actions (Ações) e depois Schedule job (Programar trabalho).
   - Se você estiver visualizando um trabalho no editor visual e ele estiver salvo, escolha a guia Schedules (Programações). Em seguida, escolha Create Schedule (Criar programação).
2. Na página Schedule job run (Programar execução de trabalho), insira as seguintes informações:
   - Name (Nome): insira um nome para a programação do trabalho.
   - Frequency (Frequência): insira a frequência da programação do trabalho. Você pode escolher uma das seguintes opções:
     - Hourly (Por hora): o trabalho será executado a cada hora, começando em um minuto específico. Você pode especificar o Minute (Minuto) da hora em que o trabalho deve ser executado. Por padrão, quando você escolhe por hora, o trabalho é executado no início da hora (minuto 0).
     - Daily (Diariamente): o trabalho será executado todos os dias, iniciando em um determinado momento. Você pode especificar o Minute (Minuto) da hora em que o trabalho deve ser executado e a Start hour (Hora de início) do trabalho. As horas são especificadas usando um relógio de 23 horas, em que você usa os números 13 a 23 para as horas após meio-dia. O valor padrão para minuto e hora é zero, o que significa que se você selecionar Daily (Diariamente), por padrão, o trabalho será executado à meia-noite.
     - Weekly (Semanal): o trabalho será executado todas as semanas em um ou mais dias. Além das mesmas configurações descritas anteriormente para Daily (Diariamente), você pode

escolher os dias da semana em que o trabalho será executado. Você pode escolher um ou mais dias.

- Monthly (Mensalmente): o trabalho será executado todos os meses em um dia específico. Além das mesmas configurações descritas anteriormente para Daily (Diariamente), você pode escolher o dia do mês em que o trabalho será executado. Especifique o dia como um valor numérico de 1 a 31. Se você selecionar um dia que não existe em um mês, por exemplo, o 30º dia de fevereiro, então o trabalho não será executado nesse mês.
- Custom (Personalizado): insira uma expressão para sua programação de trabalho usando a sintaxe do `cron`. As expressões do Cron permitem que você crie programações mais complicadas, como o último dia do mês (em vez de um dia específico do mês) ou a cada terceiro mês no 7º e 21º dias do mês.

  Consulte Expressões do Cron no Guia do desenvolvedor do AWS Glue

- Description (Descrição): como opção, você pode inserir uma descrição para a programação do trabalho. Se você planeja usar a mesma programação para vários trabalhos, uma descrição facilita determinar o que a programação do trabalho faz.

3. Escolha Create schedule (Criar programação) para salvar a programação de trabalho.
4. Depois de criar a programação, uma mensagem de êxito é exibida na parte superior da página do console. Você pode escolher Job details (Detalhes do trabalho) nesse banner, para exibir os detalhes do trabalho. Isso abre a página do editor de trabalhos visual, com a guia Schedules (Programações) selecionada.

Gerenciar programações de trabalho

Depois de criar programações para um trabalho, você pode abri-lo no editor visual e escolher a guia Schedules (Programações) para gerenciar as programações.

Na guia Schedules (Programações) do editor visual, você pode executar as seguintes tarefas:

- Criar uma nova programação.

  Escolha Create schedule (Criar programação) e insira as informações da programação, conforme descrito em the section called “Programar execuções de trabalho”.

- Editar uma programação existente.

  Escolha a programação que você deseja editar e selecione Action (Ação) e, em seguida, Edit schedule (Editar programação). Quando você opta por editar uma programação existente,

Frequency (Frequência) exibe Custom (Personalizada) e a programação é exibida como uma expressão do `cron`. Você também pode modificar a expressão do `cron` ou especificar uma nova programação usando o botão Frequency (Frequência). Ao concluir as alterações, escolha Update schedule (Atualizar programação).

- Pausar uma programação ativa.

  Escolha uma programação ativa, selecione Action (Ação) e, em seguida, Pause schedule (Pausar programação). A programação é desativada instantaneamente. Escolha o botão refresh (reload) [atualizar (recarregar)] para ver o status da programação de trabalho atualizada.

- Retomar uma programação pausada.

  Escolha uma programação desativada, selecione Action (Ação) e, em seguida, resume schedule (Retomar programação). A programação é ativada instantaneamente. Escolha o botão refresh (reload) [atualizar (recarregar)] para ver o status da programação de trabalho atualizada.

- Excluir uma programação.

  Escolha a programação que você deseja remover, selecione Action (Ação) e, em seguida, Delete schedule (Excluir programação). A programação é excluída instantaneamente. Escolha o botão refresh (reload) [atualizar (recarregar)] para ver a lista de programações de trabalho atualizada. A programação terá o status Deleting (Excluíndo) até que tenha sido completamente removida.

Interromper execuções de trabalho

Você pode interromper um trabalho antes que ele tenha concluído sua execução. Você pode escolher essa opção se souber que o trabalho não está configurado corretamente ou se ele está demorando muito para ser concluído.

Na página Monitoring (Monitoramento), na lista Job runs (Execuções de trabalho), selecione o trabalho que deseja interromper, escolha Actions (Ações) e Stop run (Interromper execução).

Visualizar os trabalhos

Você pode visualizar todos os trabalhos na página Jobs (Trabalhos). Você pode acessar essa página escolhendo Jobs (Trabalhos) no painel de navegação.

Na página Jobs (Trabalhos), você poderá ver todos os trabalhos criados na sua conta. A list Your jobs (Seus trabalhos) mostra o nome do trabalho, o tipo, o status da última execução desse trabalho

e as datas em que ele foi criado e modificado pela última vez. Você pode escolher o nome de um trabalho para ver informações detalhadas sobre ele.

Você também pode usar o painel Monitoring (Monitoramento) para exibir todos os trabalhos. Você pode acessar o painel escolhendo Monitoring (Monitoramento) no painel de navegação.

Personalizar a exibição do trabalho

Você pode personalizar como os trabalhos são exibidos na seção Your jobs (Seus trabalhos) da página Jobs (Trabalhos). Além disso, você pode inserir um texto no campo de pesquisa de texto para exibir somente trabalhos com um nome que contenha esse texto.

Se você escolher o ícone de configurações

na seção Your jobs (Seus trabalhos), poderá personalizar como AWS Glue Studio exibe as informações na tabela. Você pode optar por quebrar as linhas de texto na exibição, alterar o número de trabalhos exibidos na página e especificar quais colunas serão exibidas.

Exibir informações para execuções de trabalho recentes

Um trabalho pode ser executado várias vezes à medida que novos dados são adicionados no local de origem. Cada vez que um trabalho é executado, um ID exclusivo é atribuído à execução do trabalho e as informações sobre essa execução são coletadas. É possível exibir essas informações usando os métodos a seguir:

- Escolha a guia Runs (Execuções) do editor visual para exibir as informações de execução do trabalho exibido no momento.

  Na guia Runs (Execuções), página Recent job runs (Execuções de trabalho recentes), há um cartão para cada execução de trabalho. As informações exibidas na guia Runs (Execuções) incluem:
  - ID de execução de trabalho
  - Número de tentativas para execução desse trabalho
  - Status da execução do trabalho
  - Horário de início e de término da execução do trabalho
  - O runtime do trabalho
  - Um link para os arquivos de log do trabalho
  - Um link para os arquivos de log de erros do trabalho

  - O erro retornado para trabalhos com falha
- É possível selecionar uma execução de trabalho para ver informações adicionais sobre o trabalho, incluindo:
  - Argumentos de entrada
  - Logs contínuos
  - Métricas: é possível ver visualizações de métricas básicas. Para obter ter mais informações sobre as métricas incluídas, consulte the section called “Visualizar métricas do Amazon CloudWatch para uma execução de trabalho do Spark”.
  - Interface do usuário do Spark: é possível visualizar os logs do Spark do seu trabalho na interface do usuário do Spark. Para obter mais informações sobre o uso da interface do usuário Web do spark , consulte o the section called “Monitorar com a interface do usuário do Spark”. Habilite esse recurso seguindo o procedimento em the section called “Habilitar a interface do usuário do Spark para trabalhos”.

Você pode selecionar Visualizar detalhes para ver informações semelhantes na página de detalhes da execução do trabalho. Como alternativa, você pode navegar até a página de detalhes da execução do trabalho por meio da página Monitoramento. No painel de navegação, escolha Monitoring (Monitoramento). Role para baixo até a lista Job runs (Execuções do trabalho). Escolha o trabalho e, em seguida, escolha View run details (Visualizar os detalhes da execução). O conteúdo está descrito em Visualizar os detalhes de uma execução de trabalho.

Para obter mais informações sobre os logs de trabalhos, consulte Visualizar os logs de execuções de trabalho.

Visualizar o script de trabalho

Depois de fornecer informações para todos os nós no trabalho, o AWS Glue Studio gera um script que é usado pelo trabalho para ler os dados da origem, transformá-los e gravá-los no local de destino. Se você salvar o trabalho, poderá exibir esse script a qualquer momento.

Para exibir o script gerado para seu trabalho

1. No painel de navegação, escolha Jobs (Trabalhos).
2. Na página Jobs (Trabalhos), na lista Your jobs (Seus trabalhos), escolha o nome do trabalho que você deseja revisar. Como alternativa, você pode selecionar um trabalho na lista, escolher o menu Actions (Ações) e, em seguida, escolher Edit job (Editar trabalho).

3. Na página do editor visual, escolha a guia Script na parte superior para exibir o script de trabalho.

   Se quiser editar o script de trabalho, consulte Guia de programação do AWS Glue.

Modificar as propriedades do trabalho

Os nós no diagrama de trabalho definem as ações executadas pelo trabalho, mas há várias propriedades que você também pode configurar para o trabalho. Essas propriedades determinam o ambiente em que o trabalho é executado, os recursos que ele usa, as configurações de limite, as configurações de segurança e muito mais.

Para personalizar o ambiente de execução do trabalho

1. No painel de navegação, escolha Jobs (Trabalhos).
2. Na página Jobs (Trabalhos), na lista Your jobs (Seus trabalhos), escolha o nome do trabalho que você deseja revisar.
3. Na página do editor visual, escolha a guia Job details Detalhes do trabalho) na parte superior do painel de edição do trabalho.
4. Modifique as propriedades do trabalho, conforme necessário.

   Para obter mais informações sobre as propriedades do trabalho, consulte Definir propriedades do trabalho no Guia do desenvolvedor do AWS Glue.
5. Expanda a seção Advanced properties (Propriedades avançadas), se você precisar especificar essas propriedades de trabalho adicionais:

   - Script filename (Nome de arquivo do script): o nome do arquivo que armazena o script do trabalho no Amazon S3.
   - Script path (Caminho do script): o local do Amazon S3 em que o script do trabalho é armazenado.
   - Job metrics (Métricas de trabalho): (indisponível para trabalhos de shell do Python) ativa a criação de métricas do Amazon CloudWatch quando esse trabalho é executado.
   - Continuos logging (Registro em log contínuo): (indisponível para trabalhos de shell do Python) ativa o registro em log contínuo no CloudWatch, para que os logs estejam disponíveis para visualização antes que o trabalho seja concluído.

- Spark UI (IU do Spark) e Spark UI logs path (Caminho de logs da IU do Spark): (indisponível para trabalhos de shell do Python) ativa o uso da interface do usuário do Spark para monitorar o trabalho e especifica o local para os logs da interface do usuário do Spark.
- Maximum concurrency (Simultaneidade máxima): define o número máximo de execuções simultâneas permitidas para o trabalho.
- Temporary path (Caminho temporário): o local de um diretório de trabalho no Amazon S3 onde os resultados intermediários temporários serão gravados quando o AWS Glue executar o script.
- Delay notification threshold (minutes) (Limite de notificação de atraso [minutos]): especifica um limite de atraso para o trabalho. Se o trabalho for executado por mais tempo do que o especificado pelo limite, o AWS Glue envia uma notificação de atraso para o trabalho ao CloudWatch.
- Security configuration (Configuração de segurança) e Server-side encryption (Criptografia do lado do servidor): use esses campos para escolher as opções de criptografia do trabalho.
- Use Glue Data Catalog as the Hive metastore (Usar o Glue Data Catalog como metastore do Hive): escolha essa opção se quiser usar o AWS Glue Data Catalog como uma alternativa ao Apache Hive Metastore.
- Additional network connection(Conexão de rede adicional): para uma origem dos dados em uma VPC, você pode especificar uma conexão do tipo `Network` a fim de garantir que seu trabalho acesse seus dados por meio da VPC.
- Python library path (Caminho da biblioteca do Python), Dependent jars path (Caminho de arquivos jar dependentes, não disponível para trabalhos de shell do Python) ou Referenced files path (Caminho de arquivos referenciados): use esses campos para especificar o local dos arquivos adicionais usados pelo trabalho quando ele executa o script.
- Job Parameters (Parâmetros do trabalho): você pode adicionar um conjunto de pares de chave-valor que são transmitidos como parâmetros nomeados para o script. Nas chamadas do Python para AWS Glue APIs, é melhor transmitir os parâmetros explicitamente por nome. Para obter mais informações sobre como usar parâmetros em um script de trabalho, consulte Transmitir e acessar parâmetros do Python no AWS Glue no Guia do desenvolvedor do AWS Glue.
- Tags: você pode adicionar tags ao trabalho para ajudar a organizá-las e identificá-las.

6. Depois de modificar as propriedades do trabalho, salve-o.

Armazenar arquivos de ordem aleatória do Spark no Amazon S3

Alguns trabalhos de ETL exigem leitura e combinação de informações de várias partições, por exemplo, ao usar uma transformação de união. Essa operação é referida como shuffling (ordenamento aleatório). Durante uma geração de ordem aleatória, os dados são gravados no disco e transferidos pela rede. Com o AWS Glue versão 3.0, você pode configurar o Amazon S3 como um local de armazenamento para esses arquivos. O AWS Glue fornece um gerenciador de ordenamento aleatório que grava e lê arquivos aleatórios de e para o Amazon S3. Gravar e ler arquivos de ordem aleatória do Amazon S3 é mais lento (de 5% a 20%) em comparação com o disco local (ou o Amazon EBS, que é altamente otimizado para o Amazon EC2). No entanto, o Amazon S3 fornece capacidade de armazenamento ilimitada, assim você não precisa se preocupar com erros de "`No space left on device`" ao executar seu trabalho.

Para configurar seu trabalho a fim de usar o Amazon S3 para arquivos de ordem aleatória

1. Na página Jobs (Trabalhos), na lista Your jobs (Seus trabalhos), escolha o nome do trabalho que você deseja modificar.
2. Na página do editor visual, escolha a guia Job details Detalhes do trabalho) na parte superior do painel de edição do trabalho.

   Role para baixo até a seção Job parameters (Parâmetros do trabalho).
3. Especifique os seguintes pares de chave-valor.

   - `--write-shuffle-files-to-s3` — `true`

     Esse é o parâmetro principal que configura o gerenciador de ordenamento aleatório no AWS Glue a fim de usar buckets do Amazon S3 para gravar e ler dados de ordem aleatória. Pr padrão, esse parâmetro tem um valor `false`.
   - (Opcional) `--write-shuffle-spills-to-s3`: `true`

     Esse parâmetro permite que você descarregue arquivos de despejo em buckets do Amazon S3, o que fornece resiliência adicional ao seu trabalho do Spark no AWS Glue. Isso só é necessário para grandes workloads que despejam muitos dados no disco. Pr padrão, esse parâmetro tem um valor `false`.
   - (Opcional) `--conf spark.shuffle.glue.s3ShuffleBucket`: `S3://<`*`shuffle-bucket`*`>`

Esse parâmetro especifica o bucket do Amazon S3 que deve ser usado ao gravar os arquivos de ordem aleatória. Se você não definir esse parâmetro, o local será a pasta `shuffle-data` no local especificado como caminho temporário (`--TempDir`).

> **Note**
>
> Certifique-se de que o local do bucket de ordem aleatória está na mesma região da Região da AWS na qual o trabalho é executado.
> Além disso, o serviço de ordenamento aleatório não limpa os arquivos após a conclusão da execução do trabalho, portanto, você deve configurar as políticas de ciclo de vida de armazenamento do Amazon S3 no local do bucket de ordem aleatória. Para obter mais informações, consulte Gerenciar ciclo de vida de armazenamento no Manual do usuário do Amazon S3.

Salvar o trabalho

Um aviso em vermelho informando Job has not being saved (O trabalho não foi salvo) é exibido à esquerda do botão Save (Salvar) até que você salve o trabalho.

Para salvar seu trabalho

1. Forneça todas as informações necessárias nas guias Visual e Job details (Detalhes do trabalho).
2. Clique no botão Salvar.

   Depois de salvar o trabalho, o aviso “not saved” (não salvo) muda para exibir a hora e a data em que o trabalho foi salvo pela última vez.

Se você sair do AWS Glue Studio antes de salvar seu trabalho, na próxima vez que você entrar no AWS Glue Studio, uma notificação será exibida. A notificação indica que há um trabalho não salvo e pergunta se você deseja restaurá-lo. Se optar por restaurar o trabalho, poderá continuar a editá-lo.

Solucionar problemas com erros ao salvar um trabalho

Se escolher o botão Save (Salvar), mas houver algumas informações necessárias faltando no trabalho, um aviso em vermelho aparecerá na guia onde as informações estão faltando. O número no aviso indica quantos campos faltantes foram detectados.

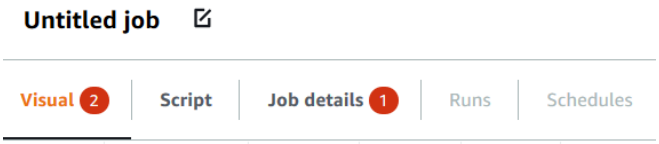

- Se um nó no editor visual não estiver configurado corretamente, a guia Visual exibirá um aviso em vermelho e o nó com o erro exibirá um símbolo de aviso ⚠.

  1. Escolher o nó. No painel de detalhes do nó, um aviso em vermelho aparece na guia onde as informações ausentes ou incorretas estão localizadas.
  2. Escolha a guia no painel de detalhes do nó que mostra um aviso em vermelho e localize os campos problemáticos, que estarão destacados. Uma mensagem de erro abaixo dos campos fornece informações adicionais sobre o problema.

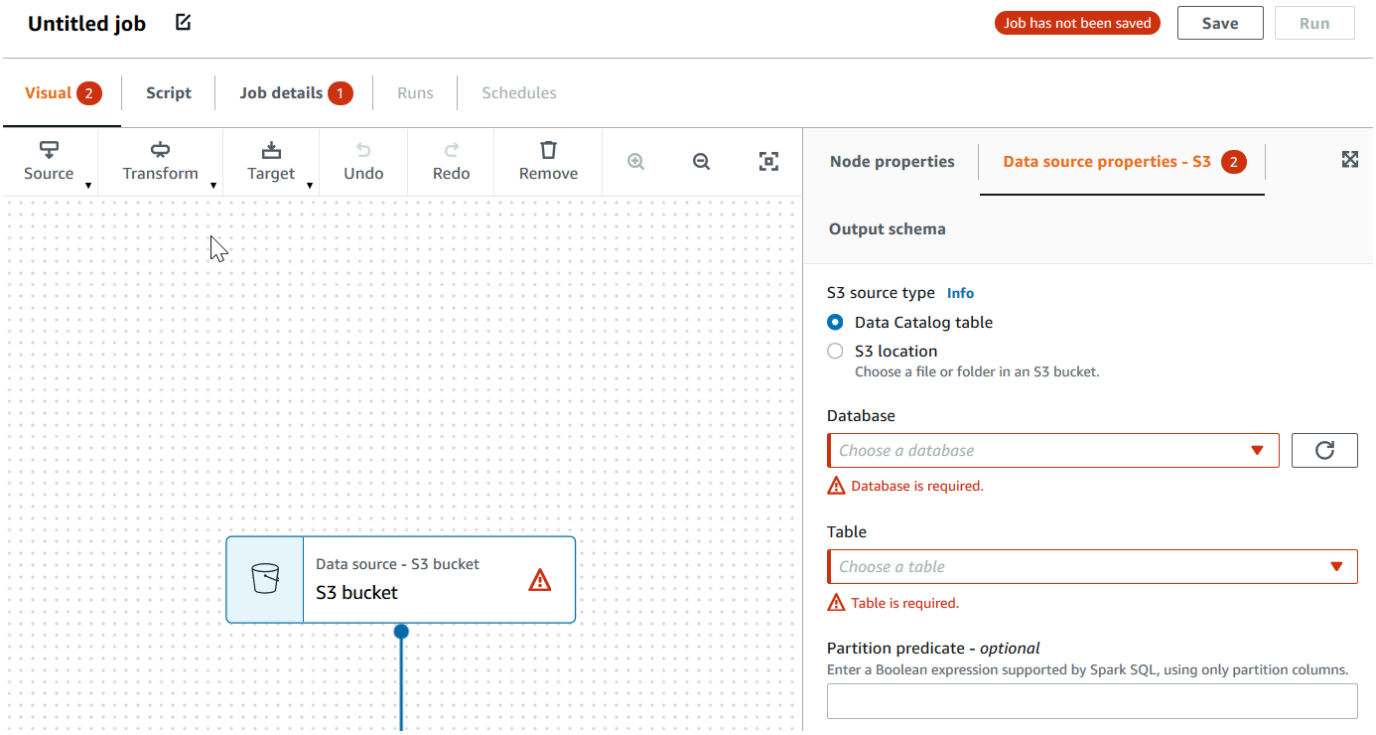

- Se houver um problema com as propriedades do trabalho, a guia Job details (Detalhes do trabalho) mostrará um aviso em vermelho. Escolha essa guia e localize os campos problemáticos,

que estarão destacados. As mensagens de erro abaixo dos campos fornecem informações adicionais sobre o problema.

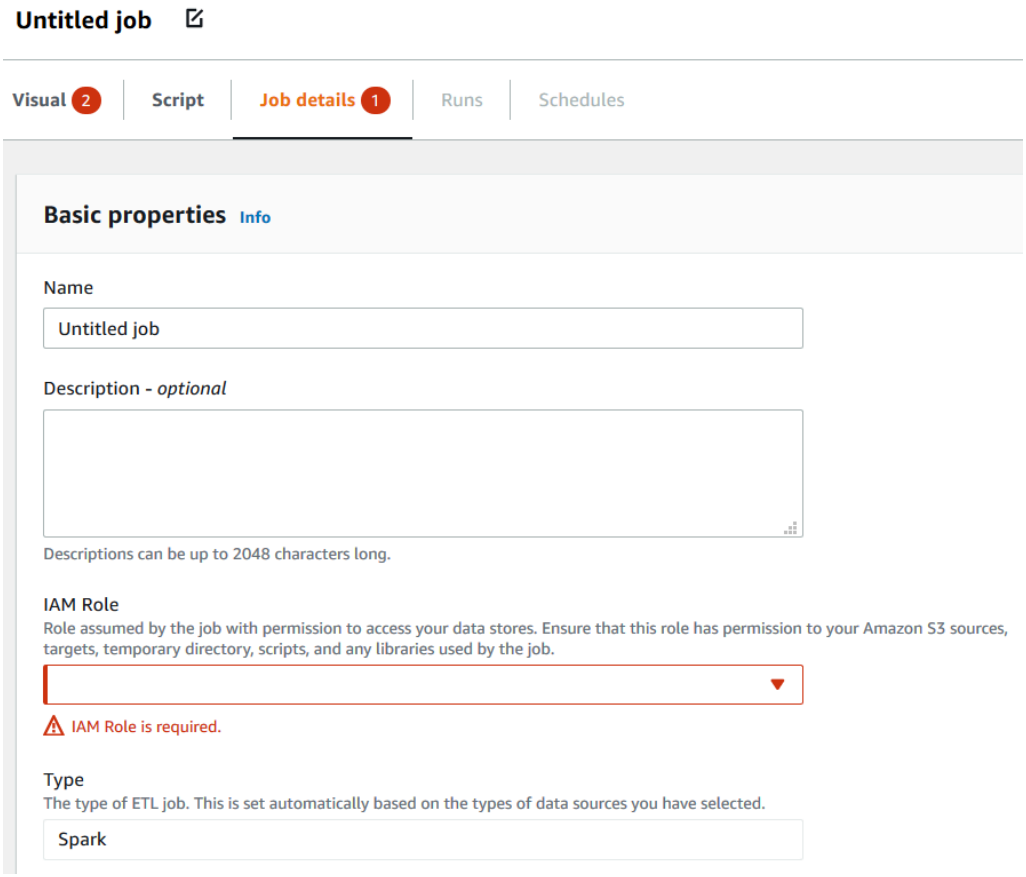

Clonar um trabalho

Você pode usar a ação Clone job (Clonar trabalho) para copiar um trabalho existente em um novo trabalho.

Para criar um trabalho por cópia de um trabalho existente

1. Na página Jobs (Trabalhos), na lista Your jobs (Seus trabalhos), escolha o nome do trabalho que você deseja duplicar.
2. No menu Actions (Ações), escolha Clone job (Clonar trabalho).
3. Insira um nome para o novo trabalho. Em seguida, você poderá salvar ou editar o trabalho.

Excluir trabalhos

É possível remover trabalhos que não sejam mais necessários. É possível excluir um ou mais trabalhos em uma única operação.

Para remover trabalhos do AWS Glue Studio

1. Na página Jobs (Trabalhos), na lista Your jobs (Seus trabalhos), escolha o nome do trabalho que você deseja excluir.
2. No menu Actions (Ações), escolha Delete job (Excluir trabalho).
3. Confirme que você deseja excluir o trabalho digitando **`delete`**.

Você também pode excluir um trabalho salvo ao visualizar a guia Job details (Detalhes do trabalho) desse trabalho no editor visual.

Executar trabalhos no AWS Glue

Um trabalho do AWS Glue encapsula um script que se conecta aos dados de origem, os processa e, depois, os grava no destino de dados. Normalmente, um trabalho executa scripts de extração, transformação e carga (ETL). Os trabalhos também podem executar scripts Python de uso geral (trabalhos do shell do Python). Os acionadores do AWS Glue podem iniciar trabalhos com base em uma programação ou um evento, ou sob demanda. É possível monitorar trabalhos para entender as métricas do runtime, status de conclusão, duração e hora de início.

Você pode usar scripts gerados pelo AWS Glue ou fornecer os seus próprios scripts. Com um esquema de fonte e um local de destino ou esquema, o gerador de códigos do AWS Glue pode criar automaticamente um script da API Apache Spark (PySpark). Você pode usar esse script como ponto de partida e editá-lo para atingir seus objetivos.

O AWS Glue pode escrever arquivos de saída em vários formatos de dados, incluindo JSON, CSV, ORC (Optimized Row Columnar), Apache Parquet e Apache Avro. Para alguns formatos de dados, é possível gravar formatos de compressão comuns.

O AWS Glue oferece suporte aos seguintes tipos de trabalhos:

- Um trabalho do Spark é executado em um ambiente Apache Spark gerenciado pelo AWS Glue. Ele processa os dados em lotes.
- Um trabalho de ETL de streaming é semelhante a um trabalho do Spark, exceto que ele executa ETL em streams de dados. Ele usa o framework do Apache Spark Structured Streaming. Alguns recursos de trabalho do Spark não estão disponíveis para trabalhos ETL de streaming.
- O trabalho do Shell do Python executa scripts Python como shell e é compatível com uma versão de Python que depende da versão do AWS Glue que você estiver usando. É possível usar esses trabalhos para programar e executar tarefas que não exigem um ambiente do Apache Spark.
- O Ray é uma estrutura de computação distribuída de código aberto que você pode usar para aumentar verticalmente a escala das workloads, com foco no Python. AWS Glue Os trabalhos e as sessões interativas do Ray permitem que você use o Ray no AWS Glue.

As seções a seguir fornecem mais informações sobre trabalhos de ETL e do Ray no AWS Glue.

Tópicos

- Versões do AWS Glue
- Lidar com trabalhos do Spark no AWS Glue

- Trabalhar com trabalhos do Ray no AWS Glue
- Configurar propriedades de trabalho para trabalhos de shell Python no AWS Glue
- Como monitorar o AWS Glue
- Status de execução de trabalhos do AWS Glue

Versões do AWS Glue

Você pode configurar o parâmetro de versão do AWS Glue ao adicionar ou atualizar um trabalho. A versão AWS Glue determina as versões do Apache Spark e do Python compatíveis com o AWS Glue. A versão do Python indica a versão compatível com trabalhos do tipo Spark. A tabela a seguir lista as versões disponíveis do AWS Glue, as versões correspondentes do Spark e do Python e outras alterações na funcionalidade.

Versões do AWS Glue

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
AWS Glue 5.0	• Spark 3.5.4 • Python 3.11 • Scala 2.12.18	Java 17	Além das atualizações na estrutura, há otimizações e atualizações incorporadas nessa versão do AWS Glue, como: • Suporte ao Amazon SageMaker Unified Studio. • Suporte ao Amazon SageMaker Lakehouse • Os formatos de tabelas abertas (OTF, na sigla

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			em inglês) foram atualizados para as versões Hudi 0.15.0, Iceberg 1.7.1 e Delta Lake 3.3.0 • Controle de acesso refinado nativo do Spark usando o Lake Formation. • Suporte à Concessão de Acesso • Suporte à instalação de bibliotecas Python adicionais usando o arquivo `requirements.txt` . • Suporte à linhagem de dados no Amazon DataZone. • Suporte ao bucket de Tabelas do Amazon S3 • Suporte a visualizações com múltiplos dialetos no Catálogo de Dados do AWS Glue

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			Limitações São limitações do AWS Glue 5.0: • Quadro dinâmico do Glue / O controle de acesso em nível de tabela baseado no `GlueContext` com permissões do AWS Lake Formation compatíveis com o Glue 4.0 ou anteriores não é compatível com o Glue 5.0. Use o novo controle de acesso refinado (FGAC) nativo para o Spark no Glue 5.0. Para obter mais informações sobre como migrar para o AWS Glue versão 5.0, consulte Migrar o AWS Glue para trabalhos do Spark para o AWS Glue versão 5.0.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade

AWS Glue 4.0	Versões do ambiente Spark
	• Spark 3.3.0
	• Python 3.10
		Java 8	O AWS Glue 4.0 oferece várias otimizações e atualizações incorporadas a essa versão do AWS Glue, como:
			• Muitas atualizações de funcionalidade do Spark 3.1 para o Spark 3.3:
			  • Várias melhorias de funcionalidade quando emparelhado com o pandas. Para obter mais informações, consulte What's New in Spark 3.3 (O que há de novo no Spark 3.3).
			  • Otimizações adicionais desenvolvidas no Amazon EMR.
			  • Atualização para o EMR File System (EMRFS) 2.53.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			• Migração do Log4j 1.x para o Log4j 2 • Várias atualizações do módulo do Python a partir do AWS Glue 3.0, como uma versão atualizada do Boto. • Atualização de vários conectores, incluindo o conector padrão do Amazon Redshift. Consulte Apêndice C: Atualizações de conectores. • Atualização de vários drivers JDBC. Consulte Apêndice B: upgrades do driver JDBC. • Atualizado com um novo conector do Amazon Redshift e driver JDBC. • Suporte nativo para estruturas de data lakes abertos com o Apache Hudi, o Delta Lake e o Apache Iceberg.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			• Suporte nativo para o Cloud Shuffle Storage Plugin baseado no Amazon S3 (um plug-in do Apache Spark) para usar o Amazon S3 para capacidade de armazenamento elástico e aleatório. Limitações As limitações com o AWS Glue 4.0 são as seguintes: • As transformações de machine learning e as informações de identificação pessoal (PII) do AWS Glue ainda não estão disponíveis no AWS Glue 4.0. Para obter mais informações sobre como migrar para o AWS Glue versão

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			4.0, consulte Migrar trabalhos do AWS Glue para Spark para o AWS Glue versão 4.0.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
	Versões do ambiente Ray • Ray 2.4.0 Python 3.9	N/D	Crie e execute aplicativos Python distribuídos com AWS Glue para Ray. • Suporta distribuição de dados Ray-2.4.0 (`ray[data]`) com Python 3.9. Para obter mais informações sobre essa versão do Ray, consulte Ray-2.4.0 no repositório do Ray no GitHub. • Suporta a instalação de bibliotecas Python adicionais no ambiente de runtime do `Ray2.4`. Para obter mais informações, consulte the section called “Módulos adicionais do Python para trabalhos do Ray”. • Integra logs e métricas de trabalhos do Ray com o Amazon

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			CloudWatch. Para obter mais informações, consulte the section called “Solucionar problemas de erros do Ray” e the section called “Métricas de trabalho do Ray”. • Agrega e visualiza métricas para trabalhos do Ray no AWS Glue Studio, em cada página de execução do trabalho. • Oferece suporte à distribuição de arquivos para cada diretório de trabalho em seu cluster, transferindo objetos do armazenamento de objetos do Ray para o Amazon S3 e controlando o número mínimo de nós de processamento alocados para seu trabalho do Ray. Para obter

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			mais informações, consulte the section called “Parâmetros de trabalho do Ray”. Limitações de trabalhos do Ray no AWS Glue 4.0 • As sessões interativas do AWS Glue para Ray permanecem em pré-visualização para esta versão. • A integração do AWS Glue para Ray com a Amazon VPC não está disponível no momento. Os recursos em uma VPC no AWS não estarão acessíveis sem uma rota pública. Para obter mais informações sobre o uso do AWS Glue com a Amazon VPC, consulte the section called “Configur

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			ar VPC endpoints de interface (AWS PrivateLink) para AWS Glue ”. • O AWS Glue for Ray está disponível em Leste dos EUA (Norte da Virgínia), Leste dos EUA (Ohio), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio) e Europa (Irlanda).

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
AWS Glue 3.0	• Spark 3.1.1 • Python 3.7	Java 8	Além da atualização do mecanismo Spark para 3.0, há otimizações e atualizações incorporadas nessa versão do AWS Glue, como: • Compila a biblioteca de ETL do AWS Glue em relação ao Spark 3.0, que é uma versão importante do Spark. • Os trabalhos de transmissão são suportados no AWS Glue 3.0. • Inclui novas otimizações do runtime do Spark no AWS Glue para performance e confiabilidade: • Processamento colunar na memória mais rápido baseado no Apache Arrow para leitura de dados CSV.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			• Execução baseada em SIMD para leituras vetorizadas com dados CSV. • A atualização do Spark também inclui otimizações adicionais desenvolvidas no Amazon EMR. • O EMRFS foi atualizado de 2.38 para 2.46, permitindo novos recursos e correções de bugs para o acesso ao Amazon S3. • Atualizadas várias dependências que eram necessárias para a nova versão do Spark. • Drivers do JDBC atualizados para nossas origens de dados com suporte nativo.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			Limitações Veja a seguir as limitações do AWS Glue 3.0: • As transformações de machine learning do AWS Glue ainda não estão disponíveis no AWS Glue 3.0. • Alguns conectores do Spark personalizados não funcionam com o AWS Glue 3.0 se dependerem do Spark 2.4 e não tiverem compatibilidade com o Spark 3.1.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
AWS Glue 2.0 (fim da vida útil em 1.º de abril de 2026)	• Spark 2.4.3 • Python 3.7	N/D	Além dos recursos fornecidos no AWS Glue versão 1.0, o AWS Glue versão 2.0 também oferece: • Uma infraestrutura atualizada para executar trabalhos de ETL do Apache Spark no AWS Glue com tempos de inicialização reduzidos. • O registro em log padrão agora é em tempo real, com streams separados para drivers e executores, além de saídas e erros. • Suporte para especificação de módulos do Python adicionais ou versões diferentes no nível do trabalho.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			Note O AWS Glue versão 2.0 difere do AWS Glue versão 1.0 para algumas dependências e versões graças a alterações de arquitetura subjacentes. Valide os trabalhos do AWS Glue antes de migrar entre as principais versões do AWS Glue.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
AWS Glue 1.0 (fim da vida útil em 1.º de abril de 2026)	• Spark 2.4.3 • Python 2.7 • Python 3.6	N/D	É possível manter marcadores de trabalho para os formatos Parquet e ORC em trabalhos de ETL do AWS Glue (usando o AWS Glue versão 1.0). Anteriormente, só era possível marcar formatos comuns de fonte do Amazon S3, como JSON, CSV, Apache Avro e XML em trabalhos de ETL do AWS Glue. Ao definir opções de formato para entradas e saídas de ETL, é possível especificar o uso do formato do leitor/gravador Apache Avro 1.8 para oferecer suporte à leitura e gravação do tipo lógico Avro (usando o AWS Glue versão 1.0). Anteriormente, somente o formato da versão de leitor/gravador Avro 1.7 era compatível.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
			O tipo de conexão do DynamoDB é compatível com uma opção de gravador (usando o AWS Glue versão 1.0). Limitações As limitações com o AWS Glue 1.0 são as seguintes: • A partir de agora, as versões 0.9 e 1.0 do AWS Glue não estarão disponíveis na Ásia-Pacífico (Jacarta) (`ap-southeast-3`), Oriente Médio (EAU) (`me-central-1`) ou em outras regiões novas.

Versão do AWS Glue	Versões do ambiente de runtime compatíveis	Versão compatível com Java	Alterações na funcionalidade
AWS Glue 0.9 (fim da vida útil em 1.º de abril de 2026)	• Spark 2.2.1 • Python 2.7	N/D	Os trabalhos criados sem especificar uma versão do AWS Glue usam como padrão o AWS Glue 0.9. Limitações As limitações com o AWS Glue 0.9 são as seguintes: • A partir de agora, as versões 0.9 e 1.0 do AWS Glue não estarão disponíveis na Ásia-Pacífico (Jacarta) (`ap-southeast-3`), Oriente Médio (EAU) (`me-central-1`) ou em outras regiões novas.

> **Note**
>
> As seguintes versões do Glue são compatíveis com estas versões do PythonShell:
>
> • O PythonShell v3.6 é compatível com o Glue versão 1.0.
> • O PythonShell v3.9 é compatível com o Glue versão 3.0.

Além disso, os endpoints de desenvolvimento são compatíveis somente com as versões 1.0 e 0.9 do Glue.

Política de suporte a versão do AWS Glue

O AWS Glue é um serviço de integração de dados sem servidor que facilita a descoberta, preparação e combinação de dados para analytics, machine learning e desenvolvimento de aplicações. Um trabalho do AWS Glue contém a lógica de negócios que executa o trabalho de integração de dados no AWS Glue. Há três tipos de trabalho no AWS Glue: Spark (lote e streaming), Ray e shell do Python. Ao definir o trabalho, você especifica a versão do AWS Glue que configura as versões nos ambiente de runtime do Spark, Ray e Python subjacente. Por exemplo: um trabalho do Spark na versão 5.0 do AWS Glue é compatível com o Spark 3.5.4 e com o Python 3.11.

Política de suporte

As versões do AWS Glue são desenvolvidas com base em uma combinação de sistema operacional, linguagem de programação e bibliotecas de software, todos sujeitos a manutenção e atualizações de segurança .A política de suporte de versões do AWS Glue estabelece o encerramento do suporte para uma versão quando qualquer um de seus componentes principais atinge o fim do suporte de longo prazo (LTS, na sigla em inglês) da comunidade e não recebe mais atualizações de segurança .A política de suporte de versões do AWS Glue inclui os seguintes status:

Fim do suporte (EOS): quando uma versão do AWS Glue atinge o status de EOS:

- O AWS Glue não aplicará mais correções de segurança nem outras atualizações a versões com o status de EOS.
- Os trabalhos do AWS Glue que são executados em versões com o status de EOS não são elegíveis ao suporte técnico.
- A execução de trabalhos do AWS Glue em versões com o status de EOS pode não estar coberta pelos SLAs.

Fim da vida útil (EOL): quando uma versão do AWS Glue atinge o status EOL:

- Não é mais possível criar novos trabalhos ou sessões interativas do AWS Glue nas versões com status de EOL.

- Não é mais possível iniciar execuções de trabalhos nessas versões do AWS Glue.
- O AWS Glue interromperá as execuções de trabalhos e as sessões interativas em andamento nas versões com status de EOL.
- As versões com status de EOL serão removidas dos SDKs e das APIs do AWS Glue.

As versões do AWS Glue apresentadas a seguir atingiram o fim do suporte e serão descontinuadas após a respectiva data de fim da vida útil. As alterações no status de suporte de uma versão entram em vigor à meia-noite (no horário do Pacífico) na data especificada.

Tipo	Versão do Glue	Término do suporte	Fim da vida útil
Spark	Versão 0.9 do Glue (Spark 2.2, Scala 2 e Python 2)	1/6/2022	1/4/2026
Spark	Versão 1.0 do Glue (Spark 2.4 e Python 2)	1/6/2022	1/4/2026
Spark	Versão 1.0 do Glue (Spark 2.4, Scala 2 e Python 3)	30/9/2022	1/4/2026
Spark	Versão 2.0 do Glue (Spark 2.4 e Python 3)	31/1/2024	1/4/2026
Tipo	Versão do Python	Término do suporte	Fim da vida útil
Shell Python	Python 2 (Glue versão 1.0)	1/6/2022	1/4/2026
Shell Python	PythonShell 3.6 (Glue versão 1.0)	31/3/2026	NA

Tipo	Versão do notebook	Término do suporte	Fim da vida útil
Endpoint de desenvolvimento	Notebook do Zeppelin	30/9/2022	NA

A AWS recomenda enfaticamente migrar seus trabalhos para versões compatíveis.

Para obter informações sobre como migrar seus trabalhos do Spark para a versão mais recente do AWS Glue, consulte Migrar o AWS Glue para trabalhos do Spark para o AWS Glue versão 5.0.

Para migrar seus trabalhos de shell do Python para a versão mais recente do AWS Glue:

- No console, escolha `Python 3 (Glue Version 4.0)`.
- Na API CreateJob/UpdateJob, defina o parâmetro `GlueVersion` como `2.0` e `PythonVersion` como `3` no parâmetro `Command`. A configuração do `GlueVersion` não afeta o comportamento dos trabalhos de shell do Python, portanto, não há vantagem em incrementar o `GlueVersion`.
- Você precisa tornar seu script de trabalho compatível com o Python 3.

Migrar o AWS Glue para trabalhos do Spark para o AWS Glue versão 5.0

Este tópico descreve as alterações entre as versões 0.9, 1.0, 2.0, 3.0 e 4.0 do AWS Glue para permitir que você migre suas aplicações do Spark e trabalhos de ETL para o AWS Glue 5.0. Ele também descreve os recursos do AWS Glue 5.0 e as vantagens de usá-lo.

Para usar esse recurso com seus trabalhos de ETL do AWS Glue, escolha **`5.0`** para a `Glue version` ao criar seus trabalhos.

Tópicos

- Novos recursos
- Ações para migrar para o AWS Glue 5.0
- Lista de verificação da migração
- Recursos do AWS Glue 5.0
- Migrar do AWS Glue 4.0 para o AWS Glue 5.0
- Migrar do AWS Glue 3.0 para o AWS Glue 5.0
- Migrar do AWS Glue 2.0 para o AWS Glue 5.0
- Mudanças do comportamento de registro em log no AWS Glue 5.0

- Migração de conectores e drivers JDBC para AWS Glue 5.0

Novos recursos

Esta seção descreve novos recursos e vantagens do AWS Glue versão 5.0.

- Atualização do Apache Spark de versão 3.3.0 no AWS Glue 4.0 para versão 3.5.4 no AWS Glue 5.0. Consulte Principais aprimoramentos da versão Spark 3.3.0 para a versão Spark 3.5.4.
- Controle de acesso refinado (FGAC) nativo do Spark usando o Lake Formation. Isso inclui FGAC para tabelas do tipo Iceberg, Delta e Hudi. Para obter mais informações, consulte Usar o AWS Glue com AWS Lake Formation para controle de acesso refinado.

  Observe as seguintes considerações ou limitações para o FGAC nativo do Spark:

  - No momento, não há suporte a gravação de dados
  - Gravar no Iceberg via `GlueContext` usando o Lake Formation requer, em vez disso, o uso do controle de acesso do IAM

  Para obter uma lista completa das limitações e considerações ao usar o FGAC nativo para o Spark, consulte the section called “Considerações”.
- Suporte à Concessão de Acesso do Amazon S3 como uma solução de controle de acesso escalável aos dados do Amazon S3 do AWS Glue. Para obter mais informações, consulte Usar Concessão de Acesso do Amazon S3 com o AWS Glue.
- Os formatos de tabelas abertas (OTF, na sigla em inglês) foram atualizados para as versões Hudi 0.15.0, Iceberg 1.7.1 e Delta Lake 3.3.0
- Suporte ao Amazon SageMaker Unified Studio.
- Amazon SageMaker Lakehouse e integração de abstração de dados. Para obter mais informações, consulte Consultando catálogos de dados do metastore com base no ETL AWS Glue.
- Suporte à instalação de bibliotecas Python adicionais usando o arquivo `requirements.txt`. Para obter mais informações, consulte Instalar bibliotecas Python adicionais no AWS Glue 5.0 usando o arquivo requirements.txt.
- O AWS Glue 5.0 oferece suporte à linhagem de dados no Amazon DataZone. É possível configurar o AWS Glue para coletar automaticamente informações de linhagem durante a execução de trabalhos do Spark e enviar os eventos de linhagem para serem visualizados no Amazon DataZone. Para obter mais informações, consulte Linhagem de dados no Amazon DataZone.

Para configurá-la no console do AWS Glue, ative Gerar eventos de linhagem e insira o ID do seu domínio do Amazon DataZone na guia Detalhes do trabalho.

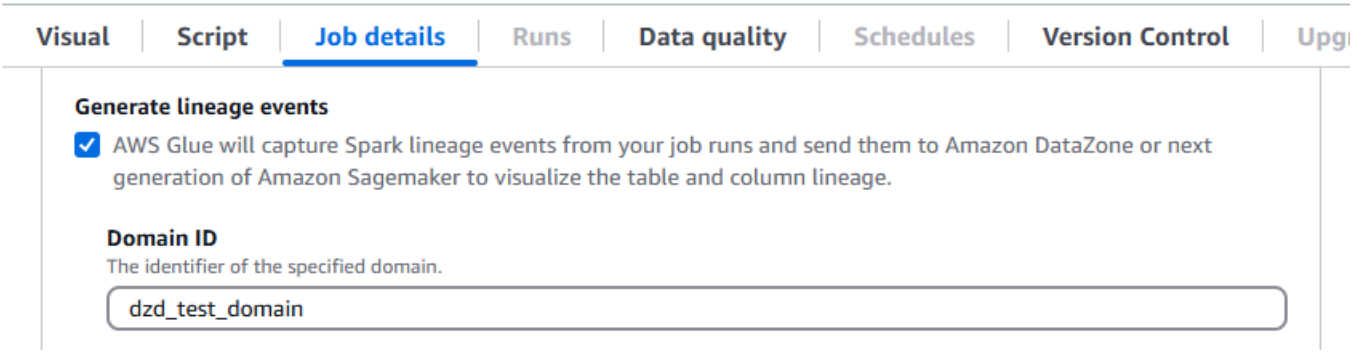

Como alternativa, é possível fornecer o parâmetro de trabalho a seguir (forneça ID do seu domínio do DataZone):

- Chave: `--conf`
- Value (Valor):

```
extraListeners=io.openlineage.spark.agent.OpenLineageSparkListener
—conf spark.openlineage.transport.type=amazon_datazone_api
-conf spark.openlineage.transport.domainId=<your-domain-ID>
```

- Atualizações do conector e do driver JDBC. Para obter mais informações, consulte Apêndice B: upgrades do driver JDBC e Apêndice C: Atualizações de conectores.
- Atualização do Java de 8 para 17.
- Maior armazenamento para operadores do AWS Glue `G.1X` e `G.2X` com espaço em disco aumentando para 94 GB e 138 GB, respectivamente. Para obter mais informações, consulte Tarefas.
- Suporte ao AWS SDK para Java, versão 2: os trabalhos do AWS Glue 5.0 poderão usar o Java versões 1.12.569 ou 2.28.8 se o trabalho for compatível com a v2. O AWS SDK para Java 2.x é uma reescrita principal do código de base da versão 1.x. Ele foi criado com base no Java 8+ e adiciona vários recursos frequentemente solicitados. Entre eles, suporte para E/S sem bloqueio e capacidade de conectar uma implementação HTTP diferente no runtime. Para obter mais informações, incluindo um Guia de migração do SDK para Java v1 a v2, consulte o guia AWS SDK para Java, versão 2.
-

Alterações significativas

Observe as seguintes alterações importantes:

- No AWS Glue 5.0, ao usar o sistema de arquivos S3A, e se “fs.s3a.endpoint” e “fs.s3a.endpoint.region” não estiverem definidos, a região padrão usada pelo S3A será “us-east-2”. Isso pode causar problemas, como erros de tempo limite de upload do S3, especialmente para trabalhos da VPC. Para mitigar os problemas causados por essa alteração, defina a configuração “fs.s3a.endpoint.region” do Spark ao usar o sistema de arquivos S3A no AWS Glue 5.0.
- Controle de acesso de alta granularidade (FGAC) do Lake Formation
  - O AWS Glue 5.0 só é compatível com o novo FGAC nativo do Spark usando Spark DataFrames. Ele não oferece suporte ao FGAC usando AWS Glue DynamicFrames.
    - O uso do FGAC na versão 5.0 requer a migração de AWS Glue DynamicFrames para Spark DataFrames.
    - Se não precisar do FGAC, não será necessário migrar para o Spark DataFrame e os recursos do GlueContext, como marcadores de tarefas e predicados push-down, continuarão funcionando.
  - Os trabalhos com o FGAC nativo do Spark exigem no mínimo 4 operadores: um driver de usuário, um driver de sistema, um executor de sistema e um executor de usuário em espera.
  - Para obter mais informações, consulte Usar o AWS Glue com AWS Lake Formation para controle de acesso refinado.
- Acesso total à tabela (FTA) do Lake Formation
  - O AWS Glue 5.0 é compatível com FTA com DataFrames nativo do Spark (novo) e GlueContext DynamicFrames (legado, com limitações)
  - FTA nativo do Spark
    - Se o script 4.0 usar GlueContext, migre para o uso do Spark nativo.
    - Esse recurso é limitado a tabelas do Hive e do Iceberg
    - Para obter mais informações sobre como configurar um trabalho 5.0 para usar o FTA nativo do Spark, consulte
  - FTA DynamicFrame do GlueContext
    - Não é necessário fazer nenhuma alteração de código.
    - Esse recurso é limitado a tabelas não OTF. Ele não funcionará com Iceberg, Delta Lake e Hudi.
- Não há suporte ao Leitor de CSV SIMD vetorizado.

- Não há suporte ao registro em log contínuo para grupos de logs de saída. Em vez disso, use o grupo de logs `error`.
- O `job-insights-rule-driver` de insights de execução de trabalho do AWS Glue foi descontinuado. O fluxo de logs `job-insights-rca-driver` agora está localizado no grupo de logs de erros.
- Não há suporte a conectores de mercado/personalizados baseados em Athena.
- Não há suporte aos conectores Adobe Marketo Engage, Facebook Ads, Google Analytics 4, Planilhas Google, Hubspot, Instagram Ads, Intercom, Jira Cloud, Oracle NetSuite, Salesforce, Salesforce Marketing Cloud, Salesforce Marketing Cloud Account Engagement, SAP OData, ServiceNow, Slack, Snapchat Ads, Stripe, Zendesk e Zoho CRM.
- Propriedades log4j personalizadas não são compatíveis no AWS Glue 5.0.

Principais aprimoramentos da versão Spark 3.3.0 para a versão Spark 3.5.4

Observe os seguintes aprimoramentos:

- Cliente Python para Spark Connect (SPARK-39375).
- Implementação de suporte a valores DEFAULT para colunas de tabelas (SPARK-38334).
- Suporte a "Referências a alias de colunas laterais" (SPARK-27561).
- Fortalecimento do uso do SQLSTATE para classes de erro (SPARK-41994).
- Habilitação de junções do filtro Bloom por padrão (SPARK-38841).
- Melhor escalabilidade da interface do usuário do Spark e estabilidade do driver para aplicações grandes (SPARK-41053).
- Rastreamento de progresso assíncrono em streaming estruturado (SPARK-39591).
- Processamento stateful arbitrário de Python em streaming estruturado (SPARK-40434).
- Melhorias na cobertura da API do Pandas (SPARK-42882) e suporte a entradas NumPy no PySpark (SPARK-39405).
- Fornecimento de um profiler de memória para funções do PySpark definidas pelo usuário (SPARK-40281).
- Implementação do distribuidor PyTorch (SPARK-41589).
- Publicação de artefatos SBOM (SPARK-41893).
- Suporte a ambiente somente IPv6 (SPARK-39457).
- Programador K8s personalizado (Apache UniKorn e Volcano) GA (SPARK-42802).

- Suporte a clientes Scala e Go no Spark Connect (SPARK-42554) e (SPARK-43351).
- Suporte a ML distribuído baseado em PyTorch para Spark Connect (SPARK-42471).
- Suporte a streaming estruturado para Spark Connect em Python e Scala (SPARK-42938).
- Suporte à API do Pandas para o Python Spark Connect Client (SPARK-42497).
- Introdução das UDFs do Arrow Python (SPARK-40307).
- Suporte a funções de tabela definidas pelo usuário do Python (SPARK-43798).
- Migração dos erros do PySpark para classes de erro (SPARK-42986).
- Estrutura de teste do PySpark (SPARK-44042).
- Adição de suporte a Datasketches HLLSketch (SPARK-16484).
- Aprimoramento da função SQL integrada (SPARK-41231).
- Cláusula IDENTIFIER (SPARK-43205).
- Adição de funções SQL às APIs do Scala, Python e R (SPARK-43907).
- Adição de suporte a argumentos nomeados para funções SQL (SPARK-43922).
- Prevenção de re-execução desnecessária de tarefas em um executor descomissionado perdido se os dados do shuffle forem migrados (SPARK-41469).
- ML distribuído <> spark connect (SPARK-42471).
- Distribuidor DeepSpeed (SPARK-44264).
- Implementação do ponto de verificação do changelog para o armazenamento de estados RocksDB (SPARK-43421).
- Introdução da propagação da marca d'água entre operadores (SPARK-42376).
- Introdução de dropDuplicatesWithinWatermark (SPARK-42931).
- Aprimoramentos no gerenciamento de memória do provedor de armazenamento de estados RocksDB (SPARK-43311).

Ações para migrar para o AWS Glue 5.0

Para trabalhos existentes, altere a `Glue version` da versão anterior para `Glue 5.0` na configuração do trabalho.

- No AWS Glue Studio, escolha `Glue 5.0 - Supports Spark 3.5.4, Scala 2, Python 3` em `Glue version`.

- Na API, escolha **`5.0`** no parâmetro `GlueVersion` na operação da API `UpdateJob`.

Para novos trabalhos, escolha `Glue 5.0` ao criar um trabalho.

- No console, escolha `Spark 3.5.4, Python 3 (Glue Version 5.0) or Spark 3.5.4, Scala 2 (Glue Version 5.0)` em `Glue version`.
- No AWS Glue Studio, escolha `Glue 5.0 - Supports Spark 3.5.4, Scala 2, Python 3` em `Glue version`.
- Na API, escolha **`5.0`** no parâmetro `GlueVersion` na operação da API `CreateJob`.

Para visualizar os logs de eventos do Spark no AWS Glue 5.0, partindo do AWS Glue 2.0 ou anterior, inicie um servidor de histórico do Spark atualizado para o AWS Glue 5.0 usando o AWS CloudFormation ou o Docker.

Lista de verificação da migração

Revise esta lista de verificação para migração:

- Atualizações do Java 17
- [Scala] Atualização das chamadas do AWS SDK de v1 para v2
- Migração do Python 3.10 para 3.11
- [Python] Atualização das referências ao boto de 1.26 para 1.34

Recursos do AWS Glue 5.0

Esta seção descreve os recursos do AWS Glue de forma mais detalhada.

Consultando catálogos de dados do metastore com base no ETL AWS Glue

É possível registrar seu trabalho do AWS Glue para acessar o AWS Glue Data Catalog, o que disponibiliza tabelas e outros recursos do metastore para consumidores diferentes. O Catálogo de Dados oferece suporte a uma hierarquia de vários catálogos, que unifica todos os seus dados nos data lakes do Amazon S3. Ele também fornece uma API de metastore do Hive e uma API de código aberto do Apache Iceberg para acessar os dados. Esses recursos estão disponíveis para o AWS Glue e outros serviços orientados por dados, como Amazon EMR, Amazon Athena e Amazon Redshift.

Ao criar recursos no Catálogo de Dados, será possível acessá-los de qualquer mecanismo SQL que ofereça suporte à API REST do Apache Iceberg. O AWS Lake Formation gerencia as permissões. Após a configuração, é possível utilizar os recursos do AWS Glue para consultar dados diferentes fazendo consultas para esses recursos do metastore com aplicações bem conhecidas. Isso inclui o Apache Spark e o Trino.

Como os recursos de metadados são organizados

Os dados são organizados em uma hierarquia lógica de catálogos, bancos de dados e tabelas, usando o AWS Glue Data Catalog:

- Catálogo: um contêiner lógico que contém objetos de um armazenamento de dados, como esquemas ou tabelas.
- Banco de dados: organiza objetos de dados, como tabelas e visualizações, em um catálogo.
- Tabelas e visualizações: objetos de dados em um banco de dados que fornecem uma camada de abstração com um esquema compreensível. Elas facilitam o acesso aos dados subjacentes, que podem estar em vários formatos e em vários locais.

Migrar do AWS Glue 4.0 para o AWS Glue 5.0

Todos os parâmetros de trabalho e principais recursos existentes no AWS Glue 4.0 existirão no AWS Glue 5.0, com exceção das transformações de machine learning.

Os seguintes parâmetros novos foram adicionados:

- `--enable-lakeformation-fine-grained-access`: habilita o recurso de controle de acesso refinado (FGAC) nas tabelas do AWS Lake Formation.

Consulte a documentação de migração do Spark:

- Guia de migração: Spark Core
- Guia de migração: SQL, conjuntos de dados e DataFrame
- Guia de migração: streaming estruturado
- Como atualizar o PySpark

Migrar do AWS Glue 3.0 para o AWS Glue 5.0

> **Note**
>
> Para ver as etapas de migração relacionadas ao AWS Glue 4.0, consulte Migrar do AWS Glue 3.0 para o AWS Glue 4.0.

Todos os parâmetros de trabalho e principais recursos existentes no AWS Glue 3.0 existirão no AWS Glue 5.0, com exceção das transformações de machine learning.

Migrar do AWS Glue 2.0 para o AWS Glue 5.0

> **Note**
>
> Para obter as etapas de migração relacionadas ao AWS Glue 4.0 e uma lista das diferenças de migração entre as versões 3.0 e 4.0 do AWS Glue, consulte Migrar do AWS Glue 3.0 para o AWS Glue 4.0.

Observe também as seguintes diferenças de migração entre as versões 3.0 e 2.0 do AWS Glue:

- Todos os parâmetros de trabalho e principais recursos existentes no AWS Glue 2.0 existirão no AWS Glue 5.0, com exceção das transformações de machine learning.
- Várias alterações do Spark sozinhas podem exigir a revisão de seus scripts para garantir que os recursos removidos não estejam sendo referenciados. Por exemplo, o Spark 3.1.1 e as versões posteriores não habilitam UDFs sem tipo Scala, mas o Spark 2.4 as permite.
- Não há suporte ao Python 2.7.
- Quaisquer jars extras fornecidos em trabalhos do AWS Glue 2.0 existentes podem trazer dependências conflitantes, uma vez que houve atualizações em várias dependências. É possível evitar conflitos de classpath com o parâmetro de trabalho `--user-jars-first`.
- Alterações no comportamento de carregar/salvar de timestamps de/para arquivos parquet. Para obter mais detalhes, consulte Atualização do Spark SQL 3.0 para 3.1.
- Paralelismo de tarefas do Spark diferente para configuração do driver/executor. É possível ajustar o paralelismo de tarefas ao passar o argumento `--executor-cores` do trabalho.

Mudanças do comportamento de registro em log no AWS Glue 5.0

Veja a seguir as mudanças no comportamento de registro em log no AWS Glue 5.0. Para obter mais informações, consulte Registro contínuo para trabalhos do AWS Glue.

- Agora, todos os logs (logs do sistema, logs do daemon do Spark, logs de usuário e logs do Glue Logger) são gravados no grupo de logs do `/aws-glue/jobs/error` por padrão.
- O grupo de logs do `/aws-glue/jobs/logs-v2` usado para registro contínuo em log nas versões anteriores não é mais usado.
- Você não pode mais renomear ou personalizar os nomes do grupo de logs ou do fluxo de logs usando os argumentos de registro contínuo em log que foram removidos. Em vez disso, veja os novos argumentos de trabalho no AWS Glue 5.0.

O AWS Glue 5.0 introduziu dois novos argumentos de trabalho.

- `--custom-logGroup-prefix`: permite que você especifique um prefixo personalizado para os grupos de logs `/aws-glue/jobs/error` e `/aws-glue/jobs/output`.
- `--custom-logStream-prefix`: permite que você especifique um prefixo personalizado para os nomes do fluxo de logs nos grupos de logs.

  As regras de validação e as limitações para prefixos personalizados incluem:
  - O nome completo do fluxo de logs precisa ter de 1 a 512 caracteres.
  - O prefixo personalizado para nomes de fluxo de logs é limitado a 400 caracteres.
  - Os caracteres permitidos nos prefixos incluem caracteres alfanuméricos, sublinhados (“_”), hifens (“-”) e barras (“/”).

Argumentos de registro contínuo em log descontinuados no AWS Glue 5.0

Os seguintes argumentos de trabalho para registro contínuo em log foram descontinuados no AWS Glue 5.0.

- `--enable-continuous-cloudwatch-log`
- `--continuous-log-logGroup`
- `--continuous-log-logStreamPrefix`
- `--continuous-log-conversionPattern`
- `--enable-continuous-log-filter`

Migração de conectores e drivers JDBC para AWS Glue 5.0

Para as versões do JDBC e dos conectores de data lake que foram atualizadas, consulte:

- Apêndice B: upgrades do driver JDBC
- Apêndice C: Atualizações de conectores
- Apêndice D: Atualizações do formato de tabela aberta

As alterações a seguir se aplicam às versões do conector ou do driver identificadas nos apêndices do Glue 5.0.

Amazon Redshift

Observe as seguintes alterações:

- Adiciona suporte a nomes de tabelas em três partes para permitir que o conector consulte tabelas de compartilhamento de dados do Redshift.
- Corrige o mapeamento de `ShortType` do Spark para usar `SMALLINT` em vez de `INTEGER` do Redshift para corresponder melhor ao tamanho de dados esperado.
- Adição de suporte a nomes de cluster personalizados (CNAME) para Amazon Redshift sem servidor.

Apache Hudi

Observe as seguintes alterações:

- Suporte a índice de nível de registro.
- Suporte a geração automática de chaves de registro. Agora você não precisa especificar o campo de chave do registro.

Apache Iceberg

Observe as seguintes alterações:

- Suporte ao controle de acesso refinado com o AWS Lake Formation.
- Suporte à ramificação e à marcação, que são referências nomeadas a snapshots com seus próprios ciclos de vida independentes.

- Adição de um procedimento de visualização do log de alterações que gera uma visualização que contém as alterações feitas em uma tabela durante um período especificado ou entre snapshots específicos.

Delta Lake

Observe as seguintes alterações:

- Suporte ao Delta Universal Format (UniForm), que permite acesso contínuo por meio do Apache Iceberg e do Apache Hudi.
- Suporte a vetores de exclusão que implementam um paradigma Merge-on-Read.

AzureCosmos

Observe as seguintes alterações:

- Adição de suporte a chaves de partição hierárquicas.
- Adição de opção para usar um esquema personalizado com StringType (json bruto) para uma propriedade aninhada.
- Adição da opção de configuração `spark.cosmos.auth.aad.clientCertPemBase64` para permitir o uso da autenticação SPN (nome do ServicePrincipal) com um certificado em vez do segredo do cliente.

Para obter mais informações, consulte Log de alterações do conector Spark do Azure Cosmos DB.

Microsoft SQL Server

Observe as seguintes alterações:

- A criptografia TLS é habilitada por padrão.
- Quando encrypt = false, mas o servidor exige criptografia, o certificado é validado com base na configuração `trustServerCertificate` da conexão.
- `aadSecurePrincipalId` e `aadSecurePrincipalSecret` obsoletos.
- Remoção da API `getAADSecretPrincipalId`.
- Resolução CNAME adicionada quando o realm é especificado.

MongoDB

Observe as seguintes alterações:

- Suporte ao modo de micro lotes com o Spark Structured Streaming.
- Suporte a tipos de dados BSON.
- Adição de suporte à leitura de várias coleções ao usar os modos de micro lote ou streaming contínuo.
  - Se o nome de uma coleção usada em sua opção de configuração `collection` contiver uma vírgula, o Spark Connector a tratará como duas coleções diferentes. Para evitar isso, coloque uma barra invertida (\) antes dela.
  - Se o nome de uma coleção usada em sua opção de configuração `collection` for "*", o Spark Connector a interpretará como uma instrução para verificar todas as coleções. Para evitar isso, coloque uma barra invertida (\) antes dele.
  - Se o nome de uma coleção usada em sua opção de configuração `collection` contiver uma barra invertida (\), o Spark Connector tratará a barra invertida como um caractere de escape, o que pode mudar a forma como ele interpreta o valor. Para evitar isso, coloque uma outra barra invertida (\) antes dela.

Para obter mais informações, consulte Notas da versão do conector do MongoDB para Spark.

Snowflake

Observe as seguintes alterações:

- Introdução de um novo parâmetro `trim_space` que pode ser usado para cortar valores de colunas `StringType` automaticamente ao salvar em uma tabela do Snowflake. Padrão: `false`.
- Desabilitação do parâmetro `abort_detached_query` no nível da sessão por padrão.
- Remoção do requisito do parâmetro `SFUSER` ao usar OAUTH.
- Remoção do recurso Advanced Query Pushdown. Alternativas ao recurso estão disponíveis. Por exemplo, em vez de carregar dados das tabelas do Snowflake, os usuários podem carregar dados diretamente das consultas SQL do Snowflake.

Para obter mais informações, consulte Notas da versão do conector do Snowflake para Spark.

Apêndice A: atualizações de dependência notáveis

Veja a seguir as atualizações de dependência:

Dependência	Versão no AWS Glue 5.0	Versão no AWS Glue 4.0	Versão no AWS Glue 3.0	Versão no AWS Glue 2.0	Versão no 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	2.12.18	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
Arrow	12.0.1	7.0.0	2.0.0	0.10.0	0.10.0
Cliente do AWS Glue Data Catalog	4.5.0	3.7.0	3.0.0	1.10.0	N/D
AWS SDK para Java	2.29.52	1.12	1.12		
Python	3.11	3.10	3.7	2.7 e 3.6	2.7 e 3.6
Boto	1.34.131	1.26	1.18	1.12	N/D
Conector EMR DynamoDB	5.6.0	4.16.0			

Apêndice B: upgrades do driver JDBC

A seguir estão as atualizações do driver JDBC:

Driver	Versão do driver JDBC no AWS Glue 5.0	Versão do driver JDBC no AWS Glue 4.0	Versão do driver JDBC no AWS Glue 3.0	Versão do driver JDBC nas versões do AWS Glue anteriores
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
Bancos de dados da Oracle	23.3.0.23.09	21.7	21.1	11.2
PostgreSQL	42.7.3	42.3.6	42.2.18	42.1.0
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		

Apêndice C: Atualizações de conectores

As atualizações do conector são as seguintes:

Driver	Versão do conector no AWS Glue 5.0	Versão do conector no AWS Glue 4.0	Versão do conector no AWS Glue 3.0
Conector 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

Driver	Versão do conector no AWS Glue 5.0	Versão do conector no AWS Glue 4.0	Versão do conector no AWS Glue 3.0
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	

Apêndice D: Atualizações do formato de tabela aberta

São atualizações do formato de tabela aberta:

OTF	Versão do conector no AWS Glue 5.0	Versão do conector no AWS Glue 4.0	Versão do conector no AWS Glue 3.0
Hudi	0.15.0	0.12.1	0.10.1
Delta Lake	3.3.0	2.1.0	1.0.0
Iceberg	1.7.1	1.0.0	0.13.1

Migrar trabalhos do AWS Glue para Spark para o AWS Glue versão 4.0

Este tópico descreve as alterações entre as versões 0.9, 1.0, 2.0 e 3.0 do AWS Glue, para permitir que você migre suas aplicações do Spark e trabalhos do ETL para o AWS Glue 4.0. Ele também descreve os recursos do AWS Glue 4.0 e as vantagens de usá-lo.

Para usar esse recurso com seus trabalhos de ETL do AWS Glue, escolha **`4.0`** para a `Glue version` ao criar seus trabalhos.

Tópicos

- Novos recursos compatíveis
- Ações para migrar para o AWS Glue 4.0

- Lista de verificação da migração
- Migrar do AWS Glue 3.0 para o AWS Glue 4.0
- Migrar do AWS Glue 2.0 para o AWS Glue 4.0
- Migrar do AWS Glue 1.0 para o AWS Glue 4.0
- Migrar do AWS Glue 0.9 para o AWS Glue 4.0
- Migração de conectores e drivers JDBC para AWS Glue 4.0
- Apêndice A: atualizações de dependência notáveis
- Apêndice B: upgrades do driver JDBC
- Apêndice C: Atualizações de conectores

Novos recursos compatíveis

Esta seção descreve novos recursos e vantagens do AWS Glue versão 4.0.

- Ele é baseado no Apache Spark 3.3.0, mas inclui otimizações no AWS Glue e no Amazon EMR, como execuções de consultas adaptáveis, leitores vetorizados e agrupamento de partições e ordem aleatória otimizados.
- Drivers JDBC atualizados para todas as fontes nativas do AWS Glue, incluindo MySQL, Microsoft SQL Server, Oracle, PostgreSQL, MongoDB e bibliotecas e dependências do Spark atualizadas trazidas pelo Spark 3.3.0.
- Atualizado com um novo conector do Amazon Redshift e driver JDBC.
- Acesso otimizado ao Amazon S3 com o EMR File System (EMRFS) atualizado e committers de saída otimizados do Amazon S3 habilitados por padrão.
- Acesso otimizado ao Data Catalog com índices de partição, predicados de pushdown, listagem de partições e cliente de metastore do Hive atualizado.
- Integração com Lake Formation para tabelas de catálogo controladas com filtragem em nível de célula e transações de data lake.
- Latência de startup reduzida, melhorando os tempos de conclusão de trabalho e a interatividade em geral.
- Os trabalhos do Spark são cobrados em incrementos de um segundo com uma duração mínima de faturamento dez vezes mais baixa, de um mínimo de dez minutos para um mínimo de um minuto.
- Suporte nativo para estruturas de data lakes abertos com o Apache Hudi, o Delta Lake e o Apache Iceberg.

- Suporte nativo para o Cloud Shuffle Storage Plugin baseado no Amazon S3 (um plug-in do Apache Spark) para usar o Amazon S3 para capacidade de armazenamento elástico e aleatório.

Principais aprimoramentos do Spark 3.1.1 para o Spark 3.3.0

Observe os seguintes aprimoramentos:

- Filtragem de runtime em nível de linha (SPARK-32268).
- Aprimoramentos do ANSI (SPARK-38860).
- Melhorias nas mensagens de erro (SPARK-38781).
- Suporte a tipos complexos para o leitor vetorizado de Parquet (SPARK-34863).
- Suporte a metadados de arquivos ocultos para o Spark SQL (SPARK-37273).
- Fornece um compilador de perfil para UDFs do Python/Pandas (SPARK-37443).
- Apresenta Trigger.availableNow para executar consultas de streaming como Trigger.Once em vários lotes (SPARK-36533).
- Recursos mais abrangentes de pushdown do Datasource V2 (SPARK-38788).
- Migrar do log4j 1 para o log4j 2 (SPARK-37814).

Outras alterações notáveis

Observe as seguintes alterações:

- Alterações significativas
  - Elimina as referências a compatibilidade com o Python 3.6 em documentos e Python/docs (SPARK-36977).
  - Remove o hack de tupla nomeada substituindo o pickle integrado pelo cloudpickle (SPARK-32079).
  - Aumenta a versão mínima do pandas para 1.0.5 (SPARK-37465).

Ações para migrar para o AWS Glue 4.0

Para trabalhos existentes, altere a `Glue version` da versão anterior para `Glue 4.0` na configuração do trabalho.

- No AWS Glue Studio, escolha `Glue 4.0 - Supports Spark 3.3, Scala 2, Python 3` em `Glue version`.
- Na API, escolha **`4.0`** no parâmetro `GlueVersion` na operação da API `UpdateJob`.

Para novos trabalhos, escolha `Glue 4.0` ao criar um trabalho.

- No console, escolha `Spark 3.3, Python 3 (Glue Version 4.0) or Spark 3.3, Scala 2 (Glue Version 3.0)` em `Glue version`.
- No AWS Glue Studio, escolha `Glue 4.0 - Supports Spark 3.3, Scala 2, Python 3` em `Glue version`.
- Na API, escolha **`4.0`** no parâmetro `GlueVersion` na operação da API `CreateJob`.

Para visualizar os logs de eventos do Spark no AWS Glue 4.0, vindo do AWS Glue 2.0 ou anterior, inicie um servidor de histórico do Spark atualizado para o AWS Glue 4.0 usando o AWS CloudFormation ou o Docker.

Lista de verificação da migração

- As bibliotecas externas de Python do seu trabalho dependem do Python 2.7/3.6?
  - Atualize as bibliotecas dependentes do Python 2.7/3.6 para Python 3.10, pois o Spark 3.3.0 removeu o suporte ao Python 2.7 e 3.6.

Migrar do AWS Glue 3.0 para o AWS Glue 4.0

Observe as seguintes alterações ao migrar:

- Todos os parâmetros de trabalho e principais recursos existentes no AWS Glue 3.0 existirão no AWS Glue 4.0.
- O AWS Glue 3.0 usa o Spark 3.1.1 otimizado para Amazon EMR, e o AWS Glue 4.0 usa o Spark 3.3.0 otimizado para Amazon EMR.

  Várias alterações do Spark isoladas podem exigir a revisão de seus scripts para garantir que os recursos removidos não estejam sendo referenciados.
- O AWS Glue 4.0 também apresenta uma atualização para o EMRFS e o Hadoop. Para obter números de versão específicos, consulte Apêndice A: atualizações de dependência notáveis.
- O AWS SDK fornecido nas tarefas de ETL agora foi atualizado de 1.11 para 1.12.

- Todos os trabalhos do Python usarão o Python versão 3.10. Anteriormente, o Python 3.7 era usado no AWS Glue 3.0.

  Como resultado, alguns pymodules trazidos prontos para uso pelo AWS Glue são atualizados.
- O Log4j foi atualizado para o Log4j2.
  - Para obter informações sobre o caminho de migração do Log4j2, consulte a documentação do Log4j.
  - Você deve renomear qualquer arquivo log4j.properties personalizado como um arquivo log4j2.properties, com as propriedades do log4j2 apropriadas.
- Para migrar determinados conectores, consulte Migração de conectores e drivers JDBC para AWS Glue 4.0.
- O SDK de criptografia do AWS foi atualizado de 1.x para 2.x. Trabalhos do AWS Glue que usam configurações de segurança e trabalhos do AWS Glue dependentes da dependência do SDK de criptografia do AWS fornecida em runtime são afetados. Veja as instruções para migração de trabalhos do AWS Glue.

  Você pode atualizar com segurança um trabalho do AWS Glue 2.0/3.0 para um trabalho do AWS Glue 4.0 porque o AWS Glue 2.0/3.0 já contém a versão de ponte do SDK de criptografia do AWS.

Consulte a documentação de migração do Spark:

- Atualização do Spark SQL 3.1 para 3.2
- Atualização do Spark SQL 3.2 para 3.3

Migrar do AWS Glue 2.0 para o AWS Glue 4.0

Observe as seguintes alterações ao migrar:

> **Note**
>
> Para obter as etapas de migração relacionadas ao AWS Glue 3.0, consulte Migrar do AWS Glue 3.0 para o AWS Glue 4.0.

- Todos os parâmetros de trabalho e principais recursos existentes no AWS Glue 2.0 existirão no AWS Glue 4.0.

- O committer do S3 otimizado para EMRFS para gravar dados em Parquet no Amazon S3 é habilitado por padrão desde o AWS Glue 3.0. No entanto, você ainda pode desabilitar isso definindo `--enable-s3-parquet-optimized-committer` como `false`.
- O AWS Glue 2.0 usa o Spark 2.4 de código aberto e o AWS Glue 4.0 usa o Spark 3.3.0 otimizado para Amazon EMR.
  - Várias alterações do Spark sozinhas podem exigir a revisão de seus scripts para garantir que os recursos removidos não estejam sendo referenciados.
  - Por exemplo, o Spark 3.3.0 não habilita UDFs sem tipo Scala, mas o Spark 2.4 as permite.
- O AWS SDK fornecido nas tarefas de ETL agora foi atualizado de 1.11 para 1.12.
- O AWS Glue 4.0 também apresenta uma atualização para o EMRFS, drivers JDBC atualizados e inclusões de otimizações adicionais no próprio Spark fornecidas pelo AWS Glue.
- O Scala foi atualizado da versão 2.11 para a versão 2.12, e o Scala 2.12 não é compatível retroativamente com o Scala 2.11.
- O Python 3.10 também é a versão padrão usada para scripts de Python, pois o AWS Glue 2.0 utilizava apenas o Python 3.7 e 2.7.
  - O Python 2.7 não é compatível com o Spark 3.3.0. Qualquer trabalho que solicite Python 2 na configuração do trabalho falhará com uma IllegalArgumentException.
  - Um novo mecanismo de instalação de módulos adicionais do Python está disponível desde o AWS Glue 2.0.
- Várias atualizações de dependência, destacadas em Apêndice A: atualizações de dependência notáveis.
- Quaisquer arquivos JAR extras fornecidos em trabalhos do AWS Glue 2.0 podem trazer dependências conflitantes, uma vez que houve atualizações em várias dependências no 4.0 a partir do 2.0. Você pode evitar conflitos de classpath no AWS Glue 4.0 com o parâmetro de trabalho `--user-jars-first` do AWS Glue.
- O AWS Glue 4.0 usa o Spark 3.3. A partir do Spark 3.1, houve uma mudança no comportamento para carregamento/salvamento de carimbos de data/hora de/para arquivos parquet. Para obter mais detalhes, consulte Atualização do Spark SQL 3.0 para 3.1.

  Recomendamos definir os seguintes parâmetros ao ler/escrever dados de parquet que contenham colunas de carimbo de data/hora. A configuração desses parâmetros pode resolver o problema de incompatibilidade do calendário que ocorre durante a atualização do Spark 2 para o Spark 3, para o Dynamic Frame do AWS Glue e o Spark Data Frame. Use a opção CORRECTED (CORRIGIDO)

para ler o valor de data e hora como ele é; e a opção LEGACY (HERDADO) para rebasear os valores de data e hora em relação à diferença de calendário durante a leitura.

```
- 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]
```

- Para migrar determinados conectores, consulte Migração de conectores e drivers JDBC para AWS Glue 4.0.
- O SDK de criptografia do AWS foi atualizado de 1.x para 2.x. Trabalhos do AWS Glue que usam configurações de segurança e trabalhos do AWS Glue dependentes da dependência do SDK de criptografia do AWS fornecida em runtime são afetados. Veja estas instruções para migração de trabalhos do AWS Glue:
  - Você pode atualizar com segurança um trabalho AWS Glue 2.0 para um trabalho AWS Glue 4.0 porque o AWS Glue 2.0 já contém a versão de ponte do SDK de criptografia do AWS.

Consulte a documentação de migração do Spark:

- Atualização do Spark SQL 2.4 para 3.0
- Atualização do Spark SQL 3.1 para 3.2
- Atualização do Spark SQL 3.2 para 3.3
- Alterações no comportamento de data e hora a serem esperadas desde o Spark 3.0.

Migrar do AWS Glue 1.0 para o AWS Glue 4.0

Observe as seguintes alterações ao migrar:

- O AWS Glue 1.0 usa o Spark 2.4 de código aberto e o AWS Glue 4.0 usa o Spark 3.3.0 otimizado para Amazon EMR.
  - Várias alterações do Spark sozinhas podem exigir a revisão de seus scripts para garantir que os recursos removidos não estejam sendo referenciados.
  - Por exemplo, o Spark 3.3.0 não habilita UDFs sem tipo Scala, mas o Spark 2.4 as permite.
- Todos os trabalhos no AWS Glue 4.0 serão executados com tempos de startup significativamente melhorados. Os trabalhos do Spark serão cobrados em incrementos de um segundo com uma

duração mínima de cobrança dez vezes menor, já que a latência de startup passará de um máximo de dez minutos para um minuto.

- O comportamento de registro em log mudou significativamente no AWS Glue 4.0, o Spark 3.3.0 tem um requisito mínimo de Log4j2.
- Várias atualizações de dependência, destacadas no apêndice.
- O Scala também foi atualizado para o 2.12 a partir do 2.11, e o Scala 2.12 não é compatível com o Scala 2.11.
- O Python 3.10 também é a versão padrão usada para scripts de Python, pois o AWS Glue 0.9 utilizava apenas o Python 2.

  O Python 2.7 não é compatível com o Spark 3.3.0. Qualquer trabalho que solicite Python 2 na configuração do trabalho falhará com uma IllegalArgumentException.
- Um novo mecanismo de instalação de módulos adicionais do Python por meio do pip está disponível desde o AWS Glue 2.0. Para mais informações, consulte Instalação de módulos Python adicionais com pip no AWS Glue 2.0+.
- O AWS Glue 4.0 não é executado no Apache YARN, portanto, as configurações do YARN não se aplicam.
- O AWS Glue 4.0 não tem um Sistema de Arquivos Distribuído do Hadoop (HDFS).
- Quaisquer arquivos JAR extras fornecidos em trabalhos do AWS Glue 1.0 podem trazer dependências conflitantes, uma vez que houve atualizações em várias dependências no 4.0 a partir do 1.0. Nós habilitamos o AWS Glue 4.0 com os parâmetros de trabalho `--user-jars-first` AWS Glue por padrão, para evitar esse problema.
- Agora o AWS Glue 4.0 é compatível com auto scaling. Portanto, a métrica ExecutorAllocationManager estará disponível quando o auto scaling estiver ativado.
- Em trabalhos do AWS Glue 4.0, você especifica o número de operadores e o tipo de operador, mas não especifica uma `maxCapacity`.
- O AWS Glue 4.0 ainda não é compatível com transformações de machine learning.
- Para migrar determinados conectores, consulte Migração de conectores e drivers JDBC para AWS Glue 4.0.
- O SDK de criptografia do AWS foi atualizado de 1.x para 2.x. Trabalhos do AWS Glue que usam configurações de segurança e trabalhos do AWS Glue dependentes da dependência do SDK de criptografia do AWS fornecida em runtime são afetados. Veja estas instruções para migração de trabalhos do AWS Glue.

- Você não pode migrar um trabalho de AWS Glue 0.9/1.0 para um trabalho do AWS Glue 4.0 diretamente. Isso ocorre porque, ao atualizar diretamente para a versão 2.x ou posterior e ativar todos os novos recursos imediatamente, o AWS Encryption SDK não conseguirá descriptografar o texto cifrado criptografado em versões anteriores do AWS Encryption SDK.
- Para atualizar com segurança, primeiro recomendamos que você migre para um ttrabalho do AWS Glue 2.0/3.0 que contenha a versão ponte do AWS Encryption SDK. Execute o trabalho uma vez para utilizar a versão ponte do AWS Encryption SDK.
- Após a conclusão, você pode migrar com segurança o trabalho do AWS Glue 2.0/3.0 para o AWS Glue 4.0.

Consulte a documentação de migração do Spark:

- Atualização do Spark SQL 2.4 para 3.0
- Atualização do Spark SQL 3.0 para 3.1
- Atualização do Spark SQL 3.1 para 3.2
- Atualização do Spark SQL 3.2 para 3.3
- Alterações no comportamento de data e hora a serem esperadas desde o Spark 3.0.

Migrar do AWS Glue 0.9 para o AWS Glue 4.0

Observe as seguintes alterações ao migrar:

- O AWS Glue 0.9 usa o Spark 2.2.1 de código aberto e o AWS Glue 4.0 usa o Spark 3.3.0 otimizado para Amazon EMR.
  - Várias alterações do Spark isoladas podem exigir a revisão de seus scripts para garantir que os recursos removidos não estejam sendo referenciados.
  - Por exemplo, o Spark 3.3.0 não habilita UDFs sem tipo Scala, mas o Spark 2.2 as permite.
- Todos os trabalhos no AWS Glue 4.0 serão executados com tempos de startup significativamente melhorados. Os trabalhos do Spark serão cobrados em incrementos de um segundo com uma duração mínima de cobrança dez vezes menor, porque a latência de startup passará de um máximo de dez minutos para um minuto.
- O comportamento de log mudou significativamente desde o AWS Glue 4.0. O Spark 3.3.0 tem um requisito mínimo de Log4j2, conforme mencionado aqui (https://spark.apache.org/docs/latest/core-migration-guide.html#upgrading-from-core-32-to-33).

- Várias atualizações de dependência, destacadas no apêndice.
- O Scala também foi atualizado para o 2.12 a partir do 2.11, e o Scala 2.12 não é compatível com o Scala 2.11.
- O Python 3.10 também é a versão padrão usada para scripts de Python, pois o AWS Glue 0.9 utilizava apenas o Python 2.
  - O Python 2.7 não é compatível com o Spark 3.3.0. Qualquer trabalho que solicite Python 2 na configuração do trabalho falhará com uma IllegalArgumentException.
  - Um novo mecanismo de instalação de módulos adicionais do Python por meio do pip está disponível.
- O AWS Glue 4.0 não é executado no Apache YARN, portanto, as configurações do YARN não se aplicam.
- O AWS Glue 4.0 não tem um Sistema de Arquivos Distribuído do Hadoop (HDFS).
- Quaisquer arquivos JAR extras fornecidos em trabalhos do AWS Glue 0.9 podem trazer dependências conflitantes, uma vez que houve atualizações em várias dependências no 3.0 a partir do 0.9. Você pode evitar conflitos de classpath no AWS Glue 3.0 com o parâmetro de trabalho `--user-jars-first` do AWS Glue.
- Agora o AWS Glue 4.0 é compatível com auto scaling. Portanto, a métrica ExecutorAllocationManager estará disponível quando o auto scaling estiver ativado.
- Em trabalhos do AWS Glue 4.0, você especifica o número de operadores e o tipo de operador, mas não especifica uma `maxCapacity`.
- O AWS Glue 4.0 ainda não é compatível com transformações de machine learning.
- Para migrar determinados conectores, consulte Migração de conectores e drivers JDBC para AWS Glue 4.0.
- O SDK de criptografia do AWS foi atualizado de 1.x para 2.x. Trabalhos do AWS Glue que usam configurações de segurança e trabalhos do AWS Glue dependentes da dependência do SDK de criptografia do AWS fornecida em runtime são afetados. Veja estas instruções para migração de trabalhos do AWS Glue.
  - Você não pode migrar um trabalho de AWS Glue 0.9/1.0 para um trabalho do AWS Glue 4.0 diretamente. Isso ocorre porque, ao atualizar diretamente para a versão 2.x ou posterior e ativar todos os novos recursos imediatamente, o AWS Encryption SDK não conseguirá descriptografar o texto cifrado criptografado em versões anteriores do AWS Encryption SDK.
  - Para atualizar com segurança, primeiro recomendamos que você migre para um ttrabalho do AWS Glue 2.0/3.0 que contenha a versão ponte do AWS Encryption SDK. Execute o trabalho uma vez para utilizar a versão ponte do AWS Encryption SDK.

- Após a conclusão, você pode migrar com segurança o trabalho do AWS Glue 2.0/3.0 para o AWS Glue 4.0.

Consulte a documentação de migração do Spark:

- Atualização do Spark SQL 2.2 para 2.3
- Atualização do Spark SQL 2.3 para 2.4
- Atualização do Spark SQL 2.4 para 3.0
- Atualização do Spark SQL 3.0 para 3.1
- Atualização do Spark SQL 3.1 para 3.2
- Atualização do Spark SQL 3.2 para 3.3
- Alterações no comportamento de data e hora a serem esperadas desde o Spark 3.0.

Migração de conectores e drivers JDBC para AWS Glue 4.0

Para as versões do JDBC e dos conectores de data lake que foram atualizadas, consulte:

- Apêndice B: upgrades do driver JDBC
- Apêndice C: Atualizações de conectores

Hudi

- Melhorias no suporte do Spark SQL:
  - Por meio do comando `Call Procedure`, há suporte adicional para atualização, downgrade, bootstrap, limpeza e reparo. A sintaxe de `Create/Drop/Show/Refresh Index` é possível no Spark SQL.
  - Foi eliminada uma discrepância de performance entre o uso por meio de um Spark DataSource em oposição ao Spark SQL. No passado, as gravações de fontes de dados costumavam ser mais rápidas do que em SQL.
  - Todos os geradores de chaves integrados implementam operações de API específicas do Spark com mais performance.
  - Substituiu a transformação UDF na operação de `insert` em massa com transformações RDD para reduzir os custos de uso do SerDe.

  - O Spark SQL com Hudi requer que seja especificada uma `primaryKey` por `tblproperites` ou opções na instrução SQL. Para operações de atualização e exclusão, o `preCombineField` também é necessário.
- Qualquer tabela Hudi criada antes da versão 0.10.0 sem uma `primaryKey` precisa ser recriada com um campo `primaryKey` desde a versão 0.10.0.

PostgreSQL

- Várias vulnerabilidades (CVEs) foram resolvidas.
- O Java 8 tem suporte nativo.
- Se o trabalho estiver usando matrizes de matrizes, com exceção das matrizes de bytes, esse cenário poderá ser tratado como matrizes multidimensionais.

MongoDB

- O conector atual do MongoDB é compatível com o Spark versão 3.1 ou posterior e o MongoDB versão 4.0 ou posterior.
- Devido à atualização do conector, alguns nomes de propriedades foram alterados. Por exemplo, o nome da propriedade de URI foi alterado para `connection.uri`. Para obter mais informações sobre as opções atuais, consulte o blog sobre o MongoDB Spark Connector.
- O uso do MongoDB 4.0 hospedado pelo Amazon DocumentDB tem algumas diferenças funcionais. Para obter mais informações, consulte estes tópicos:
  - Diferenças funcionais: Amazon DocumentDB e MongoDB
  - APIs, operações e tipos de dados compatíveis do MongoDB.
- A opção “particionador” é restrita a `ShardedPartitioner`, `PaginateIntoPartitionsPartitioner` e `SinglePartitionPartitioner`. Ela não pode usar `SamplePartitioner` e `PaginateBySizePartitioner` padrão para o Amazon DocumentDB porque o operador de estágio não é compatível com a API do MongoDB. Para obter mais informações, consulte APIs, operações e tipos de dados compatíveis do MongoDB.

Delta Lake

- O Delta Lake agora é compatível com a viagem no tempo em SQL para consultar dados antigos com facilidade. Com essa atualização, a viagem no tempo agora está disponível no Spark SQL e por meio da API DataFrame. Foi adicionado suporte para a versão atual do TIMESTAMP em SQL.

- O Spark 3.3 apresenta o Trigger.AvailableNow para executar consultas de streaming como equivalente a `Trigger.Once` para consultas em lote. Esse suporte também está disponível ao usar tabelas Delta como fonte de streaming.
- Suporte a SHOW COLUMNS para retornar a lista de colunas em uma tabela.
- Suporte a DESCRIBE DETAIL na API Scala e Python DeltaTable. Ele recupera informações detalhadas sobre uma tabela Delta usando a API DeltaTable ou o Spark SQL.
- Suporte a retorno de métricas de operação dos comandos SQL Delete, Merge e Update. Anteriormente, esses comandos SQL retornavam um DataFrame vazio, agora eles retornam um DataFrame com métricas úteis sobre a operação executada.
- Melhorias de otimização de performance:
  - Defina a opção de configuração `spark.databricks.delta.optimize.repartition.enabled=true` para usar `repartition(1)` em vez de `coalesce(1)` no comando Optimize para melhorar a desempenho ao compactar muitos arquivos pequenos.
  - Desempenho aprimorado usando uma abordagem baseada em filas para paralelizar trabalhos de compactação.
- Outras alterações notáveis:
  - Suporte ao uso de variáveis nos comandos VACUUM e OPTIMIZE SQL.
  - Melhorias no CONVERT TO DELTA com tabelas de catálogo, incluindo:
    - Preenchimento automático do esquema de partição do catálogo quando ele não for fornecido.
    - Uso de informações de partição do catálogo para encontrar os arquivos de dados a serem confirmados em vez de fazer uma verificação completa do diretório. Em vez de confirmar todos os arquivos de dados no diretório da tabela, somente os arquivos de dados nos diretórios das partições ativas serão confirmados.
  - Suporte a leituras em lote do Change Data Feed (CDF) em tabelas habilitadas para mapeamento de colunas quando DROP COLUMN e RENAME COLUMN não foram usados. Para obter mais informações, consulte a Documentação do CloudTrail Lake.
  - Melhore a desempenho do comando Update ativando a remoção do esquema na primeira passada.

Apache Iceberg

- Foram adicionadas várias melhorias de performance para planejamento de varredura e consultas do Spark.

- Foi adicionado um cliente comum do catálogo REST que usa confirmações baseadas em alterações para resolver conflitos de confirmação no lado do serviço.
- A sintaxe `AS OF` para consultas SQL de viagem no tempo é compatível.
- Foi adicionado suporte de mesclagem na leitura para consultas MERGE e UPDATE.
- Foi adicionado suporte para reescrever partições usando a ordem Z.
- Foram adicionadas uma especificação e implementação para o Puffin, um formato para estatísticas grandes e blobs de índice, como esboços Theta ou filtros Bloom.
- Foram adicionadas novas interfaces para consumir dados de forma incremental (digitalizações de anexação e logs de alterações).
- Foi adicionado suporte para operações em massa e leituras variadas nas interfaces do FileIO.
- Foram adicionadas mais tabelas de metadados para mostrar arquivos excluídos na árvore de metadados.
- O comportamento de drop table mudou. No Iceberg 0.13.1, a execução de `DROP TABLE` remove a tabela do catálogo e também exclui o conteúdo da tabela. No Iceberg 1.0.0, `DROP TABLE` somente remove a tabela do catálogo. Para excluir o conteúdo da tabela, use `DROP TABLE PURGE`.
- As leituras vetorizadas de Parquet são habilitadas por padrão no Iceberg 1.0.0. Se você quiser desativar as leituras vetorizadas, defina `read.parquet.vectorization.enabled` como `false`.

Oracle

As mudanças são pequenas.

MySQL

As mudanças são pequenas.

Amazon Redshift

O AWS Glue 4.0 apresenta um novo conector do Amazon Redshift com um novo driver JDBC. Para obter informações sobre os aprimoramentos e como migrar de versões anteriores do AWS Glue, consulte the section called “Conexões do Redshift”.

Apêndice A: atualizações de dependência notáveis

Veja a seguir as atualizações de dependência:

Dependência	Versão no AWS Glue 4.0	Versão no AWS Glue 3.0	Versão no AWS Glue 2.0	Versão no 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
Arrow	7.0.0	2.0.0	0.10.0	0.10.0
Cliente do AWS Glue Data Catalog	3.7.0	3.0.0	1.10.0	N/D
Python	3.10	3.7	2.7 e 3.6	2.7 e 3.6
Boto	1.26	1.18	1.12	N/D

Apêndice B: upgrades do driver JDBC

A seguir estão as atualizações do driver JDBC:

Driver	Versão do driver JDBC nas versões do AWS Glue anteriores	Versão do driver JDBC no AWS Glue 3.0	Versão do driver JDBC no AWS Glue 4.0
MySQL	5.1	8.0.23	8.0.23
Microsoft SQL Server	6.1.0	7.0.0	9.4.0

Driver	Versão do driver JDBC nas versões do AWS Glue anteriores	Versão do driver JDBC no AWS Glue 3.0	Versão do driver JDBC no AWS Glue 4.0
Bancos de dados da Oracle	11.2	21.1	21.7
PostgreSQL	42.1.0	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

Apêndice C: Atualizações de conectores

As atualizações do conector são as seguintes:

Driver	Versão do conector no AWS Glue 3.0	Versão do conector no AWS Glue 4.0
MongoDB	3.0.0	10.0.4
Hudi	0.10.1	0.12.1
Delta Lake	1.0.0	2.1.0
Iceberg	0.13.1	1.0.0
DynamoDB	1.11	1.12

Atualizações de IA generativa para o Apache Spark no AWS Glue

As atualizações de IA generativa da pré-visualização do Apache Spark estão disponíveis para as versões 4.0 e 5.0 do AWS Glue nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio) e Ásia-Pacífico (Sydney). Os recursos de visualização prévia estão sujeitos a alterações.

As atualizações do Spark no AWS Glue permitem que engenheiros e desenvolvedores de dados atualizem e migrem trabalhos existentes do Spark no AWS Glue para as versões mais recentes do Spark usando IA generativa. Os engenheiros de dados podem usá-la para verificar trabalhos do Spark no AWS Glue, gerar planos de atualização, executar planos e validar resultados. Ela reduz o tempo e o custo das atualizações do Spark ao automatizar o trabalho não diferenciado de identificar e atualizar scripts, configurações, dependências, métodos e recursos do Spark.

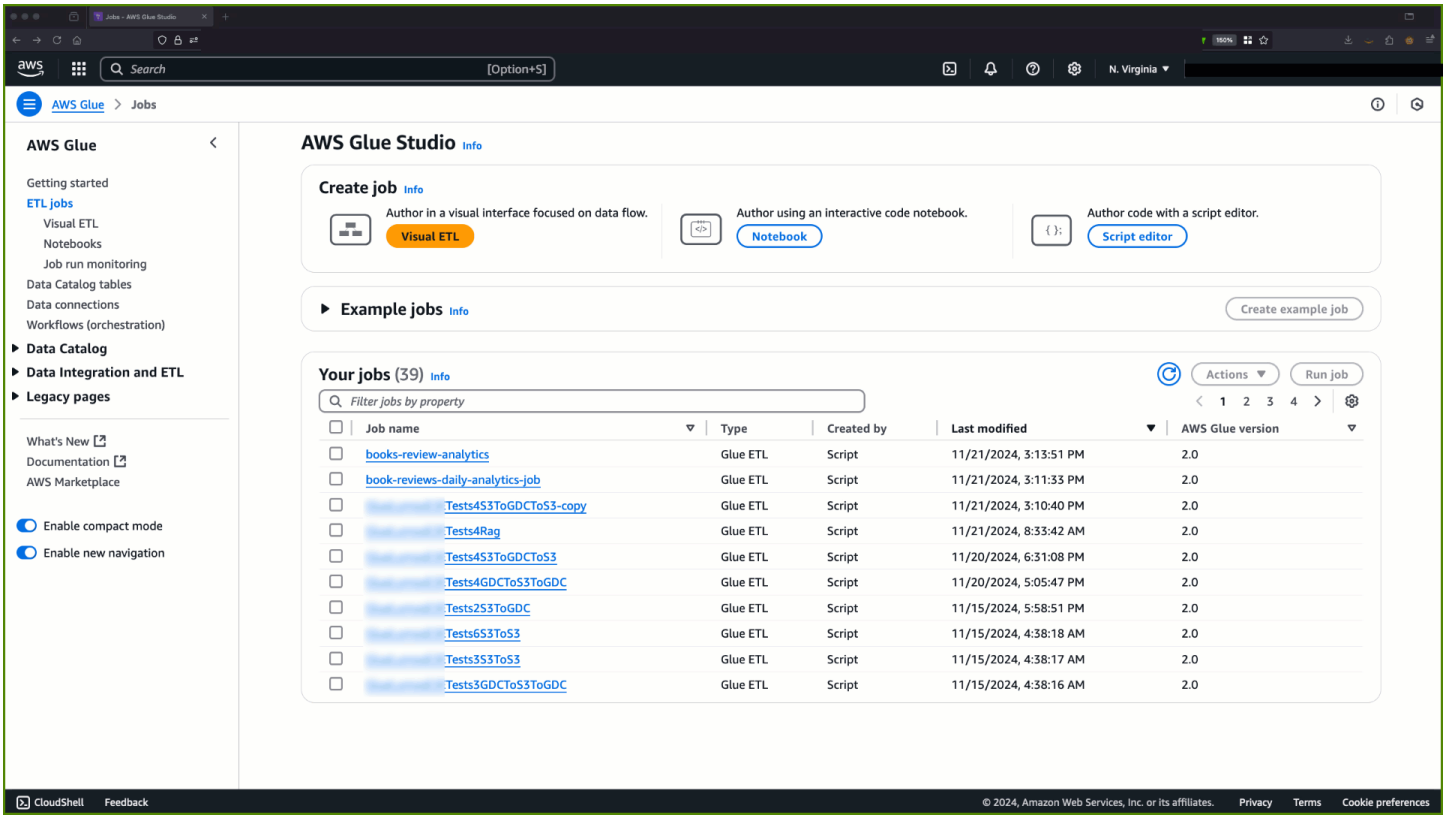

Como funciona

Quando você usa a análise de upgrade, o AWS Glue identifica diferenças entre versões e configurações no código do trabalho para gerar um plano de atualização. O plano de atualização detalha todas as alterações de código e as etapas de migração necessárias. Em seguida, o AWS Glue cria e executa a aplicação atualizada em um ambiente para validar as alterações e gerar uma lista de alterações de código para você migrar o trabalho. Você pode visualizar o script atualizado com o resumo que detalha as alterações propostas. Depois de executar seus próprios testes, aceite as alterações e o trabalho do AWS Glue será atualizado automaticamente para a versão mais recente com o novo script.

O processo de análise de upgrade pode levar algum tempo para ser concluído, dependendo da complexidade do trabalho e da workload. Os resultados da análise de atualização serão

armazenados no caminho especificado do Amazon S3 e poderão ser revisados para o entendimento da atualização e de quaisquer possíveis problemas de compatibilidade. Depois de revisar os resultados da análise de atualização, você pode decidir se deseja continuar com a atualização real ou fazer as alterações necessárias no trabalho antes da atualização.

Pré-requisitos

Os seguintes pré-requisitos são necessários para usar a IA generativa na atualização de trabalhos no AWS Glue:

- Trabalhos do PySpark no AWS Glue 2: somente trabalhos do AWS Glue 2 podem ser atualizados para o AWS Glue 5.
- São necessárias permissões do IAM para iniciar a análise, revisar os resultados e atualizar o trabalho. Para obter mais informações, consulte os exemplos na seção Permissões a seguir.
- Se você estiver usando o AWS KMS para criptografar artefatos de análise ou serviços para criptografar os dados usados para análise, serão necessárias permissões adicionais do AWS KMS. Para obter mais informações, consulte os exemplos na seção Política AWS KMS a seguir.

Permissões

Para iniciar uma nova análise de atualização, você precisa das seguintes permissões:

1. Atualize a política do IAM do chamador com a seguinte permissão:

```
{
  "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**
>
> Se você estiver usando duas chaves diferentes do AWS KMS, uma para criptografia de artefatos de resultados e outra para criptografia de metadados de serviço, a política precisará incluir uma política semelhante para ambas as chaves.

2. Atualize o perfil Execução do trabalho que você está atualizando para incluir a seguinte política em linha:

```
    {
      "Effect": "Allow",
      "Action": ["s3:GetObject"],
      "Resource": [
        "ARN of the Amazon S3 path provided on API",
        "ARN of the Amazon S3 path provided on API/*"
      ]
    }
```

Por exemplo, se você estiver usando o caminho `s3://amzn-s3-demo-bucket/upgraded-result` do Amazon S3, a política será:

```
{
      "Effect": "Allow",
      "Action": ["s3:GetObject"],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/upgraded-result/",
        "arn:aws:s3:::amzn-s3-demo-bucket/upgraded-result/*"
      ]
    }
```

Para recuperar os detalhes de uma análise, você precisa das seguintes permissões:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["glue:GetJobUpgradeAnalysis"],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    }
  ]
}
```

Para interromper uma análise em andamento, você precisa das seguintes permissões:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["glue:StopJobUpgradeAnalysis",
                 "glue:BatchStopJobRun"
                 ],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    }
```

```
  ]
}
```

Para listar todas as análises enviadas em um trabalho específico, você precisa das seguintes permissões:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": ["glue:ListJobUpgradeAnalyses"],
      "Resource": [
        "arn:aws:glue:us-east-1:123456789012:job/jobName"
      ]
    }
  ]
}
```

Para aceitar as alterações de uma análise e atualizar um trabalho, você precisa das seguintes permissões:

```
{
  "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>"
      ]
    }
  ]
```

```
}
```

Política AWS KMS

Para passar sua própria chave do AWS KMS personalizada quando iniciar uma análise, consulte a seção a seguir para configurar as permissões apropriadas nas chaves do AWS KMS.

Configuração da chave do AWS KMS de criptografia de metadados do serviço:

Você precisa de permissão (criptografar/descriptografar) para passar a chave. No exemplo de política abaixo, a conta da AWS ou o perfil especificado pelo `<IAM Customer caller ARN>` tem permissão para executar as ações permitidas:

- kms:Decrypt permite a criptografia usando a chave do AWS KMS especificada.
- kms:GenerateDataKey permite gerar uma chave de dados usando a chave do AWS KMS especificada.

```
{
    "Effect": "Allow",
    "Principal":{
        "AWS": "<IAM Customer caller ARN>"
    },
    "Action": [
      "kms:Decrypt",
      "kms:GenerateDataKey",
    ],
    "Resource": "<key-arn-passed-on-start-api>"
}
```

Você precisa dar permissão ao AWS Glue para usar a chave do AWS KMS tanto para criptografia quanto para descriptografia da chave.

```
{
    "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"
       }
     }
 }
```

Configuração da criptografia do artefato do resultado usando uma chave do AWS KMS:

Esta política garante que você tenha as permissões de criptografia e descriptografia na chave do AWS KMS.

```
{
    "Effect": "Allow",
    "Principal":{
        "AWS": "<IAM Customer caller ARN>"
    },
    "Action": [
      "kms:Decrypt",
      "kms:GenerateDataKey",
    ],
    "Resource": "<key-arn-passed-on-start-api>"
}
```

Execução de uma análise de atualização e aplicação do script de atualização

Você pode executar uma análise de atualização, que gerará um plano de atualização em um trabalho selecionado na visualização Trabalhos.

1. Em Trabalhos, selecione um trabalho do AWS Glue 2.0 e escolha Executar análise de atualização no menu Ações.

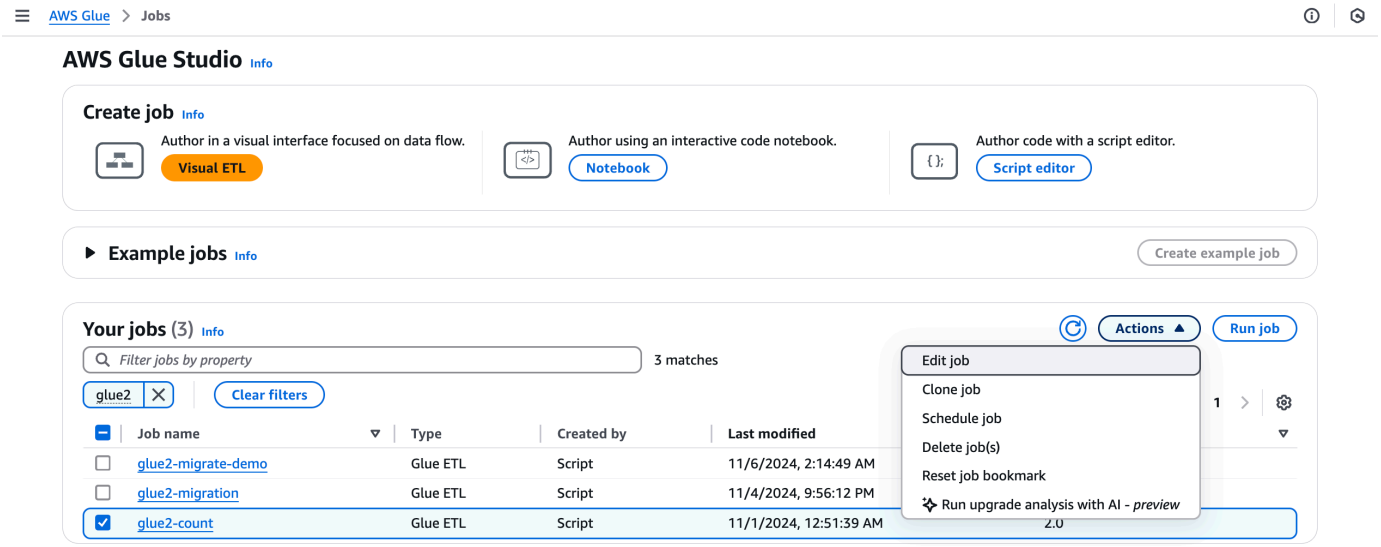

2. No modal, selecione um caminho para armazenar o plano de atualização gerado no caminho Resultado. Esse deve ser um bucket do Amazon S3 que você possa acessar e no qual você possa fazer gravações.

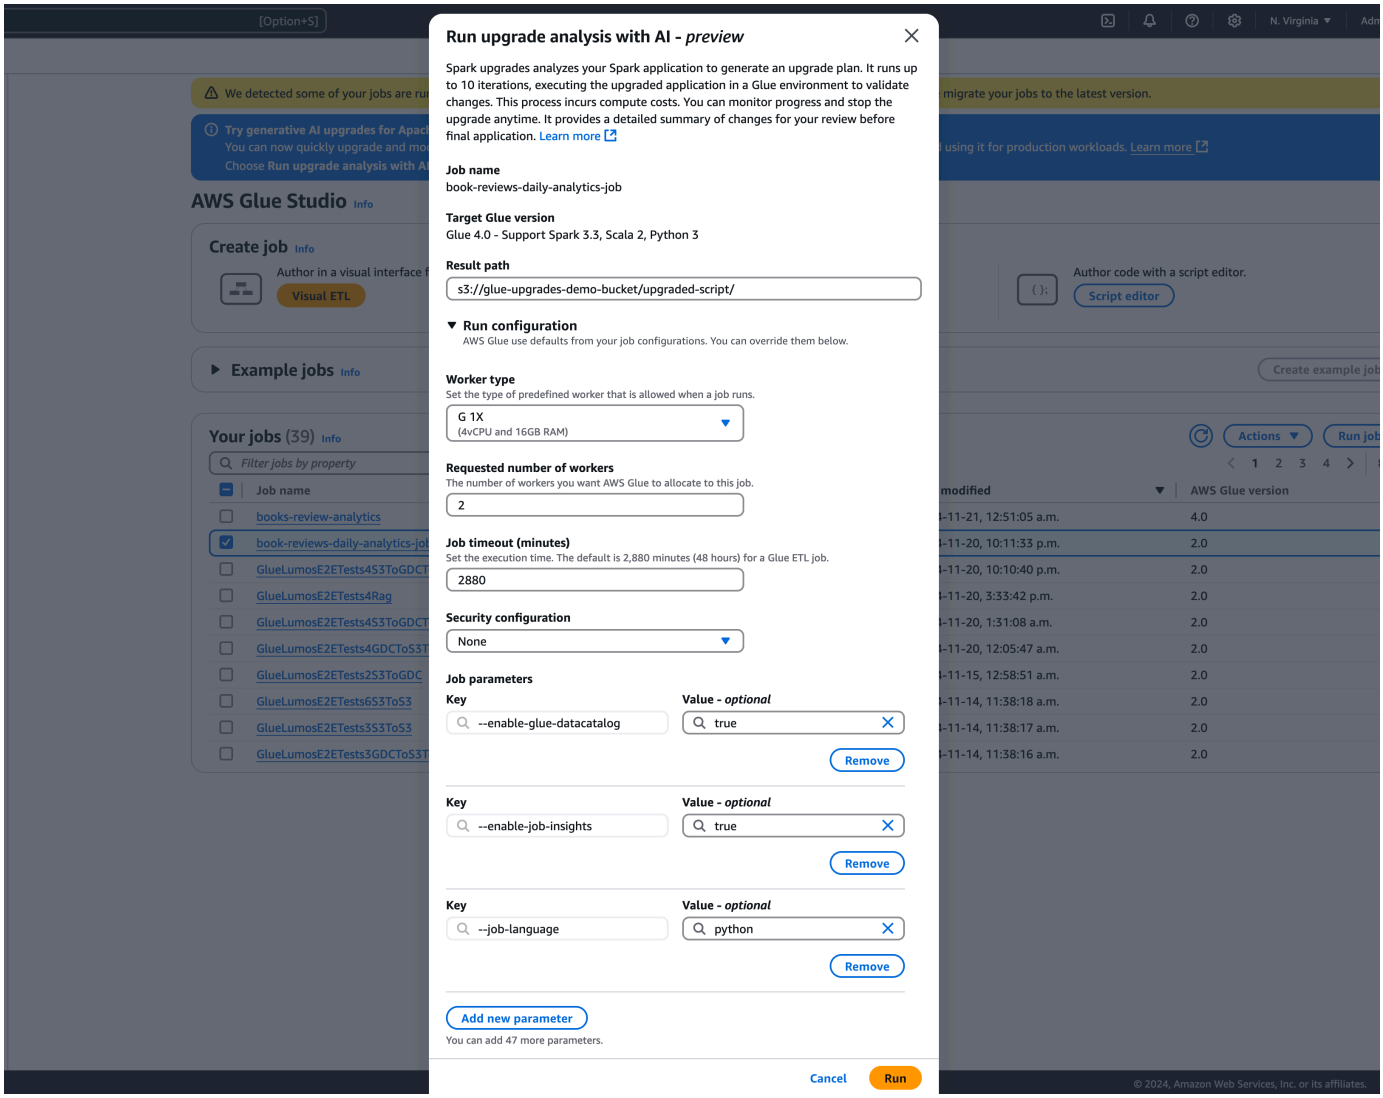

3. Configure opções adicionais se necessário:

- Configuração de execução: opcional: a configuração de execução é uma configuração opcional que permite a personalização de vários aspectos das execuções de validação realizadas durante a análise de atualização. Essa configuração é utilizada para executar o script atualizado e permite que você selecione as propriedades do ambiente de computação (tipo de trabalhador, número de trabalhadores etc.). Você deve usar as contas de desenvolvedor de não produção para executar as validações em exemplos de conjuntos de dados antes de revisar, aceitar as alterações e aplicá-las aos ambientes de produção. A configuração de execução inclui os seguintes parâmetros personalizáveis:
  - Tipo de trabalhador: você pode especificar o tipo de trabalhador a ser usado nas execuções de validação, permitindo a escolha dos recursos de computação apropriados com base nos requisitos.

- Número de trabalhadores: você pode definir o número de trabalhadores a serem provisionados para as execuções de validação, permitindo que você escale os recursos de acordo com as necessidades de workload.
- Tempo limite do trabalho (em minutos): esse parâmetro permite que você defina um limite de tempo para as execuções de validação, garantindo que os trabalhos sejam encerrados após um período especificado para evitar o consumo excessivo de recursos.
- Configuração de segurança: você pode definir configurações de segurança, como criptografia e controle de acesso, para garantir a proteção dos dados e recursos durante as execuções de validação.
- Parâmetros adicionais do trabalho: se necessário, você pode adicionar parâmetros de trabalho para personalizar ainda mais o ambiente de execução das execuções de validação.

Ao aproveitar a configuração da execução, você pode personalizar as execuções de validação para atender às suas necessidades específicas. Por exemplo, você pode configurar as execuções de validação para usar um conjunto de dados menor, o que permite que a análise seja concluída mais rapidamente e otimiza os custos. Essa abordagem garante que a análise de atualização seja executada de forma eficiente, minimizando a utilização de recursos e os custos associados durante a fase de validação.

- Configuração de criptografia: opcional:
  - Habilitar a criptografia de artefatos de atualização: habilite a criptografia em repouso quando gravar dados no caminho do resultado. Se você não quiser criptografar os artefatos de atualização, deixe essa opção desmarcada.
  - Personalizar a criptografia de metadados do serviço: os metadados do serviço são criptografados por padrão usando chaves de propriedade da AWS. Escolha essa opção se quiser usar sua própria chave para criptografia.

4. Escolha Executar para iniciar a análise de atualização. Enquanto a análise está sendo executada, você pode visualizar os resultados na guia Análise de atualização. A janela de detalhes da análise mostrará informações sobre a análise, além de links para os artefatos de atualização.

   - Caminho do resultado: é onde o resumo dos resultados e o script de atualização são armazenados.
   - Script atualizado no Amazon S3: a localização do script de atualização no Amazon S3. Você pode visualizar o script antes de aplicar a atualização.

- Resumo da atualização no Amazon S3: a localização do resumo da atualização no Amazon S3. Você pode visualizar o resumo da atualização antes de aplicar a atualização.

5. Quando a análise de atualização for concluída com êxito, você poderá aplicar o script de atualização para atualizar automaticamente o trabalho ao escolher Aplicar script atualizado.

   Depois de aplicado o script, a versão do AWS Glue será atualizada para 4.0. Você pode visualizar o novo script na guia Script.

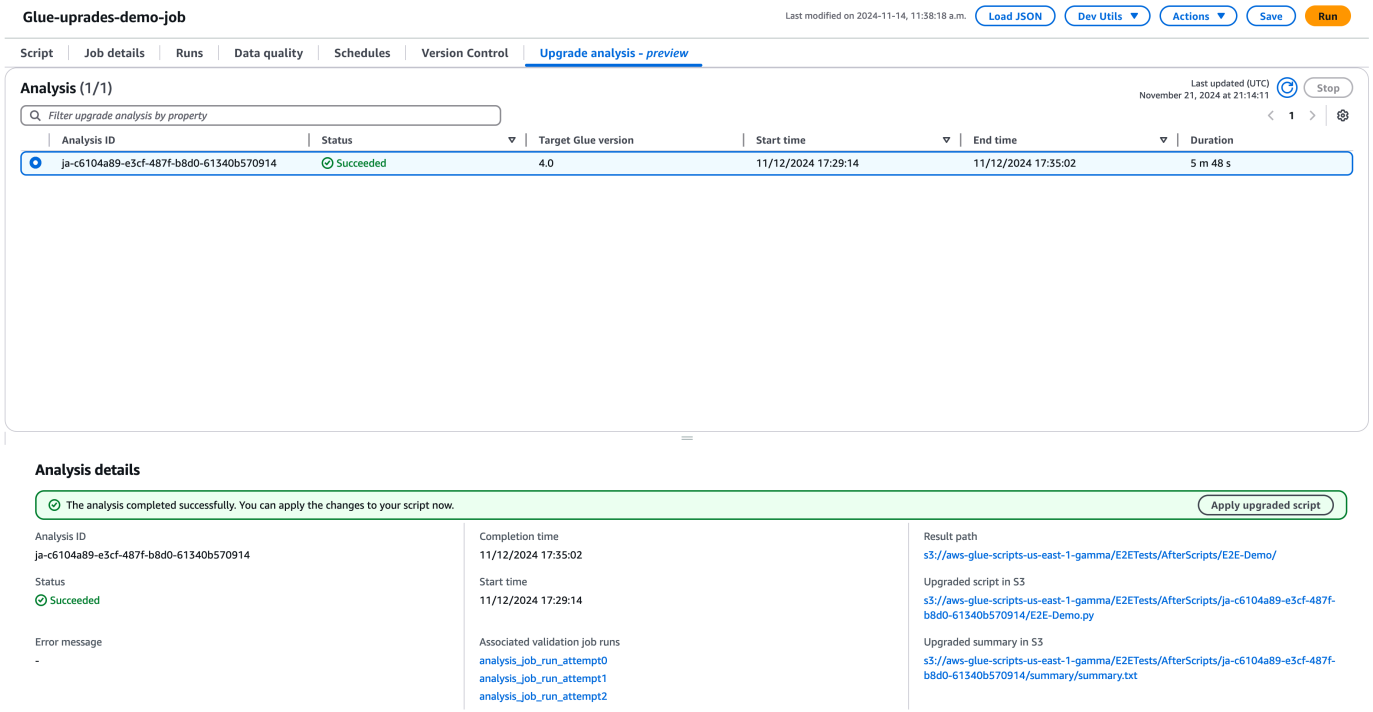

Noções básicas sobre o resumo da atualização

Este exemplo demonstra o processo de atualização de um trabalho do AWS Glue da versão 2.0 para a versão 4.0. O exemplo de trabalho lê os dados do produto de um bucket do Amazon S3, aplica várias transformações aos dados usando o Spark SQL e, em seguida, salva os resultados transformados em um bucket do Amazon S3.

Código original (AWS Glue 2.0): antes da atualização

```
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()
```

Novo código (Glue 4.0): após a atualização

```
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()
```

Explicação do resumo da análise

```
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.
```

Com base no resumo, existem quatro mudanças propostas pelo AWS Glue para atualizar com êxito o script do AWS Glue 2.0 para o AWS Glue 4.0:

1. Configuração do Spark SQL (spark.sql.adaptive.enabled): essa alteração tem a finalidade de restaurar o comportamento da aplicação, pois um novo recurso para a execução de consultas adaptáveis do Spark SQL é introduzido no Spark 3.2. Você pode inspecionar a alteração dessa configuração e habilitá-la ou desabilitá-la ainda mais de acordo com a preferência.
2. Alteração da API de DataFrame: a opção de caminho não pode coexistir com outras operações do DataFrameReader, como `load()`. Para manter o comportamento anterior, o AWS Glue atualizou o script para adicionar uma nova configuração de SQL (spark.sql.legacy.pathOptionBehavior.enabled).
3. Alteração na API do Spark SQL: o comportamento de `strfmt` em `format_string(strfmt, obj, ...)` foi atualizado para proibir `0$` como o primeiro argumento. Para garantir a compatibilidade, o AWS Glue modificou o script para usar `1$` como o primeiro argumento.

4. Alteração na API do Spark SQL: a função `unbase64` não permite entradas de string malformadas. Para manter o comportamento anterior, o AWS Glue atualizou o script para usar a função `try_to_binary`.

Interrupção de uma análise de atualização em andamento

Você pode cancelar uma análise de atualização em andamento ou simplesmente interromper a análise.

1. Escolha a guia Análise de atualização.
2. Selecione o trabalho que está sendo executado e escolha Interromper. Isso interromperá a análise. Em seguida, você pode executar outra análise de atualização no mesmo trabalho.

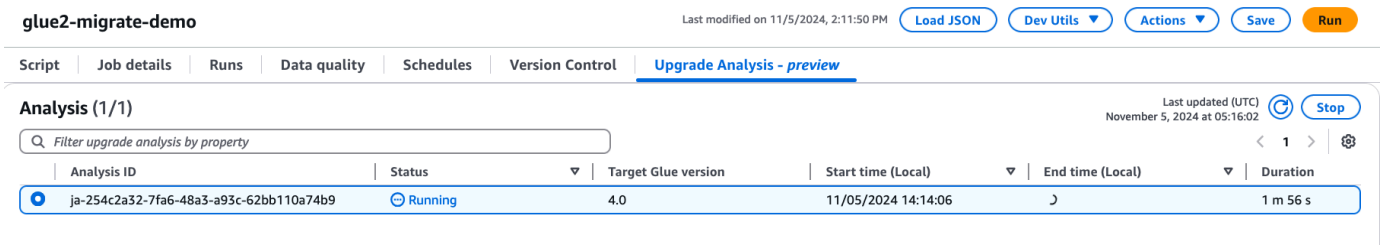

Considerações

Ao começar a usar atualizações do Spark durante o período de visualização prévia, existem vários aspectos importantes a serem considerados para otimizar o uso do serviço.

- Escopo e limitações do serviço: a pré-visualização foca as atualizações do código PySpark da versão 2.0 do AWS Glue para a versão 5.0. No momento, o serviço processa o código PySpark que não conta com dependências adicionais da biblioteca. Você pode executar atualizações automatizadas para até dez trabalhos simultaneamente em uma conta da AWS, permitindo que você atualize com eficiência vários trabalhos enquanto mantém a estabilidade do sistema.
  - Somente trabalhos do PySpark são compatíveis.
  - A análise de atualização expirará após 24 horas.
  - Somente uma análise de atualização ativa pode ser executada de cada vez em um trabalho. No nível da conta, até dez análises de atualização ativas podem ser executadas ao mesmo tempo.
- Otimização de custos durante o processo de atualização: como as atualizações do Spark usam IA generativa para validar o plano de atualização por meio de várias iterações, com cada iteração sendo executada como uma tarefa do AWS Glue na conta, é essencial otimizar as configurações

de execução do trabalho de validação para obter eficiência de custos. Para isso, recomendamos que seja especificada uma configuração de execução no início de uma análise de atualização da seguinte maneira:

- Use contas de desenvolvedor de não produção e selecione exemplos de conjuntos de dados simulados que representem seus dados de produção, mas que sejam menores, para validação com as atualizações do Spark.
- Uso de recursos de computação do tamanho certo, como trabalhadores G.1X, e seleção de um número adequado de trabalhadores para processar os exemplos de dados.
- Habilitação do ajuste de escala automático de trabalhos do AWS Glue, quando aplicável, para ajustar automaticamente os recursos com base na workload.

Por exemplo, se o trabalho de produção processa terabytes de dados com vinte trabalhadores G.2X, você pode configurar o trabalho de atualização para processar alguns gigabytes de dados representativos com dois trabalhadores G.2X e o ajuste de escala automático habilitado para validação.

- Práticas recomendadas da visualização prévia: durante o período de visualização prévia, é altamente recomendável iniciar a jornada de atualização com trabalhos de não produção. Essa abordagem permite que você se familiarize com o fluxo de trabalho de atualização e entenda como o serviço lida com diferentes tipos de padrões de código do Spark.
- Alarmes e notificações: ao utilizar o recurso de atualizações de IA generativa em um trabalho, certifique-se de que os alarmes/notificações para execuções de trabalhos com falha estejam desativados. Durante o processo de atualização, pode haver até dez falhas na execução de trabalhos na conta antes que os artefatos atualizados sejam fornecidos.
- Regras de detecção de anomalias: desative também todas as regras de detecção de anomalias no trabalho que está sendo atualizado, pois os dados gravados nas pastas de saída durante execuções de trabalhos intermediários talvez não estejam no formato esperado enquanto a validação da atualização está em andamento.
- Usar a análise de atualização com trabalhos idempotentes: use a análise de atualização com trabalhos idempotentes para garantir que cada tentativa subsequente de execução do trabalho de validação seja semelhante à anterior e não encontre problemas. Trabalhos idempotentes são trabalhos que podem ser executados várias vezes com os mesmos dados de entrada, e eles produzirão sempre a mesma saída. Ao usar as atualizações de IA generativa para o Apache Spark no AWS Glue, o serviço executará várias iterações do seu trabalho como parte do processo de validação. Durante cada iteração, ele fará alterações no código e nas configurações do Spark

para validar o plano de atualização. Se o trabalho do Spark não for idempotente, executá-lo várias vezes com os mesmos dados de entrada poderá gerar problemas.

Inferência entre regiões no Spark Upgrades

O Spark Upgrades é baseado em Amazon Bedrock e aproveita a inferência entre regiões (CRIS). Com a CRIS, o Spark Upgrades selecionará automaticamente a região ideal em sua geografia (conforme descrito em mais detalhes aqui) para processar sua solicitação de inferência, maximizando os recursos computacionais disponíveis e a disponibilidade do modelo e fornecendo a melhor experiência ao cliente. Não há custo adicional para usar a inferência entre regiões.

As solicitações de inferência entre regiões são mantidas nas regiões da AWS que fazem parte da geografia em que os dados originalmente residem. Por exemplo, uma solicitação feita nos EUA é mantida nas regiões da AWS nos EUA. Embora os dados permaneçam armazenados somente na região primária, ao usar a inferência entre regiões, seus prompts de entrada e resultados de saída podem sair da sua região primária. Todos os dados serão transmitidos criptografados pela rede segura da Amazon.

Lidar com trabalhos do Spark no AWS Glue

Fornece informações sobre os trabalhos d ETL do AWS Glue for Spark.

Tópicos

- Usar parâmetros de tarefa em tarefas do AWS Glue
- Trabalhos Spark e PySpark do AWS Glue
- Trabalhos de transmissão de ETL no AWS Glue
- Correspondência de registros com o FindMatches do AWS Lake Formation
- Migrar programas do Apache Spark para o AWS Glue

Usar parâmetros de tarefa em tarefas do AWS Glue

Ao criar uma tarefa do AWS Glue, você define alguns campos padrão, como `Role` e `WorkerType`. Você pode fornecer informações adicionais de configuração por meio dos campos `Argument` (Job Parameters no console). Nesses campos, você pode fornecer trabalhos do AWS Glue com os argumentos (parâmetros) listados neste tópico.

Para obter mais informações sobre a API do AWS Glue, consulte the section called “Tarefas”.

> **Note**
>
> Os argumentos do trabalho têm um limite máximo de tamanho de 260 KB. Uma verificação de validação gerará um erro se o tamanho do argumento for maior que 260 KB.

Definir parâmetros de trabalho

Você pode configurar um trabalho pelo console, na guia Job details (Detalhes do trabalho), no cabeçalho Job Parameters (Parâmetros do trabalho). Você também pode configurar um trabalho usando a AWS CLI definindo `DefaultArguments` ou `NonOverridableArguments` em um trabalho ou definindo `Arguments` em uma execução de trabalho. Os argumentos definidos no trabalho serão transmitidos toda vez que o trabalho for executado, enquanto os argumentos definidos na execução do trabalho serão transmitidos somente para essa execução individual.

Por exemplo, seguir temos a sintaxe para a execução de um trabalho usando `--arguments` para definir um parâmetro do trabalho.

```
$ aws glue start-job-run --job-name "CSV to CSV" --arguments='--scriptLocation="s3://
my_glue/libraries/test_lib.py"'
```

Acessar parâmetros do trabalho

Ao escrever scripts AWS Glue, talvez você queira acessar os valores dos parâmetros do trabalho para alterar o comportamento do seu próprio código. Fornecemos métodos auxiliares para fazer isso em nossas bibliotecas. Esses métodos resolvem os valores dos parâmetros de execução do trabalho que substituem os valores dos parâmetros do trabalho. Ao resolver parâmetros definidos em vários locais, o trabalho `NonOverridableArguments` substituirá a execução do trabalho `Arguments`, que substituirá o trabalho. `DefaultArguments`

No Python:

Em trabalhos do Python, fornecemos uma função denominada `getResolvedParameters`. Para obter mais informações, consulte the section called “getResolvedOptions”. Os parâmetros do trabalho estão disponíveis na variável `sys.argv`.

No Scala:

Em trabalhos do Scala, fornecemos um objeto denominado `GlueArgParser`. Para obter mais informações, consulte the section called “GlueArgParser”. Os parâmetros do trabalho estão disponíveis na variável `sysArgs`.

Referência de parâmetros de trabalho

O AWS Glue reconhece os seguintes nomes de argumento que podem ser usados para configurar o ambiente de script para os trabalhos e as execuções de trabalho:

`--additional-python-modules`

Uma lista delimitada por vírgulas representando um conjunto de pacotes do Python a serem instalados. Você pode instalar pacotes do PyPI ou fornecer uma distribuição personalizada. Uma entrada de pacote PyPI estará no formato *`package`*==*`version`*, com o nome PyPI e a versão do seu pacote de destino. Uma entrada de distribuição personalizada é o caminho do S3 para a distribuição.

As entradas usam a correspondência de versão do Python para combinar pacote e versão. Isso significa que você precisará usar dois sinais de igual, como ==. Existem outros operadores de correspondência de versão. Para obter mais informações, consulte PEP 440.

Para passar as opções de instalação do módulo para o `pip3`, use o parâmetro --python-modules-installer-option.

`--auto-scale-within-microbatch`

O valor padrão é true. Esse parâmetro só pode ser usado para trabalhos de streaming do AWS Glue, os quais processam os dados de streaming em uma série de microlotes, e o ajuste de escala automático deve estar habilitado. Ao definir esse valor como falso, ele calcula a média móvel exponencial da duração do lote para microlotes concluídos e compara esse valor com o tamanho da janela para determinar se o número de executores deve ser aumentado ou reduzido. O ajuste de escala só acontece quando um microlote é concluído. Ao definir esse valor como verdadeiro, durante um microlote, ele aumenta a escala verticalmente quando o número de tarefas do Spark permanece o mesmo por 30 segundos ou o processamento em lote atual é maior que o tamanho da janela. O número de executores diminuirá se um executor ficar inativo por mais de 60 segundos ou se a média móvel exponencial da duração do lote for baixa.

`--class`

A classe Scala que serve como ponto de entrada para o seu script Scala. Isso se aplicará somente se `--job-language` for definido como `scala`.

`--continuous-log-conversionPattern`

Especifica um padrão personalizado de conversão de logs para um trabalho habilitado para registro em log contínuo. O padrão de conversão só se aplica a logs de driver e logs de executor. Isso não afeta a barra de progresso do AWS Glue.

`--continuous-log-logGroup`

Especifica um nome de grupo de logs do Amazon CloudWatch personalizado para um trabalho habilitado para registro em log contínuo.

`--continuous-log-logStreamPrefix`

Especifica um prefixo de fluxo de logs do CloudWatch personalizado para um trabalho habilitado para registro em log contínuo.

`--customer-driver-env-vars` e **`--customer-executor-env-vars`**

Esses parâmetros definem variáveis de ambiente no sistema operacional, respectivamente, para cada operador (driver ou executor). É possível usar esses parâmetros ao criar plataformas e estruturas personalizadas com base no AWS Glue para permitir que seus usuários escrevam trabalhos em cima dele. A ativação desses dois sinalizadores permitirá definir variáveis de ambiente diferentes no driver e no executor, respectivamente, sem precisar injetar a mesma lógica no próprio script de trabalho.

Exemplo de uso

Este exemplo mostra como usar esses parâmetros:

```
"–customer-driver-env-vars", "CUSTOMER_KEY1=VAL1,CUSTOMER_KEY2=\"val2,val2 val2\"",
"–customer-executor-env-vars", "CUSTOMER_KEY3=VAL3,KEY4=VAL4"
```

Defini-los no argumento de execução do trabalho equivale a executar os seguintes comandos:

No driver:

- export CUSTOMER_KEY1=VAL1
- export CUSTOMER_KEY2="val2,val2 val2"

No executor:

- export CUSTOMER_KEY3=VAL3

Em seguida, no próprio script de trabalho, você pode recuperar as variáveis de ambiente usando `os.environ.get("CUSTOMER_KEY1")` ou `System.getenv("CUSTOMER_KEY1")`.

Sintaxe imposta

Observe os seguintes padrões ao definir variáveis de ambiente:

- Cada chave deve ter o `CUSTOMER_ prefix`.

  Por exemplo: para `"CUSTOMER_KEY3=VAL3,KEY4=VAL4"`, `KEY4=VAL4` será ignorado e não definido.
- Cada par de chave e valor deve ser delineado com uma única vírgula.

  Por exemplo: `"CUSTOMER_KEY3=VAL3,CUSTOMER_KEY4=VAL4"`
- Se o "valor" tiver espaços ou vírgulas, ele deverá ser definido entre aspas.

  Por exemplo: `CUSTOMER_KEY2=\"val2,val2 val2\"`

Essa sintaxe modela de perto os padrões de configuração de variáveis de ambiente bash.

`--datalake-formats`

Compatível com o AWS Glue 3.0 e versões posteriores.

Especifica a estrutura de data lake a ser usada. O AWS Glue adiciona os arquivos JAR necessários para as estruturas que você especifica no `classpath`. Para obter mais informações, consulte Usar estruturas de data lake com trabalhos do AWS Glue ETL.

Você pode especificar um ou mais dos seguintes valores, separados por uma vírgula:

- `hudi`
- `delta`
- `iceberg`

Por exemplo, passe o argumento a seguir para especificar todas as três estruturas.

```
'--datalake-formats': 'hudi,delta,iceberg'
```

`--disable-proxy-v2`

Desabilite o proxy de serviço para permitir chamadas de serviço da AWS para o Amazon S3, o CloudWatch e o AWS Glue originadas por seu script através da VPC. Para mais informações,

consulte Configurar chamadas do AWS para passarem pela VPC. Para desativar o proxy do serviço, defina o valor desse parâmetro como `true`.

`--enable-auto-scaling`

Ativa o recurso para usar escalação automática e faturamento por processador quando você define o valor como `true`.

`--enable-continuous-cloudwatch-log`

Habilita o registro em log contínuo e em tempo real para trabalhos do AWS Glue. Você pode visualizar logs de trabalho do Apache Spark em tempo real no CloudWatch.

`--enable-continuous-log-filter`

Especifica um filtro padrão (`true`) ou nenhum filtro (`false`) quando você cria ou edita um trabalho habilitado para registro em log contínuo. Escolher o filtro padrão elimina o driver/executor desnecessário do Apache Spark e mensagens de log de heartbeat do Apache Hadoop YARN. Não escolher filtros fornece todas as mensagens de log.

`--enable-glue-datacatalog`

Habilita o uso do AWS Glue Data Catalog como um metastore do Apache Spark Hive. Para habilitar esse recurso, defina o valor como `true`.

`--enable-job-insights`

Permite o monitoramento adicional de análise de erros com informações sobre a execução de trabalhos do AWS Glue. Para obter detalhes, consulte the section called “Monitoramento com insights de execuções de trabalho do AWS Glue”. Por padrão, o valor está definido como `true` e os insights da execução de trabalhos estão habilitados.

Essa opção só está disponível no AWS Glue versões 2.0 e 3.0.

`--enable-lakeformation-fine-grained-access`

Habilita o controle de acesso refinado para trabalhos do AWS Glue. Para obter mais informações, consulte the section called “Lake Formation para o FGAC”.

`--enable-metrics`

Habilita a coleta de métricas para criar perfis de trabalhos para essa execução da tarefa. Estas métricas estão disponíveis no console do AWS Glue e no console do Amazon CloudWatch. O valor desse parâmetro não é relevante. Para ativar esse recurso, você pode fornecer esse

parâmetro com qualquer valor, mas `true` é recomendado para maior clareza. Para desabilitar esse recurso, remova esse parâmetro da configuração do seu trabalho.

`--enable-observability-metrics`

Permite que um conjunto de métricas de observabilidade gere insights sobre o que está acontecendo dentro de cada trabalho executado na página Monitoramento de execuções de trabalhos nos consoles do AWS Glue e do Amazon CloudWatch. Para habilitar esse recurso, defina o valor como true. Para desabilitar esse recurso, configure-o como `false` ou remova esse parâmetro da configuração do seu trabalho.

`--enable-rename-algorithm-v2`

Define a versão do algoritmo de renomeação do EMRFS como versão 2. Quando um trabalho do Spark usa o modo de substituição de partição dinâmica, existe a possibilidade de que uma partição duplicada seja criada. Por exemplo, você pode acabar com uma partição duplicada, como `s3://bucket/table/location/p1=1/p1=1`. Aqui, P1 é a partição que está sendo substituída. O algoritmo de renomeação versão 2 corrige esse problema.

Essa opção só está disponível no AWS Glue versão 1.0.

`--enable-s3-parquet-optimized-committer`

Habilita o committer otimizado para S3 do EMRFS a gravar dados Parquet no Amazon S3. É possível fornecer o par parâmetro/valor por meio do console do AWS Glue ao criar ou atualizar um trabalho do AWS Glue. Definir o valor como **`true`** habilitará o committer. Por padrão, o sinalizador é ativado no AWS Glue 3.0 e desativado no AWS Glue 2.0.

Para obter mais informações, consulte Usar o committer otimizado para EMRFS S3.

`--enable-spark-ui`

Quando definido como `true`, ativa o recurso para usar a interface do usuário do Spark para monitorar e depurar trabalhos de ETL do AWS Glue.

`--executor-cores`

Número de tarefas do Spark que podem ser executadas em paralelo. Essa opção é compatível com o AWS Glue 3.0+. O valor não deve exceder 2 vezes o número de vCPUs no tipo de operador, que é 8 no `G.1X`, 16 no `G.2X`, 32 no `G.4X` e 64 no `G.8X`. Você deve ter cuidado ao atualizar essa configuração, pois isso pode afetar a performance do trabalho, pois o aumento do paralelismo de tarefas gera pressão na memória e no disco, além aplicar o controle de utilização nos sistemas de origem e de destino (por exemplo: causaria mais conexões simultâneas no Amazon RDS).

`--extra-files`

Os caminhos do Amazon S3 para arquivos adicionais, como arquivos de configuração, que o AWS Glue copia para o diretório de trabalho do seu script no nó driver antes de executá-lo. Vários valores devem ser caminhos completos separados por uma vírgula (`,`). Somente arquivos individuais têm suporte, e não um caminho de diretório. Essa opção não é compatível com os tipos de trabalho do shell do Python.

`--extra-jars`

O Amazon S3 indica caminhos para arquivos adicionais que o AWS Glue copia para o driver e os executores. O AWS Glue também adiciona esses arquivos ao classpath Java antes de executar o script. Vários valores devem ser caminhos completos separados por uma vírgula (`,`). A extensão não precisa ser `.jar`

`--extra-py-files`

Os caminhos do Amazon S3 para módulos adicionais do Python que o AWS Glue inclui no caminho do Python no nó driver antes de executar seu script. Vários valores devem ser caminhos completos separados por uma vírgula (`,`). Somente arquivos individuais têm suporte, e não um caminho de diretório.

`--job-bookmark-option`

Controla o comportamento de um marcador de trabalho. Os seguintes valores de opção podem ser definidos.

Valor --job-bookmark-option	Descrição
`job-bookmark-enable`	Acompanhe os dados processados anteriormente. Quando um trabalho for executado, processe os novos dados desde o último ponto de verificação.
`job-bookmark-disable`	Sempre processe o conjunto de dados completo. Você é responsável por gerenciar o resultado das execuções de trabalho anteriores.
`job-bookmark-pause`	Processe dados incrementais desde a última execução bem-sucedida ou os dados no intervalo identificados pelas seguintes subopções, sem atualizar o estado do último marcador. Você é responsável por gerenciar o

Valor --job-bookmark-option	Descrição
	resultado das execuções de trabalho anteriores. As duas subopções são as seguintes: • **job-bookmark-from** `<from-value>` é o ID de execução que representa toda a entrada anterior que foi processada até a última execução bem-sucedida, incluindo o ID de execução especificado. A entrada correspondente é ignorada. • **job-bookmark-to** `<to-value>` é o ID de execução que representa toda a entrada anterior que foi processada até a última execução bem-sucedida, incluindo o ID de execução especificado. A entrada correspondente, exceto a entrada identificada pelo `<from-value>` , é processada pelo trabalho. Qualquer entrada depois dessa entrada também é excluída do processamento. O estado do marcador de trabalho não será atualizado quando esse conjunto de opções for especificado. As subopções são opcionais. No entanto, quando usadas, ambas as subopções devem ser fornecidas.

Para ativar um marcador de trabalho, por exemplo, transmita o seguinte argumento.

```
'--job-bookmark-option': 'job-bookmark-enable'
```

`--job-language`

A linguagem de programação de script. Esse valor deve ser `scala` ou `python`. Se esse parâmetro não estiver presente, o padrão será `python`.

`--python-modules-installer-option`

Uma string de texto não criptografado que define as opções a serem passadas para o `pip3` ao instalar módulos com --additional-python-modules. Forneça opções como você faria na linha de comando, separadas por espaços e prefixadas por traços. Para obter mais informações sobre o

uso, consulte the section called “Instalar módulos Python adicionais com pip no AWS Glue 2.0 ou posterior”.

> **Note**
>
> Essa opção não é compatível com trabalhos do AWS Glue quando você usa o Python 3.9.

`--scriptLocation`

O local do Amazon Simple Storage Service (Amazon S3) no qual seu script de ETL está localizado (no formato `s3://path/to/my/script.py`). Esse parâmetro substitui um local de script definido no objeto `JobCommand`.

`--spark-event-logs-path`

Especifica um caminho do Amazon S3. Ao usar o recurso de monitoramento da interface do usuário do Spark,o AWS Glue libera os logs de eventos do Spark para esse caminho do Amazon S3 a cada 30 segundos para um bucket que pode ser usado como um diretório temporário para armazenar eventos de interface do usuário do Spark.

`--TempDir`

Especifica um caminho do Amazon S3 para um bucket que pode ser usado como um diretório temporário para o trabalho.

Por exemplo, para definir um diretório temporário, transmita o seguinte argumento.

```
'--TempDir': 's3-path-to-directory'
```

> **Note**
>
> O AWS Glue cria um bucket temporário para os trabalhos, se um bucket ainda não existir em uma região. Esse bucket pode permitir o acesso público. Você pode modificar o bucket no Amazon S3 para definir o bloco de acesso público ou excluir o bucket mais tarde, depois que todos os trabalhos nessa região forem concluídos.

`--use-postgres-driver`

Ao definir esse valor como `true`, ele prioriza o driver JDBC do Postgres no classpath para evitar um conflito com o driver JDBC do Amazon Redshift. Essa opção só está disponível no AWS Glue versão 2.0.

`--user-jars-first`

Ao definir esse valor como `true`, ele prioriza os arquivos JAR extras do classpath. Essa opção só está disponível no AWS Glue versão 2.0 ou posterior.

`--conf`

Controla os parâmetros de configuração do Spark. Destina-se a casos de uso avançados.

`--encryption-type`

Parâmetro legado. O comportamento correspondente deve ser configurado usando configurações de segurança. Para obter mais informações sobre configurações de segurança, consulte the section called “Criptografar dados gravados pelo AWS Glue”.

O AWS Glue usa os seguintes argumentos internamente e você nunca deve usá-los:

- `--debug`: interno do AWS Glue. Não o defina.
- `--mode`: interno do AWS Glue. Não o defina.
- `--JOB_NAME`: interno do AWS Glue. Não o defina.
- `--endpoint`: interno do AWS Glue. Não o defina.

O AWS Glue é compatível com a inicialização de um ambiente com o módulo `site` do Python usando `sitecustomize` para realizar personalizações específicas do site. A inicialização de suas próprias funções de inicialização só é recomendada para casos de uso avançados e é compatível na medida do possível com o AWS Glue 4.0.

O prefixo variável de ambiente, `GLUE_CUSTOMER`, é reservado para uso do cliente.

Trabalhos Spark e PySpark do AWS Glue

O AWS Glue oferece suporte a trabalhos do Spark e PySpark. Um trabalho do Spark é executado em um ambiente Apache Spark gerenciado pelo AWS Glue. Ele processa os dados em lotes. Um trabalho de ETL de streaming é semelhante a um trabalho do Spark, exceto que ele executa ETL em

streams de dados. Ele usa o framework do Apache Spark Structured Streaming. Alguns recursos de trabalho do Spark não estão disponíveis para trabalhos ETL de streaming.

As seções a seguir fornecem mais informações sobre trabalhos Spark e PySpark do AWS Glue.

Tópicos

- Configurar propriedades de trabalho para trabalhos do Spark no AWS Glue
- Editar scripts do Spark no console do AWS Glue
- Trabalhos (herdados)
- Rastrear dados processados usando marcadores de trabalho
- Armazenamento de dados embaralhados do Spark
- Monitorar trabalhos Spark do AWS Glue
- Solução de problemas de IA generativa para o Apache Spark no AWS Glue

Configurar propriedades de trabalho para trabalhos do Spark no AWS Glue

Ao definir o trabalho no console do AWS Glue, você fornece valores às propriedades para controlar o ambiente do runtime do AWS Glue.

Definir propriedades de trabalho para trabalhos do Spark

A lista a seguir descreve as propriedades de um trabalho do Spark. Para as propriedades de um trabalho de shell do Python, consulte Definir propriedades de trabalho para trabalhos de shell Python. Para obter propriedades de um trabalho de ETL de streaming, consulte the section called “Definir propriedades de trabalho para um trabalho de ETL de transmissão”.

As propriedades estão listadas na ordem em que aparecem no assistente de Add job (Adicionar trabalho) no console do AWS Glue.

Name

Forneça uma string UTF-8 com um tamanho máximo de 255 caracteres.

Descrição

Forneça uma descrição opcional da sua implantação com até 2048 caracteres.

Perfil do IAM

Especifique o perfil do IAM usado para a autorização de recursos necessários para a execução do trabalho e acesso aos armazenamentos de dados. Para obter mais informações sobre

permissões de execução de trabalho no AWS Glue, consulte Gerenciamento de identidade e acesso do AWS Glue.

Tipo

O tipo de trabalho de ETL. Ele é definido automaticamente com base no tipo das fontes de dados selecionadas.

- Spark executa um script de ETL do Apache Spark com o comando de trabalho `glueetl`.
- Spark Streaming executa um script de ETL de streaming do Apache Spark com o comando de trabalho `gluestreaming`. Para obter mais informações, consulte the section called “Trabalhos de transmissão de ETL”.
- Shell do Python executa um script do Python com o comando de trabalho `pythonshell`. Para obter mais informações, consulte Configurar propriedades de trabalho para trabalhos de shell Python no AWS Glue.

versão do AWS Glue

A versão do AWS Glue determina as versões do Apache Spark e do Python que estão disponíveis para o trabalho, conforme especificado na tabela a seguir.

Versão do AWS Glue	Versões compatíveis do Spark e do Python
5,0	• Spark 3.5.4 • Python 3.11
4,0	• Spark 3.3.0 • Python 3.10
3.0	• Spark 3.1.1 • Python 3.7

Idioma

O código no script de ETL define a lógica do trabalho. O script pode ser codificado em Python ou Scala. É possível escolher se o script executado pelo trabalho é gerado pelo AWS Glue ou fornecido por você. É possível fornecer o nome e o local do script no Amazon Simple Storage Service (Amazon S3). Confirme se não existe um arquivo com o mesmo nome que o diretório do

script no caminho. Para saber mais sobre como escrever scripts, consulte Guia de programação do AWS Glue.

Tipo de operador

Os seguintes tipos de operadores estão disponíveis:

Os recursos disponíveis nos operadores do AWS Glue são medidos em DPUs. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória.

- **`G.1X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia em 1 DPU (4 vCPUs, 16 GB de memória) com 94 GB de disco. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
- **`G.2X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia em 2 DPU (8 vCPUs, 32 GB de memória) com 138 GB de disco. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
- **`G.4X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia em 4 DPU (16 vCPUs, 64 GB de memória) com 256 GB de disco (aproximadamente 235 GB livres). Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes.
- **`G.8X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia em 8 DPU (32 vCPUs, 128 GB de memória) com 512 GB de disco (aproximadamente 487 GB livres). Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes.
- **`G.025X`**: ao escolher esse tipo, você também fornece um valor para Number of workers (Número de operadores). Cada operador mapeia em 0,25 DPU (2 vCPUs, 4 GB de memória) com 84 GB de disco (aproximadamente 34 GB livres). Recomendamos esse tipo de operador para trabalhos de streaming de baixo volume. Esse tipo de operador só está disponível para trabalhos de streaming do AWS Glue versão 3.0 ou posterior.

É cobrada uma taxa por hora com base no número de DPUs usadas para executar os trabalhos de ETL. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

Com trabalhos do AWS Glue versão 1.0 ou anterior, quando você configura um trabalho usando o console e especifica um Worker type (Tipo de operador) como Standard (Padrão), a Maximum capacity (Capacidade máxima) é definida e o Number of workers (Número de operadores) torna-se o valor de Maximum capacity (Capacidade máxima) - 1. Se você usar a AWS Command Line Interface (AWS CLI) ou o AWS SDK, poderá especificar o parâmetro Max capacity (Capacidade máxima), ou especificar tanto Worker type (Tipo de operador) quanto Number of workers (Número de operadores).

Para trabalhos do AWS Glue versão 2.0 ou posterior, não é possível especificar uma capacidade máxima. Em vez disso, você deve especificar um Worker type (Tipo de operador) e o Number of workers (Número de operadores).

Os tipos de operadores **`G.4X`** e **`G.8X`** estão disponíveis apenas para trabalhos Spark ETL do AWS Glue versão 3.0 ou posteriores nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (N. da Califórnia), Oeste dos EUA (Oregon), Ásia-Pacífico (Mumbai), Ásia-Pacífico (Seul), Ásia-Pacífico (Singapura), Ásia-Pacífico (Sydney), Ásia-Pacífico (Tóquio), Canadá (Central), Europa (Frankfurt), Europa (Irlanda), Europa (Londres), Europa (Espanha), Europa (Estocolmo) e América do Sul (São Paulo).

O número solicitado de operadores

Para a maioria dos tipos de trabalho, é necessário especificar o número de operadores alocados quando o trabalho é executado.

Marcador de trabalho

Especifique como o AWS Glue processa essas informações de estado quando o trabalho é executado. É possível lembrar de dados previamente processados, atualizar informações de estado ou ignorar informações de estado. Para obter mais informações, consulte the section called “Rastrear dados processados usando marcadores de trabalho”.

Enfileiramento da execução de trabalhos

Especifica se as execuções de trabalhos foram colocadas na fila para execução posterior quando elas não podem ser executadas imediatamente devido às cotas de serviço.

Quando marcada, o enfileiramento da execução de trabalhos é habilitado para as execuções de trabalhos. Se não for preenchida, as execuções do trabalho não serão consideradas para enfileiramento.

Se essa configuração não corresponder ao valor definido na execução do trabalho, o valor do campo de execução do trabalho será usado.

Execução flexível

Quando você configura um trabalho usando o AWS Studio ou a API, é possível especificar uma classe de execução padrão ou flexível de trabalho. Seus trabalhos podem ter graus diversos de prioridade e sensibilidade ao tempo. A classe de execução padrão é ideal para workloads sensíveis ao tempo que exigem a inicialização rápida de trabalhos e recursos dedicados.

A classe de execução flexível é adequada para trabalhos não urgentes, como trabalhos de pré-produção, testes e cargas de dados únicas. Execuções flexíveis de trabalho são compatíveis com trabalhos que usem o AWS Glue versão 3.0 ou posterior e os tipos de operador `G.1X` ou `G.2X`.

As execuções flexíveis de trabalho são cobradas com base no número de operadores em execução a qualquer momento. É possível adicionar ou remover o número de operadores para uma execução flexível de trabalho que esteja em andamento. Em vez de cobrar como um simples cálculo de `Max Capacity` * `Execution Time`, cada operador contribuirá pelo tempo durante o qual foi executado na execução do trabalho. A conta é a soma de (`Number of DPUs per worker` * `time each worker ran`).

Para obter mais informações, consulte o painel de ajuda no AWS Studio ou Tarefas e Execuções de trabalhos.

Número de novas tentativas

Especifique o número de vezes, de 0 a 10, que o AWS Glue deve reiniciar automaticamente o trabalho em caso de falha. Os trabalhos que atingem o limite de tempo não são reiniciados.

Tempo limite de trabalho

Define o tempo máximo de execução em minutos. A configuração máxima é de 7 dias ou 10.080 minutos. Caso contrário, os trabalhos gerarão uma exceção.

Quando o valor é deixado em branco, o tempo limite padrão é de 2.880 minutos.

Quaisquer trabalhos do AWS Glue existentes que tinham um valor de tempo limite maior que 7 dias serão padronizados para 7 dias. Por exemplo, se você especificou um tempo limite de 20 dias para um trabalho em lote, ele será interrompido no 7º dia.

> **Práticas recomendadas para tempos limite de trabalhos**
>
> Os trabalhos são cobrados com base no tempo de execução. Para evitar cobranças inesperadas, configure valores de tempo limite apropriados para o tempo de execução esperado do seu trabalho.

Propriedades avançadas

Nome do arquivo de script

Um nome de script exclusivo para seu trabalho. Não pode ser nomeado Trabalho sem título.

Caminho do script

A localização do Amazon S3 do script. O caminho deve estar no formato `s3://bucket/prefix/path/`. Ele deve terminar com uma barra (`/`) e não incluir arquivos.

Métricas de trabalho

Ative ou desative a criação de métricas do Amazon CloudWatch quando esse trabalho for executado. Para ver os dados de criação de perfil, você deve habilitar essa opção. Para obter mais informações sobre como ativar e visualizar as métricas, consulte Monitoramento e depuração de trabalho.

Métricas de observabilidade do trabalho

Ative ou desative a criação de métricas de observabilidade do CloudWatch quando esse trabalho for executado. Para obter mais informações, consulte the section called “Monitoramento com métricas de observabilidade do AWS Glue”.

Registro em log contínuo

Ative o registro em log contínuo no Amazon CloudWatch. Se esta opção não estiver habilitada, os logs estarão disponíveis somente após o trabalho ser concluído. Para obter mais informações, consulte the section called “Registro em log para trabalhos do AWS Glue”.

IU do Spark

Ative o uso da interface do usuário do Spark para monitorar esse trabalho. Para obter mais informações, consulte Habilitar a interface do usuário da Web do Apache Spark para trabalhos do AWS Glue.

Caminho dos logs da interface do usuário do Spark

O caminho para gravar logs quando a interface do usuário do Spark está habilitada.

Configuração de log e monitoramento da interface do usuário do Spark

Escolha uma das seguintes opções:

- Padrão: grave logs usando o ID de execução do trabalho do AWS Glue como nome do arquivo. Ative o monitoramento da interface do usuário do Spark no console do AWS Glue.

- Legado: grave logs usando "spark-application- {timestamp}" como nome do arquivo. Não ative o monitoramento da interface do usuário do Spark.
- Padrão e legado: grave logs nos locais padrão e legados. Ative o monitoramento da interface do usuário do Spark no console do AWS Glue.

Máximo de simultaneidade

Define o número máximo de execuções simultâneas permitidas para o trabalho. O padrão é um. Um erro será retornado quando este limite for atingido. O valor máximo que pode ser especificado é controlado por um limite de serviço. Por exemplo, se a execução anterior de um trabalho ainda estiver sendo realizada quando uma nova instância for iniciada, convém retornar um erro para evitar que duas instâncias do mesmo trabalho sejam executadas simultaneamente.

Caminho temporário

Informe o local de um diretório de trabalho no Amazon S3 onde os resultados intermediários temporários serão gravados quando o AWS Glue executar o script. Confirme se não existe um arquivo com o mesmo nome que o diretório temporário no caminho. Esse diretório é usado quando o AWS Glue lê e grava no Amazon Redshift e por determinadas transformações do AWS Glue.

> **Note**
>
> O AWS Glue criará um bucket temporário para trabalhos se um bucket ainda não existir em uma região. Esse bucket pode permitir o acesso público. É possível modificar o bucket no Amazon S3 para definir o bloco de acesso público ou excluir o bucket mais tarde, depois que todos os trabalhos nessa região forem concluídos.

Limite de notificação de atraso (minutos)

Define o valor mínimo (em minutos) antes que uma notificação de atraso seja enviada. É possível definir esse limite para enviar notificações quando uma execução de trabalho `RUNNING`, `STARTING` ou `STOPPING` levar mais do que o número de minutos esperado.

Configuração de segurança

Escolha uma configuração de segurança na lista. Uma configuração de segurança especifica como os dados no destino do Amazon S3 são criptografados: sem criptografia, criptografia

no lado do servidor com chaves gerenciadas pelo AWS KMS (SSE-KMS) ou chaves de criptografia gerenciadas pelo Amazon S3 (SSE-S3).

Criptografia do lado do servidor

Se você selecionar essa opção, quando o trabalho de ETL gravar no Amazon S3, os dados serão criptografados em repouso usando criptografia SSE-S3. Tanto o seu destino de dados do Amazon S3 quanto outros dados gravados em um diretório temporário do Amazon S3 serão criptografados. Essa opção é passada como um parâmetro de trabalho. Para obter mais informações, consulte Proteção de dados usando criptografia no lado do servidor com chaves de criptografia gerenciadas pelo Amazon S3 (SSE-S3) no Manual do usuário do Amazon Simple Storage Service.

> **Important**
>
> Esta opção será ignorada se uma configuração de segurança for especificada.

Usar o catálogo de dados do Glue como metastore do Hive

Selecione para usar o AWS Glue Data Catalog como a metastore do Hive. O perfil do IAM usado para o trabalho deve ter a permissão `glue:CreateDatabase`. Um banco de dados chamado “default” (padrão) é criado no Data Catalog, caso não exista.

Conexões

Escolha uma configuração de VPC para acessar fontes de dados do Amazon S3 localizadas na sua nuvem privada virtual (VPC). É possível criar e gerenciar a conexão de rede no AWS Glue. Para obter mais informações, consulte Conectar a dados.

Bibliotecas

Caminho da biblioteca Python, caminho dos JARs dependentes e caminho de arquivos referenciados

Especifique essas opções se o script precisar. É possível definir os caminhos do Amazon S3 separados por vírgulas para essas opções ao definir o trabalho. É possível substituir esses caminhos ao executar o trabalho. Para obter mais informações, consulte Fornecer seus próprios scripts personalizados.

Parâmetros de trabalho

Um conjunto de pares de valor-chave que são transmitidos como parâmetros nomeados para o script. Esses são valores padrão que são usados quando o script é executado, mas é possível substituí-los em trigger ou ao executar o trabalho. É necessário iniciar o nome da chave com `--`; por exemplo: `--myKey`. Passe os parâmetros do trabalho como um mapa ao usar a AWS Command Line Interface.

Para ver exemplos, consulte os parâmetros Python em Transmitir e acessar parâmetros de Python no AWS Glue.

Tags

Marque o trabalho com uma Tag key (Chave de tag) e um Tag value (Valor de tag) opcional. Depois que as chaves de tags são criadas, elas são somente leitura. Use as tags em alguns recursos para ajudar a organizá-los e identificá-los. Para obter mais informações, consulte Etiquetas da AWS no AWS Glue.

Restrições para trabalhos que acessam tabelas gerenciadas pelo Lake Formation

Tenha em mente as seguintes observações e restrições ao criar trabalhos que leiam ou gravem em tabelas gerenciadas pelo AWS Lake Formation:

- Não há suporte para os seguintes recursos em trabalhos que acessem tabelas com filtros no nível da célula:
  - Marcadores de trabalhos e execução limitada
  - Aplicação de predicados
  - Predicados de partição de catálogo do lado do servidor
  - enableUpdateCatalog

Editar scripts do Spark no console do AWS Glue

Um script contém o código que extrai os dados das fontes, os transforma e os carrega nos destinos. O AWS Glue executa um script quando inicia um trabalho.

Os scripts de ETL do AWS Glue podem ser codificados em Python ou Scala. Os scripts Python usam uma linguagem que é a uma extensão do dialeto PySpark Python para trabalhos de extração, transformação e carregamento (ETL). O script contém construtores estendidos para lidar com transformações de ETL. Quando você gera automaticamente a lógica do código fonte para um

trabalho, o script é criado. Você pode editar este script ou fornecer seu próprio script para processar seu trabalho de ETL.

Para obter informações sobre como definir e editar scripts usando no AWS Glue, consulte Guia de programação do AWS Glue.

Bibliotecas ou arquivos adicionais

Se seu script precisar de bibliotecas ou arquivos adicionais, você poderá especificá-los da seguinte forma:

Caminho da biblioteca Python

Caminhos do Amazon Simple Storage Service (Amazon S3) separados por vírgulas para bibliotecas Python exigidas pelo script.

> **Note**
>
> Somente bibliotecas Python puras podem ser usadas. Bibliotecas que contam com extensões C, como a biblioteca de análise de dados Python pandas, ainda não são compatíveis.

Caminho de arquivos JAR dependentes

Caminhos do Amazon S3 separados por vírgulas para arquivos JAR exigidos pelo script.

> **Note**
>
> Atualmente, apenas bibliotecas Java ou Scala (2.11) podem ser usadas.

Caminho de arquivos referenciados

Caminhos do Amazon S3 separados por vírgula para arquivos adicionais (por exemplo, arquivos de configuração) exigidos pelo script.

Trabalhos (herdados)

Um script contém o código que executa o trabalho de extração, transformação e carregamento (ETL). Você pode fornecer seu próprio script, ou o AWS Glue pode gerar um script com a sua

orientação sua. Para obter informações sobre como criar seus próprios scripts, consulte Fornecer seus próprios scripts personalizados.

Você pode editar um script no console do AWS Glue. Ao editar um script, você pode adicionar fontes, destinos e transformações.

Para editar um script

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/. Em seguida, escolha a guia Jobs.
2. Selecione um trabalho na lista e escolha Action, Edit script para abrir o editor de scripts.

   Você também pode acessar o editor de scripts na página de detalhes do trabalho. Escolha a guia Script e, em seguida, Edit script (Editar script).

Editor de scripts

O editor de scripts do AWS Glue permite inserir, modificar e excluir fontes, destinos e transformações no seu script. O editor de scripts exibe o script e um diagrama para ajudar você a visualizar o fluxo de dados.

Para criar um diagrama para o script, escolha Generate diagram (Gerar diagrama). O AWS Glue usa linhas de anotação no script que começam com ## para renderizar o diagrama. Para representar corretamente seu script no diagrama, você precisa manter em sincronia os parâmetros nas anotações e os parâmetros no código Apache Spark.

O editor de scripts permite que você adicione modelos de código sempre que o cursor estiver posicionado no script. Na parte superior do editor, escolha as seguintes opções:

- Para adicionar uma tabela de origem ao script, escolha Source.
- Para adicionar uma tabela de destino ao script, escolha Target.
- Para adicionar um local de destino ao script, escolha Target location.
- Para adicionar uma transformação ao script, escolha Transform. Para obter informações sobre as funções que são chamadas no seu script, consulte Programar scripts de ETL do AWS Glue em PySpark.
- Para adicionar uma transformação Spigot ao script, escolha Spigot.

No código inserido, modifique o `parameters` nas anotações e no código Apache Spark. Por exemplo, se você adicionar uma transformação Spigot, verifique se `path` foi substituído na linha de anotação `@args` e na linha de código `output`.

A guia Logs mostra os logs associados ao seu trabalho à medida que ele é executado. As mil linhas mais recentes são exibidas.

A guia Schema (Esquema) mostra o esquema das fontes e dos destinos selecionados, quando disponíveis no Data Catalog.

Rastrear dados processados usando marcadores de trabalho

O AWS Glue rastreia os dados que já foram processados durante uma execução anterior de um trabalho de ETL persistindo as informações do estado do trabalho executado. Essa informação de estado persistente é chamada de marcador de trabalho. Os marcadores do trabalho ajudam o AWS Glue a manter as informações de estado e a impedir o reprocessamento de dados antigos. Com marcadores de trabalho, você pode processar novos dados ao executar novamente em um intervalo programado. Um marcador de trabalho é composto pelos estados de vários elementos de trabalho, como fontes, transformações e destinos. Por exemplo, seu trabalho de ETL pode ler novas partições em um arquivo do Amazon S3. O AWS Glue rastreia as partições que o trabalho processou com êxito para evitar processamento e dados duplicados no armazenamento de dados de destino do trabalho.

Os marcadores de trabalho são implantados para fontes de dados JDBC, a transformação Relationalize e algumas fontes do Amazon Simple Storage Service (Amazon S3). A tabela a seguir lista os formatos de fonte do Amazon S3 aos quais o AWS Glue oferece suporte para marcadores de trabalho.

Versão do AWS Glue	Formatos de fonte do Amazon S3
Versão 0.9	JSON, CSV, Apache Avro, XML
Versão 1.0 e posterior	JSON, CSV, Apache Avro, XML, Parquet, ORC

Para obter mais informações sobre as versões do AWS Glue, consulte Definir propriedades de trabalho para trabalhos do Spark.

O atributo de marcadores de trabalhos tem funcionalidades adicionais quando acessado por meio de scripts do AWS Glue. Ao navegar pelo script gerado, você pode ver contextos de transformação

relacionados a esse atributo. Para ter mais informações, consulte the section called “Usar marcadores de trabalho”.

Tópicos

- Usar marcadores de trabalho no AWS Glue
- Detalhes operacionais do atributo de marcadores de trabalho

Usar marcadores de trabalho no AWS Glue

A opção de marcador de trabalho é passada como um parâmetro quando o trabalho é iniciado. A tabela a seguir descreve as opções para configuração de marcadores de trabalho no console do AWS Glue.

Marcador de trabalho	Descrição
Enable (Habilitar)	Faz com que o trabalho atualize o estado após uma execução para controlar os dados processados anteriormente. Se seu trabalho tiver uma origem com suporte para marcador de trabalho, ele irá controlar os dados processados e, quando um trabalho for executado, processará novos dados desde o último ponto de verificação.
Disable (Desabilitar)	Os marcadores de trabalho não são usados, e o trabalho sempre processa todo o conjunto de dados. Você é responsável por gerenciar o resultado das execuções de trabalho anteriores. Esse é o padrão.
Pause	Processe dados incrementais desde a última execução bem-sucedida ou os dados no intervalo identificados pelas seguintes subopções, sem atualizar o estado do último marcador. Você é responsável por gerenciar o resultado das execuções de trabalho anteriores. As duas subopções são: • job-bookmark-from <from-value> é o ID de execução que represent a toda a entrada anterior que foi processada até a última execução bem-sucedida, incluindo o ID de execução especificado. A entrada correspondente é ignorada. • job-bookmark-to <to-value> é o ID de execução que representa toda a entrada anterior que foi processada até a última execução bem-suced

Marcador de trabalho	Descrição
	ida, incluindo o ID de execução especificado. A entrada correspon dente, exceto a entrada identificada pelo <from-value>, é processad a pelo trabalho. Qualquer entrada depois dessa entrada também é excluída do processamento. O estado do marcador de trabalho não será atualizado quando esse conjunto de opções for especificado. As subopções são opcionais. No entanto, quando usadas, é necessário fornecer as duas subopções.

Para obter detalhes sobre os parâmetros passados para um trabalho na linha de comando, e especificamente para marcadores de trabalho, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.

Para fontes de entrada do Amazon S3, os marcadores de trabalho do AWS Glue conferem a hora da última modificação dos objetos para verificar quais objetos precisam ser reprocessados. Se os dados da fonte de entrada tiverem sido modificados desde a última execução do trabalho, os arquivos serão reprocessados quando você executar o trabalho novamente.

Para fontes JDBC, as seguintes regras se aplicam:

- Para cada tabela, o AWS Glue usa uma ou mais colunas como chaves de marcadores para determinar dados novos e processados. As chaves de marcadores combinam-se para formar uma única chave composta.
- Por padrão, o AWS Glue usará a chave primária como chave de marcadores, desde que ela esteja aumentando ou diminuindo sequencialmente (sem lacunas).
- Você pode especificar as colunas a serem usadas como chaves de marcadores no seu script do AWS Glue. Para obter mais informações sobre como usar marcadores de trabalhos em scripts do AWS Glue, consulte the section called “Usar marcadores de trabalho”.
- O AWS Glue não oferece suporte ao uso de colunas com nomes que diferenciam maiúsculas e minúsculas como chaves de marcadores de trabalho.

É possível retroceder seus marcadores de trabalho de ETL do Spark do AWS Glue para qualquer execução de trabalho anterior. É possível oferecer melhor suporte a cenários de preenchimento ao retroceder os marcadores de trabalho para qualquer execução de trabalho anterior, resultando no reprocessamento de dados subsequente de execução de trabalho somente a partir da execução do trabalho marcado.

Para reprocessar todos os dados usando o mesmo trabalho, redefina o marcador do trabalho. Para redefinir o estado do marcador de trabalho, use o console do AWS Glue, a Ação ResetJobBookmark (Python: reset_job_bookmark) operação da API ou a AWS CLI. Por exemplo, digite o comando a seguir usando a AWS CLI:

```
aws glue reset-job-bookmark --job-name my-job-name
```

Quando você retrocede ou redefine um marcador, o AWS Glue não limpa os arquivos de destino porque pode haver vários destinos e eles não são rastreados com marcadores de trabalho. Somente os arquivos de fontes são rastreados com marcadores de trabalho. Você pode criar diferentes destinos de saída ao retroceder e reprocessar os arquivos de fontes para evitar dados duplicados em sua saída.

O AWS Glue monitora os marcadores de trabalho por trabalho. Se você excluir um trabalho, o marcador dele será excluído.

Em alguns casos, você pode ter habilitado marcadores de trabalho do AWS Glue, mas o trabalho de ETL está reprocessando dados que já foram processados em uma execução anterior. Para obter informações sobre como resolver as causas comuns desse erro, consulte Solucionar problemas de erros no Spark.

Detalhes operacionais do atributo de marcadores de trabalho

Esta seção descreve mais detalhes operacionais sobre o uso de marcadores de trabalho.

Os marcadores de trabalho armazenam os estados de um trabalho. Cada instância do estado é codificada por um nome e um número de versão do trabalho. Quando um script invoca `job.init`, ele recupera seu estado e sempre obtém a versão mais recente. Em um estado, há vários elementos de estado, que são específicos a cada origem, transformação e instância coletora no script. Esses elementos de estado são identificados por um contexto de transformação que é anexado ao elemento correspondente (origem, transformação ou coletor) no script. Os elementos do estado são

salvos automaticamente quando `job.commit` é invocado no script do usuário. O script obtém o nome do trabalho e a opção de controle dos marcadores do trabalho nos argumentos.

Os elementos do estado no marcador do trabalho são origem, transformação ou dados específicos ao coletor. Por exemplo, suponha que você queira ler dados incrementais em um local do Amazon S3 que está sendo gravado constantemente por um trabalho ou processo upstream. Nesse caso, o script deve determinar o que foi processado até o momento. A implantação do marcador de trabalho para a fonte do Amazon S3 salva informações para que, quando o trabalho for executado novamente, ele possa filtrar somente os novos objetos usando as informações salvas e recalcular o estado para a próxima execução do trabalho. Um time stamp é usado para filtrar os novos arquivos.

Além dos elementos de estado, os marcadores de trabalho têm um número de execuções, um número de tentativas e um número de versão. O número de execução rastreia a execução do trabalho, e o número de tentativas registra as tentativas de uma execução de trabalho. O número de execuções do trabalho é um número incrementado de forma monotônica para cada execução bem-sucedida. O número de tentativas rastreia as tentativas de cada execução e só é incrementado quando há uma execução após uma tentativa com falha. O número da versão aumenta de forma monotônica e rastreia as atualizações em um marcador de trabalho.

No banco de dados do serviço AWS Glue, os estados de marcador para todas as transformações são armazenados juntos como pares de chave-valor:

```
{
  "job_name" : ...,
  "run_id": ...,
  "run_number": ..,
  "attempt_number": ...
  "states": {
    "transformation_ctx1" : {
      bookmark_state1
    },
    "transformation_ctx2" : {
      bookmark_state2
    }
  }
}
```

Práticas recomendadas

Veja a seguir as práticas recomendadas para usar marcadores de trabalhos.

- Não altere a propriedade origem dos dados com o marcador habilitado. Por exemplo, há um datasource0 apontando para um caminho de entrada A do Amazon S3, e o trabalho está lendo uma fonte que está sendo executada há várias rodadas com o marcador habilitado. Se você alterar o caminho de entrada de datasource0 para o caminho B do Amazon S3 sem alterar `transformation_ctx`, o trabalho do AWS Glue usará o antigo estado de marcador armazenado. Isso resultará em arquivos ausentes ou ignorados no caminho de entrada B, já que o AWS Glue presumiria que esses arquivos foram processados em execuções anteriores.
- Use uma tabela de catálogo com marcadores para um melhor gerenciamento de partições. Os marcadores funcionam tanto para origens de dados do Data Catalog quanto para origens de dados das opções. No entanto, é difícil remover/adicionar novas partições com a abordagem de opções. Usar uma tabela de catálogo com crawlers pode fornecer melhor automação para rastrear as partições recém-adicionadas e proporcionar a flexibilidade para selecionar partições específicas com um predicado de aplicação.
- Use o compilador de listas de arquivos para Amazon S3 do AWS Glue para conjuntos de dados grandes. Um marcador listará todos os arquivos em cada partição de entrada e fará o arquivamento. Logo, se houver muitos arquivos em uma só partição, o marcador poderá entrar no driver OOM. Use o compilador de listas de arquivos para Amazon S3 do AWS Glue a fim de evitar listar todos os arquivos na memória de uma só vez.

Armazenamento de dados embaralhados do Spark

A colocação em ordem aleatória é uma etapa importante em um trabalho do Spark sempre que os dados são reorganizados entre partições. Isso é necessário porque transformações amplas, como `join`, `groupByKey`, `reduceByKey` e `repartition`, exigem informações de outras partições para concluir o processamento. O Spark reúne os dados necessários de cada partição e os combina em uma nova partição. Durante uma geração de ordem aleatória, os dados são gravados no disco e transferidos pela rede. Como resultado, a operação de ordem aleatória está vinculada à capacidade do disco local. O Spark lança os erros `No space left on device` ou `MetadataFetchFailedException` quando não há espaço em disco suficiente no executor e não há recuperação.

> **Note**
>
> O plugin AWS Glue Spark shuffle com Amazon S3 só é compatível com trabalhos de ETL do AWS Glue.

Solução

Com o AWS Glue, você pode usar o Amazon S3 para armazenar dados em ordem aleatória do Spark. O Amazon S3 é um serviço de armazenamento de objetos que oferece escalabilidade, disponibilidade de dados, segurança e performance líderes do setor. Essa solução desagrega computação e armazenamento de seus trabalhos do Spark e oferece elasticidade completa e armazenamento em ordem aleatória de baixo custo, permitindo que você execute suas workloads mais intensas em ordem aleatória de forma confiável.

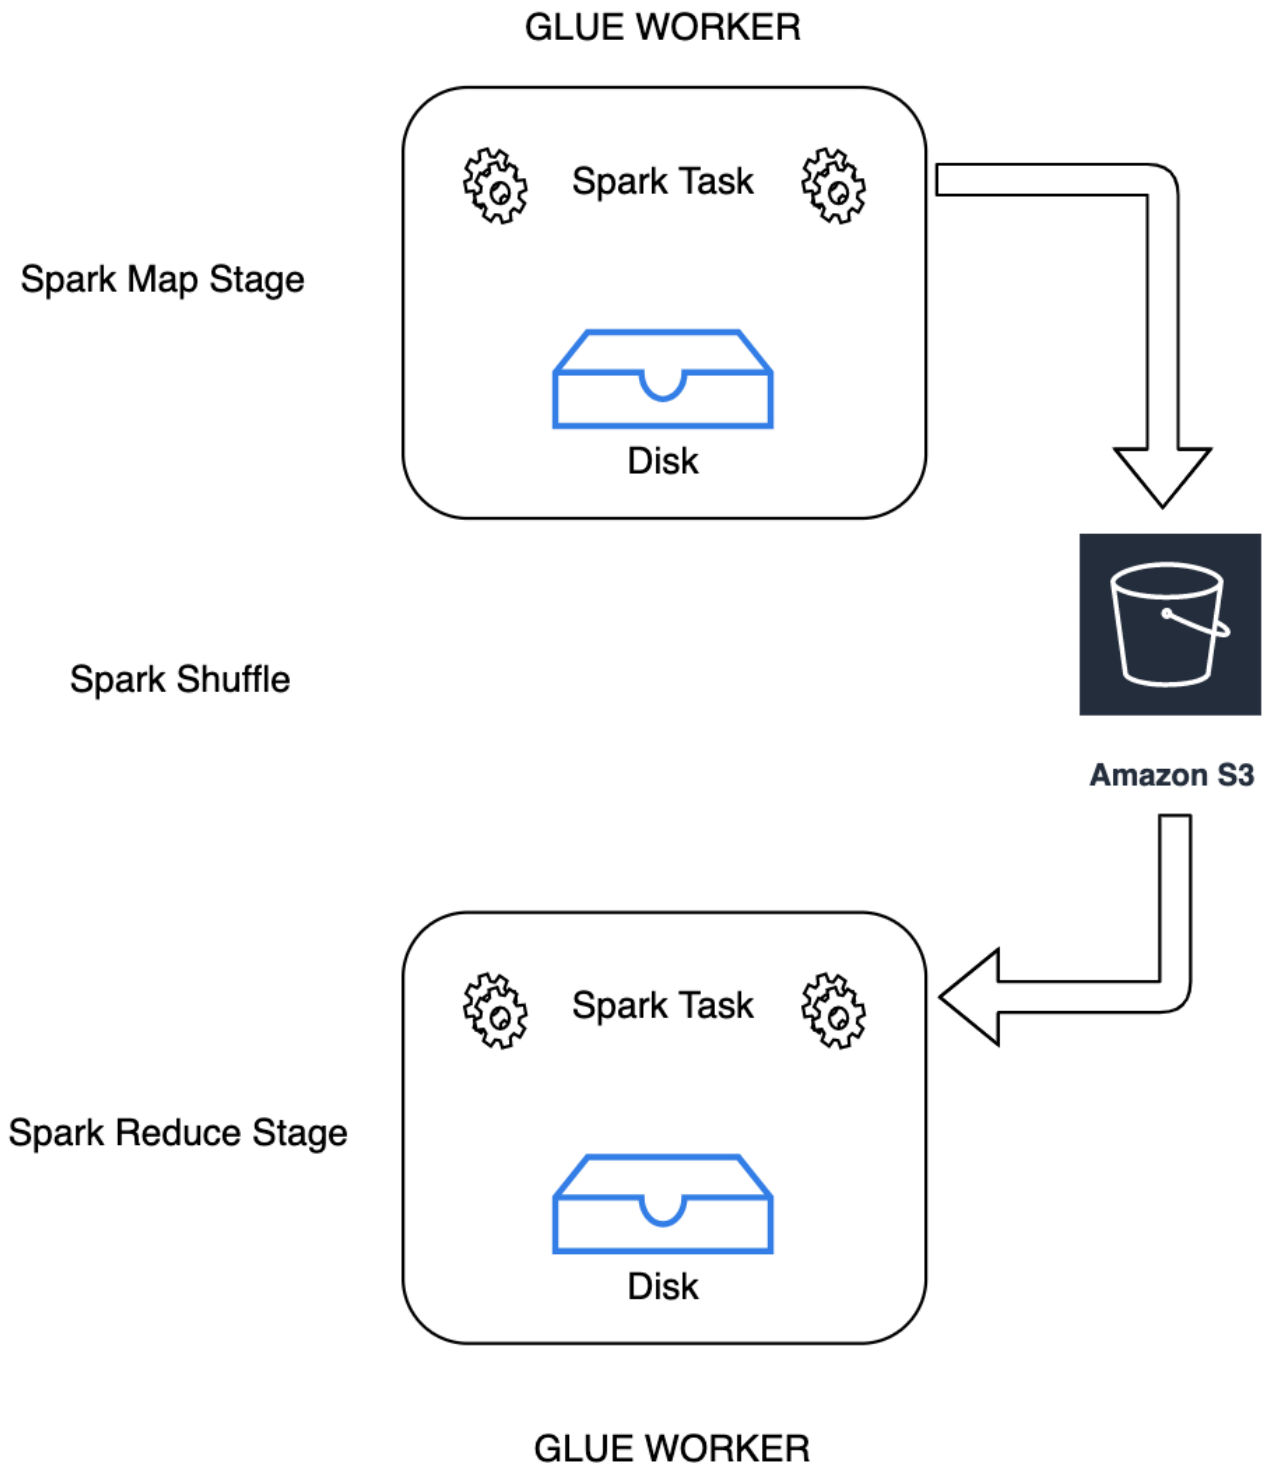

Estamos apresentando um novo Cloud Shuffle Storage Plugin for Apache Spark para usar o Amazon S3. Você pode ativar a ordem aleatória do Amazon S3 para executar trabalhos do AWS Glue de forma confiável e sem falhas, caso eles estejam vinculados à capacidade do disco local para grandes operações de ordem aleatória. Em alguns casos, a ordem aleatória para o Amazon S3 é ligeiramente

mais lenta do que o disco local (ou EBS), se você tiver um grande número de partições pequenas ou arquivos gravados em ordem aleatória no Amazon S3.

Pré-requisitos para usar o plug-in Cloud Shuffle Storage

Para usar o plug-in Cloud Shuffle Storage com trabalhos de ETL do AWS Glue, você precisa do seguinte:

- Um bucket do Amazon S3 localizado na mesma região em que seu trabalho é executado, para armazenar dados intermediários embaralhados e vazados. O prefixo de armazenamento embaralhado do Amazon S3 pode ser especificado com o `--conf spark.shuffle.glue.s3ShuffleBucket=s3://`*`shuffle-bucket`*`/`*`prefix`*`/`, como no exemplo a seguir:

```
--conf spark.shuffle.glue.s3ShuffleBucket=s3://glue-shuffle-123456789-us-east-1/glue-shuffle-data/
```

- Defina as políticas de ciclo de vida de armazenamento do Amazon S3 no prefixo (como `glue-shuffle-data`), pois o gerenciador de ordem aleatória não limpa os arquivos após a conclusão do trabalho. O embaralhamento intermediário e os dados vazados devem ser excluídos após a conclusão do trabalho. Os usuários podem definir políticas de ciclo de vida curto no prefixo. Instruções para definir política do ciclo de vida do Amazon S3 estão disponíveis em Definir a configuração do ciclo de vida em um bucket no Guia do usuário do Amazon Simple Storage Service.

Usar o gerenciador de ordem aleatória do Spark no AWS Glue no Console da AWS

Para configurar o gerenciador de ordem aleatória do Spark no AWS Glue usando o console do AWS Glue ou o AWS Glue Studio ao configurar um trabalho: escolha o parâmetro de trabalho –write-shuffle-files-to-s3 para ativar a ordem aleatória do Amazon S3 para o trabalho.

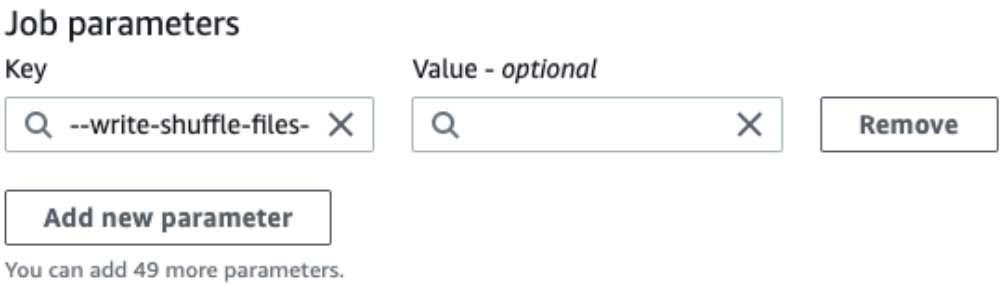

Usar o plug-in de ordem aleatória do AWS Glue Spark

Os seguintes parâmetros de trabalho ativam e ajustam o gerenciador de ordem aleatória no AWS Glue. Esses parâmetros são sinalizadores, portanto, qualquer valor fornecido não será considerado.

- `--write-shuffle-files-to-s3`: o sinalizador principal que habilita o gerenciador de ordem aleatória do AWS Glue Spark para usar buckets do Amazon S3 a fim de gravar e ler dados em ordem aleatória. Quando o sinalizador não é especificado, o gerenciador de ordem aleatória não é usado.
- `--write-shuffle-spills-to-s3` - (compatível apenas com o AWS Glue versão 2.0). Um sinalizador opcional que permite que você descarregue arquivos de despejo em buckets do Amazon S3, o que fornece resiliência adicional ao seu trabalho do Spark. Isso só é necessário para grandes workloads que despejam muitos dados no disco. Quando o sinalizador não é especificado, nenhum arquivo de vazamento intermediário é gravado.
- `--conf spark.shuffle.glue.s3ShuffleBucket=s3://<shuffle-bucket>`: outro sinalizador opcional que especifica o bucket do Amazon S3 onde você grava os arquivos em ordem aleatória. Por padrão, `--TempDir`/shuffle-data. O AWS Glue 3.0+ suporta a gravação aleatória de arquivos em vários buckets especificando compartimentos com delimitador de vírgula, como em `--conf spark.shuffle.glue.s3ShuffleBucket=s3://`*`shuffle-bucket-1`*`/`*`prefix`*`,s3://`*`shuffle-bucket-2`*`/`*`prefix`*`/`. O uso de vários buckets melhora a performance.

É necessário fornecer configurações de segurança para habilitar a criptografia em repouso para os dados em ordem aleatória. Para obter mais informações sobre as configurações de segurança, consulte the section called “Configurar a criptografia”. O AWS Glue oferece suporte a todas as outras configurações relacionadas a ordem aleatória fornecidas pelo Spark.

Binários de software para o Cloud Shuffle Storage Plugin

Você também pode baixar os binários de software Cloud Shuffle Storage Plugin for Apache Spark sob a licença do Apache 2.0 e executá-lo em qualquer ambiente do Spark. O novo plug-in vem com suporte pronto para uso para o Amazon S3 e também pode ser facilmente configurado para usar outras formas de armazenamento em nuvem, como o Google Cloud Storage e o Microsoft Azure Blob Storage. Para obter mais informações, consulte Cloud Shuffle Storage Plugin for Apache Spark.

Observações e limitações

As seguintes são observações ou limitações sobre o gerenciador de ordem aleatória no AWS Glue:

- O AWS Glue shuffle manager não exclui automaticamente os arquivos de dados aleatórios (temporários) armazenados em seu bucket do Amazon S3 após a conclusão de um trabalho. Para garantir a proteção dos dados, siga as instruções no Pré-requisitos para usar o plug-in Cloud Shuffle Storage antes de ativar o plugin de Cloud Shuffle Storage.
- Você pode usar esse recurso se seus dados estiverem distorcidos.

Cloud Shuffle Storage Plugin for Apache Spark

O Cloud Shuffle Storage Plugin é um plug-in do Apache Spark compatível com a API `ShuffleDataIO` que permite armazenar dados em ordem aleatória nos sistemas de armazenamento em nuvem (como o Amazon S3). Ele ajuda você a complementar ou substituir a capacidade de armazenamento em disco local para grandes operações de ordem aleatória, como `join`, `reduceByKey`, `groupByKey` e `repartition`, nas aplicações do Spark, reduzindo assim as falhas comuns ou a depreciação de preço/performance dos dados de tecnologia sem servidor em trabalhos de análise e pipelines.

AWS Glue

As versões 3.0 e 4.0 do AWS Glue vêm com o plug-in pré-instalado e pronto para habilitar ordem aleatória para o Amazon S3 sem nenhuma etapa adicional. Para obter mais informações, consulte Gerenciador de ordem aleatória do Spark no AWS Glue com o Amazon S3 para ativar o recurso para as aplicações do Spark.

Outros ambientes do Spark

O plug-in exige que as seguintes configurações do Spark sejam definidas em outros ambientes do Spark:

- `--conf spark.shuffle.sort.io.plugin.class=com.amazonaws.spark.shuffle.io.cloud.Choppe` isso informa ao Spark que deve usar esse plug-in para E/S de ordem aleatória.
- `--conf spark.shuffle.storage.path=s3://`*`bucket-name`*`/`*`shuffle-file-dir`*: o caminho no qual os arquivos de ordem aleatória serão armazenados.

> **Note**
>
> O plug-in sobrescreve a classe principal do Spark. Como resultado, o jar do plugin precisa ser carregado antes dos jars do Spark. Você pode fazer isso usando `userClassPathFirst` em ambientes YARN locais se o plug-in for usado fora do AWS Glue.

Empacotar o plug-in com aplicações do Spark

Você pode empacotar o plug-in com aplicações do Spark e distribuições do Spark (versões 3.1 e superiores) adicionando a dependência do plug-in no `pom.xml` Maven enquanto desenvolve as aplicações do Spark localmente. Para obter mais informações sobre versões do Spark, consulte Versões do 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>
```

Ou então, você pode baixar os binários diretamente dos artefatos doAWS Glue Maven e incluí-los na aplicação do Spark como se segue.

```
#!/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/
```

Exemplo 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> \
```

Configurações opcionais

Estas são as configurações opcionais que controlam o comportamento de ordem aleatória do Amazon S3.

- `spark.shuffle.storage.s3.enableServerSideEncryption`: habilite/desabilite o S3 SSE para arquivos de ordem aleatória e despejo. O valor padrão é `true`.
- `spark.shuffle.storage.s3.serverSideEncryption.algorithm`: o algoritmo de hash a ser usado. O valor padrão é `AES256`.
- `spark.shuffle.storage.s3.serverSideEncryption.kms.key`: o ARN da chave do KMS quando o SSE aws:kms está habilitado.

Junto com essas configurações, talvez seja necessário definir configurações como `spark.hadoop.fs.s3.enableServerSideEncryption` e outras configurações específicas do ambiente para garantir que a criptografia apropriada seja aplicada ao seu caso de uso.

Versões do plug-in

Esse plug-in é compatível com as versões do Spark associadas a cada versão do AWS Glue. A tabela a seguir mostra a versão do AWS Glue, a versão do Spark e a versão do plug-in associada, com o local do Amazon S3 para o binário de software do plug-in.

Versão do AWS Glue	Versão do Spark	Versão do plug-in	Local do 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-

Versão do AWS Glue	Versão do Spark	Versão do plug-in	Local do Amazon S3
			plugin/3.3-amzn-0/chopper-plugin-3.3-amzn-LATEST.jar

Licença

O binário do software para este plugin é licenciado sob a Licença do Apache-2.0.

Monitorar trabalhos Spark do AWS Glue

Tópicos

- Métricas do Spark disponíveis no AWS Glue Studio
- Monitorar trabalhos usando a interface do usuário da Web do Apache Spark
- Monitoramento com insights de execuções de trabalho do AWS Glue
- Monitorar o com o Amazon CloudWatch
- Monitoramento e depuração de trabalho

Métricas do Spark disponíveis no AWS Glue Studio

A guia Metrics (Métricas) mostra métricas coletadas quando um trabalho é executado e a criação de perfil está ativada. Os seguintes gráficos são exibidos em trabalhos do Spark:

- Movimentação de dados ETL
- Perfil de memória: driver e executores

Escolha View additional metrics (Ver métricas adicionais) para mostrar os gráficos a seguir:

- Movimentação de dados ETL
- Perfil de memória: driver e executores
- Embaralhamento de dados em executores
- Carga da CPU: driver e executores
- Execução de trabalho: executores ativos, estágios concluídos e executores máximos necessários

Os dados para esses gráficos serão enviados para as métricas do CloudWatch se o trabalho estiver configurado para coletar métricas. Para obter mais informações sobre como ativar métricas e interpretar os gráficos, consulte Monitoramento e depuração de trabalho.

Example Grafo de movimentação de dados de ETL

O gráfico de movimentação de dados ETL mostra as seguintes métricas:

- O número de bytes lidos do Amazon S3 por todos os executores: `glue.ALL.s3.filesystem.read_bytes`
- O número de bytes gravados no Amazon S3 por todos os executores: `glue.ALL.s3.filesystem.write_bytes`

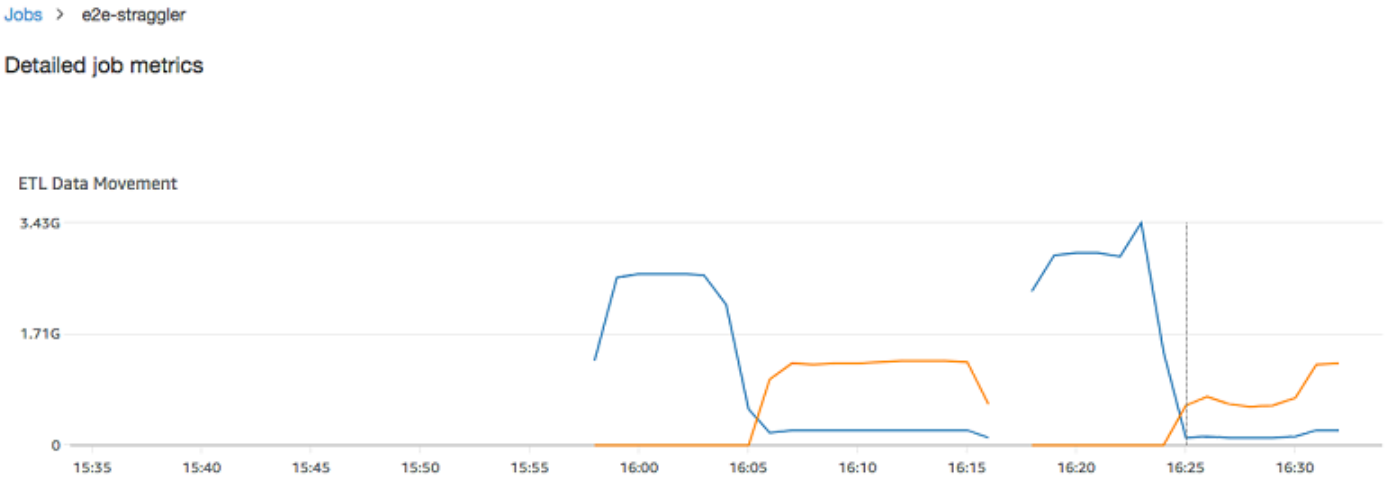

Example Grafo de perfil de memória

O gráfico de perfil de memória mostra as seguintes métricas:

- A fração de memória usada pelo heap da JVM para este driver (escala: 0–1) pelo driver, um executor identificado por executorId ou todos os executores:
  - `glue.driver.jvm.heap.usage`
  - `glue.executorId.jvm.heap.usage`
  - `glue.ALL.jvm.heap.usage`

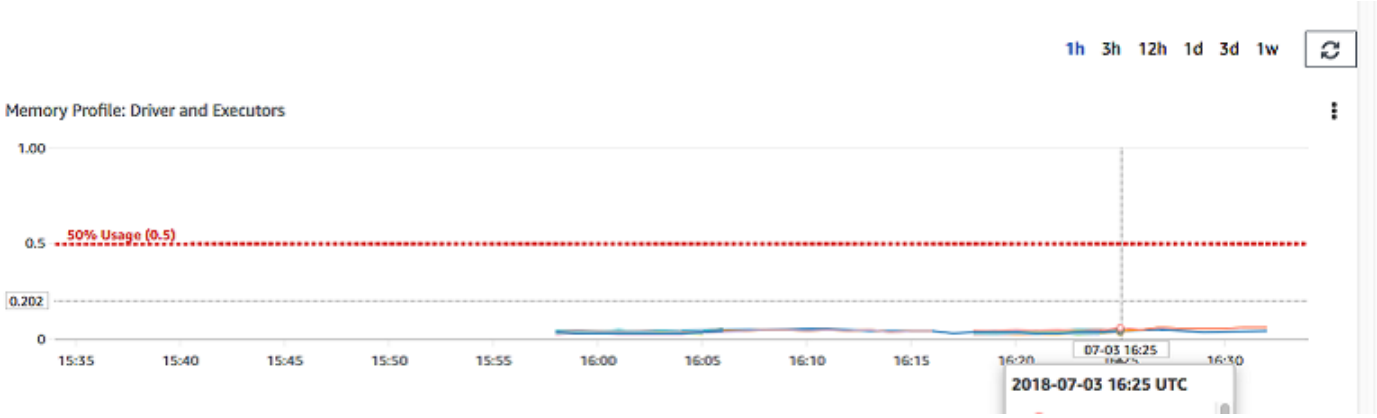

Example Grafo de embaralhamento de dados em executores

O gráfico de embaralhamento de dados nos executores mostra as seguintes métricas:

- O número de bytes lidos por todos os executores para embaralhar os dados entre eles — `glue.driver.aggregate.shuffleLocalBytesRead`
- O número de bytes gravados por todos os executores para embaralhar os dados entre eles — `glue.driver.aggregate.shuffleBytesWritten`

Example Grafo de carga de CPU

O gráfico de carga de CPU mostra as seguintes métricas:

- A fração de carga de sistema da CPU usada (escala: 0–1) pelo driver, um executor identificado por executorId ou todos os executores:
  - `glue.driver.system.cpuSystemLoad`
  - `glue.`*`executorId`*`.system.cpuSystemLoad`
  - `glue.ALL.system.cpuSystemLoad`

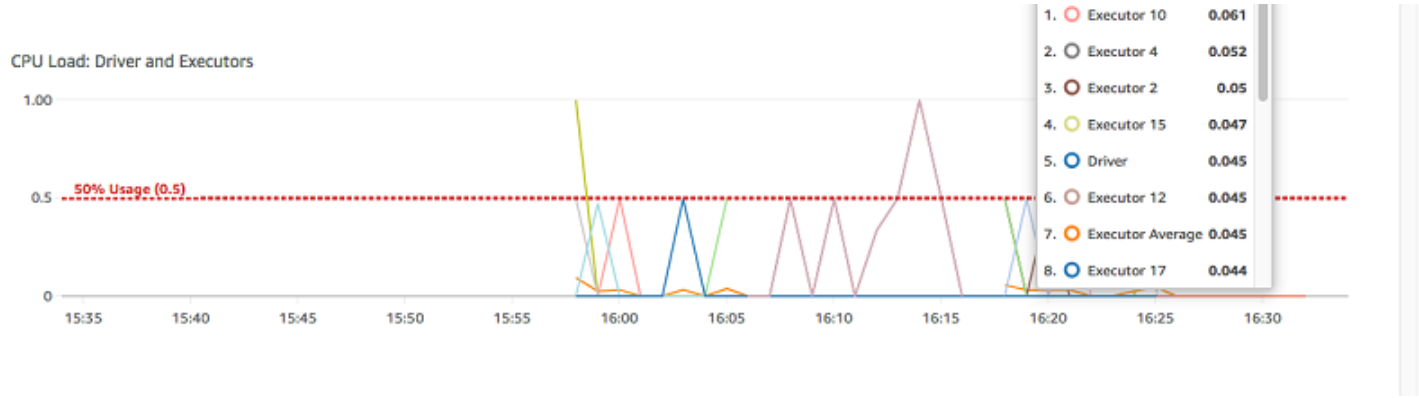

Example Grafo de execução de trabalho

O gráfico de execução de trabalho mostra as seguintes métricas:

- O número de executores ativamente em execução — `glue.driver.ExecutorAllocationManager.executors.numberAllExecutors`
- O número de estágios concluídos — `glue.aggregate.numCompletedStages`
- O número máximo de executores necessários — `glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors`

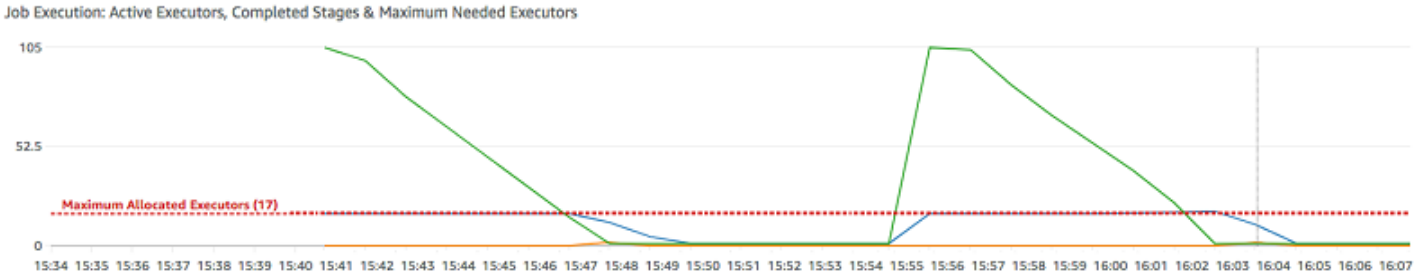

Monitorar trabalhos usando a interface do usuário da Web do Apache Spark

Você pode usar a interface do usuário Web do Apache Spark para monitorar e depurar trabalhos de ETL do AWS Glue em execução no sistema de trabalhos do AWS Glue e também aplicativos Spark em execução em endpoints de desenvolvimento do AWS Glue. A interface do usuário do Spark permite que você verifique o seguinte para cada trabalho:

- O cronograma de eventos de cada estágio do Spark
- Um gráfico acíclico dirigido (DAG) do trabalho
- Planos físicos e lógicos para consultas SparkSQL

- As variáveis de ambiente do Spark subjacentes para cada trabalho

Para obter mais informações sobre como usar a interface do usuário Web do Spark, consulte Interface do usuário Web na documentação do Spark. Para obter orientação sobre como interpretar os resultados da interface do usuário do Spark para melhorar a performance do seu trabalho, consulte Best practices for performance tuning AWS Glue for Apache Spark jobs em AWS Prescriptive Guidance.

É possível ver a interface do usuário do Spark no console do AWS Glue. Isso está disponível quando um trabalho do AWS Glue é executado no AWS Glue 3.0 ou versões posteriores com logs gerados no formato Padrão (em vez de legado), o que é o padrão para trabalhos mais recentes. Se você tiver arquivos de log maiores que 0,5 GB, poderá ativar o suporte a logs contínuos para execuções de trabalhos em versões do AWS Glue 4.0 ou posteriores para simplificar o arquivamento, a análise e a solução de problemas de logs.

Você pode habilitar a interface do usuário do Spark usando o console do AWS Glue ou a AWS Command Line Interface (AWS CLI). Quando você habilita a interface do usuário do Spark, os trabalhos de ETL do AWS Glue e as aplicações do Spark em endpoints de desenvolvimento do AWS Glue podem fazer backup dos logs de eventos do Spark em um local especificado por você no Amazon Simple Storage Service (Amazon S3). É possível usar os logs de eventos armazenados em backup no Amazon S3 com a interface do usuário do Spark em tempo real à medida que o trabalho é executado e após a conclusão do trabalho. Enquanto os logs permanecerem no Amazon S3, a interface do usuário do Spark no console do AWS Glue poderá visualizá-los.

Permissões

Para usar a interface do usuário do Spark no console do AWS Glue, é possível usar o `UseGlueStudio` ou adicionar todas as APIs de serviço individuais. Todas as APIs são necessárias para aproveitar ao máximo a interface do usuário do Spark. No entanto, os usuários podem acessar os recursos da interface do usuário do Spark adicionando suas APIs de serviço à permissão do IAM para acesso refinado.

`RequestLogParsing` é o mais crítico, pois executa a análise dos logs. As APIs restantes destinam-se à leitura dos respectivos dados analisados. Por exemplo, `GetStages` fornece acesso aos dados sobre todas as etapas de um trabalho do Spark.

A lista de APIs de serviço da interface do usuário do Spark mapeadas em `UseGlueStudio` é mostrada no exemplo de política abaixo. A política abaixo fornece acesso para uso somente dos

recursos da interface do usuário do Spark. Para adicionar mais permissões, como Amazon S3 e IAM, consulte Criar políticas personalizadas do IAM para AWS Glue Studio.

A lista de APIs de serviço da interface do usuário do Spark mapeadas em `UseGlueStudio` é mostrada no exemplo de política abaixo. Ao usar uma API de serviço da interface do usuário do Spark, use o seguinte namespace: `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": [
    "*"
   ]
  }
 ]
}
```

Limitações

- A interface do usuário do Spark no console do AWS Glue não está disponível para execuções de trabalhos que ocorreram antes de 20 de novembro de 2023, pois elas estão no formato de log legado.
- A interface do Spark no console do AWS Glue não é compatível com logs contínuos, para o AWS Glue 4.0, como aqueles gerados por padrão em trabalhos de streaming. A soma máxima de todos os arquivos de eventos de logs acumulados gerados é 2 GB. Para trabalhos do AWS Glue sem suporte a logs contínuos, o tamanho máximo do arquivo de eventos de log suportado pelo SparkUI é de 0,5 GB.
- A interface de usuário do Spark sem servidor não está disponível para registros de eventos do Spark armazenados em um bucket do Amazon S3 que só pode ser acessado pela sua VPC.

Exemplo: interface do usuário Web do Apache Spark

Este exemplo mostra como usar a interface do usuário do Spark para entender a performance do trabalho. As capturas de tela mostram a interface do usuário Web do Spark fornecida por um servidor de histórico autogerenciado do Spark. A interface do usuário do Spark no console do AWS Glue oferece visualizações semelhantes. Para obter mais informações sobre como usar a interface do usuário Web do Spark, consulte Interface do usuário Web na documentação do Spark.

Veja a seguir um exemplo de uma aplicação Spark que lê de duas fontes de dados, realiza uma transformação de junção e a grava no Amazon S3 no formato 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()
```

A visualização do DAG a seguir mostra os diferentes estágios nesse trabalho do Spark.

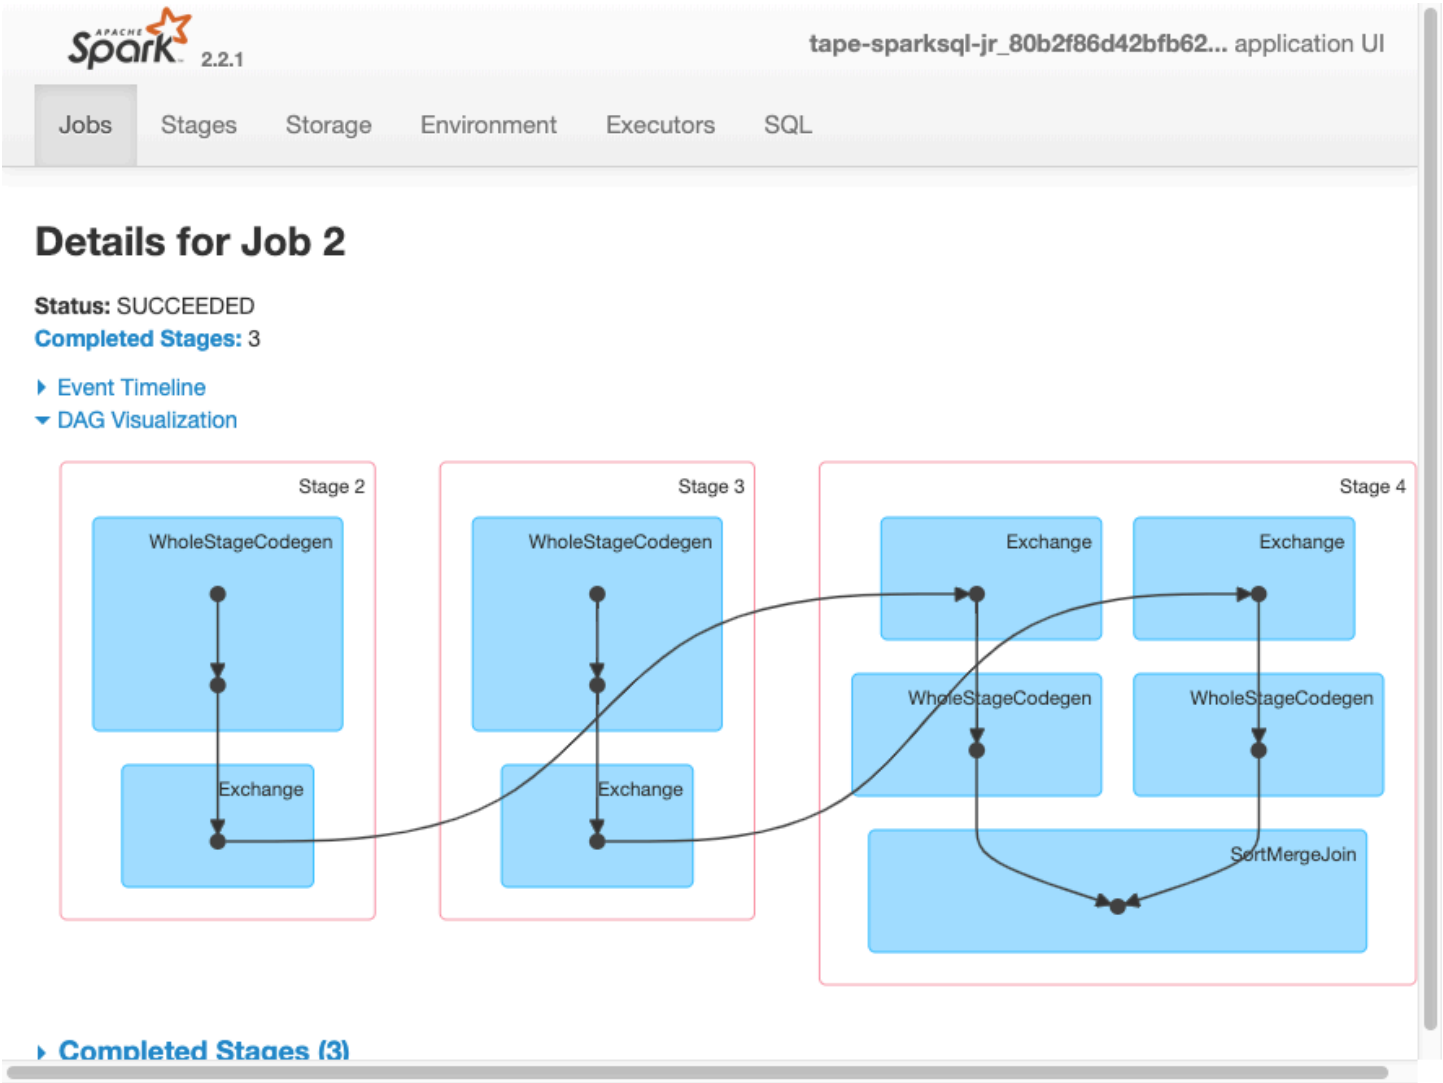

O cronograma de eventos a seguir para um trabalho mostra o início, a execução e o encerramento de diferentes executores do Spark.

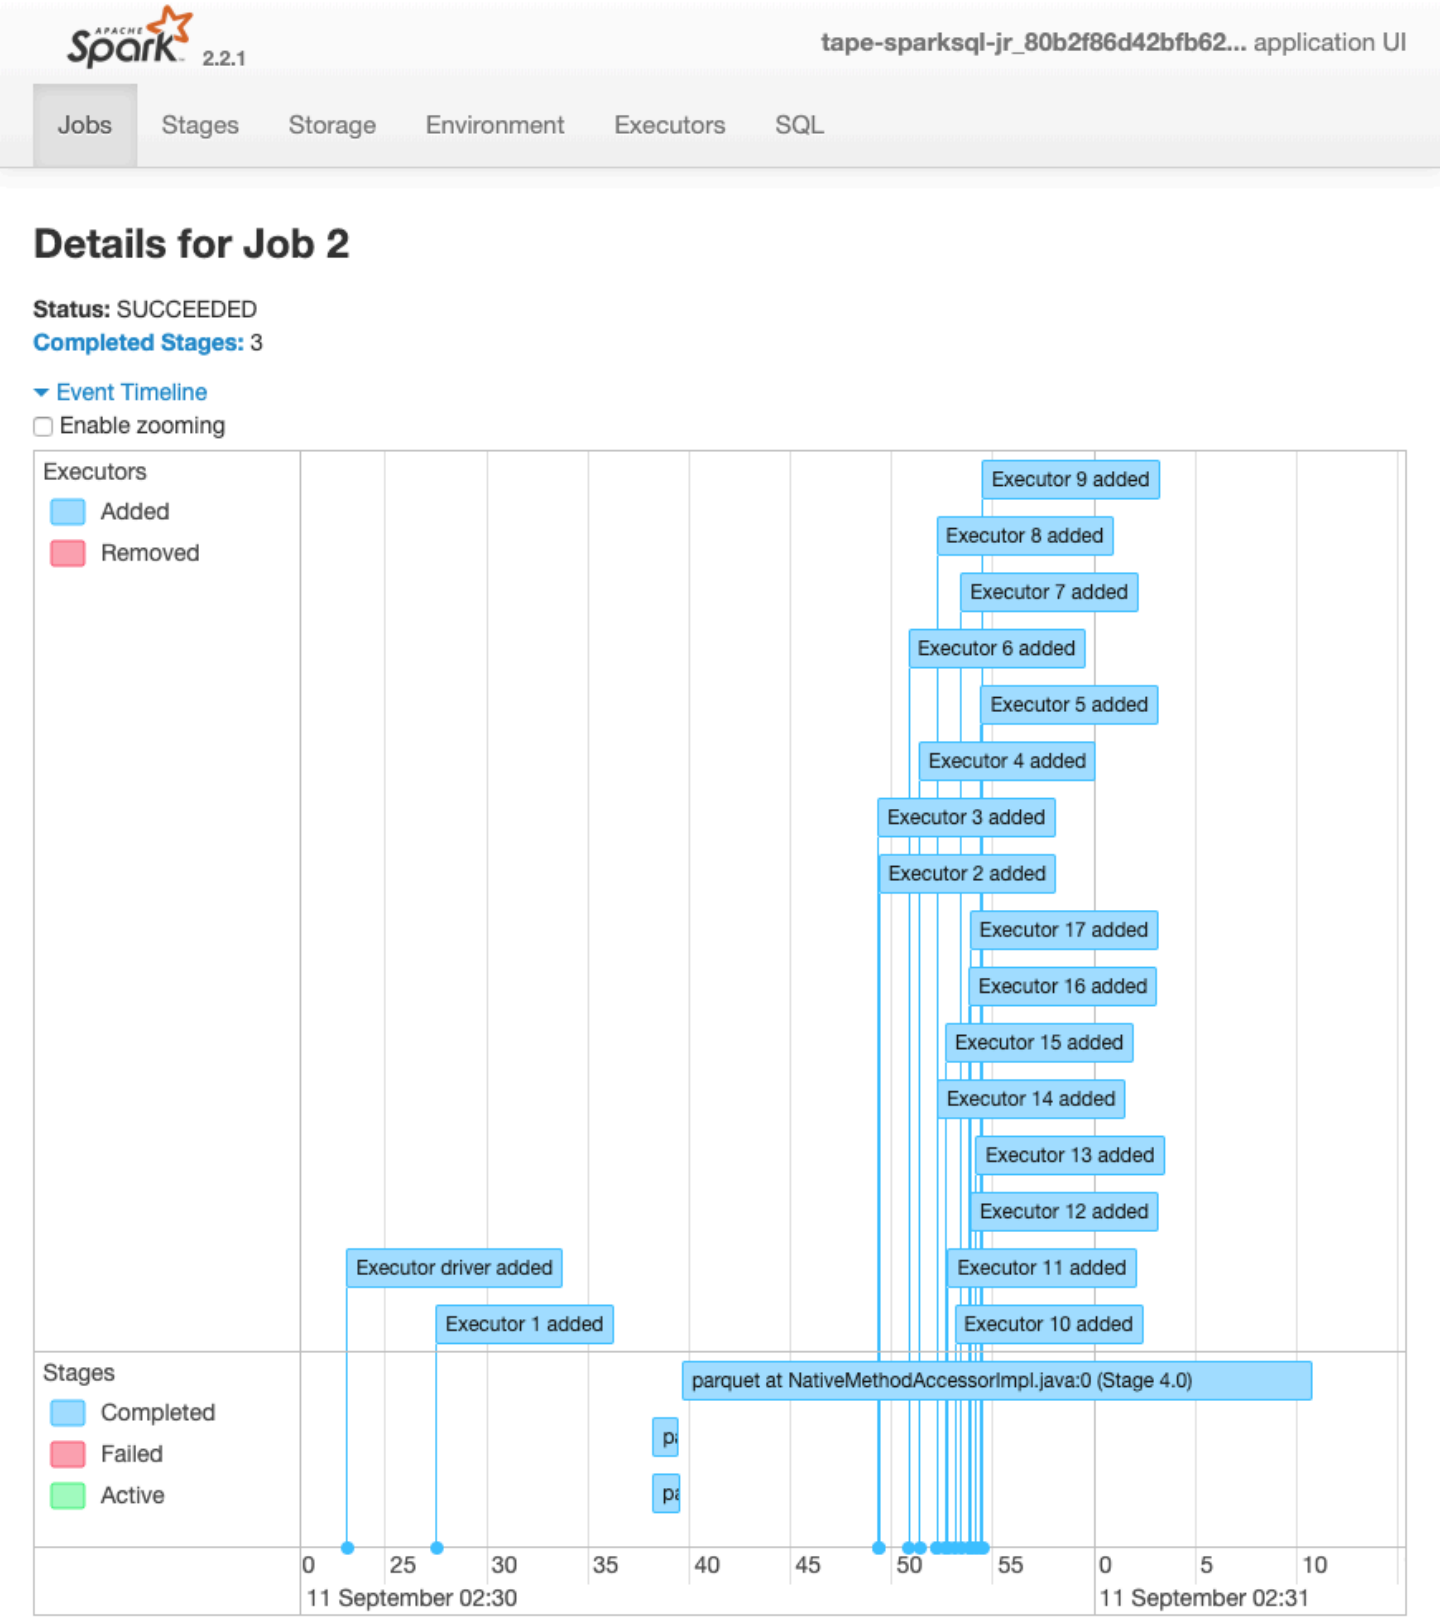
Spark 2.2.1
tape-sparksql-jr_80b2f86d42bfb62... application UI
Jobs
Stages
Storage
Environment
Executors
SQL
Details for Job 2
Status: SUCCEEDED
Completed Stages: 3
Event Timeline
Enable zooming
Executors
Added
Removed
Executor 9 added
Executor 8 added
Executor 7 added
Executor 6 added
Executor 5 added
Executor 4 added
Executor 3 added
Executor 2 added
Executor 17 added
Executor 16 added
Executor 15 added
Executor 14 added
Executor 13 added
Executor 12 added
Executor 11 added
Executor 10 added
Executor driver added
Executor 1 added
Stages
Completed
Failed
Active
parquet at NativeMethodAccessorImpl.java:0 (Stage 4.0)
0
25
30
35
40
45
50
55
0
5
10
11 September 02:30
11 September 02:31
DAG Visualization
Completed Stages (3)

A tela a seguir mostra os detalhes dos planos de consulta do SparkSQL:

- Plano lógico examinado
- Plano lógico analisado
- Plano lógico otimizado
- Plano físico para execução

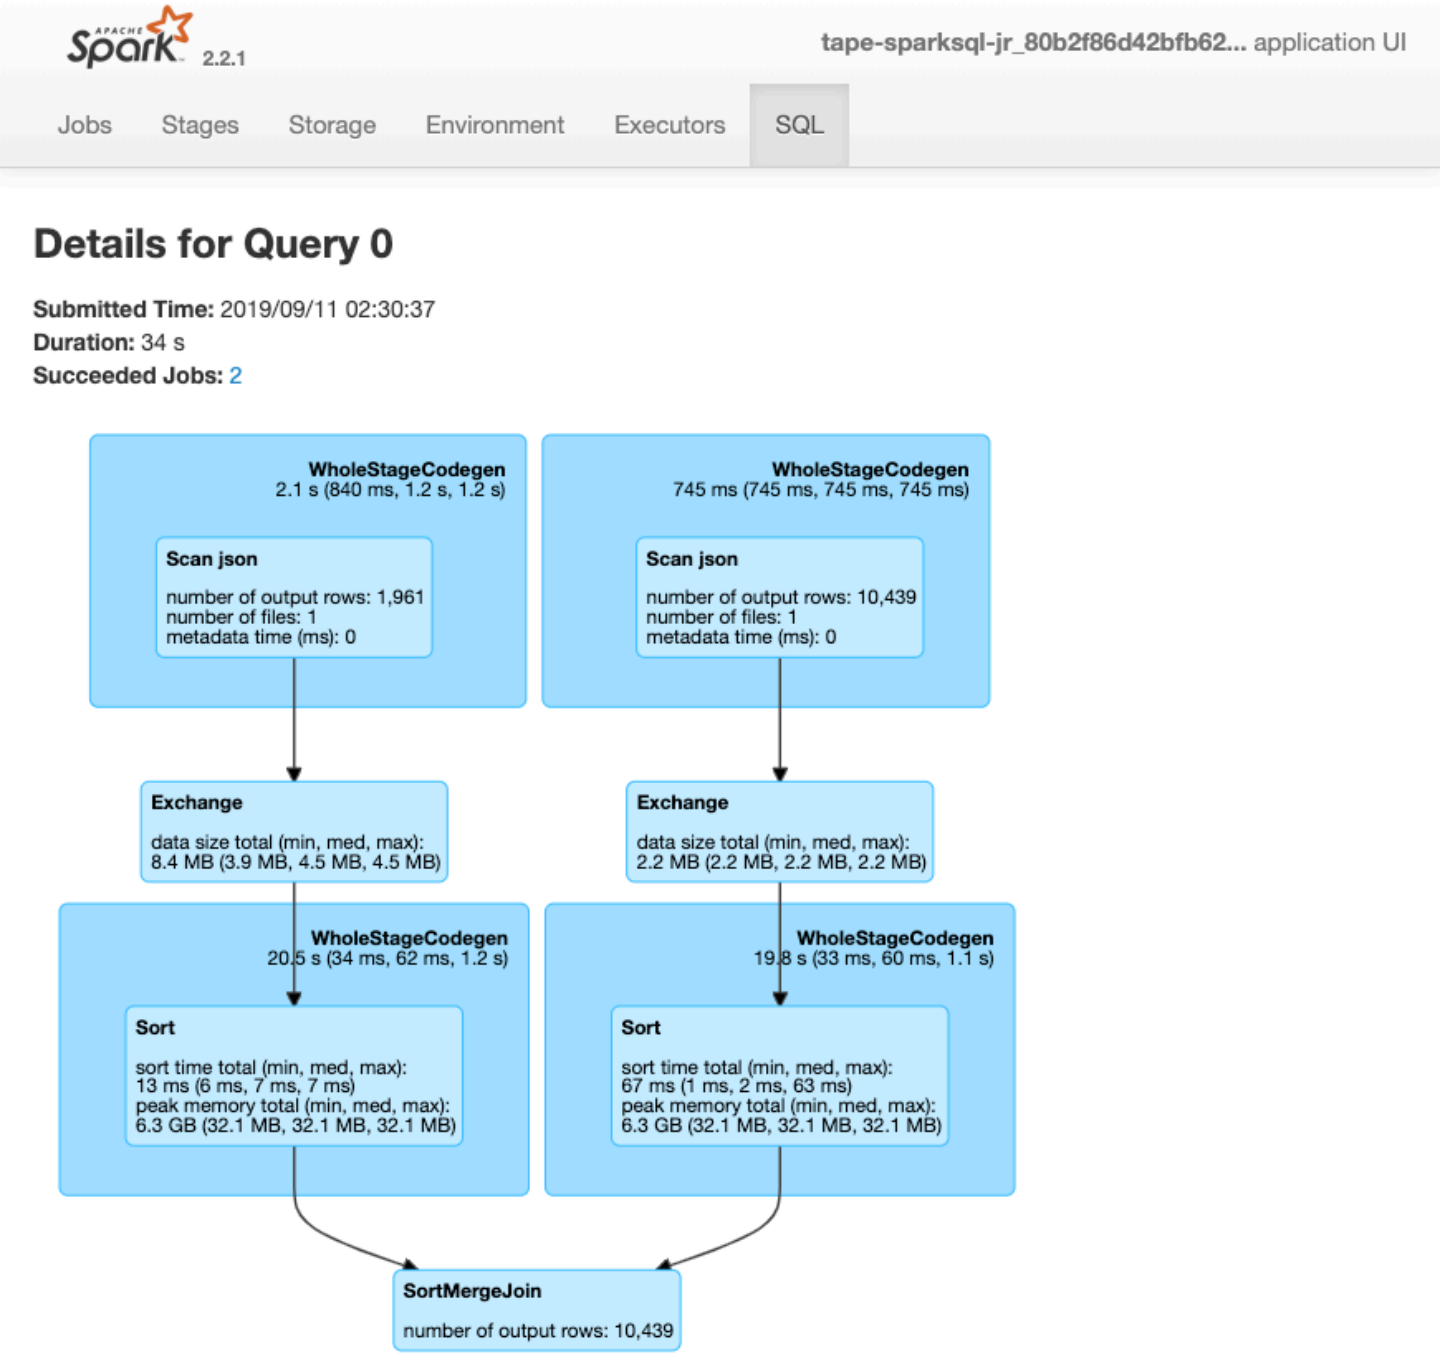

▾ Details

```
== 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<note:string,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)
```

Tópicos

- Habilitar a interface do usuário da Web do Apache Spark para trabalhos do AWS Glue
- Iniciar o servidor de histórico do Spark

Habilitar a interface do usuário da Web do Apache Spark para trabalhos do AWS Glue

Você pode usar a interface do usuário Web do Apache Spark para monitorar e depurar trabalhos de ETL do AWS Glue em execução no sistema de trabalhos do AWS Glue. Você pode configurar a interface do usuário do Spark usando o console do AWS Glue ou a AWS Command Line Interface (AWS CLI).

A cada 30 segundos, o AWS Glue faz backup dos logs de eventos do Spark para o caminho do Amazon S3 especificado.

Tópicos

- Configurar a interface do usuário do Spark (console)
- Configurar a interface do usuário do Spark (AWS CLI)
- Configurar a interface do usuário do Spark para sessões usando cadernos
- Habilitar logs contínuos

Configurar a interface do usuário do Spark (console)

Siga estas etapas para configurar a interface do usuário do Spark usando o AWS Management Console. Na criação de um trabalho do AWS Glue, a interface do usuário do Spark é habilitada por padrão.

Para ativar a interface do Spark quando você cria ou edita um trabalho

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Tarefas.
3. Escolha Adicionar trabalho ou selecione um trabalho que já exista.
4. Em Detalhes do trabalho, abra as Propriedades avançadas.
5. Na guia Interface do usuário do Spark, escolha Gravar logs da interface do usuário do Spark no Amazon S3.

6. Especifique um caminho do Amazon S3 para armazenar os logs de eventos do Spark para o trabalho. Observe que, se você usar uma configuração de segurança no trabalho, a criptografia também se aplicará ao arquivo de log da interface do usuário do Spark. Para ter mais informações, consulte Criptografar dados gravados pelo AWS Glue.
7. Em Configuração de log e monitoramento da interface do usuário do Spark:
   - Selecione Padrão se você estiver gerando logs para visualizar no console do AWS Glue.
   - Selecione Legado se você estiver gerando logs para visualizar em um servidor de histórico do Spark.
   - Você também pode optar por gerar os dois.

Configurar a interface do usuário do Spark (AWS CLI)

Para gerar logs para visualização com a interface do usuário do Spark no console do AWS Glue, use AWS CLI para passar os seguintes parâmetros de trabalho para os trabalhos do AWS Glue. Para ter mais informações, consulte the section called “Parâmetros de trabalho”.

```
'--enable-spark-ui': 'true',
'--spark-event-logs-path': 's3://s3-event-log-path'
```

Para distribuir logs para seus locais legados, defina o parâmetro `--enable-spark-ui-legacy-path` como `"true"`. Se não quiser gerar logs nos dois formatos, remova o parâmetro `--enable-spark-ui`.

Configurar a interface do usuário do Spark para sessões usando cadernos

> **Warning**
>
> No momento, as sessões interativas do AWS Glue não oferecem suporte à interface do usuário do Spark no console. Configure um servidor de histórico do Spark.

Se você usa cadernos do AWS Glue, configure a interface do usuário do Spark antes de iniciar a sessão. Para fazer isso, use a célula da mágica `%%configure`:

```
%%configure { “--enable-spark-ui”: “true”, “--spark-event-logs-path”: “s3://path” }
```

Habilitar logs contínuos

Habilitar o SparkUI e os arquivos de eventos de logs contínuos para trabalhos do AWS Glue oferece vários benefícios:

- Arquivos de eventos de logs contínuo: com os arquivos de eventos de logs contínuo ativados, o AWS Glue gera arquivos de log separados para cada etapa da execução do trabalho, facilitando a identificação e a solução de problemas específicos de um determinado estágio ou transformação.
- Melhor gerenciamento de registros: arquivos de eventos de logs contínuos ajudam a gerenciar arquivos de log com mais eficiência. Em vez de ter um único arquivo de log potencialmente grande, os registros são divididos em arquivos menores e mais gerenciáveis com base nos estágios de execução do trabalho. Isso pode simplificar o arquivamento, a análise e a solução de problemas de logs.
- Maior tolerância a falhas: se um trabalho do AWS Glue falhar ou for interrompido, os arquivos de eventos de logs contínuos podem fornecer informações valiosas sobre o último estágio bem-sucedido, facilitando a retomada do trabalho a partir desse ponto, em vez de começar do zero.
- Otimização de custos: ao ativar arquivos de eventos de logs contínuos, você pode economizar nos custos de armazenamento associados aos arquivos de log. Em vez de armazenar um único arquivo de log potencialmente grande, você armazena arquivos de log menores e mais gerenciáveis, o que pode ser mais econômico, especialmente para trabalhos complexos ou de longa duração.

Em um novo ambiente, os usuários podem habilitar explicitamente os logs contínuos por meio de:

```
'—conf': 'spark.eventLog.rolling.enabled=true'
```

ou

```
'—conf': 'spark.eventLog.rolling.enabled=true —conf
spark.eventLog.rolling.maxFileSize=128m'
```

Quando os logs contínuos são ativados, o `spark.eventLog.rolling.maxFileSize` especifica o tamanho máximo do arquivo de log de eventos antes da rolagem. Se esse parâmetro não for especificado, o valor 128 MB será usado como padrão. O mínimo é 10 MB.

A soma máxima de todos os arquivos de eventos de logs acumulados gerados é 2 GB. Para trabalhos do AWS Glue sem suporte a logs contínuos, o tamanho máximo do arquivo de eventos de logs suportado pelo SparkUI é 0,5 GB.

É possível desativar os logs contínuos de um trabalho de streaming por meio da passagem de uma configuração adicional. Observe que a manutenção de arquivos de log muito grandes pode ser cara.

Para desativar os logs contínuos, forneça a seguinte configuração:

```
'--spark-ui-event-logs-path': 'true',
'--conf': 'spark.eventLog.rolling.enabled=false'
```

Iniciar o servidor de histórico do Spark

É possível usar um servidor de histórico do Spark para visualizar os logs do Spark em sua própria infraestrutura. Você pode ver as mesmas visualizações no console do AWS Glue para execuções de trabalhos do AWS Glue no AWS Glue 4.0 ou versões posteriores com logs gerados no formato padrão (em vez de legado). Para ter mais informações, consulte the section called “Monitorar com a interface do usuário do Spark”.

Você pode iniciar o servidor de histórico do Spark usando um modelo do AWS CloudFormation que hospeda o servidor em uma instância do EC2 ou executar localmente usando o Docker.

Tópicos

- Iniciar o servidor de histórico do Spark e visualizar a interface do usuário do Spark usando o AWS CloudFormation
- Iniciar o servidor de histórico do Spark e visualizar a interface do usuário do Spark usando o Docker

Iniciar o servidor de histórico do Spark e visualizar a interface do usuário do Spark usando o AWS CloudFormation

Você pode usar um modelo do AWS CloudFormation para iniciar o servidor de histórico do Apache Spark e visualizar a interface do usuário Web do Spark. Esses modelos são exemplos que você deve modificar para atender aos seus requisitos.

Como iniciar o servidor de histórico do Spark e visualizar a interface do usuário do Spark usando o AWS CloudFormation

1. Escolha um dos botões Launch Stack (Iniciar pilha) na tabela a seguir. Isso inicia a pilha no console do AWS CloudFormation.

Região	Executar
Leste dos EUA (Ohio)	
Leste dos EUA (N. da Virgínia)	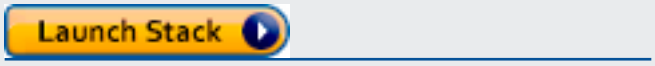
Oeste dos EUA (N. da Califórnia)	
Oeste dos EUA (Oregon)	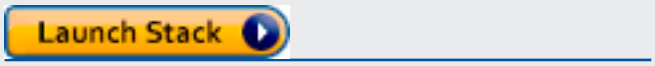
África (Cidade do Cabo)	
Ásia-Pacífico (Hong Kong)	
Ásia-Pacífico (Mumbai)	
Ásia-Pacífico (Osaka)	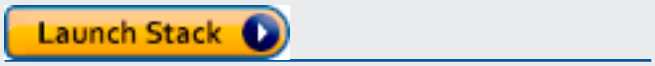
Ásia-Pacífico (Seul)	
Ásia-Pacífico (Singapura)	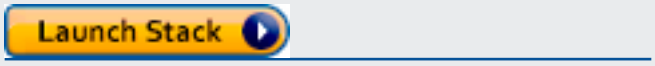
Ásia-Pacífico (Sydney)	
Ásia-Pacífico (Tóquio)	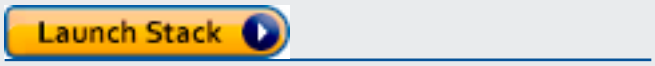
Canadá (Central)	
Europa (Frankfurt)	

Região	Executar
Europa (Irlanda)	Launch Stack
Europa (Londres)	Launch Stack
Europa (Milão)	Launch Stack
Europa (Paris)	Launch Stack
Europa (Estocolmo)	Launch Stack
Oriente Médio (Bahrein)	Launch Stack
South America (São Paulo)	Launch Stack

2. Na página Specify template (Especificar modelo), escolha Next (Próximo).
3. Na página Specify stack details (Especificar detalhes da pilha), insira o Stack name (Nome da pilha). Insira informações adicionais em Parameters (Parâmetros).

   a. Configuração da interface do usuário do Spark

      Forneça as informações a seguir:

      - IP address range (Intervalo de endereços IP): o intervalo de endereços IP que pode ser usado para visualizar a interface do usuário do Spark. Se você deseja restringir o acesso de um intervalo de endereços IP específico, use um valor personalizado.
      - History server port (Porta do servidor de histórico): a porta da interface do usuário do Spark. Você pode usar o valor padrão.
      - Event log directory (Diretório de logs de evento): escolha o local onde os logs de eventos do Spark são armazenados nos endpoints de trabalho ou de desenvolvimento do AWS Glue. Você deve usar **`s3a://`** para o esquema de caminho dos logs de eventos.
      - Spark package location (Local do pacote do Spark): você pode usar o valor padrão.

- Keystore path (Caminho do repositório de chaves): o caminho do repositório de chaves SSL/TLS para HTTPS. Se você quiser usar um arquivo de armazenamento de chaves personalizado, especifique o caminho do S3 `s3://path_to_your_keystore_file` aqui. Se você deixar esse parâmetro vazio, um armazenamento de chaves baseado em certificado autoassinado será gerado e usado.
- Keystore password (Senha do repositório de chaves): insira uma senha do repositório de chaves SSL/TLS para HTTPS.

b. Configuração de instância do EC2

Forneça as informações a seguir:

- Instance type (Tipo de instância): o tipo de instância do Amazon EC2 que hospeda o servidor de histórico do Spark. Como esse modelo inicia a instância do Amazon EC2 em sua conta, o custo do Amazon EC2 será cobrado em sua conta separadamente.
- Latest AMI ID (ID da AMI mais recente): o ID da AMI do Amazon Linux 2 para a instância do servidor de histórico do Spark. Você pode usar o valor padrão.
- VPC ID (ID da VPC): o ID da nuvem privada virtual (VPC) da instância do servidor de histórico do Spark. Você pode usar qualquer uma das VPCs disponíveis em sua conta. Não é recomendado usar uma VPC padrão com uma Network ACL padrão. Para obter mais informações, consulte VPC padrão e sub-redes padrão e Criar uma VPC no Manual do usuário da Amazon VPC.
- Subnet ID (ID da sub-rede): o ID da instância do servidor de histórico do Spark. Você pode usar qualquer uma das sub-redes em sua VPC. Você deve ser capaz de acessar a rede do seu cliente para a sub-rede. Se quiser acessar pela Internet, você deverá usar uma sub-rede pública que tenha o gateway da Internet na tabela de rotas.

c. Escolha Próximo.

4. Na página Configure stack options (Configurar opções de pilha), para usar as credenciais do usuário atual para determinar como o CloudFormation pode criar, modificar ou excluir recursos na pilha, escolha Next (Próximo). Você também pode especificar um perfil na seção Permissões para usar em vez das permissões do usuário atual e, em seguida, escolher Próximo.
5. Na página Review (Revisar), revise o modelo.

   Selecione Reconheço que o AWS CloudFormation pode criar recursos do IAM e escolha Criar pilha.
6. Aguarde até que a pilha seja criada.

7. Abra a guia Outputs (Saídas).

   a. Copie o URL de SparkUiPublicUrl se você estiver usando uma sub-rede pública.

   b. Copie o URL de SparkUiPrivateUrl se você estiver usando uma sub-rede privada.

8. Abra um navegador da Web e cole o URL. Isso permite que você acesse o servidor usando HTTPS na porta especificada. É possível que seu navegador não reconheça o certificado do servidor. Se isso acontecer, substitua a proteção e prossiga.

Iniciar o servidor de histórico do Spark e visualizar a interface do usuário do Spark usando o Docker

Se você preferir acesso local (não ter uma instância do EC2 para o servidor de histórico do Apache Spark), também poderá usar o Docker para iniciar o servidor de histórico do Apache Spark e visualizar a interface do usuário do Spark localmente. Este Dockerfile é um exemplo que você deve modificar para atender aos seus requisitos.

Pré-requisitos

Para obter informações sobre como instalar o Docker em seu laptop, consulte a Comunidade do Docker Engine.

Como iniciar o servidor de histórico do Spark e visualizar a interface do usuário do Spark localmente usando o Docker

1. Faça download de arquivos do GitHub.

   Baixe o Dockerfile e o `pom.xml` dos exemplos de código do AWS Glue.

2. Determine se você deseja usar suas credenciais de usuário ou credenciais de usuário federado para acessar AWS.

   - Para usar as credenciais do usuário atual para acessar AWS, obtenha os valores para usar em `AWS_ACCESS_KEY_ID` e `AWS_SECRET_ACCESS_KEY` no comando `docker run`. Para obter mais informações, consulte Gerenciamento de chaves de acesso de usuários do IAM no Guia do usuário do IAM.
   - Para usar usuários federados do SAML 2.0 para acessar AWS, obtenha os valores para `AWS_ACCESS_KEY_ID`, `AWS_SECRET_ACCESS_KEY`, e `AWS_SESSION_TOKEN`. Para obter mais informações, consulte Solicitação de credenciais de segurança temporárias.

3. Determine a localização do diretório do log de eventos, a ser usado no comando `docker run`.

4. Crie a imagem do Docker usando os arquivos no diretório local, usando o nome `glue/sparkui` e a marcação `latest`.

```
$ docker build -t glue/sparkui:latest .
```

5. Crie e inicie o contêiner do Docker.

   Nos comandos a seguir, use os valores obtidos anteriormente nas etapas 2 e 3.

   a. Para criar o contêiner do Docker usando suas credenciais de usuário, use um comando semelhante ao seguinte

```
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. Para criar o contêiner do Docker usando credenciais temporárias, use `org.apache.hadoop.fs.s3a.TemporaryAWSCredentialsProvider` como provedor, e forneça os valores de credenciais obtidos na etapa 2. Para obter mais informações, consulte Uso de credenciais de sessão com TemporaryAWSCredentialsProvider na documentação Hadoop: Integração com a 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**
>
> Esses parâmetros de configuração vêm do Módulo Hadoop-AWS. Talvez seja necessário adicionar uma configuração específica com base em seu caso

de uso. Por exemplo: usuários em regiões isoladas precisarão configurar o `spark.hadoop.fs.s3a.endpoint`.

6. Abra `http://localhost:18080` no navegador para visualizar a interface do usuário do Spark localmente.

Monitoramento com insights de execuções de trabalho do AWS Glue

Os insights de execução de trabalhos do AWS Glue são um recurso do AWS Glue que simplifica a depuração e a otimização de trabalhos para seus trabalhos do AWS Glue. O AWS Glue fornece a IU do Spark e logs e métricas do CloudWatch para monitorar seus trabalhos do AWS Glue. Com esse recurso, você obtém essas informações sobre a execução do seu trabalho do AWS Glue:

- Número da linha do script do trabalho do AWS Glue que apresentou uma falha.
- Ação Spark executada por último no plano de consulta do Spark pouco antes da falha do seu trabalho.
- Eventos de exceção do Spark relacionados à falha apresentados em um fluxo de log ordenado ao longo do tempo.
- Análise de causa raiz e ação recomendada (como ajustar seu script) para corrigir o problema.
- Eventos comuns do Spark (mensagens de log relacionadas a uma ação do Spark) com uma ação recomendada que aborda a causa raiz.

Todos esses insights estão disponíveis para você usando dois novos fluxos de log nos logs do CloudWatch para seus trabalhos do AWS Glue.

Requisitos

O atributo de insights de execução de trabalhos do AWS Glue está disponível para as versões 2.0, 3.0, 4.0 e 5.0 do AWS Glue. É possível seguir o guia de migração para seus trabalhos existentes para atualizá-los das versões mais antigas do AWS Glue.

Habilitação de insights de execução de trabalhos para um trabalho ETL do AWS Glue

É possível habilitar insights de execução de trabalhos por meio do AWS Glue Studio ou da CLI.

AWS Glue Studio

Ao criar um trabalho via AWS Glue Studio, é possível habilitar ou desabilitar insights de execuções de trabalhos na guia Detalhes do trabalho. Verifique se a caixa Gerar insights de trabalhos está selecionada.

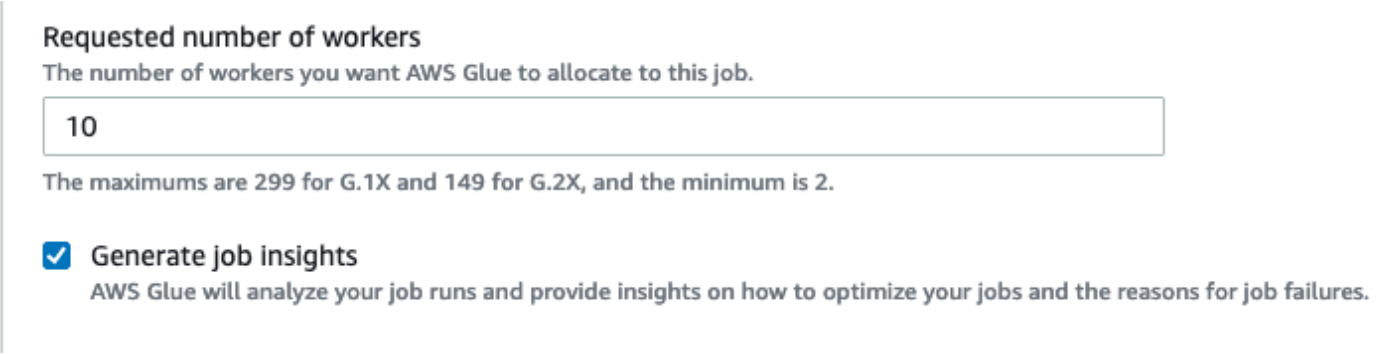

Linha de comando

Se estiver criando um trabalho por meio da CLI, será possível iniciar uma execução de trabalho com um único novo parâmetro de trabalho: `--enable-job-insights = true`.

Por padrão, os fluxos de log de insights de execução de trabalhos são criados sob o mesmo grupo de logs padrão usado pelo log contínuo do AWS Glue, ou seja, `/aws-glue/jobs/logs-v2/`. É possível configurar o nome do grupo de logs personalizado, filtros de log e configurações de grupo de logs usando o mesmo conjunto de argumentos para o log contínuo. Para obter mais informações, consulte Habilitar o log contínuo para trabalhos do AWS Glue.

Acessar os fluxos de log de insights de execução de trabalhos no CloudWatch

Com o recurso de insights de execução de trabalhos habilitado, pode haver dois fluxos de log criados quando uma execução de trabalho falha. Quando um trabalho termina com sucesso, nenhum dos fluxos é gerado.

1. Fluxo de log de análise de exceção: `<job-run-id>-job-insights-rca-driver`. Este stream fornece o seguinte:
   - Número da linha do script do trabalho do AWS Glue que causou a falha.
   - Ação do Spark executada por último no plano de consulta do Spark (DAG).
   - Eventos concisos ordenados por tempo do driver e executores do Spark relacionados à exceção. Será possível encontrar detalhes como mensagens de erro completas, a tarefa do Spark com falha e os IDs dos executores para obter ajuda para se concentrar no fluxo de log do executor específico para uma investigação mais profunda, se necessário.

2. Fluxo de insights baseado em regras:
   - Análise de causa raiz e recomendações sobre como corrigir os erros (como usar um parâmetro de trabalho específico para otimizar a performance).
   - Eventos relevantes do Spark servindo de base para a análise de causa raiz e uma ação recomendada.

> **Note**
>
> O primeiro fluxo só existirá se qualquer evento de exceção do Spark estiver disponível para uma execução de trabalho com falha, e o segundo fluxo só existirá se houver insights disponíveis para a execução do trabalho com falha. Por exemplo, se o trabalho for concluído com êxito, nenhum dos fluxos será gerado; se o trabalho falhar, mas não houver uma regra definida por serviço que possa corresponder ao seu cenário de falha, somente o primeiro fluxo será gerado.

Se o trabalho for criado do AWS Glue Studio, os links para os fluxos acima também estarão disponíveis na guia de detalhes da execução do trabalho (insights da execução do trabalho) como "Concise and consolidated error logs" (Logs de erros concisos e consolidados) e "Error analysis and guidance" (Análise de erros e orientações).

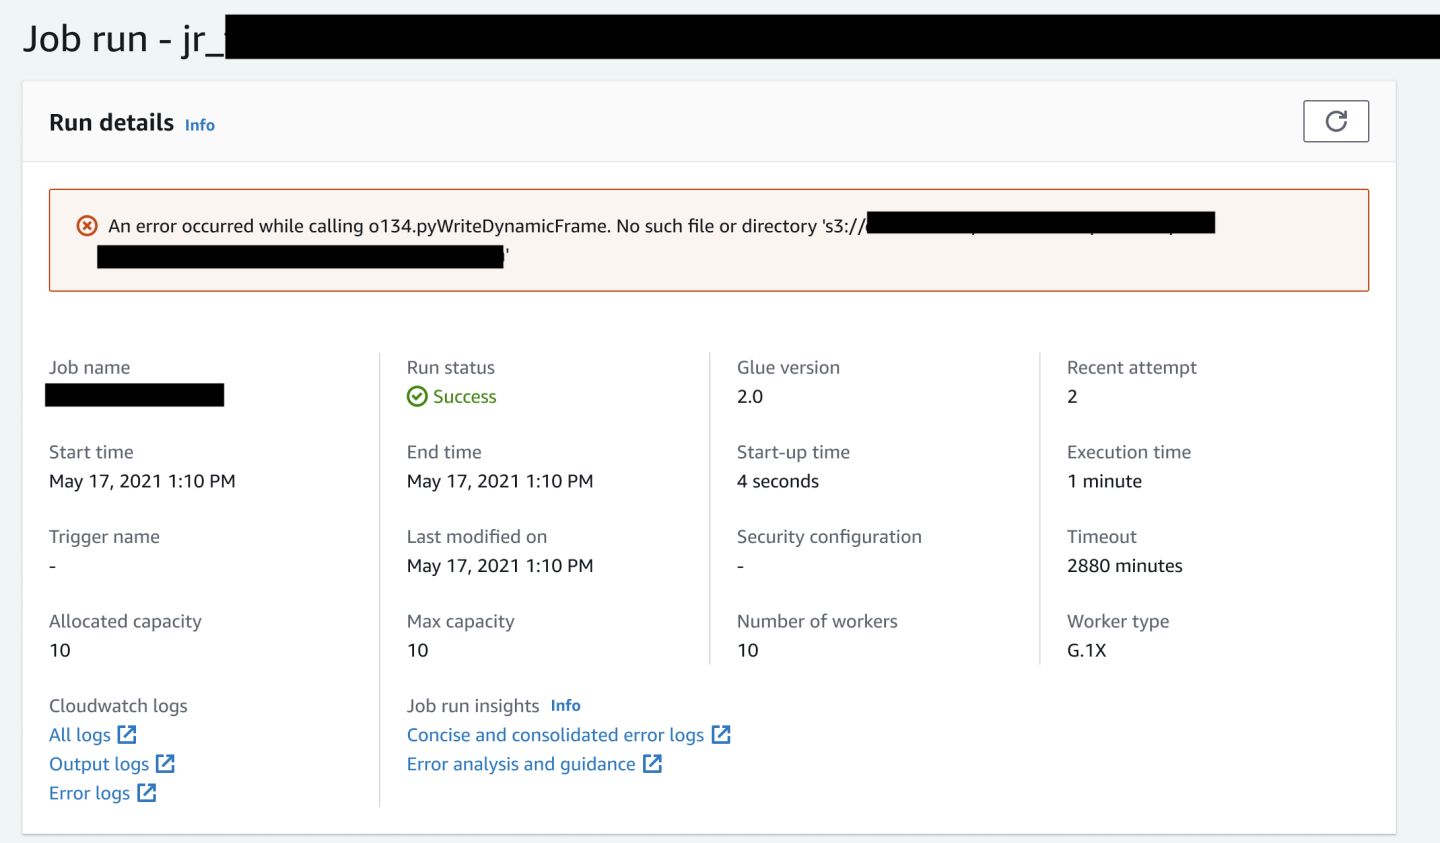

Exemplo de insights de execuções de trabalhos do AWS Glue

Nesta seção, apresentamos um exemplo de como o recurso de insights de execução de trabalhos pode ajudar a resolver um problema em um trabalho que falhou. Neste exemplo, um usuário esqueceu de importar o módulo necessário (tensorflow) em um trabalho do AWS Glue para analisar e criar um modelo de machine learning em seus dados.

```
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())
```

Sem o recurso de insights de execução de trabalhos, quando o trabalho falhar, você só vê esta mensagem emitida pelo Spark:

`An error occurred while calling o111.collectToPython. Traceback (most recent call last):`

A mensagem é ambígua e limita sua experiência de depuração. Nesse caso, esse recurso fornece informações adicionais em dois fluxos de log do CloudWatch:

1. O fluxo de log do `job-insights-rca-driver`:
   - Eventos de exceção: este fluxo de log fornece os eventos de exceção do Spark relacionados à falha coletada do driver do Spark e de diferentes operadores distribuídos. Esses eventos ajudam a entender a propagação ordenada por tempo da exceção à medida que o código defeituoso é executado em tarefas, executores e estágios do Spark distribuídos pelos operadores do AWS Glue.
   - Números de linha: este fluxo de log identifica a linha 21, que fez a chamada para importar o módulo Python ausente que causou a falha; ele também identifica a linha 24, a chamada para a ação `collect()` do Spark, como a última linha executada em seu script.

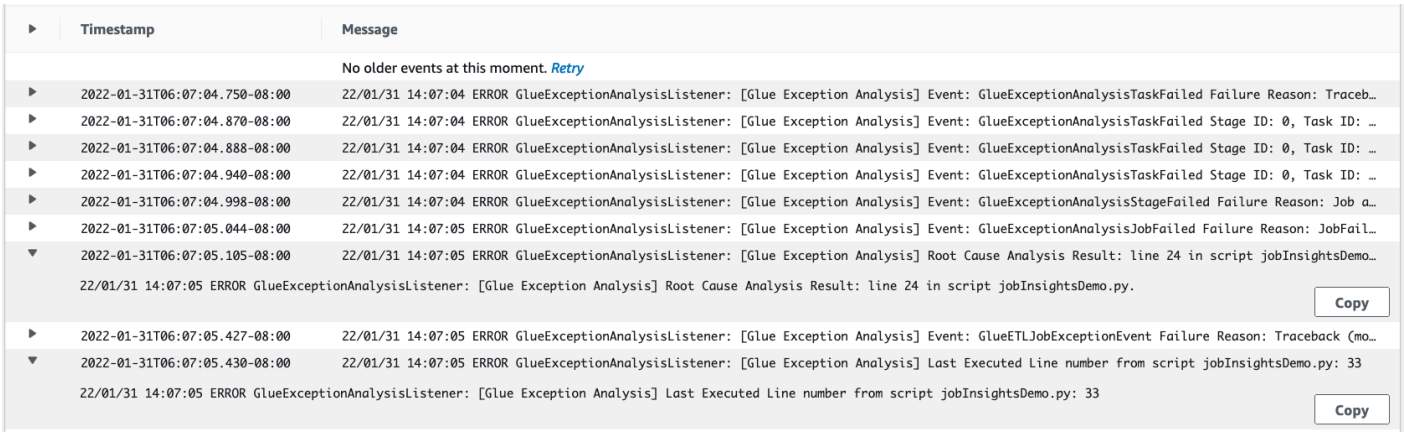

2. O fluxo de log do `job-insights-rule-driver`:

   - Causa raiz e recomendação: além do número da linha e do número da última linha executada para a falha no script, esse fluxo de log mostra a análise da causa raiz e a recomendação para que você siga o doc do AWS Glue e configure os parâmetros de trabalho necessários para usar um módulo Python adicional em seu trabalho do AWS Glue.
   - Evento base: este fluxo de log também mostra o evento de exceção do Spark que foi avaliado com a regra definida pelo serviço para inferir a causa raiz e fornecer uma recomendação.

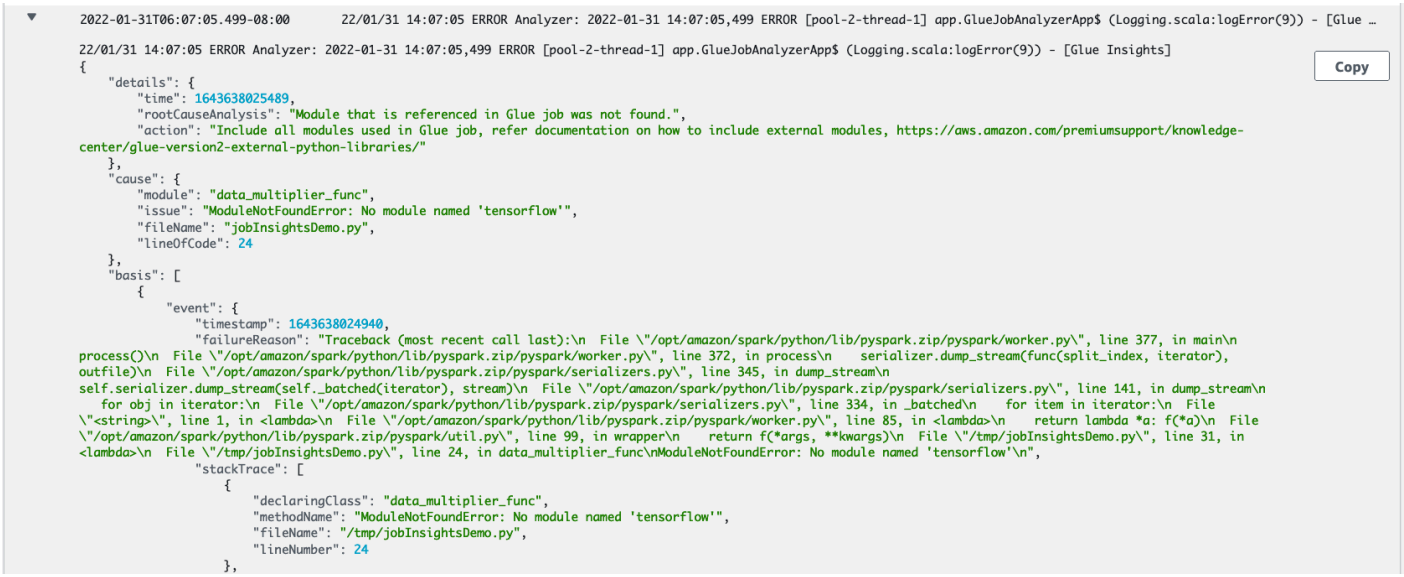

Monitorar o com o Amazon CloudWatch

É possível monitorar o AWS Glue usando o Amazon CloudWatch, que coleta e processa dados brutos do AWS Glue e os transforma em métricas legíveis quase em tempo real. Essas estatísticas são registradas por um período de duas semanas, para que você possa acessar informações históricas para obter uma perspectiva melhor sobre a performance do seu serviço ou da sua

aplicação Web. Por padrão, os dados de métricas do AWS Glue são enviados para o CloudWatch automaticamente. Para obter mais informações, consulte O que é o Amazon CloudWatch? no Manual do usuário do Amazon CloudWatch e em AWS Glue métricas.

Log contínuo

O AWS Glue também oferece suporte a registro contínuo em tempo real para tarefas do AWS Glue. Quando o registro em log contínuo está habilitado para um trabalho, é possível visualizar os logs em tempo real no console do AWS Glue ou no painel do console do CloudWatch. Para ter mais informações, consulte Registro em log para trabalhos do AWS Glue.

Métricas de observabilidade

Quando as Métricas de observabilidade do trabalho estão ativadas, Amazon CloudWatch métricas adicionais são geradas quando o trabalho é executado. Use métricas de observabilidade do AWS Glue para gerar insights sobre o que está acontecendo dentro do seu AWS Glue para melhorar a triagem e a análise de problemas.

Tópicos

- Monitorar o AWS Glue usando métricas do Amazon CloudWatch
- Configurar alarmes do Amazon CloudWatch nos perfis de trabalho do AWS Glue
- Registro em log para trabalhos do AWS Glue
- Monitoramento com métricas de observabilidade do AWS Glue

Monitorar o AWS Glue usando métricas do Amazon CloudWatch

É possível criar perfis e monitorar operações do AWS Glue usando o criador de perfis de tarefas do AWS Glue. Ele coleta e processa dados brutos de trabalhos do AWS Glue e os transforma em métricas legíveis, quase em tempo real, armazenadas no Amazon CloudWatch. Essas estatísticas são retidas e agregadas no CloudWatch, para que você possa acessar informações históricas e obter uma perspectiva melhor sobre como sua aplicação está se saindo.

> **Note**
>
> Você pode incorrer em cobranças adicionais ao habilitar que métricas de trabalho e métricas personalizadas do CloudWatch sejam criadas. Para obter mais informações, consulte Preço do Amazon CloudWatch.

Visão geral das métricas do AWS Glue

Quando você interage com o AWS Glue, ele envia métricas ao CloudWatch. É possível visualizar essas métricas usando o console do AWS Glue (o método de preferência), o painel do console do CloudWatch ou a AWS Command Line Interface (AWS CLI).

Para visualizar as métricas usando o painel do console do AWS Glue

Você pode visualizar gráficos de métricas detalhados ou resumidos de uma tarefa, ou gráficos detalhadas da execução de uma tarefa.

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Monitoramento de execução de trabalho.
3. Em Execuções de trabalhos, escolha Ações para interromper um trabalho que está em execução no momento, exibir um trabalho ou retroceder o marcador de trabalho.
4. Selecione um trabalho e escolha Exibir detalhes da execução para ver informações adicionais sobre a execução do trabalho.

Para exibir métricas usando o painel do console do CloudWatch

As métricas são agrupadas primeiro pelo namespace do serviço e, em seguida, por várias combinações de dimensão dentro de cada namespace.

1. Abra o console do CloudWatch em https://console.aws.amazon.com/cloudwatch/.
2. No painel de navegação, selecione Métricas.
3. Selecione o namespace Glue.

Para visualizar métricas usando a AWS CLI

- Em um prompt de comando, use o seguinte comando.

```
aws cloudwatch list-metrics --namespace Glue
```

O AWS Glue relata métricas para o CloudWatch a cada 30 segundos, e os painéis de métricas do CloudWatch são configurados para exibi-las a cada minuto. As métricas do AWS Glue representam valores do delta a partir dos valores relatados anteriormente. Quando apropriado, os painéis de

métricas agregam (somam) os valores de 30 segundos para obter um valor para o último minuto inteiro.

Comportamento de métricas do AWS Glue para trabalhos do Spark

As métricas do AWS Glue são ativadas na inicialização de um `GlueContext` em um script e geralmente são atualizadas somente no final de um trabalho do Apache Spark. Eles representam os valores agregados em todas as tarefas do Spark concluídas até agora.

No entanto, as métricas do Spark que o AWS Glue transfere para o CloudWatch são geralmente valores absolutos que representam o estado atual no momento em que elas são relatadas. O AWS Glue as informa ao CloudWatch a cada 30 segundos, e os painéis de métricas geralmente mostram a média em todos os pontos de dados recebidos no último minuto.

Os nomes de métricas do AWS Glue são todos precedidos por um dos seguintes tipos de prefixo:

- `glue.driver.`: métricas cujos nomes começam com esse prefixo representam métricas do AWS Glue agregadas em todos os executores no driver do Spark ou métricas do Spark correspondentes ao driver do Spark.
- `glue.`executorId`.`: o executorId é o número de um executor específico do Spark. Ele corresponde ao executores listados nos logs.
- `glue.ALL.` - Métricas cujos nomes começam com esse prefixo agregam valor a todos os executores do Spark.

AWS Glue métricas

O AWS Glue traça o perfil e envia as seguintes métricas para o CloudWatch a cada 30 segundos, e o painel do console do AWS Glue as relata uma vez por minuto:

Métrica	Descrição
`glue.driver.aggregate.bytesRead`	O número de bytes lidos de todas as fontes de dados por todas as tarefas do Spark concluídas em execução em todos os executores. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem).

Métrica	Descrição
	Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: bytes Pode ser usada para monitorar: • Bytes lidos. • Progresso do trabalho. • Fontes de dados JDBC. • Problemas com marcadores do trabalho. • Variação entre execuções do trabalho. Essa métrica pode ser usada da mesma maneira que a métrica `glue.ALL.s3.filesystem.read_bytes` , com a diferença de que essa métrica é atualizada no final de uma tarefa do Spark e também captura fontes de dados que não sejam do S3.

Métrica	Descrição
`glue.driver.aggregate.elapsedTime`	O tempo de ETL decorrido em milissegundos (não inclui os tempos de bootstrap do trabalho). Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: milissegundos Pode ser usado para determinar quanto tempo leva em média para uma execução de trabalho ser executada. Algumas maneiras de usar os dados: • Ajustar alarmes para retardatários. • Medir a variação entre execuções do trabalho.

Métrica	Descrição
`glue.driver.aggregate.numCompletedStages`	O número de etapas concluídas no trabalho. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: contagem Pode ser usada para monitorar: • Progresso do trabalho. • Cronograma por etapa de execução de trabalhos, quando correlacionado com outras métricas. Algumas maneiras de usar os dados: • Identificar etapas exigentes na execução de um trabalho. • Definir alarmes para picos correlacionados (etapas exigentes) em execuções de trabalhos.

Métrica	Descrição
`glue.driver.aggregate.numCompletedTasks`	O número de tarefas concluídas no trabalho. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: contagem Pode ser usada para monitorar: • Progresso do trabalho. • Paralelismo dentro de uma etapa.

Métrica	Descrição
`glue.driver.aggregate.numFailedTasks`	O número de tarefas que falharam. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: contagem Pode ser usada para monitorar: • Anormalidades de dados que fazem com que as tarefas de trabalhos falhem. • Anormalidades de cluster que fazem com que as tarefas de trabalhos falhem. • Anormalidades de script que fazem com que as tarefas de trabalhos falhem. Os dados podem ser usados para definir alarmes para falhas aumentadas que possam sugerir anormalidades em dados, cluster ou scripts.

Métrica	Descrição
`glue.driver.aggregate.numKilledTasks`	O número de tarefas encerradas. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: contagem Pode ser usada para monitorar: • Anormalidades na distorção de dados que resultam em exceções (OOMs) que encerram tarefas. • Anormalidades no script que resultam em exceções (OOMs) que encerram tarefas. Algumas maneiras de usar os dados: • Definir alarmes para falhas aumentadas indicando anormalidades dos dados. • Definir alarmes para falhas aumentadas indicando anormalidades do cluster. • Definir alarmes para falhas aumentadas indicando anormalidades dos scripts.

Métrica	Descrição
`glue.driver.aggregate.recordsRead`	O número de registros lidos de todas as fontes de dados por todas as tarefas do Spark concluídas em execução em todos os executores. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: contagem Pode ser usada para monitorar: • Registros lidos. • Progresso do trabalho. • Fontes de dados JDBC. • Problemas com marcadores do trabalho. • Distorções em execuções de trabalhos ao longo dos dias. Essa métrica pode ser usada da mesma maneira que a métrica `glue.ALL.s3.filesystem.read_bytes` , com a diferença de que essa métrica é atualizada no final de uma tarefa do Spark.

Métrica	Descrição
`glue.driver.aggregate.shuffleBytesWritten`	O número de bytes gravados por todos os executores para gerar a ordem aleatória de dados entre eles desde o relatório anterior (agregado pelo painel de métricas do AWS Glue como o número de bytes gravados para esse fim durante o minuto anterior). Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: bytes Pode ser usado para monitorar: ordem aleatória de dados em trabalhos (junções grandes, groupBy, repartição, união). Algumas maneiras de usar os dados: • Reparticionar ou descompactar arquivos de entrada grandes antes de processamento adicional. • Reparticionar dados de forma mais uniforme para evitar teclas de atalho. • Pré-filtrar dados antes de junções ou operações de groupBy.

Métrica	Descrição
`glue.driver.aggregate.shuffleLocalBytesRead`	O número de bytes lidos por todos os executores para gerar a ordem aleatória dos dados entre eles desde o relatório anterior (agregado pelo painel de métricas do AWS Glue como o número de bytes lidos para esse fim durante o minuto anterior). Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. Unidade: bytes Pode ser usado para monitorar: ordem aleatória de dados em trabalhos (junções grandes, groupBy, repartição, união). Algumas maneiras de usar os dados: • Reparticionar ou descompactar arquivos de entrada grandes antes de processamento adicional. • Reparticionar dados de forma mais uniforme usando teclas de atalho. • Pré-filtrar dados antes de junções ou operações de groupBy.

Métrica	Descrição
`glue.driver.BlockManager.disk.diskSpaceUsed_MB`	O número de megabytes de espaço em disco usado em todos os executores. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (medida). Estatística válida: média. Essa é uma métrica do Spark, relatada como um valor absoluto. Unidade: megabytes Pode ser usada para monitorar: • Espaço em disco usado para blocos que representam partições RDD armazenadas em cache. • Espaço em disco usado para blocos que representam saídas em ordem aleatória intermediárias. • Espaço em disco usado para blocos que representam emissões. Algumas maneiras de usar os dados: • Identificar falhas de trabalho pelo aumento do uso do disco. • Identificar partições grandes que resultam em despejo ou embaralhamento. • Aumentar a capacidade da DPU provisionada para corrigir esses problemas.

Métrica	Descrição
`glue.driver.ExecutorAllocationManager.executors.numberAllExecutors`	O número de executores ativamente executando trabalhos. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (medida). Estatística válida: média. Essa é uma métrica do Spark, relatada como um valor absoluto. Unidade: contagem Pode ser usada para monitorar: • Atividade do trabalho. • Executadores atrasados (com alguns executores em execução apenas) • Paralelismo atual no nível do executor. Algumas maneiras de usar os dados: • Reparticionar ou descompactar arquivos de entrada grandes de antemão, se o cluster estiver subutilizado. • Identificar atrasos na etapa ou na execução do trabalho por cenários atrasados. • • Compare com numberMaxNeededExecutors para entender o backlog para provisionamento de mais DPUs.

Métrica	Descrição
`glue.driver.ExecutorAllocationManager.executors.numberMaxNeededExecutors`	O número máximo de executores de trabalho (em execução ativa e pendentes) necessários para satisfazer a carga atual. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (medida). Estatísticas válidas: máximo. Essa é uma métrica do Spark, relatada como um valor absoluto. Unidade: contagem Pode ser usada para monitorar: • Atividade do trabalho. • Paralelismo atual no nível do executor e backlog de tarefas pendentes ainda não agendadas por causa de executores indisponíveis devido à capacidade da DPU ou executores encerrados/falhados. Algumas maneiras de usar os dados: • Identificar pendência/backlog da fila de agendamento. • Identificar atrasos na etapa ou na execução do trabalho por cenários atrasados. • Comparar com numberAllExecutors para entender o backlog para provisionamento de mais DPUs. • Aumentar a capacidade da DPU provisionada para corrigir o backlog pendente do executor.

Métrica	Descrição

`glue.driver.jvm.heap.usage`
 	
`glue.executorId.jvm.heap.usage`
 	
`glue.ALL.jvm.heap.usage`
	A fração de memória usada pelo heap da JVM para este driver (escala: 0 a 1) pelo driver, executor identificado por executorId ou TODOS os executore s.
	
	Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (medida).
	
	Estatística válida: média. Essa é uma métrica do Spark, relatada como um valor absoluto.
	
	Unidade: porcentagem
	
	Pode ser usada para monitorar:
	
	• Condições de falta de memória (OOM) do driver usando `glue.driver.jvm.heap.usage` .
	• Condições de falta de memória (OOM) do executor usando `glue.ALL.jvm.heap.usage` .
	
	Algumas maneiras de usar os dados:
	
	• Identificar os IDs e etapas do executor que consomem memória.
	• Identificar os IDs e etapas do executor atrasado.
	• Identificar uma condição de falta de memória (OOM) do driver.
	• Identificar uma condição de falta de memória (OOM) do executor e obter o ID de executor correspondente, para obter um rastreamento de pilha do log do executor.
	• Identificar arquivos ou partições que podem ter distorção de dados resultando em atrasos ou condições de falta de memória (OOMs).

Métrica	Descrição

`glue.driver.jvm.heap.used`
 	
`glue.executorId.jvm.heap.used`
 	
`glue.ALL.jvm.heap.used`
	O número de bytes de memória usados pelo heap da JVM para o driver, o executor identificado por executorId ou TODOS os executores.
	
	Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (medida).
	
	Estatística válida: média. Essa é uma métrica do Spark, relatada como um valor absoluto.
	
	Unidade: bytes
	
	Pode ser usada para monitorar:
	
	• Condições de falta de memória (OOM) do driver.
	• Condições de falta de memória (OOM) do executor.
	
	Algumas maneiras de usar os dados:
	
	• Identificar os IDs e etapas do executor que consomem memória.
	• Identificar os IDs e etapas do executor atrasado.
	• Identificar uma condição de falta de memória (OOM) do driver.
	• Identificar uma condição de falta de memória (OOM) do executor e obter o ID de executor correspondente, para obter um rastreamento de pilha do log do executor.
	• Identificar arquivos ou partições que podem ter distorção de dados resultando em atrasos ou condições de falta de memória (OOMs).

Métrica	Descrição

`glue.driver.s3.filesystem.read_bytes`
 	
`glue.executorId.s3.filesystem.read_bytes`
 	
`glue.ALL.s3.filesystem.read_bytes`
	O número de bytes lidos do Amazon S3 pelo driver, um executor identificado por executorId ou TODOS os executores desde o relatório anterior (agregado pelo painel de métricas do AWS Glue como o número de bytes lidos durante o minuto anterior).
	
	Dimensões válidas: `JobName`, `JobRunId` e `Type` (medida).
	
	Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. A área sob a curva no painel de métricas do AWS Glue pode ser usada para comparar visualmente os bytes lidos por duas execuções de trabalho diferentes.
	
	Unidade: Bytes.
	
	Pode ser usada para monitorar:
	
	• Movimentação de dados de ETL.
	• Progresso do trabalho.
	• Problemas com marcadores de trabalhos (dados processados, reprocessados e ignorados).
	• Comparação de leituras com a taxa de ingestão de fontes de dados externas.
	• Variação entre execuções do trabalho.
	
	Os dados resultantes podem ser usados para:
	
	• Planejar a capacidade da DPU.
	• Configurar alarmes para grandes picos ou quedas de dados lidos para execuções e etapas de trabalhos.

Métrica	Descrição

`glue.driver.s3.filesystem.write_bytes`
 	
`glue.executorId.s3.filesystem.write_bytes`
 	
`glue.ALL.s3.filesystem.write_bytes`
	O número de bytes gravados no Amazon S3 pelo driver, um executor identificado por executorId ou TODOS os executores desde o relatório anterior (agregado pelo painel de métricas do AWS Glue como o número de bytes gravados durante o minuto anterior).
	
	Dimensões válidas: `JobName`, `JobRunId` e `Type` (medida).
	
	Estatística válida: SUM (SOMA). Essa métrica é um valor delta do último valor relatado, portanto, no painel de métricas do AWS Glue, uma estatística SUM (SOMA) é usada para agregação. A área sob a curva no painel de métricas do AWS Glue pode ser usada para comparar visualmente os bytes gravados por duas execuções de trabalho diferentes.
	
	Unidade: bytes
	
	Pode ser usada para monitorar:
	
	• Movimentação de dados de ETL.
	• Progresso do trabalho.
	• Problemas com marcadores de trabalhos (dados processados, reprocessados e ignorados).
	• Comparação de leituras com a taxa de ingestão de fontes de dados externas.
	• Variação entre execuções do trabalho.
	
	Algumas maneiras de usar os dados:
	
	• Planejar a capacidade da DPU.

Métrica	Descrição
	• Configurar alarmes para grandes picos ou quedas de dados lidos para execuções e etapas de trabalhos.
`glue.driver.streaming.numRecords`	O número de registros que são recebidos em um microlote. Essa métrica só está disponível para os trabalhos de transmissão do AWS Glue com o AWS Glue versão 2.0 e posterior. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatísticas válidas: soma , máximo, mínimo, média, porcentagem Unidade: contagem Pode ser usada para monitorar: • Registros lidos. • Progresso do trabalho.

Métrica	Descrição
`glue.driver.streaming.batchProcessingTimeInMs`	O tempo necessário para processar os lotes em milissegundos. Essa métrica só está disponível para os trabalhos de transmissão do AWS Glue com o AWS Glue versão 2.0 e posterior. Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (contagem). Estatísticas válidas: soma , máximo, mínimo, média, porcentagem Unidade: contagem Pode ser usada para monitorar: • Progresso do trabalho. • Performance do script.

Métrica	Descrição

`glue.driver.system.cpuSystemLoad`
 	
`glue.executorId.system.cpuSystemLoad`
 	
`glue.ALL.system.cpuSystemLoad`
	A fração de carga de sistema da CPU usada (escala: 0 a 1) pelo driver, um executor identificado por executorId ou TODOS os executores.
	
	Dimensões válidas: `JobName` (o nome do trabalho do AWS Glue), `JobRunId` (o ID de JobRun. ou `ALL`) e `Type` (medida).
	
	Estatística válida: média. Essa métrica é relatada como um valor absoluto.
	
	Unidade: porcentagem
	
	Pode ser usada para monitorar:
	
	• Carga de CPU do driver.
	• Carga de CPU do executor.
	• Detecção de executores ou etapas vinculados à CPU ou E/S em um trabalho.
	
	Algumas maneiras de usar os dados:
	
	• Planejar a capacidade da DPU junto com métricas de E/S (bytes de leitura/ordem aleatória de de bytes, paralelismo de tarefas) e a métrica de número máximo de executores necessários.
	• Identificar a relação entre vinculção à CPU e a E/S. Isso permite reparticionar e aumentar a capacidade provisionada para trabalhos de longa execução com conjuntos de dados divisíveis com menor utilização da CPU.

Dimensões para métricas do AWS Glue

As métricas do AWS Glue usam namespace do AWS Glue e fornecem métricas para as seguintes dimensões:

Dimensão	Descrição
`JobName`	Esta dimensão filtra as métricas de todas as execuções de trabalho de um trabalho do AWS Glue.
`JobRunId`	Esta dimensão filtra as métricas de um trabalho do AWS Glue específico executado por um ID JobRun ou `ALL`.
`Type`	Esta dimensão filtra as métricas por `count` (um número agregado) ou `gauge` (um valor em um determinado ponto no tempo).

Para mais informações, consulte o Guia do usuário do Amazon CloudWatch.

Configurar alarmes do Amazon CloudWatch nos perfis de trabalho do AWS Glue

As métricas do AWS Glue também estão disponíveis no Amazon CloudWatch. Você pode configurar alarmes em qualquer métrica do AWS Glue para tarefas agendadas.

Alguns cenários comuns para a configuração de alarmes são os seguintes:

- Trabalhos sem memória (OOM): defina um alarme quando o uso de memória exceder a média normal para o driver ou um executor para um trabalho do AWS Glue.
- Executores difíceis: defina um alarme quando o número de executores cair abaixo de um determinado limite por um grande período em um trabalho do AWS Glue.
- Backlog ou reprocessamento de dados: compare as métricas de trabalhos individuais em um fluxo de trabalho usando uma expressão matemática do CloudWatch. Em seguida, você pode acionar um alarme no valor da expressão resultante (como a proporção de bytes gravados por um trabalho e bytes lidos por um trabalho seguinte).

Para obter instruções detalhadas sobre como definir alarmes, consulte Criar ou editar um alarme do CloudWatch no Manual do usuário do Amazon CloudWatch Events.

Para cenários de monitoramento e depuração usando o CloudWatch, consulte Monitoramento e depuração de trabalho.

Registro em log para trabalhos do AWS Glue

No AWS Glue 5.0, todos os trabalhos têm capacidades de registro em log em tempo real. Além disso, você pode especificar opções personalizadas de configuração para adaptar o comportamento de registro em log. Essas opções incluem definir o nome do grupo de logs do Amazon CloudWatch, o prefixo do fluxo de logs do Amazon CloudWatch (que precederá o ID de execução de trabalho do AWS Glue e o ID do driver/executor), e o padrão de conversão de logs para mensagens de log. Essas configurações permitem agregar logs em grupos personalizados de logs do Amazon CloudWatch com diferentes políticas de expiração. Além disso, você pode analisar os logs de modo mais eficaz usando prefixos de fluxo de logs e padrões de conversão personalizados. Esse nível de personalização permite que você otimize o gerenciamento e a análise de logs de acordo com seus requisitos específicos.

Comportamento de registro em log no AWS Glue 5.0

Por padrão, os logs do sistema, os logs do daemon do Spark e os logs do AWS Glue Logger do usuário são gravados no grupo de logs `/aws-glue/jobs/error` no Amazon CloudWatch. Por outro lado, os logs stdout (saída padrão) e stderr (erro padrão) do usuário são gravados no grupo de logs `/aws-glue/jobs/output` por padrão.

Logs personalizados

Você pode personalizar o grupo de logs padrão e os prefixos do fluxo de logs usando os seguintes argumentos de trabalho:

- `--custom-logGroup-prefix`: permite que você especifique um prefixo personalizado para os grupos de logs `/aws-glue/jobs/error` e `/aws-glue/jobs/output`. Se você fornecer um prefixo personalizado, os nomes dos grupos de logs estarão no seguinte formato:
  - `/aws-glue/jobs/error` será *`<customer prefix>`*`/error`
  - `/aws-glue/jobs/output` será *`<customer prefix>`*`/output`
- `--custom-logStream-prefix`: permite que você especifique um prefixo personalizado para os nomes do fluxo de logs nos grupos de logs. Se você fornecer um prefixo personalizado, os nomes dos fluxos de logs estarão no seguinte formato:
  - `jobrunid-driver` será *`<customer log stream>`*`-driver`
  - `jobrunid-executorNum` será *`<customer log stream>`*`-executorNum`

As regras de validação e as limitações para prefixos personalizados:

- O nome completo do fluxo de logs precisa ter de 1 a 512 caracteres.
- O prefixo personalizado é restrito a 400 caracteres.
- O prefixo personalizado precisa corresponder ao padrão de expressão regular “[^:*]*” (os caracteres especiais permitidos são “_”, “-” e “/”).

Registrar em log mensagens específicas da aplicação usando o registrador de script personalizado

É possível usar o registrador do AWS Glue para registrar qualquer mensagem específica do aplicativo no script que foi enviado em tempo real ao stream de log do driver.

O exemplo a seguir mostra um 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")
```

O exemplo a seguir mostra um 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")
  }
}
```

Habilitar a barra de progresso para exibir o progresso do trabalho

O AWS Glue fornece uma barra de progresso em tempo real no stream de log `JOB_RUN_ID-progress-bar` para verificar o status de execução da tarefa do AWS Glue. No momento, ele

oferece suporte somente a tarefas que inicializam o `glueContext`. Se você executar uma tarefa pura do Spark sem inicializar o `glueContext`, a barra de progresso do AWS Glue não será exibida.

A barra de progresso mostra a atualização de progresso a seguir a cada 5 segundos.

```
Stage Number (Stage Name): > (numCompletedTasks + numActiveTasks) /
 totalNumOfTasksInThisStage]
```

Configuração de segurança com registro em log do Amazon CloudWatch

Quando uma configuração de segurança é habilitada para logs do Amazon CloudWatch, o AWS Glue cria grupos de logs com padrões específicos de nomenclatura que incorporam o nome da configuração de segurança.

Nomenclatura de grupos de logs com configuração de segurança

Os grupos de log padrão e personalizado serão os seguintes:

- Grupo de logs padrão de erros: `/aws-glue/jobs/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/error`
- Grupo de logs padrão de saída: `/aws-glue/jobs/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/output`
- Grupo de logs personalizado de erros (AWS Glue 5.0): *`custom-log-group-prefix`*`/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/error`
- Grupo de logs personalizado de saída (AWS Glue 5.0): *`custom-log-group-prefix`*`/`*`Security-Configuration-Name`*`-role/`*`glue-job-role`*`/output`

Permissões obrigatórias do IAM

Se você habilitar uma configuração de segurança com o Amazon CloudWatch Logs, será necessário adicionar a permissão `logs:AssociateKmsKey` às permissões do seu perfil do IAM. Se essa permissão não for incluída, o registro em log contínuo será desabilitado.

Além disso, para configurar a criptografia do Amazon CloudWatch Logs, siga as instruções em Criptografar dados de log no Amazon CloudWatch Logs usando o AWS Key Management Service no Guia do usuário do Amazon Amazon CloudWatch Logs.

Informações adicionais

Para obter mais informações sobre como criar configurações de segurança, consulte Gerenciar configurações de segurança no console do AWS Glue.

Tópicos

- Habilitar o registro contínuo em log para trabalhos do AWS Glue 4.0 e versões anteriores
- Visualizar logs para trabalhos do AWS Glue

Habilitar o registro contínuo em log para trabalhos do AWS Glue 4.0 e versões anteriores

> **Note**
>
> No AWS Glue 4.0 e versões anteriores, o registro contínuo em log era um recurso disponível. No entanto, com o lançamento do AWS Glue 5.0, todos os trabalhos têm capacidade de registro em log em tempo real. Para obter mais detalhes sobre as capacidades de registro em log e as opções de configuração no AWS Glue 5.0, consulte Registro contínuo para trabalhos do AWS Glue.

É possível habilitar o registro contínuo usando o console do AWS Glue ou por meio da AWS Command Line Interface (AWS CLI).

É possível habilitar o registro em log contínuo ao criar um trabalho ou editar um trabalho existente ou habilitá-lo via AWS CLI.

Também é possível especificar opções de configuração personalizadas, como o nome do grupo de logs do Amazon CloudWatch, o prefixo da transmissão de logs do CloudWatch antes do ID de driver/ID de executor da execução de trabalho do AWS Glue e o padrão de conversão de logs para mensagens de log. Essas configurações ajudam a definir logs agregados em grupos de logs personalizados do CloudWatch com diferentes políticas de expiração e a analisá-los em mais detalhes com prefixos de fluxo de logs e padrões de conversões personalizados.

Tópicos

- Como usar o AWS Management Console
- Registrar em log mensagens específicas da aplicação usando o registrador de script personalizado
- Habilitar a barra de progresso para exibir o progresso do trabalho

- Configuração de segurança com registro contínuo

Como usar o AWS Management Console

Siga estas etapas para usar o console para habilitar o registro contínuo ao criar ou editar uma tarefa do AWS Glue.

Para criar uma tarefa do AWS Glue com registro contínuo

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Trabalhos de ETL.
3. Escolha ETL visual.
4. Na guia Detalhes do trabalho, expanda a seção Propriedades avançadas.
5. Em Registro em log contínuo, selecione Ativar logs no CloudWatch.

Para habilitar o registro contínuo para um tarefa existente do AWS Glue

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Tarefas.
3. Escolha uma tarefa existente na lista Jobs (Tarefas).
4. Selecione Action (Ação), Edit job (Editar tarefa).
5. Na guia Detalhes do trabalho, expanda a seção Propriedades avançadas.
6. Em Registro em log contínuo, selecione Ativar logs no CloudWatch.

Usar o AWS CLI

Para habilitar o registro contínuo, transmita parâmetros de tarefa para uma tarefa do AWS Glue. Transmita os parâmetros de trabalho especiais a seguir semelhantes a outros parâmetros de trabalho do AWS Glue. Para obter mais informações, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.

```
'--enable-continuous-cloudwatch-log': 'true'
```

É possível especificar um nome de grupo de logs personalizado do Amazon CloudWatch. Se não for especificado, o nome do grupo de logs padrão será `/aws-glue/jobs/logs-v2`.

```
'--continuous-log-logGroup': 'custom_log_group_name'
```

É possível especificar um prefixo de transmissão de logs personalizado do Amazon CloudWatch. Se não for especificado, o prefixo do fluxo de logs padrão será o ID de execução do trabalho.

```
'--continuous-log-logStreamPrefix': 'custom_log_stream_prefix'
```

É possível especificar um padrão contínuo e personalizado de conversão de logs. Se não for especificado, o padrão de conversão padrão será `%d{yy/MM/dd HH:mm:ss} %p %c{1}: %m%n`. Observe que o padrão de conversão só se aplica a logs de driver e logs de executor. Isso não afeta a barra de progresso do AWS Glue.

```
'--continuous-log-conversionPattern': 'custom_log_conversion_pattern'
```

Registrar em log mensagens específicas da aplicação usando o registrador de script personalizado

É possível usar o registrador do AWS Glue para registrar qualquer mensagem específica do aplicativo no script que foi enviado em tempo real ao stream de log do driver.

O exemplo a seguir mostra um 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")
```

O exemplo a seguir mostra um 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")
  }
}
```

Habilitar a barra de progresso para exibir o progresso do trabalho

O AWS Glue fornece uma barra de progresso em tempo real no stream de log `JOB_RUN_ID-progress-bar` para verificar o status de execução da tarefa do AWS Glue. No momento, ele oferece suporte somente a tarefas que inicializam o `glueContext`. Se você executar uma tarefa pura do Spark sem inicializar o `glueContext`, a barra de progresso do AWS Glue não será exibida.

A barra de progresso mostra a atualização de progresso a seguir a cada 5 segundos.

```
Stage Number (Stage Name): > (numCompletedTasks + numActiveTasks) /
 totalNumOfTasksInThisStage]
```

Configuração de segurança com registro contínuo

Se uma configuração de segurança estiver habilitada para logs do CloudWatch, o AWS Glue criará um grupo de logs chamado da seguinte forma para logs contínuos:

```
<Log-Group-Name>-<Security-Configuration-Name>
```

Os grupos de log padrão e personalizado serão os seguintes:

- O grupo de logs contínuos padrão será `/aws-glue/jobs/error-`*`<Security-Configuration-Name>`*
- O grupo de logs contínuos personalizado será *`<custom-log-group-name>`*`-`*`<Security-Configuration-Name>`*

É necessário adicionar `logs:AssociateKmsKey` a suas permissões de função do IAM, se você habilitar uma configuração de segurança com o CloudWatch Logs. Se essa permissão não for incluída, o registro em log contínuo será desabilitado. Além disso, para configurar a criptografia do CloudWatch Logs, siga as instruções em Criptografar dados de log no CloudWatch Logs usando o AWS Key Management Service no Manual do usuário do Amazon CloudWatch Logs.

Para obter mais informações sobre como criar configurações de segurança, consulte Gerenciar configurações de segurança no console do AWS Glue.

> **Note**
>
> Você poderá incorrer em cobranças adicionais ser habilitar o registro em log e houver a criação eventos de log adicionais do CloudWatch. Para obter mais informações, consulte Preço do Amazon CloudWatch.

Visualizar logs para trabalhos do AWS Glue

É possível visualizar logs em tempo real usando o console do AWS Glue ou o console do Amazon CloudWatch.

Para visualizar logs em tempo real usando o painel do console do AWS Glue

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Tarefas.
3. Adicione ou inicie uma tarefa existente. Selecione Action (Ação), Run job (Executar tarefa).

   Ao começar a executar uma tarefa, você navega até uma página que contém informações sobre a tarefa em execução:

   - A guia Logs mostra os logs do aplicativo agregados mais antigos.
   - A guia Logs mostra uma barra de progresso em tempo real quando o trabalho está sendo executado com o `glueContext` inicializado.
   - A guia Logs também contém os Logs de driver, que capturam logs de driver do Apache Spark em tempo real, além de logs de aplicativo do script registrado usando o registrador de aplicação do AWS Glue quando a tarefa está em execução.
4. Para tarefas mais antigas, também é possível visualizar logs em tempo real na exibição Job History (Histórico de tarefas) selecionando Logs. Essa ação leva você até o console do CloudWatch, que mostra todas as transmissões de log da barra de progresso, do executor e do driver do Spark para essa execução de trabalho.

Para visualizar logs em tempo real usando o painel do console do CloudWatch

1. Abra o console do CloudWatch, em https://console.aws.amazon.com/cloudwatch/.
2. No painel de navegação, selecione Log.

3. Selecione o grupo de logs /aws-glue/jobs/error/.
4. Na caixa Filter (Filtro), cole o ID da execução da tarefa.

   É possível visualizar os logs de driver, logs de executor e a barra de progresso (se estiver usando o Standard filter (Filtro padrão)).

Monitoramento com métricas de observabilidade do AWS Glue

> **Note**
>
> As métricas de observabilidade do AWS Glue estão disponíveis no AWS Glue 4.0 e versões posteriores.

Use métricas de observabilidade do AWS Glue para gerar insights sobre o que está acontecendo dentro do seu AWS Glue para trabalhos do Apache Sparks para melhorar a triagem e a análise de problemas. As métricas de observabilidade são visualizadas por meio de painéis do Amazon CloudWatch e podem ser usadas para ajudar a realizar a análise da causa raiz de erros e para diagnosticar gargalos de performance. É possível reduzir o tempo gasto na depuração de problemas em escala para que você possa se concentrar em resolver problemas com mais rapidez e eficiência.

A observabilidade do AWS Glue fornece métricas do Amazon CloudWatch categorizadas nos quatro grupos a seguir:

- Confiabilidade (ou seja, classes de erros): identifique facilmente os motivos de falha mais comuns em um determinado intervalo de tempo que você talvez queira resolver.
- Performance (ou seja, assimetria): identifique um gargalo de performance e aplique técnicas de ajuste. Por exemplo, quando você enfrenta uma degradação de performance causada pela assimetria de um trabalho, convém ativar a execução adaptativa de consultas do Spark e ajustar o limite de junção assimétrica.
- Throughput (ou seja, throughput por fonte/coletor): monitore as tendências de leituras e gravações de dados. Você também pode configurar alarmes do Amazon CloudWatch para anomalias.
- Utilização de recursos (ou seja, operadores, memória e utilização de disco): encontre de forma eficiente os trabalhos com baixa utilização de capacidade. Talvez você queira habilitar o ajuste de escala automático do AWS Glue para esses trabalhos.

Conceitos básicos das métricas de observabilidade do AWS Glue

> **Note**
>
> As métricas novas são habilitadas por padrão no console do AWS Glue Studio.

Para configurar métricas de observabilidade no AWS Glue Studio:

1. Faça login no console do AWS Glue e escolha Trabalhos ETL no menu do console.
2. Escolha um trabalho clicando no nome do trabalho na seção Seus trabalhos.
3. Escolha a guia Job details (Detalhes do trabalho).
4. Role até a parte inferior e escolha Propriedades avançadas e, em seguida, Métricas de observabilidade do trabalho.

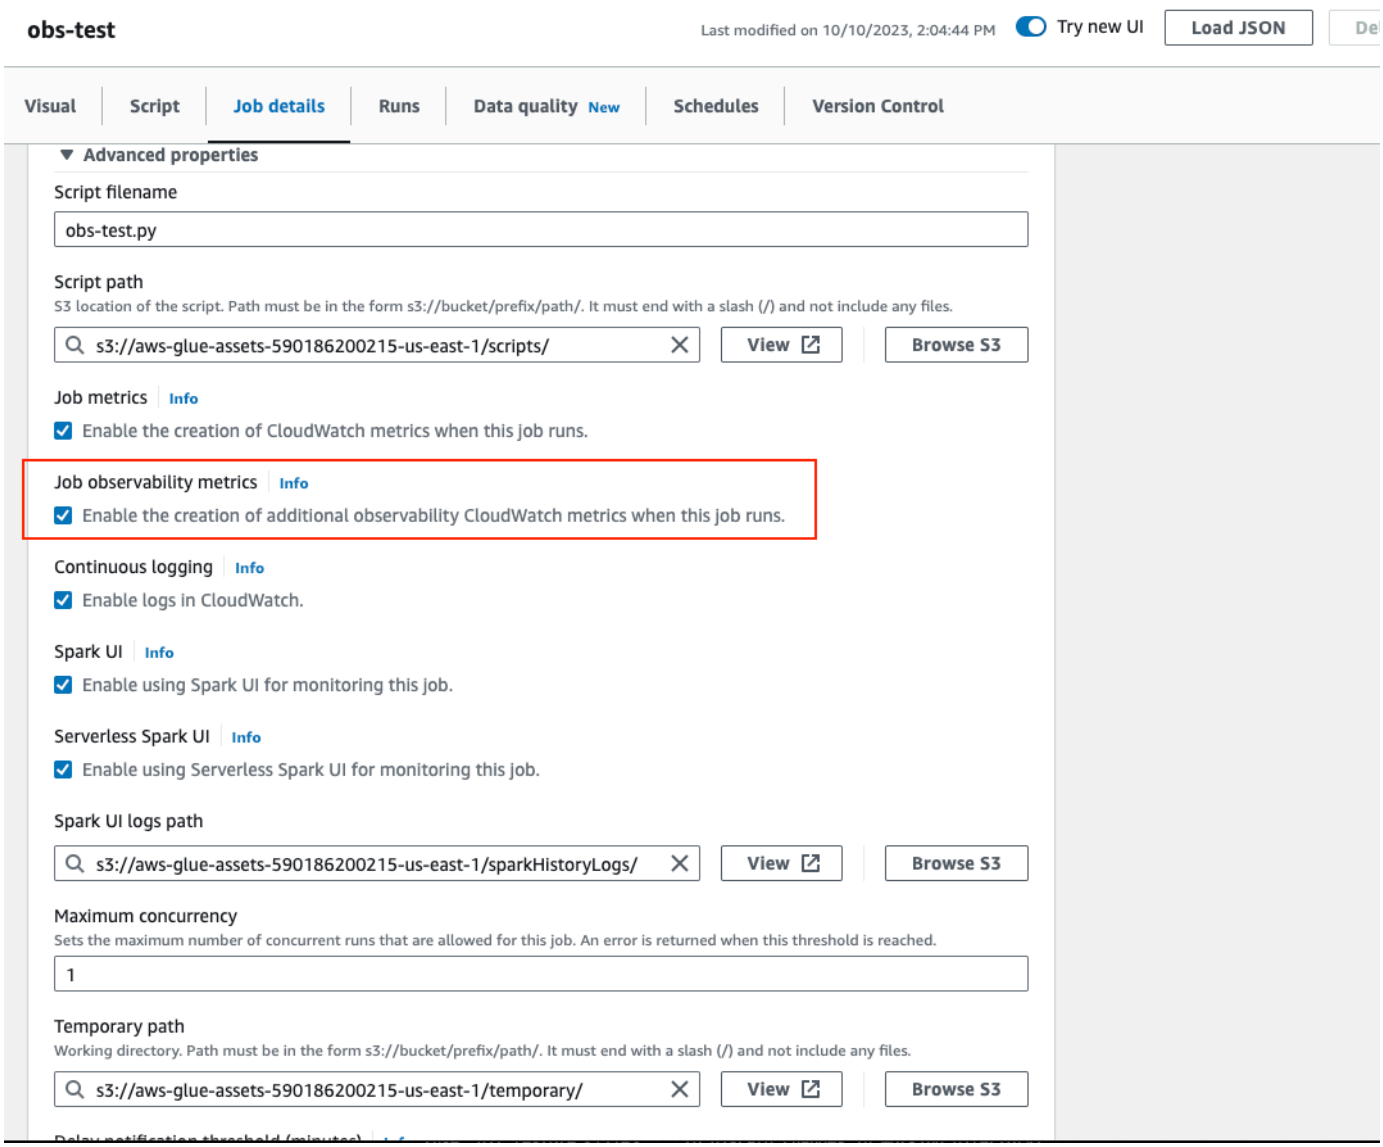

Para habilitar as métricas de observabilidade do AWS Glue usando a AWS CLI:

- Adicione ao mapa `--default-arguments` o seguinte par chave-valor no arquivo JSON de entrada:

```
--enable-observability-metrics, true
```

Usar a observabilidade do AWS Glue

Como as métricas de observabilidade do AWS Glue são fornecidas por meio do Amazon CloudWatch, você pode usar o console do Amazon CloudWatch, a AWS CLI, o SDK ou a API para consultar os pontos de dados das métricas de observabilidade. Consulte Como usar a observabilidade do Glue para monitorar a utilização de recursos para reduzir custos para ver um exemplo de caso de uso de métricas de observabilidade do AWS Glue.

Usar a observabilidade do AWS Glue no console do Amazon CloudWatch

Para consultar e visualizar métricas no console do Amazon CloudWatch:

1. Abra o console do Amazon CloudWatch e escolha Todas as métricas.
2. Em Namespaces personalizados, escolha AWS Glue.
3. Escolha Métricas de observabilidade do trabalho, Métricas de observabilidade por fonte ou Métricas de observabilidade por coletor.
4. Pesquise o nome da métrica específica, o nome do trabalho, o ID da execução do trabalho e selecione-os.
5. Na guia Métricas representadas graficamente, configure a estatística, o período e outras opções preferidas.

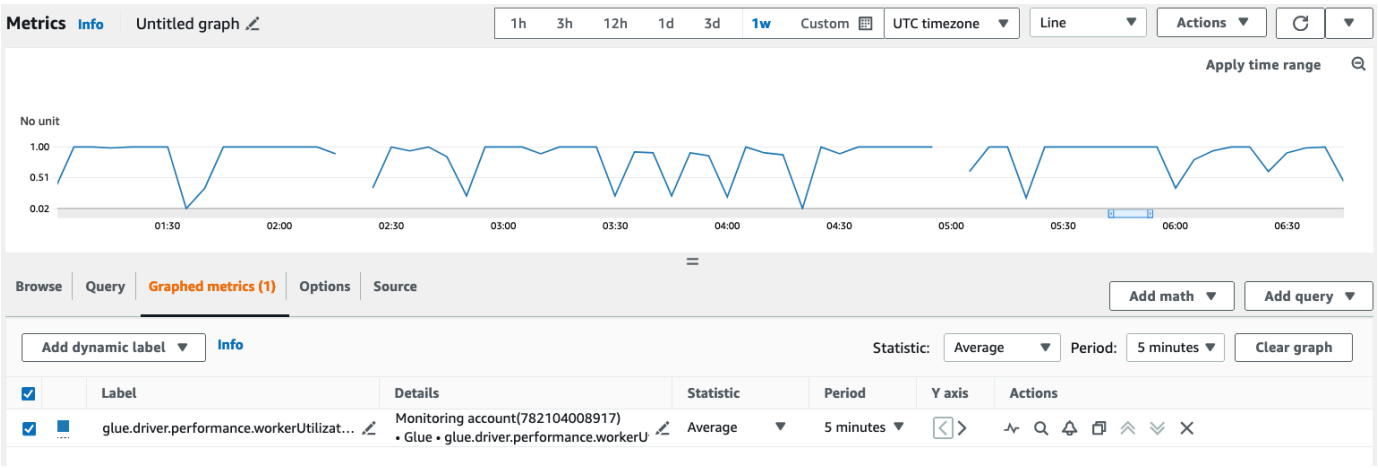

Para consultar uma métrica de observabilidade usando a AWS CLI:

1. Crie um arquivo JSON de definição métrica e substitua `your-Glue-job-name` e `your-Glue-job-run-id` pelos seus.

```
$ 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. Execute o comando `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": []
}
```

Métricas de observabilidade

A observabilidade do AWS Glue traça o perfil e envia as seguintes métricas do Amazon CloudWatch a cada 30 segundos. Algumas dessas métricas podem ser visíveis na página de monitoramento de execução de trabalhos do AWS Glue Studio.

Métrica	Descrição	Categoria
glue.driver.skewness.stage	Categoria métrica: job_performance Distorção da assimetria dos estágios do Spark: essa métrica captura a assimetria da execução, que pode ser causada pela assimetria dos dados de entrada ou por uma transformação (p. ex., junção assimétrica). Os valores dessa métrica estão na faixa de [0, infinito[, em que 0 significa que a razão entre o tempo máximo e a mediana de execução das tarefas, entre todas as tarefas no estágio, é menor que um determinado	job_performance

Métrica	Descrição	Categoria
	fator de distorção do estágio. O fator de assimetria de estágio padrão é `5` e pode ser sobrescrito por meio do spark conf: spark.metrics.conf .driver.source.glue.jobPerf ormance.skewnessFactor Um valor de assimetria de estágio de 1 significa que a proporção é o dobro do fator de assimetria do estágio. O valor de assimetria do estágio é atualizado a cada 30 segundos para refletir a assimetria atual. O valor no final do estágio reflete a assimetria do estágio final. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e observabilityGroup (job_performance) Estatísticas válidas: média, máximo, mínimo, porcentag em Unidade: Contagem	

Métrica	Descrição	Categoria
glue.driver.skewness.job	Categoria métrica: job_performance A assimetria do trabalho é a média ponderada da assimetria do estágio do trabalho. A média ponderada dá mais peso aos estágios que demoram mais para serem executados. Isso é para evitar situações extremas quando um estágio muito assimétrico está realmente funcionando por um tempo muito curto em relação a outros estágios (e, portanto, sua assimetria não é significativa para o desempenho geral do trabalho e não vale a pena tentar resolver sua assimetria). Essa métrica é atualizada após a conclusão de cada estágio e, portanto, o último valor reflete a assimetria geral real do trabalho. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e observabilityGroup (job_performance)	job_performance

Métrica	Descrição	Categoria
	Estatísticas válidas: média, máximo, mínimo, porcentagem Unidade: Contagem	
glue.succeed.ALL	Categoria métrica: erro Número total de execuções de trabalhos com êxito para completar o quadro das categorias de falhas Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (count) e ObservabilityGroup (error) Estatística válida: SUM Unidade: Contagem	erro

Métrica	Descrição	Categoria
glue.error.ALL	Categoria métrica: erro Número total de erros de execução de trabalho para completar o quadro das categorias de falhas Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (count) e ObservabilityGroup (error) Estatística válida: SUM Unidade: Contagem	erro

Métrica	Descrição	Categoria
glue.error.[error category]	Categoria métrica: erro Na verdade, este é um conjunto de métricas que são atualizadas somente quando a execução de um trabalho falha. A categoriz ação de erros ajuda na triagem e na depuração . Quando a execução de uma tarefa falha, o erro que causa a falha é categoriz ado e a métrica da categoria de erro correspondente é definida como 1. Isso ajuda a realizar análises de falhas ao longo do tempo, bem como a análise geral de erros de trabalhos para identific ar as categorias de falhas mais comuns e começar a resolvê-las. O AWS Glue tem 28 categorias de erro, incluindo as categorias de erro OUT_OF_MEMORY (driver e executor), PERMISSION, SYNTAX e THROTTLING. As categorias de erro também incluem as categorias de erro COMPILATION, LAUNCH e TIMEOUT. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de	erro

Métrica	Descrição	Categoria
	JobRun. ou ALL), Type (count) e ObservabilityGroup (error) Estatística válida: SUM Unidade: Contagem	
glue.driver.workerUtilization	Categoria métrica: resource_utilization A porcentagem dos trabalhadores alocados que são realmente usados. Se não for bom, o ajuste de escala automático pode ajudar. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatísticas válidas: média, máximo, mínimo, porcentagem Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.driver.memory.heap.[available | used]	Categoria métrica: resource_utilization A memória heap disponível/usado do driver durante a execução do trabalho. Isso ajuda a entender as tendências de uso da memória, especialmente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relacionadas à memória. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: bytes	resource_utilization

Métrica	Descrição	Categoria
glue.driver.memory.heap.used.percentage	Categoria métrica: resource_utilization A memória heap usada pelo driver (%) durante a execução do trabalho. Isso ajuda a entender as tendências de uso da memória, especialmente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relacionadas à memória. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.driver.memory.non-heap.[available | used]	Categoria métrica: resource_utilization A memória não heap disponível/usado do driver durante a execução do trabalho. Isso ajuda a entender as tendências de uso da memória, especialm ente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relacionadas à memória. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: bytes	resource_utilization

Métrica	Descrição	Categoria
glue.driver.memory.non-heap .used.percentage	Categoria métrica: resource_ utilization A memória não heap usada pelo driver (%) durante a execução do trabalho. Isso ajuda a entender as tendência s de uso da memória, especialmente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relaciona das à memória. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.driver.memory.total.[available | used]	Categoria métrica: resource_utilization A memória total do driver disponível/usada durante a execução do trabalho. Isso ajuda a entender as tendências de uso da memória, especialmente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relacionadas à memória. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: bytes	resource_utilization

Métrica	Descrição	Categoria
glue.driver.memory.total.used.percentage	Categoria métrica: resource_utilization A memória total usada pelo driver (%) durante a execução do trabalho. Isso ajuda a entender as tendências de uso da memória, especialmente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relacionadas à memória. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.ALL.memory.heap.[available | used]	Categoria métrica: resource_utilization A memória heap disponível/usada dos executores. ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: bytes	resource_utilization
glue.ALL.memory.heap.used.percentage	Categoria métrica: resource_utilization A memória heap usada dos executores (%). ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.ALL.memory.non-heap.[available | used]	Categoria métrica: resource_utilization A memória não heap disponível/usada dos executores. ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: bytes	resource_utilization
glue.ALL.memory.non-heap.used.percentage	Categoria métrica: resource_utilization A memória não heap usada (%) dos executores. ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.ALL.memory.total.[available | used]	Categoria métrica: resource_utilization A memória total disponível/usada dos executores. ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: bytes	resource_utilization
glue.ALL.memory.total.used.percentage	Categoria métrica: resource_utilization A memória total usada (%) dos executores. ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.driver.disk.[available_GB | used_GB]	Categoria métrica: resource_utilization O espaço em disco disponível/usado do driver durante a execução do trabalho. Isso ajuda a entender as tendências de uso do disco, especialmente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relacionadas à falta de espaço em disco. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: gigabytes	resource_utilization

Métrica	Descrição	Categoria
glue.driver.disk.used.percentage]	Categoria métrica: resource_utilization O espaço em disco disponível/usado do driver durante a execução do trabalho. Isso ajuda a entender as tendências de uso do disco, especialmente ao longo do tempo, o que pode ajudar a evitar possíveis falhas, além de depurar falhas relacionadas à falta de espaço em disco. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.ALL.disk.[available_GB | used_GB]	Categoria métrica: resource_utilization O espaço em disco disponível/usado dos executores. ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: gigabytes	resource_utilization
glue.ALL.disk.used.percentage	Categoria métrica: resource_utilization O espaço em disco disponível/usado/usado(%) dos executores. ALL significa todos os executores. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge) e ObservabilityGroup (resource_utilization) Estatística válida: média Unidade: porcentagem	resource_utilization

Métrica	Descrição	Categoria
glue.driver.bytesRead	Categoria métrica: throughput O número de bytes lidos por fonte de entrada nessa execução de trabalho, bem como para TODAS as fontes. Isso ajuda a entender o volume de dados e suas mudanças ao longo do tempo, o que ajuda a resolver problemas como assimetria de dados. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge), ObservabilityGroup (resource_utilization) e Source (local da fonte de dados) Estatística válida: média Unidade: bytes	throughput

Métrica	Descrição	Categoria
glue.driver.[recordsRead | filesRead]	Categoria métrica: throughput O número de registros/ arquivos lidos por fonte de entrada nessa execução de trabalho, bem como para TODAS as fontes. Isso ajuda a entender o volume de dados e suas mudanças ao longo do tempo, o que ajuda a resolver problemas como assimetria de dados. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge), ObservabilityGroup (resource_utilization) e Source (local da fonte de dados) Estatística válida: média Unidade: Contagem	throughput

Métrica	Descrição	Categoria
glue.driver.partitionsRead	Categoria métrica: throughput O número de partições lidas por fonte de entrada do Amazon S3 nessa execução de trabalho, bem como para TODAS as fontes. Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge), ObservabilityGroup (resource_utilization) e Source (local da fonte de dados) Estatística válida: média Unidade: Contagem	throughput

Métrica	Descrição	Categoria
glue.driver.bytesWrittten	Categoria métrica: throughput O número de bytes gravados por coletor de saída nessa execução de trabalho, bem como para TODOS os coletores. Isso ajuda a compreender o volume de dados e como ele evolui ao longo do tempo, o que ajuda a resolver problemas como a assimetria do processamento Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge), ObservabilityGroup (resource_utilization) e Source (local do coletor de dados) Estatística válida: média Unidade: bytes	throughput

Métrica	Descrição	Categoria
glue.driver.[recordsWritten | filesWritten]	Categoria métrica: throughput O número de registros/ arquivos gravados por coletor de saída nessa execução de trabalho, bem como para TODOS os coletores . Isso ajuda a compreend er o volume de dados e como ele evolui ao longo do tempo, o que ajuda a resolver problemas como a assimetria do processamento Dimensões válidas: JobName (o nome do trabalho do AWS Glue), JobRunId (a ID de JobRun. ou ALL), Type (gauge), ObservabilityGroup (resource_utilization) e Source (local do coletor de dados) Estatística válida: média Unidade: Contagem	throughput

Categorias de erros

Categorias de erros	Descrição
COMPILATION_ERROR	Os erros surgem durante a compilação do código Scala.

Categorias de erros	Descrição
CONNECTION_ERROR	Os erros surgem durante a conexão com um serviço/host remoto/serviço de banco de dados etc.
DISK_NO_SPACE_ERROR	Os erros surgem quando não há mais espaço em disco no driver/executor.
OUT_OF_MEMORY_ERROR	Os erros surgem quando não há mais espaço na memória do driver/executor.
IMPORT_ERROR	Os erros surgem ao importar dependências.
INVALID_ARGUMENT_ERROR	Erros surgem quando os argumentos de entrada são inválidos/ilegais.
PERMISSION_ERROR	Os erros surgem quando não há permissão para serviços, dados etc.
RESOURCE_NOT_FOUND_ERROR	Os erros surgem quando os dados, a localizaç ão etc. não existem.
QUERY_ERROR	Os erros surgem da execução da consulta do Spark SQL.
SYNTAX_ERROR	Os erros surgem quando há um erro de sintaxe no script.
THROTTLING_ERROR	Os erros surgem ao atingir a limitação de simultaneidade de serviços ou ao exceder a limitação de cotas de serviço.
DATA_LAKE_FRAMEWORK_ERROR	Os erros surgem de estruturas de data lake com suporte nativo do AWS Glue, como Hudi, Iceberg etc.
UNSUPPORTED_OPERATION_ERROR	Os erros surgem ao realizar uma operação não compatível.

Categorias de erros	Descrição
RESOURCES_ALREADY_EXISTS_ERROR	Os erros surgem quando um recurso a ser criado ou adicionado já existe.
GLUE_INTERNAL_SERVICE_ERROR	Os erros surgem quando há um problema de serviço interno do AWS Glue.
GLUE_OPERATION_TIMEOUT_ERROR	Os erros surgem quando uma operação do AWS Glue atinge o tempo limite.
GLUE_VALIDATION_ERROR	Os erros surgem quando um valor exigido não pôde ser validado para um trabalho do AWS Glue.
GLUE_JOB_BOOKMARK_VERSION_MISMATCH_ERROR	Os erros surgem quando o mesmo trabalho transcreve o mesmo bucket de origem e grava no mesmo destino ou em outro simultaneamente (simultaneidade >1)
LAUNCH_ERROR	Os erros surgem durante a fase de lançamento do trabalho do AWS Glue.
DYNAMODB_ERROR	Os erros genéricos surgem do serviço do Amazon DynamoDB.
GLUE_ERROR	Os erros genéricos surgem do serviço do AWS Glue.
LAKEFORMATION_ERROR	Os erros genéricos surgem do serviço do AWS Lake Formation.
REDSHIFT_ERROR	Os erros genéricos surgem do serviço do Amazon Redshift.
S3_ERROR	Os erros genéricos surgem do serviço do Amazon S3.
SYSTEM_EXIT_ERROR	Erro genérico de saída do sistema.

Categorias de erros	Descrição
TIMEOUT_ERROR	Os erros genéricos surgem quando o trabalho falha devido ao tempo limite da operação.
UNCLASSIFIED_SPARK_ERROR	Os erros genéricos surgem do Spark.
UNCLASSIFIED_ERROR	Categoria de erro padrão.

Limitações

> **Note**
>
> O `glueContext` deve ser inicializado para publicar as métricas.

Na Dimensão de origem, o valor é o caminho ou o nome da tabela do Amazon S3, dependendo do tipo de fonte. Além disso, se a origem for JDBC e a opção de consulta for usada, a string de consulta será definida na dimensão de origem. Se o valor tiver mais de 500 caracteres, ele será reduzido em 500 caracteres. Abaixo, estão as limitações do valor:

- Os caracteres não ASCII serão removidos.
- Se o nome da fonte não contiver nenhum caractere ASCII, ele será convertido para <non-ASCII input>.

Limitações e considerações sobre métricas de throughput

- O DataFrame e o DynamicFrame baseado em DataFrame (por exemplo, JDBC, leitura de parquet no Amazon S3) são compatíveis, no entanto, o DynamicFrame baseado em RDD (por exemplo, leitura de csv, json no Amazon S3 etc.) não é compatível. Tecnicamente, todas as leituras e gravações visíveis na UI do Spark são compatíveis.
- A métrica `recordsRead` será emitida se a fonte de dados for uma tabela de catálogo e o formato for JSON, CSV, text ou Iceberg.
- As métricas `glue.driver.throughput.recordsWritten`, `glue.driver.throughput.bytesWritten` e `glue.driver.throughput.filesWritten` não estão disponíveis nas tabelas JDBC e Iceberg.

- As métricas podem estar atrasadas. Se o trabalho for concluído em cerca de um minuto, talvez não haja métricas de throughput nas métricas do Amazon CloudWatch.

Monitoramento e depuração de trabalho

Você pode coletar métricas sobre trabalhos do AWS Glue e visualizá-las nos consoles do AWS Glue e do Amazon CloudWatch para identificar e corrigir problemas. A criação do perfil dos seus trabalhos do AWS Glue requer as seguintes etapas:

1. Habilitar métricas:

   a. Habilite a opção Job metrics (Métricas de trabalho) na definição do trabalho. Você pode habilitar a criação de perfil no console do AWS Glue ou como um parâmetro para o trabalho. Para obter mais informações, consulte Definir propriedades de trabalho para trabalhos do Spark ou Usar parâmetros de tarefa em tarefas do AWS Glue.

   b. Habilite a opção Métricas de observabilidade do AWS Glue na definição do trabalho. É possível habilitar a observabilidade no console do AWS Glue ou como parâmetro para o trabalho. Para ter mais informações, consulte Monitoramento com métricas de observabilidade do AWS Glue.

2. Confirme se o script do trabalho inicializa um `GlueContext`. Por exemplo, o snippet de script a seguir inicializa um `GlueContext` e mostra onde o código perfilado é colocado no script. Este formato geral é usado nos cenários de depuração a seguir.

```
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. Execute o trabalho.
4. Visualize as métricas:
   a. Visualize as métricas de trabalho no console do AWS Glue e identifique métricas anormais para o driver ou um executor.
   b. Verifique as métricas de observabilidade na página de monitoramento da execução de trabalhos, na página de detalhes da execução de trabalhos ou no Amazon CloudWatch. Para ter mais informações, consulte Monitoramento com métricas de observabilidade do AWS Glue.
5. Refine a causa raiz usando a métrica identificada.
6. Opcionalmente, confirme a causa raiz usando o fluxo de log do driver identificado ou executor do trabalho.

Casos de uso para métricas de observabilidade do AWS Glue

- Depurar exceções OOM e anomalias de trabalho
- Depurar estágios exigentes e tarefas de retardatário
- Monitorar o progresso de vários trabalhos
- Monitorar planejamento de capacidade de DPU
- Como usar a observabilidade do AWS Glue para monitorar a utilização de recursos para reduzir custos

Depurar exceções OOM e anomalias de trabalho

Você pode depurar exceções de memória insuficiente (OOM) e anomalias de trabalho no AWS Glue. As seções a seguir descrevem cenários para depuração de exceções de memória insuficiente do driver do Apache Spark ou um executor do Spark.

- Depurar uma exceção OOM do driver
- Depurar uma exceção OOM do executor

Depurar uma exceção OOM do driver

Nesse cenário, um trabalho do Spark está lendo um grande número de arquivos pequenos do Amazon Simple Storage Service (Amazon S3). Ele converte os arquivos no formato Apache Parquet e, em seguida, os grava no Amazon S3. O driver do Spark está sendo executado sem memória. A entrada de dados do Amazon S3 tem mais de 1 milhão de arquivos em diferentes partições do Amazon S3.

O código perfilado é assim:

```
data = spark.read.format("json").option("inferSchema", False).load("s3://input_path")
data.write.format("parquet").save(output_path)
```

Visualizar as métricas perfiladas no console do AWS Glue

O gráfico a seguir mostra o uso de memória como uma porcentagem para o driver e executores. Esse uso é representado como um ponto de dados cuja média é calculada com base nos valores relatados no último minuto. Você pode ver no perfil de memória do trabalho que a memória do driver ultrapassa o limite de 50% de uso rapidamente. Por outro lado, a média de uso de memória em todos os executores ainda é menos de 4%. Isso mostra claramente anomalia com a execução do driver nesse trabalho do Spark.

A execução do trabalho logo falha, e o seguinte erro é exibido na guia History (Histórico) no console do AWS Glue: Command Failed with Exit Code 1 (Falha do comando com código de saída 1). Essa string de erro significa que o trabalho falhou devido a um erro sistêmico, que neste caso é a falta de memória do driver.

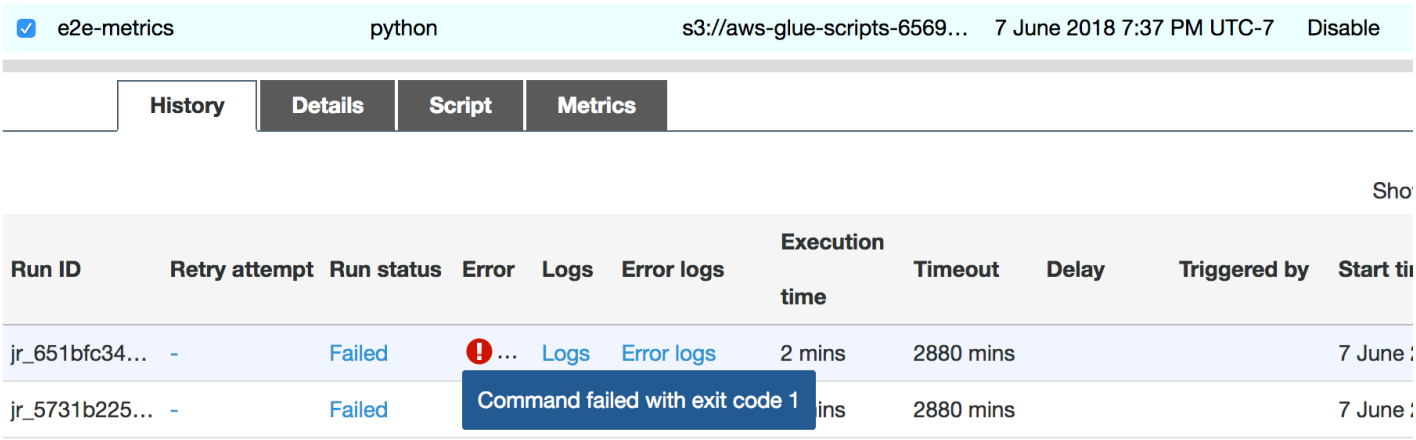

No console, escolha o link Error logs (Logs de erro) na guia History (Histórico) para confirmar a descoberta do CloudWatch Logs sobre a OOM do driver. Procure "**`Error`**" nos logs de erro do trabalho para confirmar que foi uma exceção OOM que falhou o trabalho:

```
# java.lang.OutOfMemoryError: Java heap space
# -XX:OnOutOfMemoryError="kill -9 %p"
```

```
# Executing /bin/sh -c "kill -9 12039"...
```

Na guia History (Histórico) do trabalho, escolha Logs. Você pode encontrar as seguintes evidências da execução do driver no CloudWatch Logs no início do trabalho. O driver do Spark tenta listar todos os arquivos em todos os diretórios, cria um `InMemoryFileIndex` e inicia uma tarefa por arquivo. Isso, por sua vez, resulta no driver do Spark precisar manter uma grande quantidade de estado na memória para rastrear todas as tarefas. Ele armazena em cache a lista completa de um grande número de arquivos para o índice na memória, o que resulta em um driver OOM.

Corrigir o processamento de vários arquivos usando agrupamento

Você pode corrigir o processamento de vários arquivos usando o recurso de agrupamento no AWS Glue. O agrupamento é habilitado automaticamente quando você usa quadros dinâmicos e quando o conjunto de dados de entrada tem um grande número de arquivos (mais de 50.000). Agrupar permite reunir vários arquivos em um grupo, e isso permite que uma tarefa processe todo o grupo em vez de um único arquivo. Como resultado, o driver do Spark armazena significativamente menos estado na memória para rastrear menos tarefas. Para obter mais informações sobre como habilitar manualmente o agrupamento para o seu conjunto de dados, consulte Ler arquivos de entrada em grupos maiores.

Para verificar o perfil de memória do trabalho do AWS Glue, crie o perfil do código a seguir com agrupamento habilitado:

```
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")
```

Você pode monitorar o perfil de memória e a movimentação de dados ETL no perfil de trabalho do AWS Glue.

O driver é executado abaixo do limite de 50% de uso de memória ao longo de toda a duração do trabalho do AWS Glue. Os executores transmitem os dados do Amazon S3, os processam e os gravam no Amazon S3. Como resultado, eles consomem menos de 5% de memória a qualquer momento.

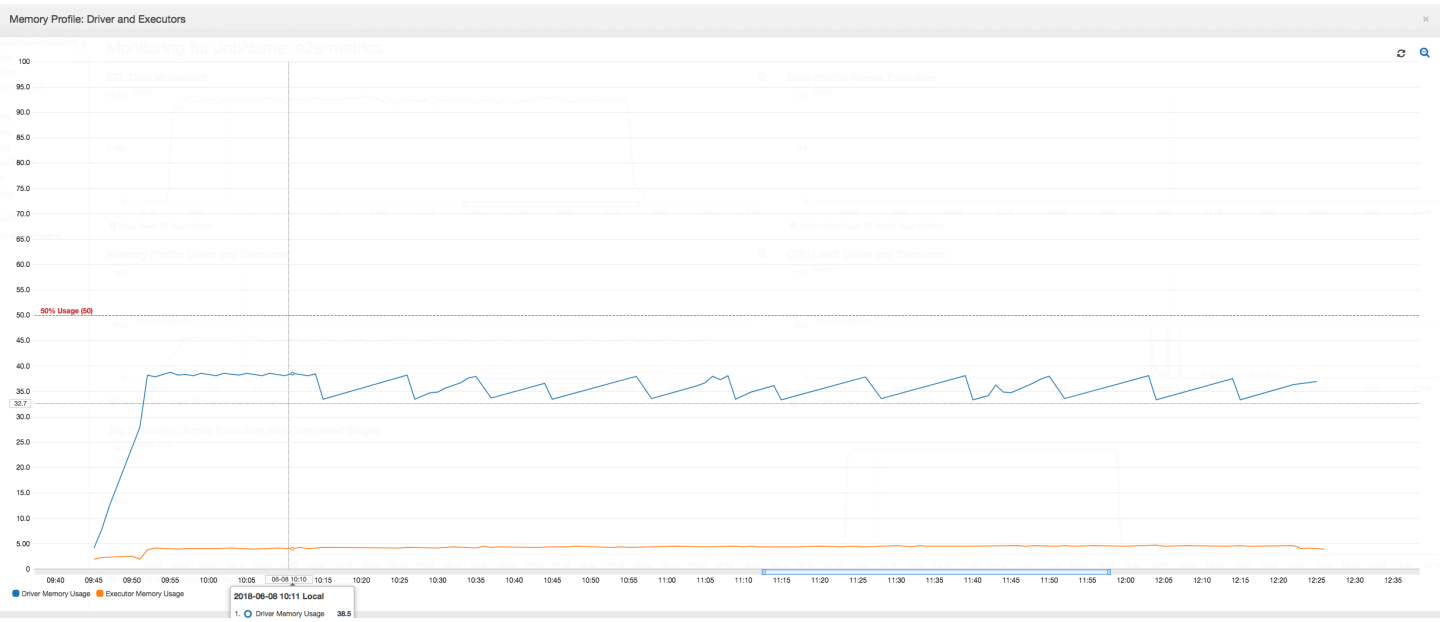

O perfil de movimentação de dados abaixo mostra o número total de bytes do Amazon S3 que são lidos e gravados no último minuto por todos os executores conforme o trabalho progride. Ambos seguem um padrão semelhante conforme os dados são transmitidos em todos os executores. O trabalho termina o processamento de um milhão de arquivos em menos de três horas.

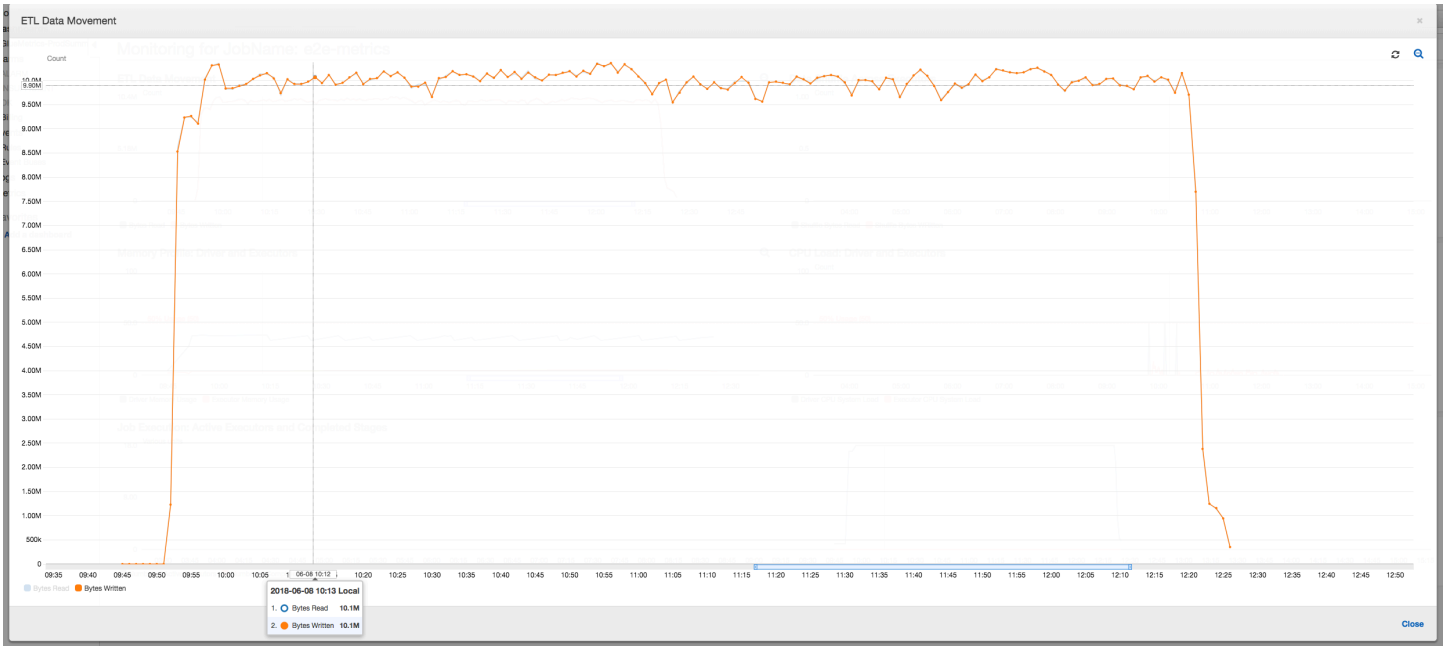

Depurar uma exceção OOM do executor

Nesse cenário, você pode saber como depurar exceções OOM que podem ocorrer em executores do Apache Spark. O código a seguir usa o leitor Spark MySQL para ler uma grande tabela de cerca de 34 milhões de linhas em um dataframe do Spark. Em seguida, ele grava no Amazon S3 em formato

Parquet. Você pode fornecer as propriedades da conexão e usar as configurações padrão do Spark para ler a tabela.

```
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)
```

Visualizar as métricas perfiladas no console do AWS Glue

Se a inclinação do gráfico de uso de memória for positiva e ultrapassar 50%, e se ocorrer uma falha no trabalho antes que a próxima métrica seja emitida, o esgotamento da memória será uma causa provável. O seguinte gráfico mostra que, dentro de um minuto da execução, a média de uso de memória em todos os executores ultrapassa rapidamente 50%. O uso atinge até 92%, e o contêiner que executa o executor é interrompido pelo Apache Hadoop YARN.

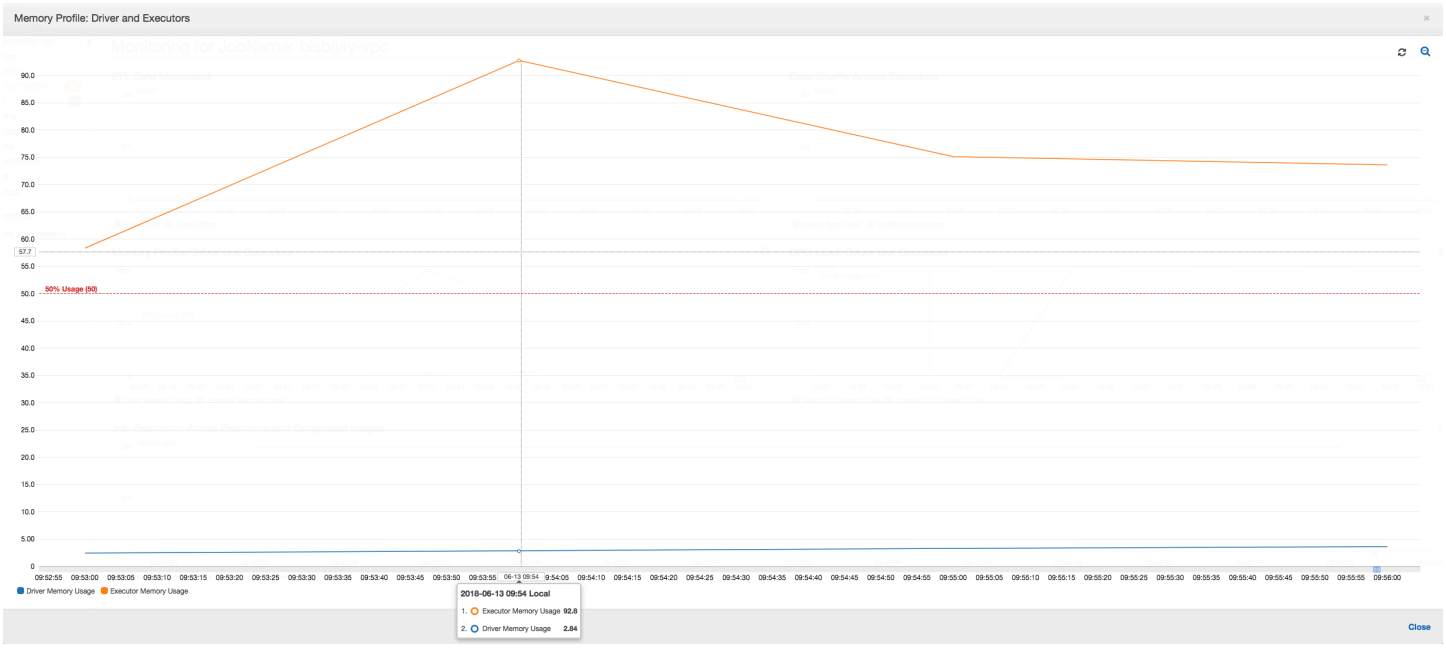

Como o seguinte gráfico mostra, há sempre um único executor em execução até o trabalho falhar. Isso ocorre porque um novo executor é iniciado para substituir o executor eliminado. As leituras da fonte de dados JDBC não são paralelizadas por padrão porque isso exigiria particionamento de tabela em uma coluna e abrir várias conexões. Como resultado, apenas um executor lê na tabela completa sequencialmente.

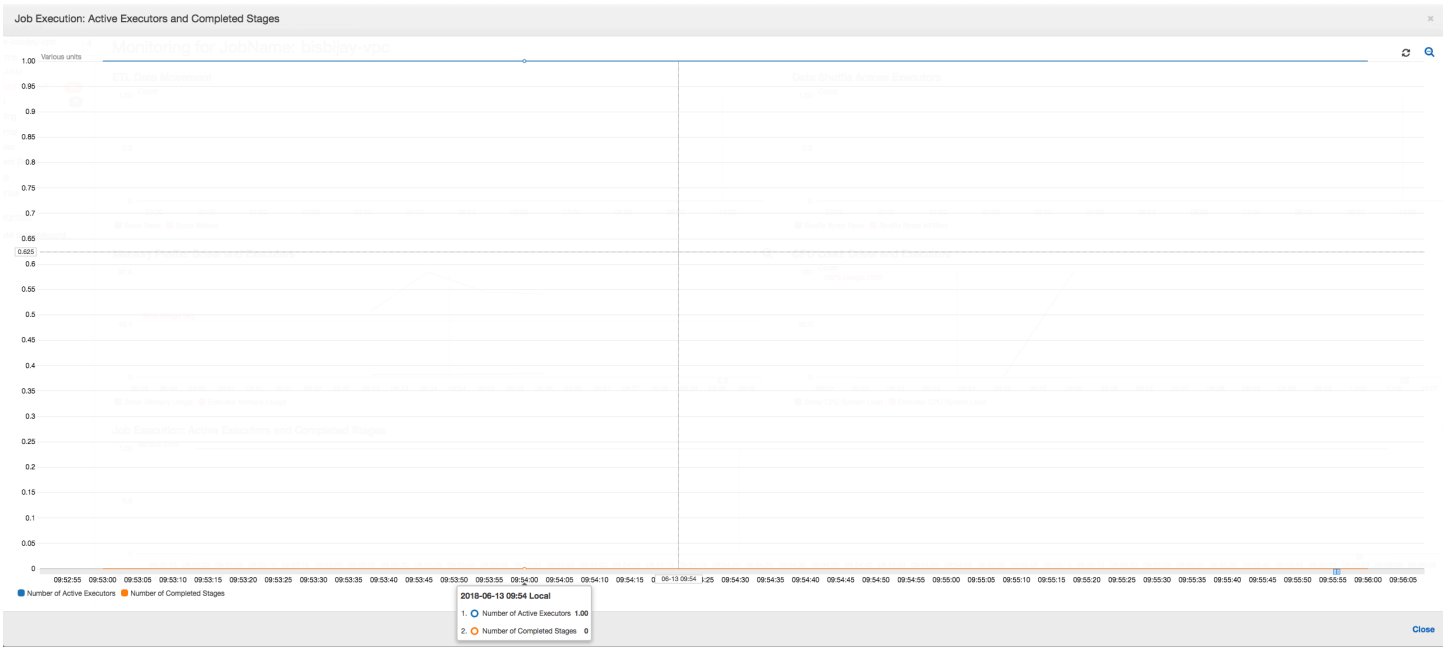

Como o seguinte gráfico mostra, o Spark tenta iniciar uma nova tarefa quatro vezes antes da falha no trabalho. Você pode ver o perfil de memória de três executores. Cada executor usa rapidamente toda sua memória. O quarto executor fica sem memória e o trabalho falha. Como resultado, a métrica não é relatada imediatamente.

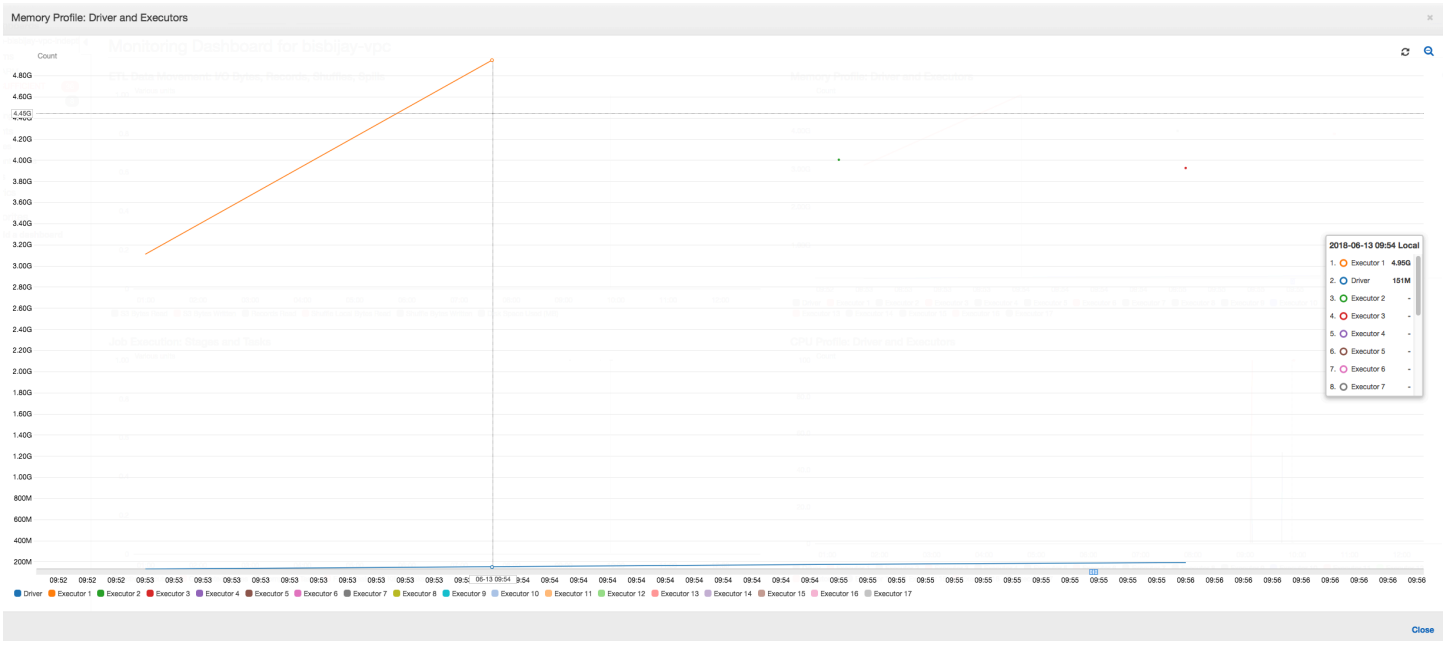

Você pode confirmar na string de erro no console do AWS Glue que o trabalho falhou devido a exceções OOM, conforme mostrado na imagem a seguir.

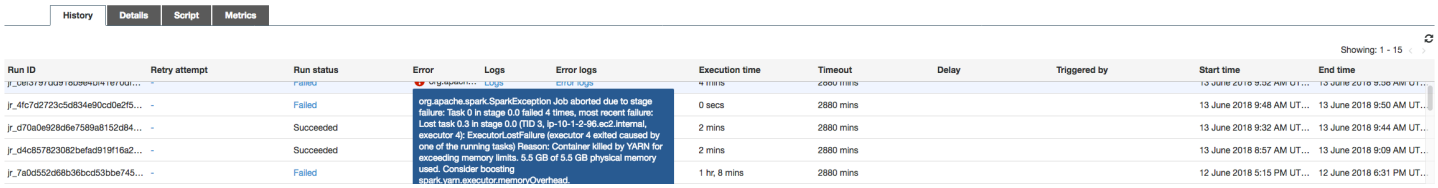

Logs de saída de trabalho: para confirmação adicional da descoberta de uma exceção OOM de executor, consulte o CloudWatch Logs. Quando você pesquisar por **`Error`**, encontrará os quatro executores interrompidos aproximadamente na mesma janela de tempo, como mostrado no painel de métricas. Todos são encerrados pelo YARN à medida que excedem os limites de memória.

Executor 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.
```

Executor 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.
```

Executor 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.
```

Executor 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.
```

Corrigir a configuração do tamanho da busca usando quadros dinâmicos do AWS Glue

O executor ficou sem memória ao ler a tabela JDBC porque a configuração padrão para o tamanho da busca JDBC do Spark é zero. Isso significa que o driver JDBC no executor do Spark tenta buscar as 34 milhões de linhas no banco de dados em conjunto e as armazena em cache, embora o Spark transmita por meio de linhas, uma de cada vez. Com o Spark, você pode evitar esse cenário ao configurar o parâmetro de tamanho de busca como um valor padrão diferente de zero.

Você também pode corrigir esse problema usando os quadros dinâmicos do AWS Glue. Por padrão, os quadros dinâmicos usam um tamanho de busca de 1.000 linhas, que normalmente é um valor suficiente. Como resultado, o executor não consome mais de 7% da memória total. O trabalho do AWS Glue é concluído em menos de dois minutos com apenas um único executor. Embora usar quadros dinâmicos do AWS Glue seja a abordagem recomendada, também é possível definir o tamanho de busca usando a propriedade `fetchsize` do Apache Spark. Consulte o Guia do Spark SQL, DataFrames e conjuntos de dados.

```
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")
```

Métricas perfiladas normais: a memória do executor com quadros dinâmicos do AWS Glue jamais excede o limite seguro, conforme mostrado na imagem a seguir. Ele transmite nas linhas do banco de dados e armazena em cache apenas 1.000 linhas no driver JDBC a qualquer momento. Não ocorre uma exceção de falta de memória.

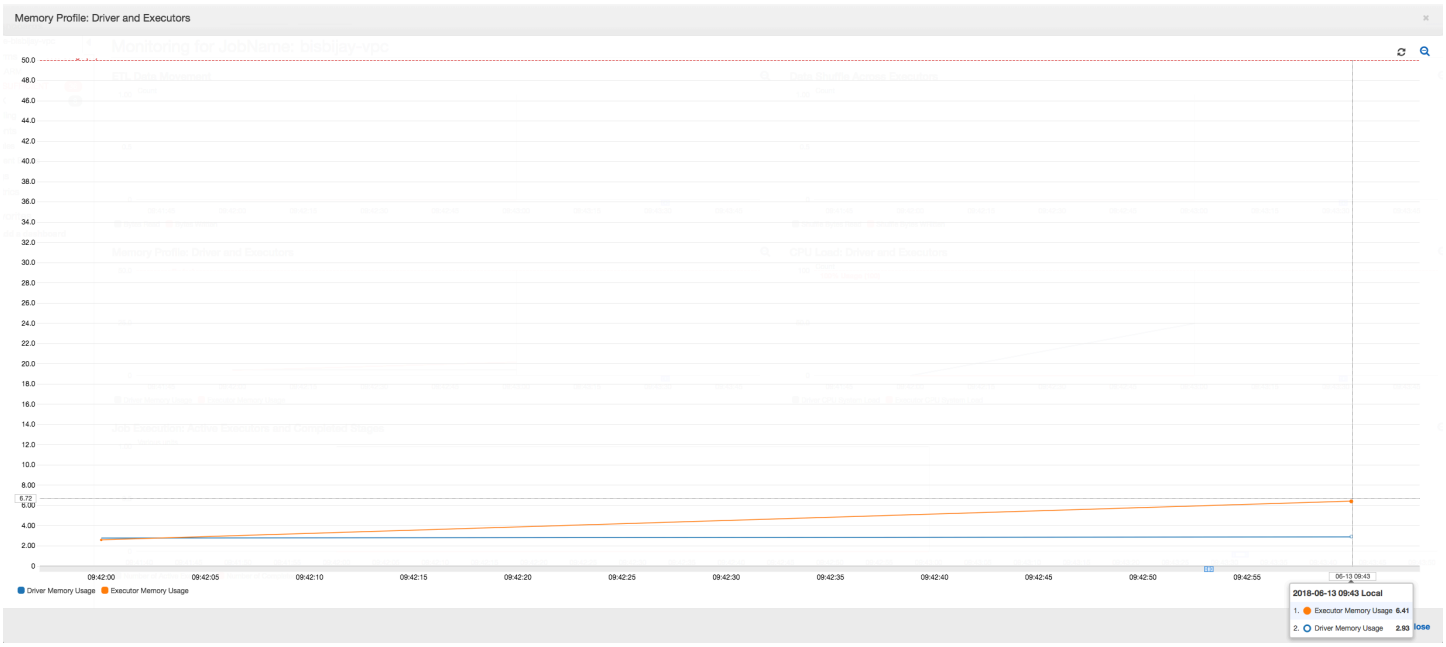

Depurar estágios exigentes e tarefas de retardatário

Você pode usar perfis de trabalho do AWS Glue para identificar estágios exigentes e tarefas de retardatário em seus trabalhos de extração, transformação e carga (ETL). Uma tarefa de retardatário leva muito mais tempo do que o restante das tarefas em um estágio de um trabalho do AWS Glue. Como resultado, o estágio leva mais tempo para ser concluído, o que também atrasa o tempo total de execução do trabalho.

Reunir arquivos de entrada pequenos em arquivos de saída maiores

Uma tarefa de retardatário pode ocorrer quando há uma distribuição não uniforme de trabalho em diferentes tarefas, ou um desvio de dados resulta em uma tarefa processando mais dados.

Você pode criar o perfil do seguinte código (um padrão comum no Apache Spark) para reunir um grande número de arquivos pequenos em arquivos de saída maiores. Para este exemplo, o conjunto de dados de entrada é 32 GB de arquivos JSON com compactação Gzip. O conjunto de dados de saída tem aproximadamente 190 GB de arquivos JSON não compactados.

O código perfilado é assim:

```
datasource0 = spark.read.format("json").load("s3://input_path")
df = datasource0.coalesce(1)
df.write.format("json").save(output_path)
```

Visualizar as métricas perfiladas no console do AWS Glue

Você pode criar o perfil do trabalho para examinar quatro conjuntos de métricas diferentes:

- Movimentação de dados ETL
- Embaralhamento de dados em executores
- Execução de trabalho
- Perfil de memória

Movimentação de dados ETL: no perfil ETL Data Movement (Movimentação de dados ETL), os bytes são lidos bastante rapidamente por todos os executores no primeiro estágio concluído nos primeiros seis minutos. No entanto, o tempo total de execução do trabalho é de cerca de uma hora, principalmente consistindo em gravações de dados.

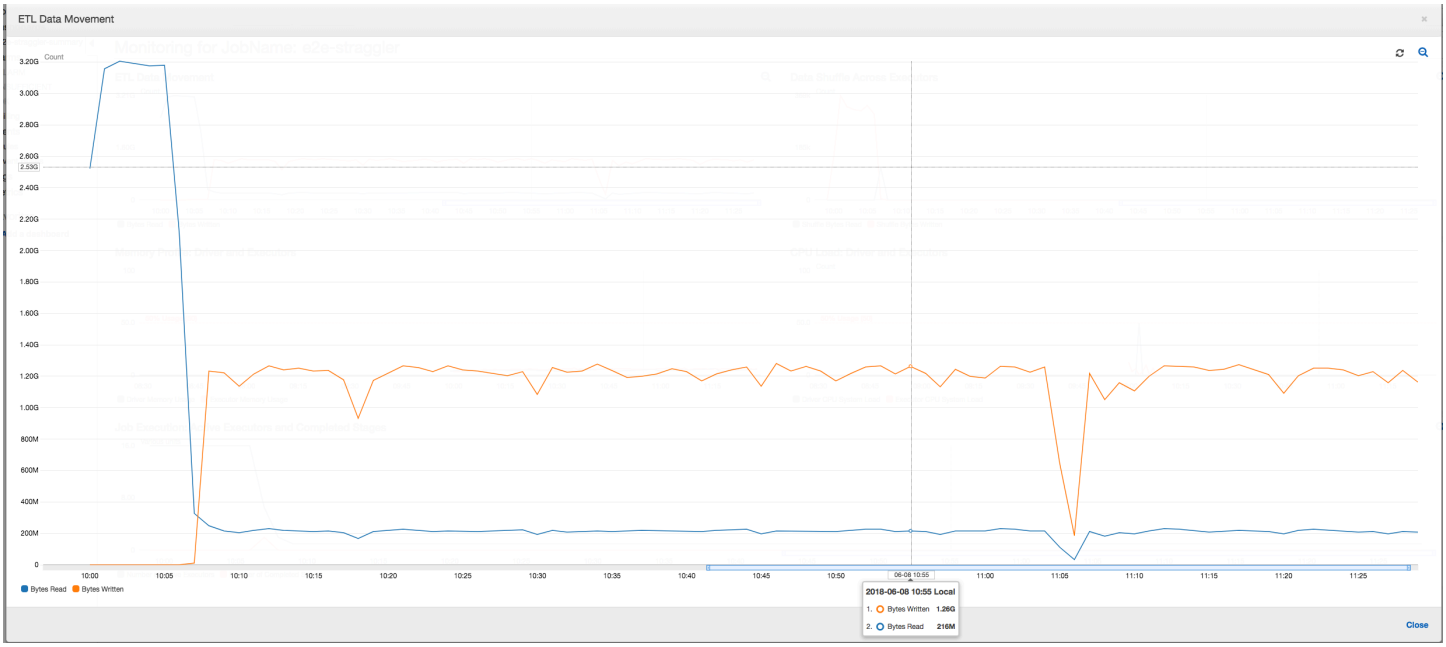

Embaralhamento de dados em executores: o número de bytes lidos e gravados durante o embaralhamento também mostra um pico antes da fase 2 terminar, conforme indicado pelas métricas Job Execution (Execução do trabalho) e Data Shuffle (Embaralhamento de dados). Depois que os dados são embaralhados em todos os executores, as leituras e gravações prosseguem no executor número 3 apenas.

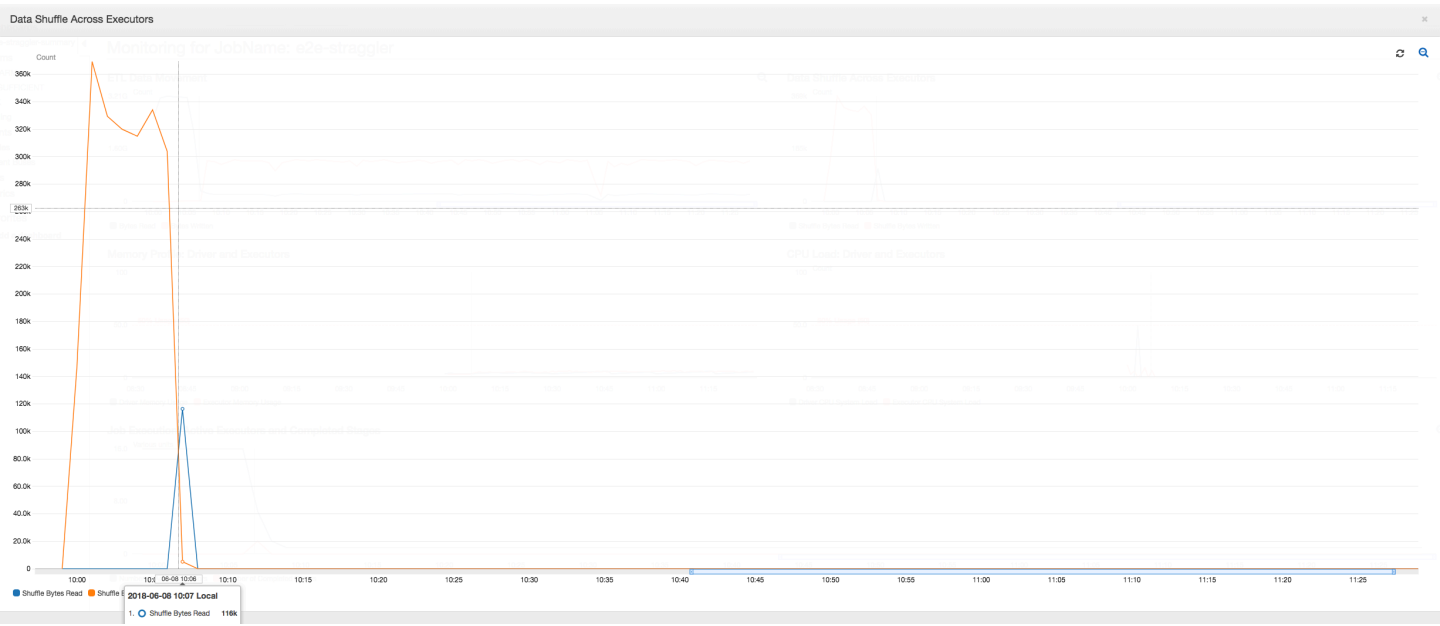

Execução de trabalho: como mostrado no gráfico a seguir, todos os outros executores estão ociosos e acabam sendo desativados às 10h09. Nesse momento, o número total de executores diminui a apenas um. Isso claramente mostra que o executor número 3 consiste na tarefa de retardatário que está levando o tempo de execução mais longo e está contribuindo para a maior parte do tempo de execução do trabalho.

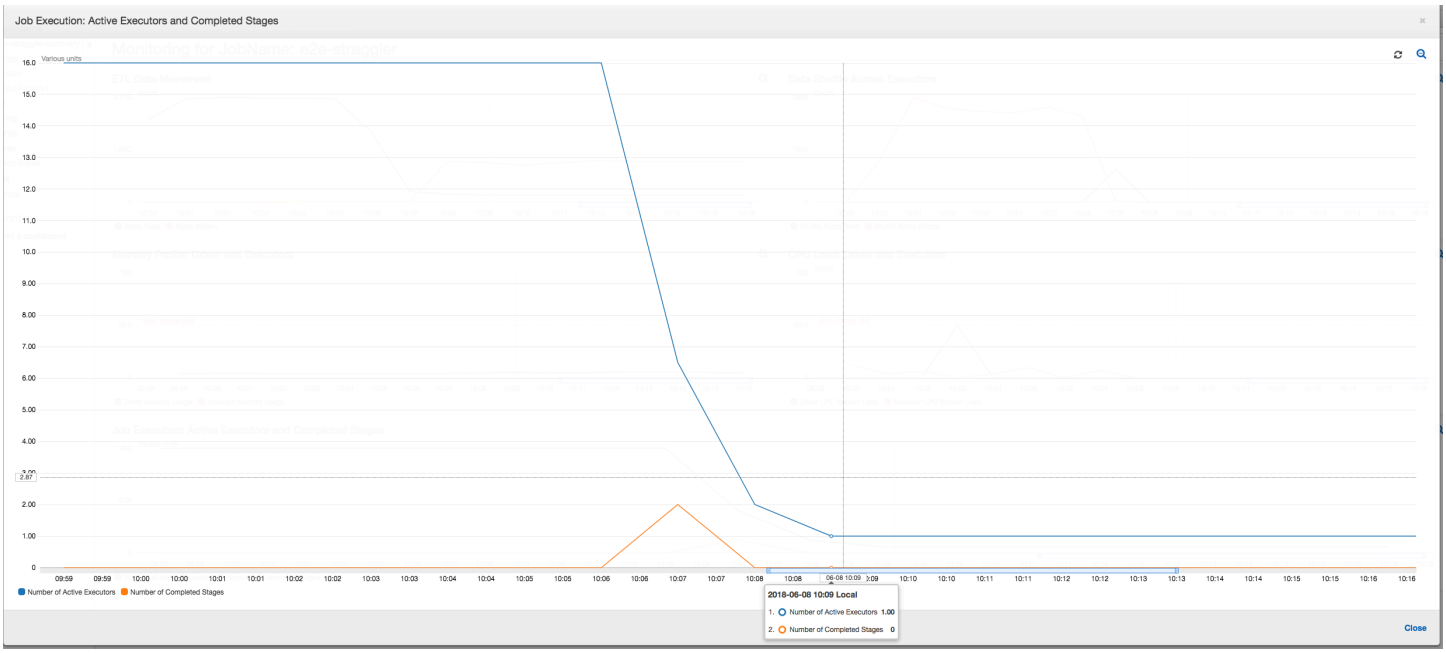

Perfil de memória: após os dois primeiros estágios, apenas o executor número 3 está ativamente consumindo memória para processar os dados. Os executores restantes estão simplesmente ociosos ou foram desativados logo após a conclusão dos dois primeiros estágios.

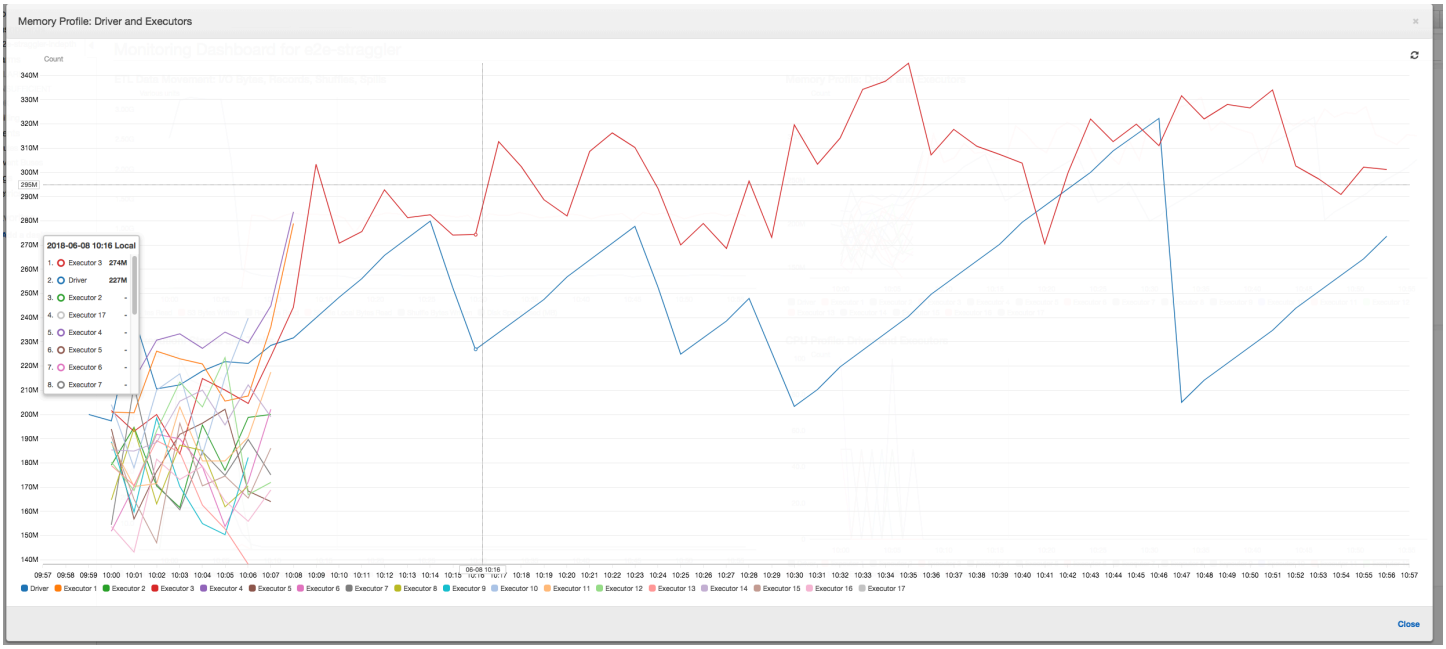

Corrigir executores retardatários usando agrupamento

Você pode evitar executores retardatários usando o recurso de agrupamento no AWS Glue. Use o agrupamento para distribuir os dados uniformemente em todos os executores e agrupar os arquivos em arquivos maiores usando todos os executores disponíveis no cluster. Para ter mais informações, consulte Ler arquivos de entrada em grupos maiores.

Para verificar as movimentações de dados ETL no AWS Glue, crie o perfil do código a seguir com agrupamento habilitado:

```
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")
```

Movimentação de dados ETL: as gravações de dados agora são transmitidas em paralelo com os dados lidos durante todo o tempo de execução do trabalho. Como resultado, o trabalho é concluído em oito minutos, muito mais rápido do que anteriormente.

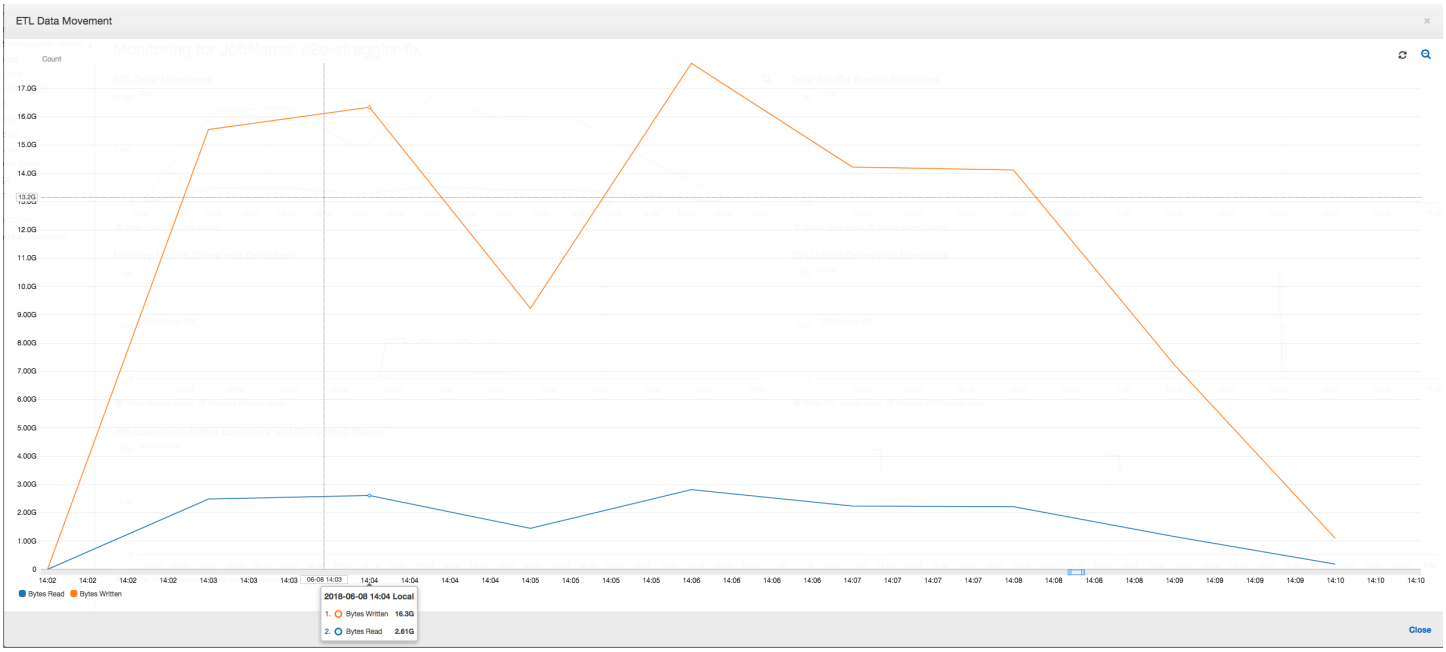

Embaralhamento de dados em executores: conforme os arquivos de entrada são agrupados durante as leituras usando o recurso de agrupamento, não há embaralhamento de dados dispendioso depois das leituras.

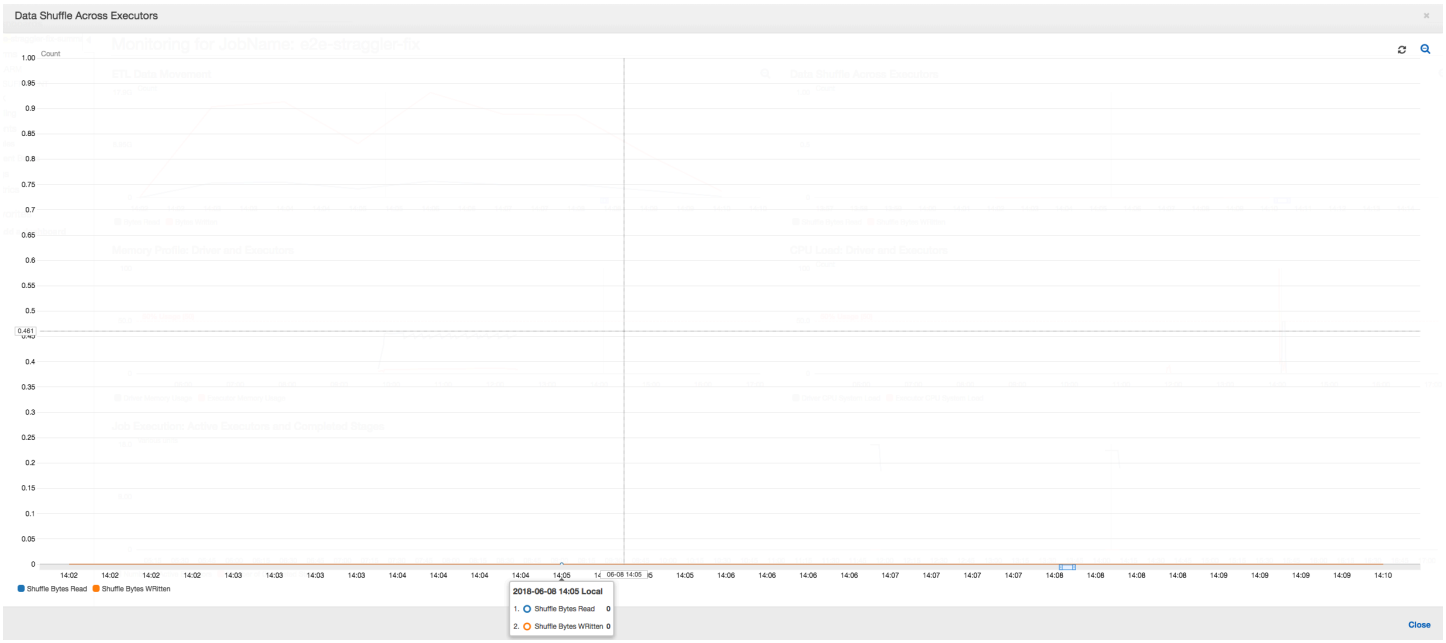

Execução do trabalho: as métricas de execução do trabalho mostram que o número total de executores ativos em execução e o processamento de dados permanece constante. Não há um único retardatário no trabalho. Todos os executores estão ativos e não são desativados até a conclusão do trabalho. Como não há embaralhamento intermediário dos dados nos executores, há somente uma única fase do trabalho.

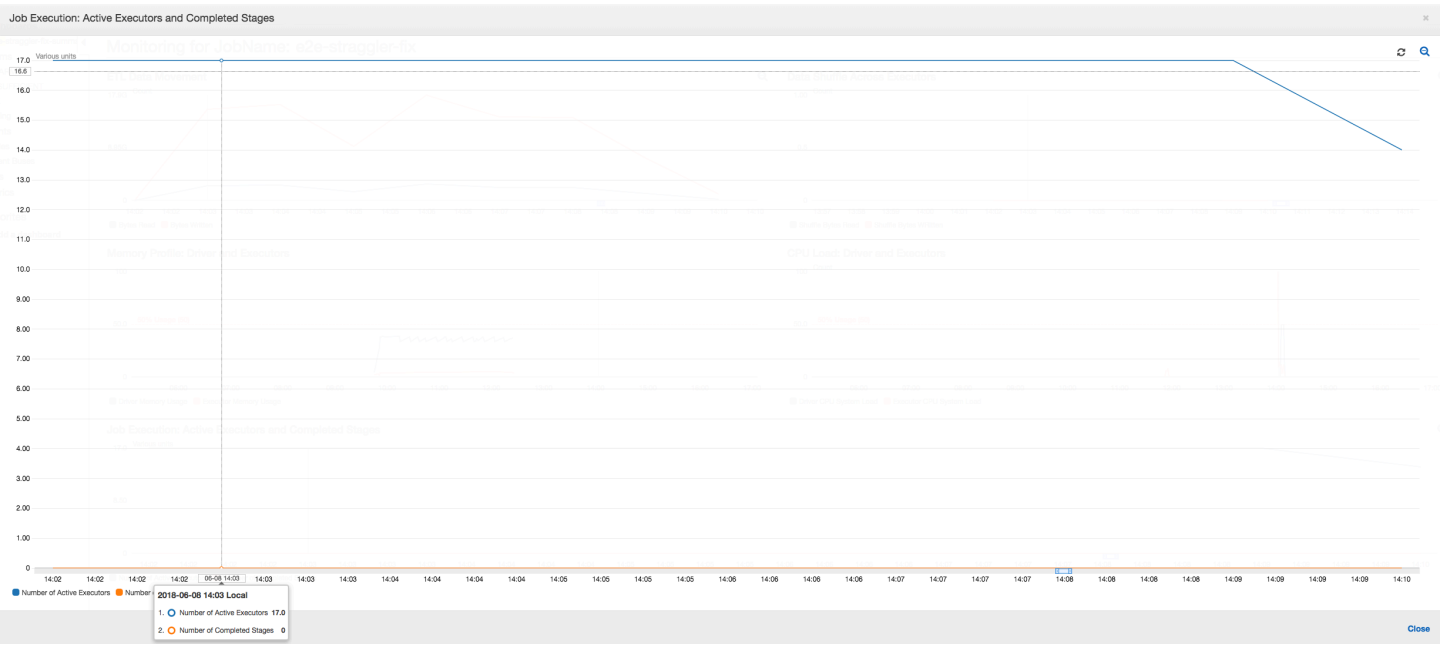

Perfil de memória: as métricas mostram o consumo de memória ativa em todos os executores, reconfirmando que há atividade em todos eles. À medida que os dados são transmitidos e gravados em paralelo, o total de espaço de memória de todos os executores é aproximadamente uniforme e bem abaixo do limite de segurança para todos os executores.

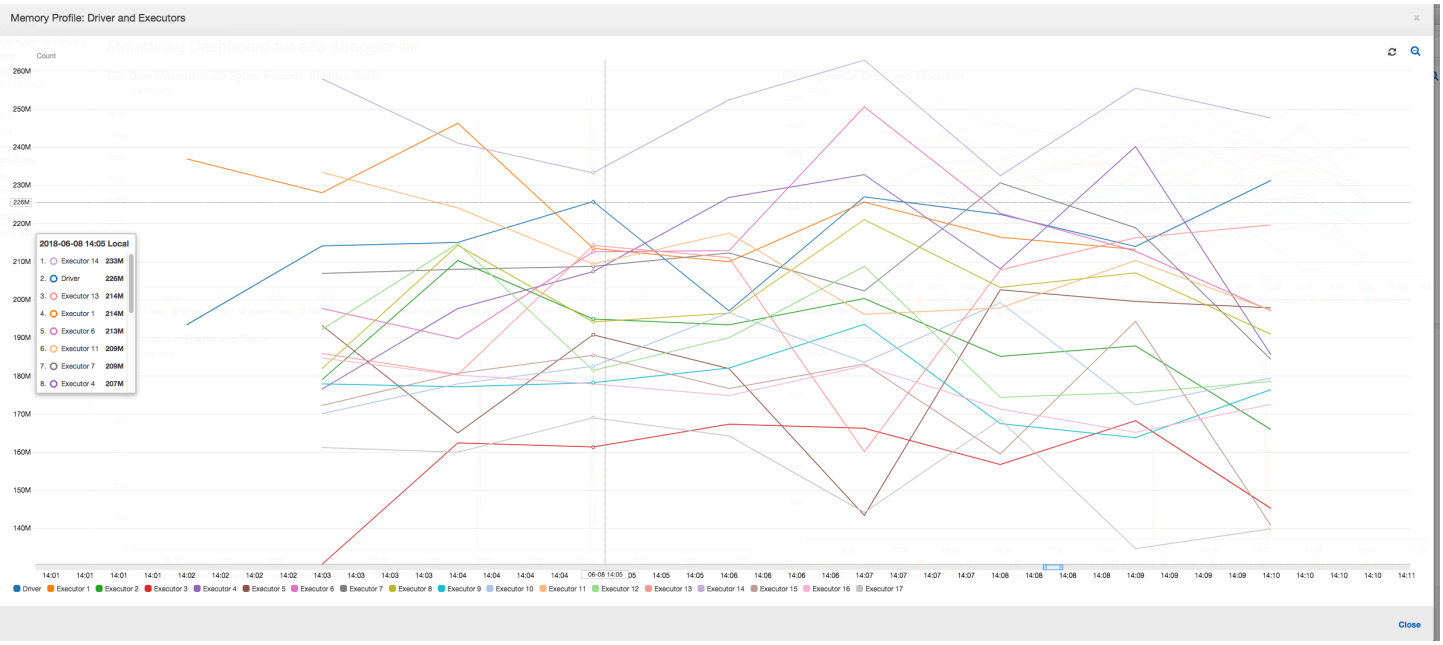

Monitorar o progresso de vários trabalhos

Você pode criar o perfil de vários trabalhos do AWS Glue e monitorar o fluxo de dados entre eles. Esse é um padrão de fluxo de trabalho comum e requer monitoramento de andamento de trabalho

individual, backlog de processamento de dados, reprocessamento de dados e marcadores de trabalho.

Tópicos

- Código perfilado
- Visualizar as métricas perfiladas no console do AWS Glue
- Corrigir o processamento de arquivos

Código perfilado

Neste fluxo de trabalho, você tem dois trabalhos: um de entrada e um de saída. O trabalho de entrada está programado para ser executado a cada 30 minutos usando um gatilho periódico. O trabalho de saída está programado para ser executado após cada execução bem-sucedida do trabalho de entrada. Essas tarefas agendadas são controladas usando gatilhos de trabalho.

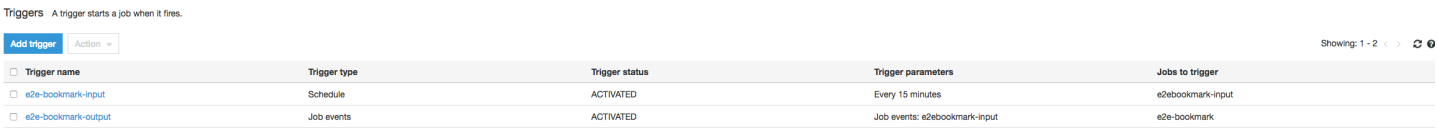

Trabalho de entrada: esse trabalho lê dados de um local do Amazon Simple Storage Service (Amazon S3), transforma-os usando `ApplyMapping` e os grava em um local de preparação do Amazon S3. O código a seguir é o código perfilado para o trabalho de entrada:

```
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")
```

Trabalho de saída: esse trabalho lê a saída do trabalho de entrada no local de preparação no Amazon S3, transforma-a novamente e a grava em um destino:

```
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")
```

Visualizar as métricas perfiladas no console do AWS Glue

O seguinte painel sobrepõe a métrica de bytes gravados do Amazon S3 do trabalho de entrada na métrica de bytes lidos do Amazon S3 no mesmo cronograma do trabalho de saída. O cronograma mostra diferentes execuções de trabalhos de entrada e saída. O trabalho de entrada (mostrado em vermelho) começa a cada 30 minutos. O trabalho de saída (mostrado em marrom) começa na conclusão do trabalho de entrada, com uma simultaneidade máxima de 1.

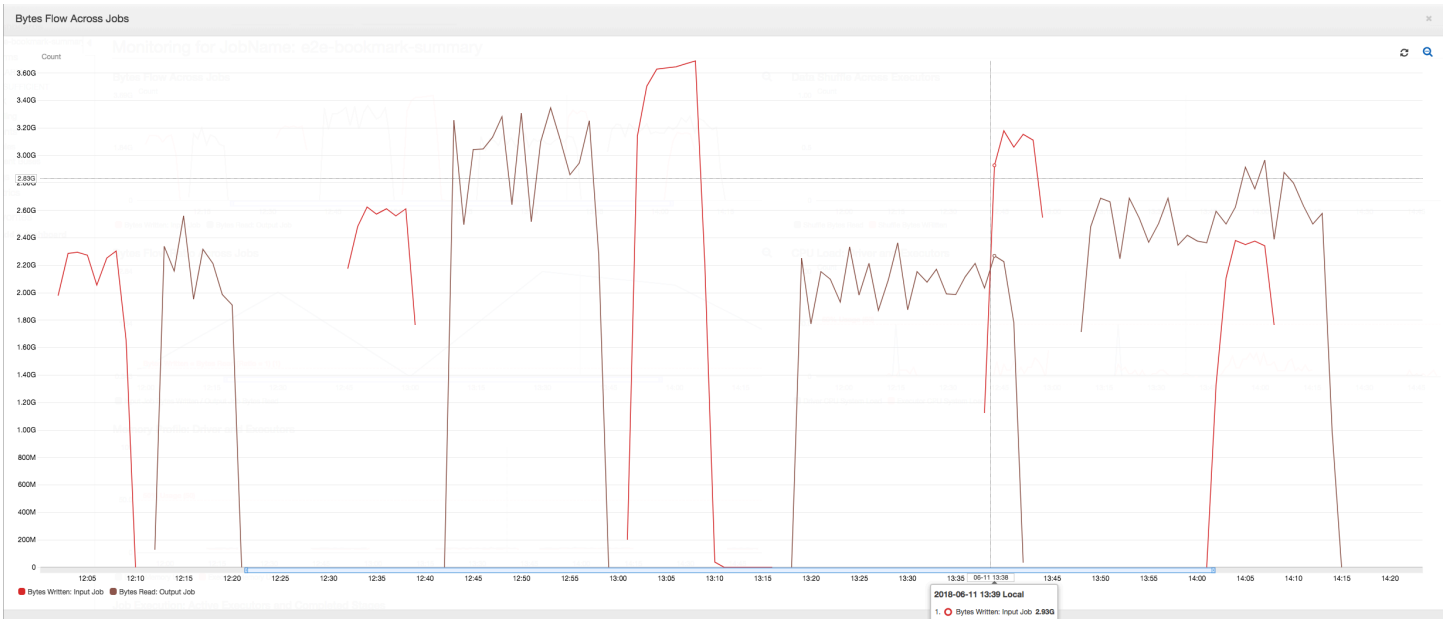

Neste exemplo, marcadores de trabalho não estão habilitados. Nenhum contexto de transformação é usado para habilitar marcadores de trabalho no código de script.

Histórico de trabalho: os trabalhos de entrada e saída têm várias execuções, conforme mostrado na guia History (Histórico), a partir do meio-dia.

O trabalho de entrada no console do AWS Glue é semelhante a este:

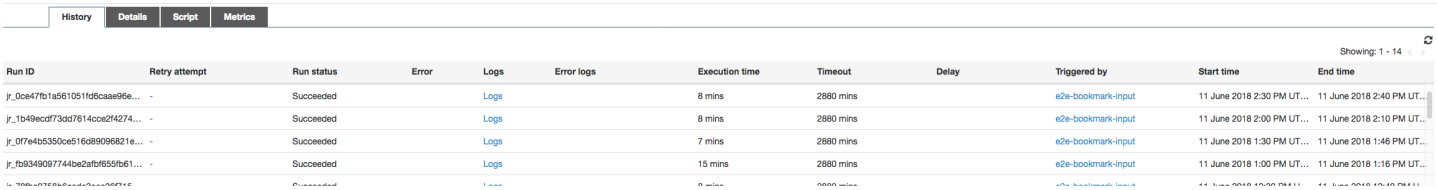

A imagem a seguir mostra o trabalho de saída:

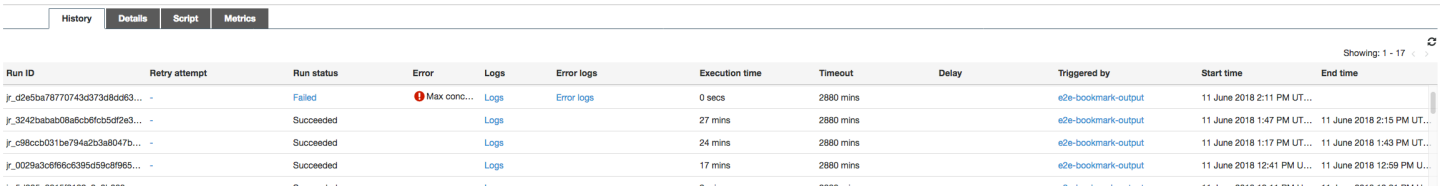

Primeiras execuções de trabalho: como mostrado no gráfico de bytes de dados lidos e gravados abaixo, as primeiras execuções dos trabalhos de entrada e saída entre 12h e 12h30 mostram aproximadamente a mesma área sob as curvas. Essas áreas representam os bytes do Amazon S3 gravados pelo trabalho de entrada e os bytes do Amazon S3 lidos pelo trabalho de saída. Esses dados também são confirmados pela relação de bytes do Amazon S3 gravados (somados por 30 minutos: a frequência do acionador do trabalho de entrada). O ponto de dados da relação para a execução do trabalho de entrada que começou ao meio-dia também é 1.

O gráfico a seguir mostra a relação do fluxo de dados em todas as execuções de trabalho:

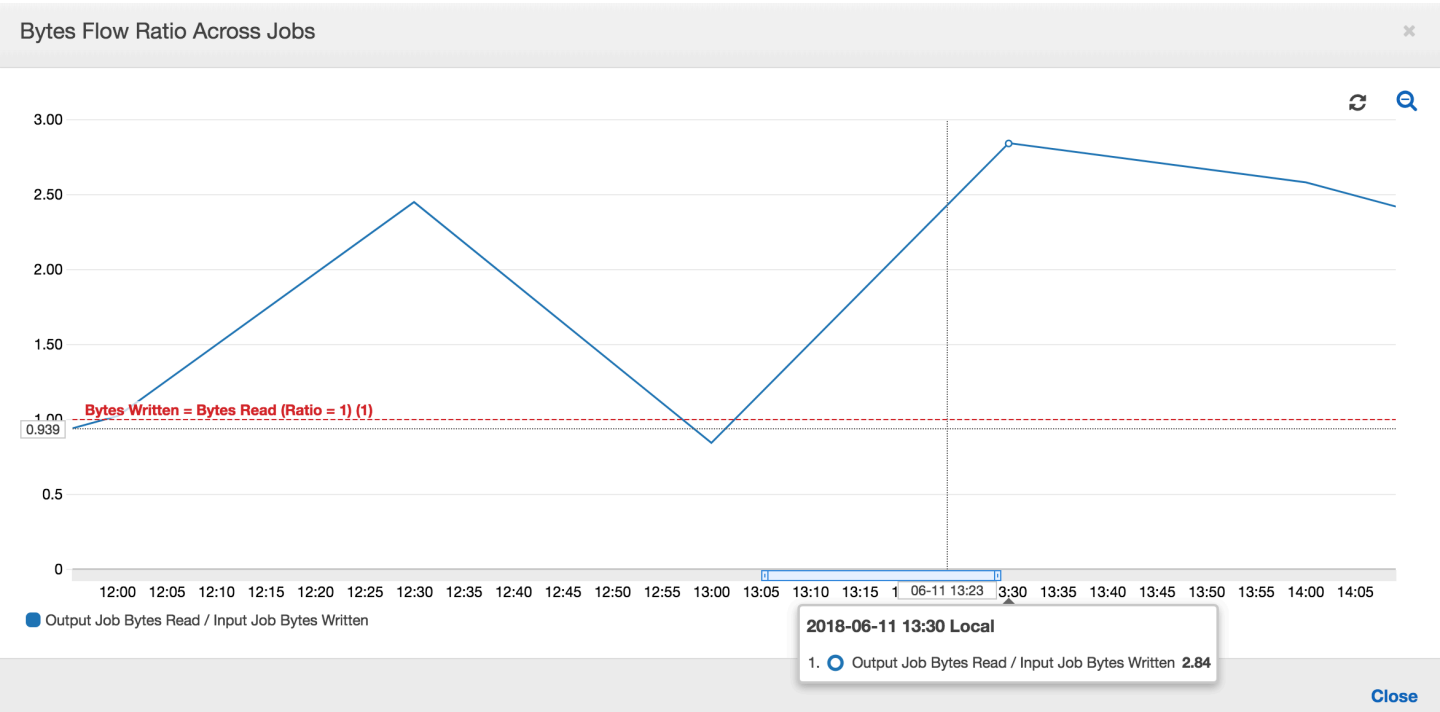

Segunda execução do trabalho: na segunda execução do trabalho, existe uma clara diferença no número de bytes lidos pelo trabalho de saída em comparação com o número de bytes gravados pelo trabalho de entrada. Compare a área sob a curva nas duas execuções do trabalho de saída, ou compare as áreas na segunda execução dos trabalhos de entrada e saída. A relação dos bytes lidos e gravados mostra que o trabalho de saída lê cerca de 2,5x os dados gravados pelo trabalho de entrada no segundo período de 30 minutos das 12h30 às 13h. Isso ocorre porque o trabalho de saída reprocessou a saída da primeira execução do trabalho de entrada porque os marcadores de

trabalho não foram ativados. Uma relação acima de 1 mostra que há um backlog adicional de dados que foi processado pelo trabalho de saída.

Terceira execução do trabalho: o trabalho de entrada é bastante consistente em termos do número de bytes gravados (consulte a área sob as curvas vermelhas). No entanto, a terceira execução do trabalho de entrada foi maior que o esperado (consulte a extremidade longa da curva vermelha). Como resultado, a terceira execução do trabalho de saída iniciou com atraso. A terceira execução do trabalho processou apenas uma fração dos dados acumulados no local de preparação nos 30 minutos restantes entre 13h e 13h30. A relação do fluxo de bytes mostra que ele processou apenas 0,83 de dados gravados pela terceira execução do trabalho de entrada (consulte a relação às 13h).

Sobreposição de trabalhos de entrada e saída: a quarta execução do trabalho de entrada começou às 13h30 de acordo com a programação, antes de a terceira execução do trabalho de saída ser concluída. Existe uma sobreposição parcial entre essas duas execuções de trabalho. No entanto, a terceira execução do trabalho de saída captura apenas os arquivos listados no local de preparação do Amazon S3 quando ela começou, em torno das 13h17. Isso consiste na saída de todos os dados da primeira execução do trabalho de entrada. A taxa real às 13h30 é em torno de 2,75. A terceira execução do trabalho de saída processou cerca de 2,75x de dados gravados pela quarta execução do trabalho de entrada das 13h30 às 14h.

Como essas imagens mostram, o trabalho de saída reprocessa dados do local de preparação de todas as execuções anteriores do trabalho de entrada. Como resultado, a quarta execução do trabalho de saída é a mais longa e se sobrepõe à quinta execução do trabalho de entrada.

Corrigir o processamento de arquivos

Você deve garantir que o trabalho de saída processe apenas os arquivos que não foram processados por execuções anteriores do trabalho de saída. Para fazer isso, habilite marcadores de trabalho e defina o contexto de transformação no trabalho de saída, da seguinte forma:

```
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")
```

Com marcadores de trabalho ativados, o trabalho de saída não reprocessa os dados no local de preparação de todas as execuções anteriores do trabalho de entrada. Na imagem a seguir que mostra os dados lidos e gravados, a área sob a curva marrom é bastante consistente e semelhante às curvas vermelhas.

As relações de fluxo de bytes também permanecem cerca de 1 porque não há dados adicionais processados.

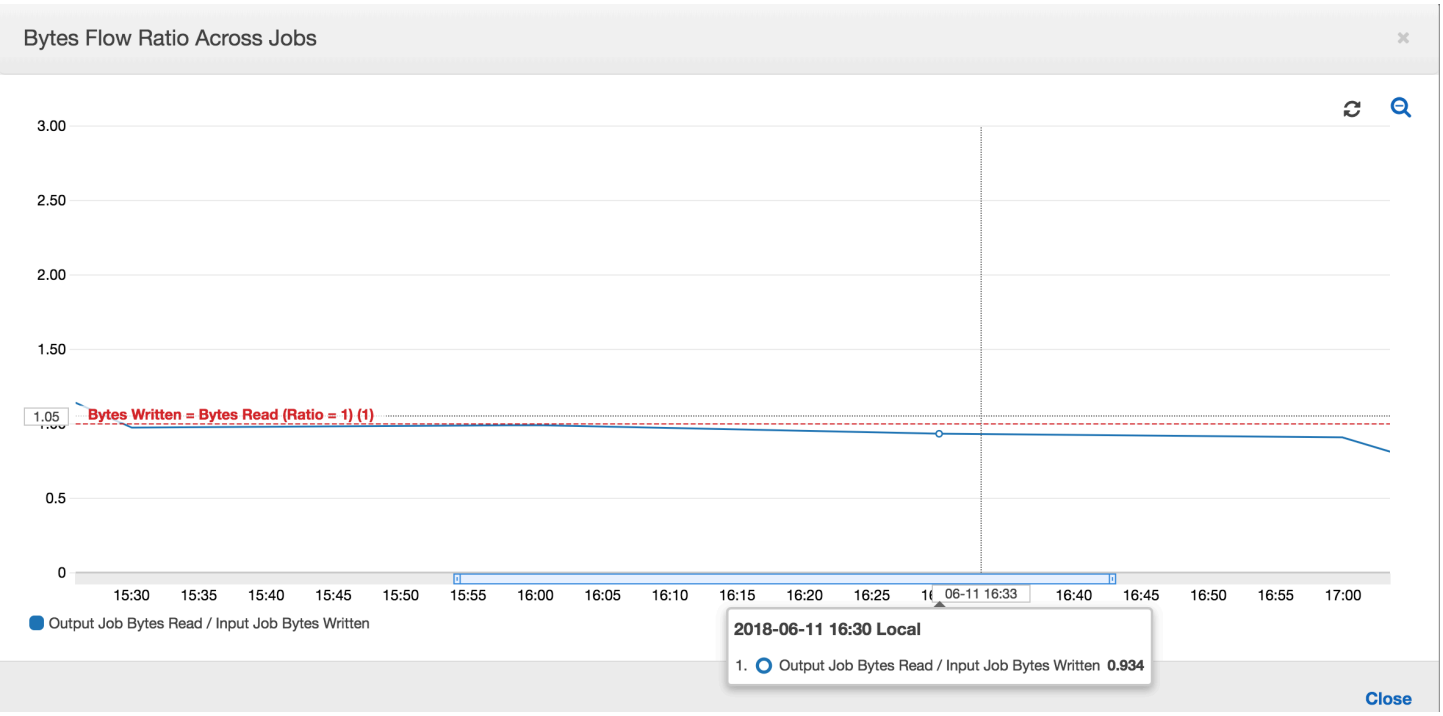

Uma execução do trabalho de saída é iniciada e captura os arquivos no local de preparação antes da próxima execução do trabalho de entrada começar a colocar mais dados no local de preparação.

Desde que continue a fazer isso, ela processa apenas os arquivos capturados na execução do trabalho de entrada anterior, e a relação permanece próxima a 1.

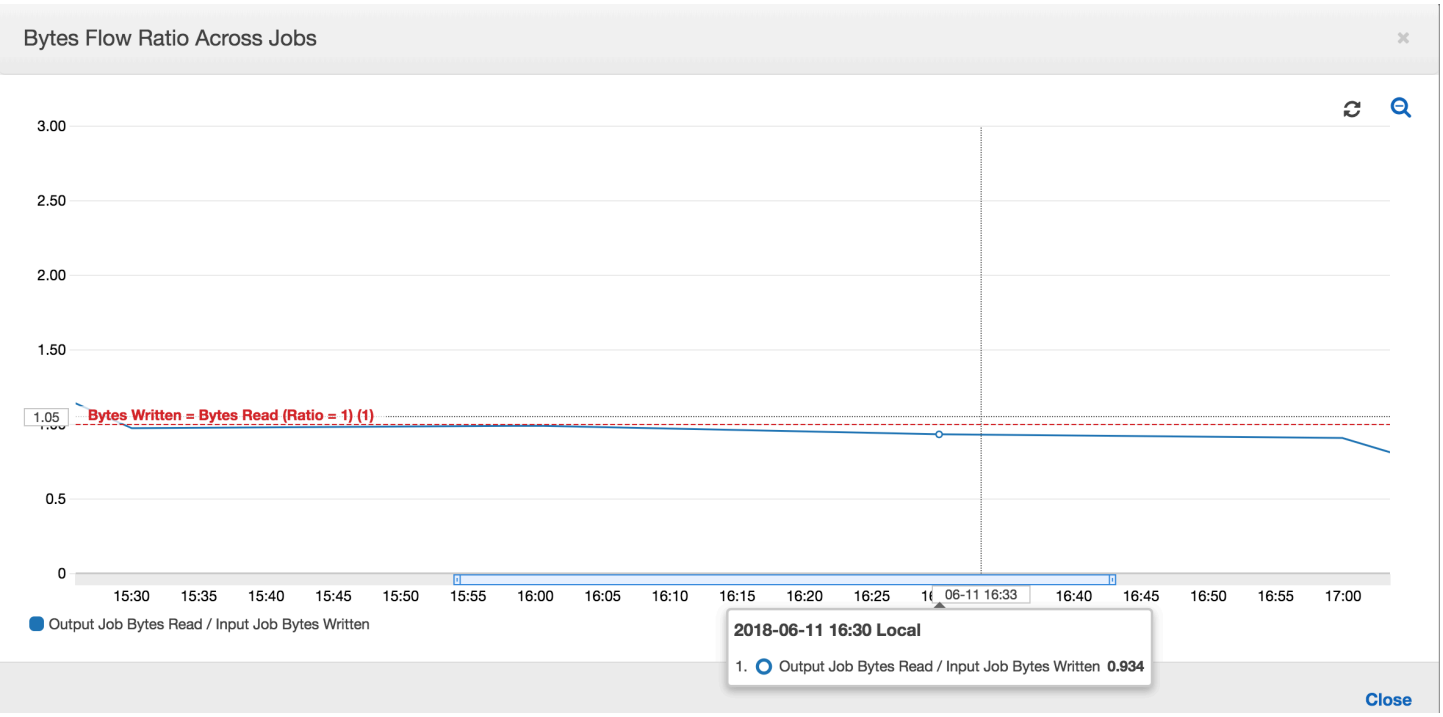

Suponha que o trabalho de entrada leve mais tempo do que o esperado e, como resultado, o trabalho de saída capture arquivos no local de preparação de duas execuções do trabalho de entrada. A relação é maior que 1 para essa execução do trabalho de saída. No entanto, as próximas execuções do trabalho de saída não processam os arquivos que já foram processados pelas execuções anteriores do trabalho de saída.

Monitorar planejamento de capacidade de DPU

Você pode usar métricas de trabalho no AWS Glue para estimar o número de unidades de processamento de dados (DPUs) que podem ser usadas para expandir um trabalho do AWS Glue.

> **Note**
>
> Esta página só é aplicável às versões 0.9 e 1.0 do AWS Glue. Versões posteriores do AWS Glue contêm recursos de economia de custos que introduzem considerações adicionais ao planejar a capacidade.

Tópicos

- Código perfilado

- Visualizar as métricas perfiladas no console do AWS Glue
- Determinar a capacidade de DPU ideal

Código perfilado

O script a seguir lê uma partição do Amazon Simple Storage Service (Amazon S3) contendo 428 arquivos JSON em gzip. O script aplica um mapeamento para alterar os nomes dos campos e os converte e grava no Amazon S3 no formato Apache Parquet. Você provisiona dez DPUs de acordo com o padrão e executa esse trabalho.

```
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")
```

Visualizar as métricas perfiladas no console do AWS Glue

Execução de trabalho 1: nessa execução de trabalho, mostramos como descobrir se há DPUs não provisionadas no cluster. A funcionalidade da execução do trabalho no AWS Glue mostra o número total de executores ativamente em execução, o número de estágios concluídos e o número máximo de executores necessários.

O número máximo de executores necessário é calculado adicionando o número total de tarefas em execução e tarefas pendentes e dividindo pelas tarefas por executor. Esse resultado é uma medida do número total de executores necessários para satisfazer a carga atual.

Por outro lado, o número de executores em execução ativamente mede quantos executores estão executando tarefas ativas do Apache Spark. À medida que o trabalho progride, o máximo necessário de executores pode mudar e normalmente diminui no final do trabalho conforme a fila de tarefas pendentes fica menor.

A linha vermelha horizontal no gráfico a seguir mostra o número de executores máximos alocados, que depende do número de DPUs que você aloca para o trabalho. Nesse caso, você aloca 10 DPUs para a execução do trabalho. Uma DPU é reservada para gerenciamento. Nove DPUs executam dois executores cada, e um executor é reservado para o driver do Spark. O driver do Spark é executado dentro da aplicação principal. Portanto, o número máximo de executores alocados é 2*9 - 1 = 17 executores.

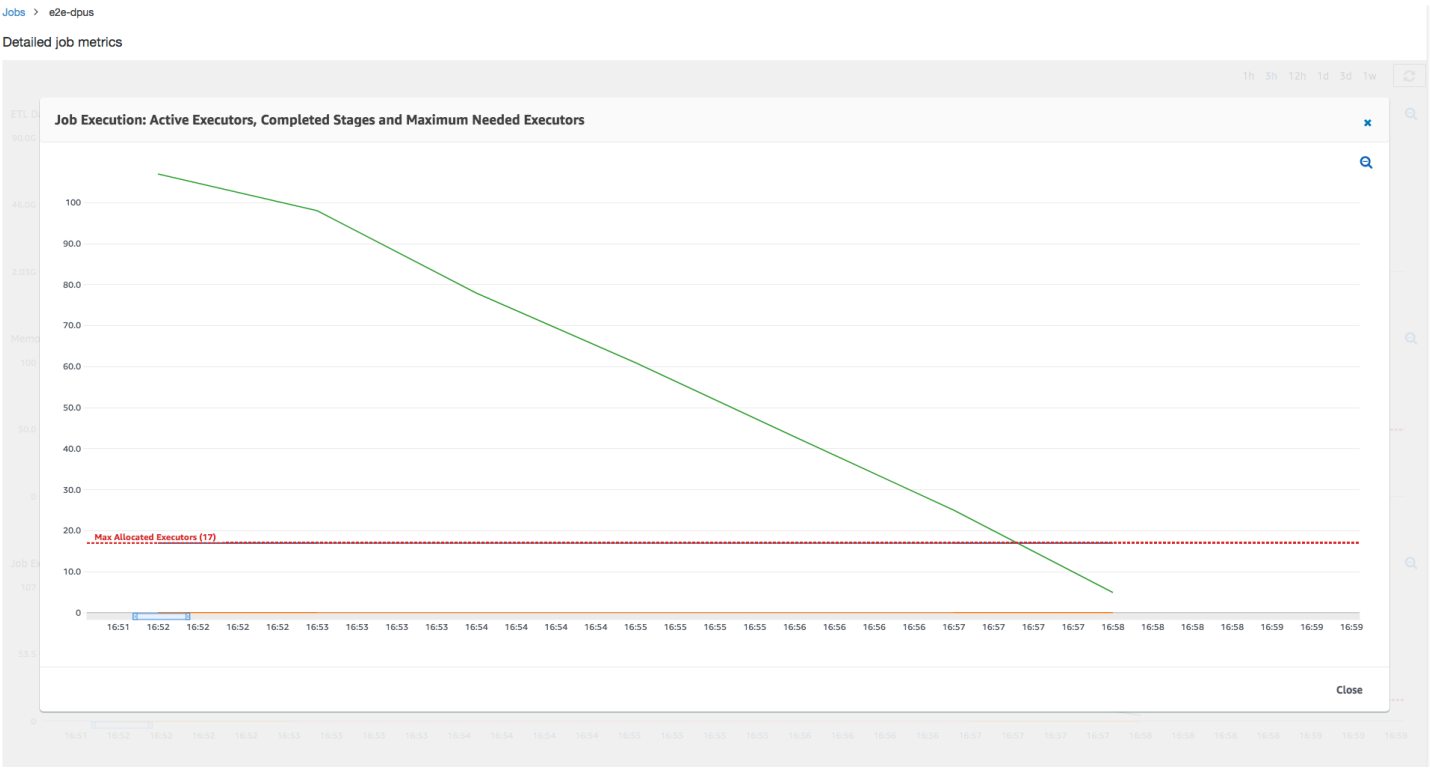

Como o gráfico mostra, o número de executores máximos necessários começa em 107 no início do trabalho, enquanto o número de executores ativos permanece 17. Isso equivale ao número de executores máximos alocados com 10 DPUs. A relação entre o máximo de executores necessários e o máximo de executores alocados (adicionando 1 a ambos para o driver do Spark) fornece o fator de subprovisionamento: 108/18 = 6x. É possível provisionar 6 (de acordo com a taxa de provisionamento) * 9 (capacidade atual de DPU - 1) + 1 DPUs = 55 DPUs para expandir o trabalho a fim de executá-lo com o máximo de paralelismo e terminar mais rapidamente.

O console do AWS Glue exibe as métricas de trabalho detalhadas como uma linha estática representando o número original do máximo de executores alocados. O console computa o máximo de executores alocados da definição do trabalho para as métricas. Em contrapartida, para as métricas detalhadas de execução do trabalho, o console computa o máximo de executores alocados da configuração de execução de trabalho, especificamente as DPUs alocadas para a execução do trabalho. Para visualizar as métricas da execução de um trabalho individual, selecione a execução do trabalho e selecione View run metrics (Visualizar métricas de execução).

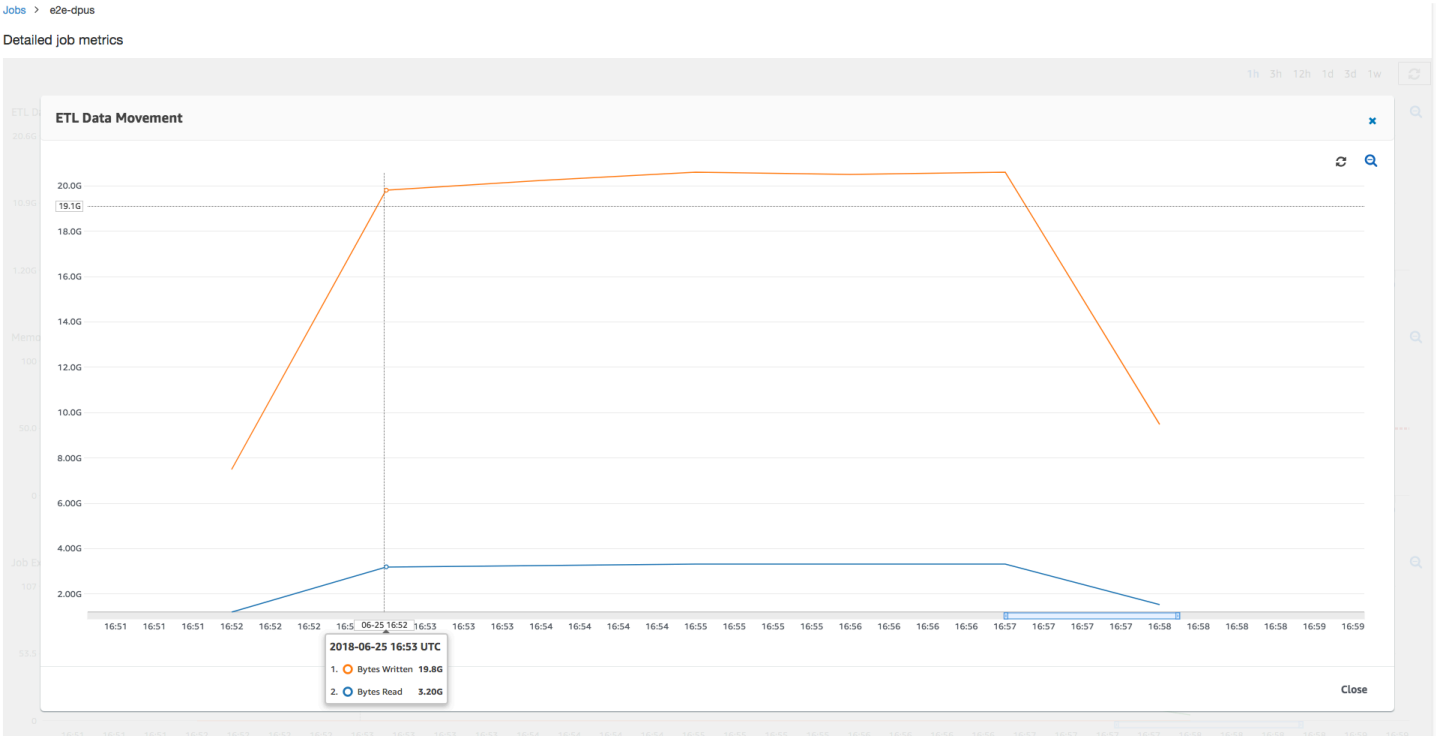

Analisando os bytes lidos e gravados do Amazon S3, observe que o trabalho gasta os seis minutos de transmissão em dados do Amazon S3 e na gravação simultaneamente. Todos os núcleos nas DPUs alocadas estão lendo e gravando no Amazon S3. O número máximo de executores necessários sendo 107 também corresponde ao número de arquivos no caminho de entrada do Amazon S3: 428. Cada executor pode iniciar quatro tarefas do Spark para processar quatro arquivos de entrada (JSON gzip).

Determinar a capacidade de DPU ideal

Com base nos resultados da execução de trabalho anterior, você pode aumentar o número total de DPUs alocadas para 55 e ver como o trabalho é realizado. O trabalho é concluído em menos de três minutos, metade do tempo necessário anteriormente. A expansão do trabalho não é linear nesse caso porque ele é um trabalho de execução curta. Os trabalhos com tarefas de longa duração ou um grande número de tarefas (um grande número de executores máximos necessários) se beneficiam de uma aceleração da performance de expansão da DPU quase linear.

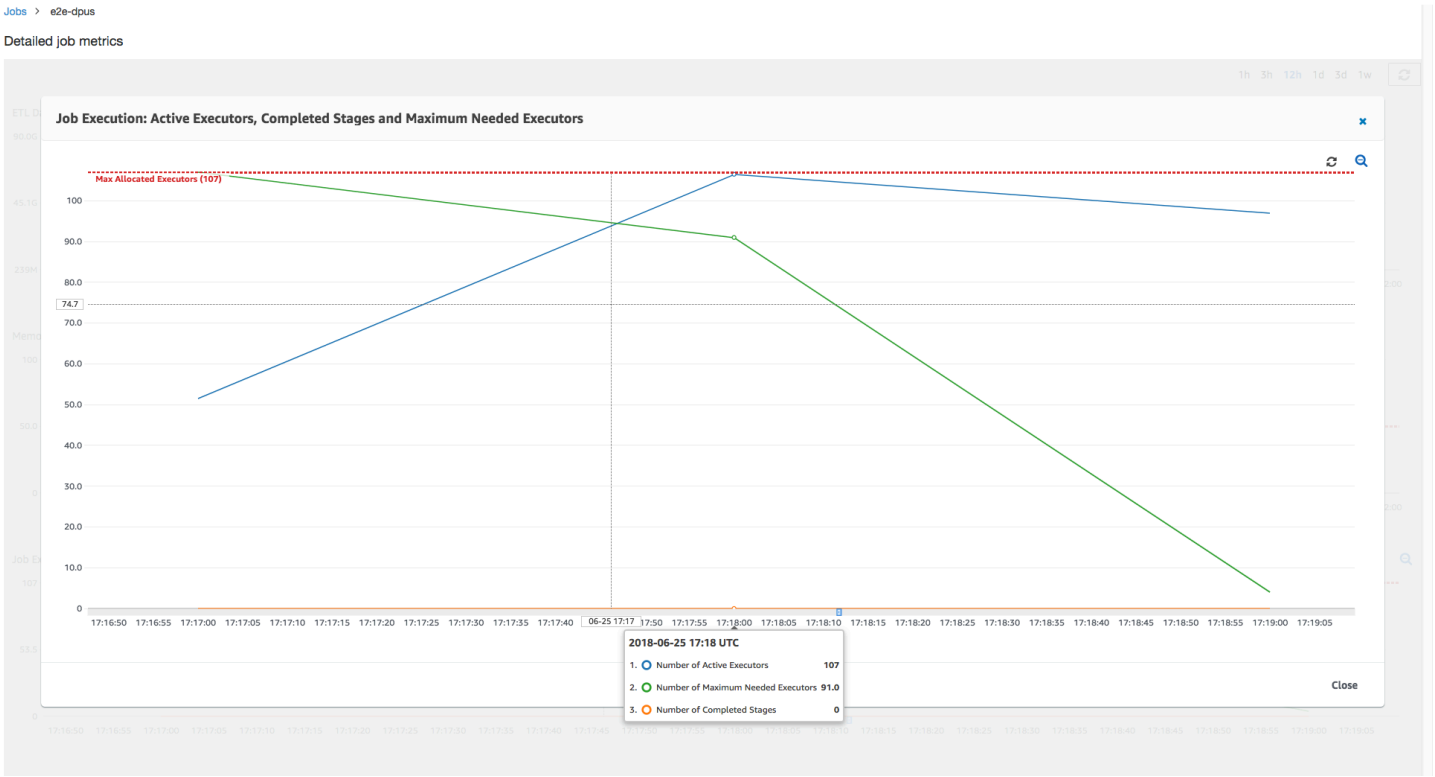

Como mostra a imagem a seguir, o número total de executores ativos atinge o máximo alocado: 107 executores. Da mesma forma, o máximo necessário de executores nunca é acima do máximo alocado de executores. O número máximo de executores necessários é calculado a partir da contagem de tarefas pendentes e ativamente em execução e, portanto, pode ser menor do que o número de executores ativos. Isso ocorre porque pode haver executores que estão parcial ou completamente ociosos por um curto período e ainda não estão desativados.

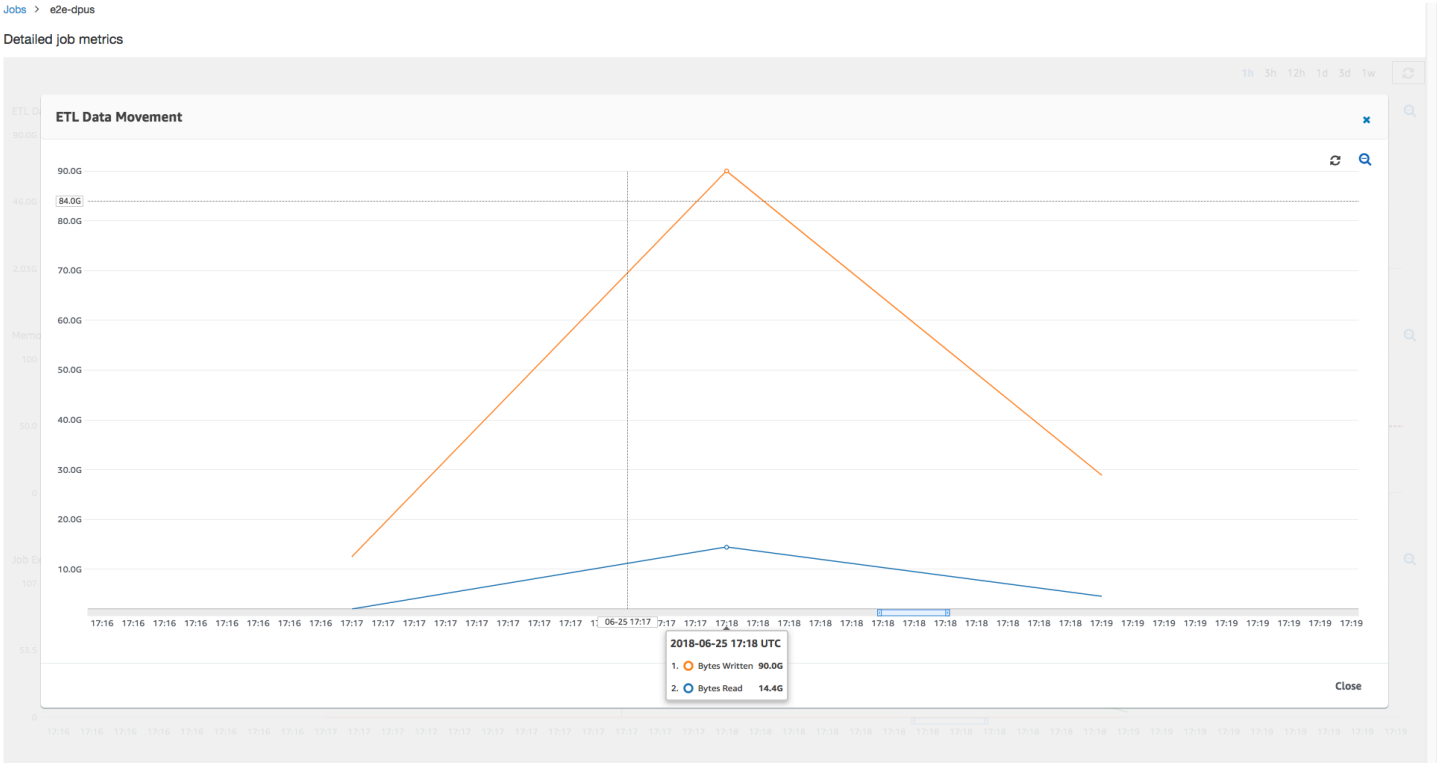

Essa execução de trabalho usa seis vezes mais executores para ler e gravar no Amazon S3 simultaneamente. Como resultado, essa execução de trabalho usa mais largura de banda do Amazon S3 para leituras e gravações e termina mais rapidamente.

Identificar DPUs provisionadas em excesso

Em seguida, você pode determinar se expandir o trabalho com 100 DPUs (99 * 2 = 198 executores) ajuda a expandir mais. Como o seguinte gráfico mostra, o trabalho ainda tem três minutos para terminar. Da mesma forma, o trabalho não ser expandido além de 107 executores (configuração de 55 DPUs) e os 91 executores restantes são fornecidos em excesso e não são usados. Isso mostra que o aumento do número de DPUs nem sempre pode melhorar a performance, como evidente no máximo necessário de executores.

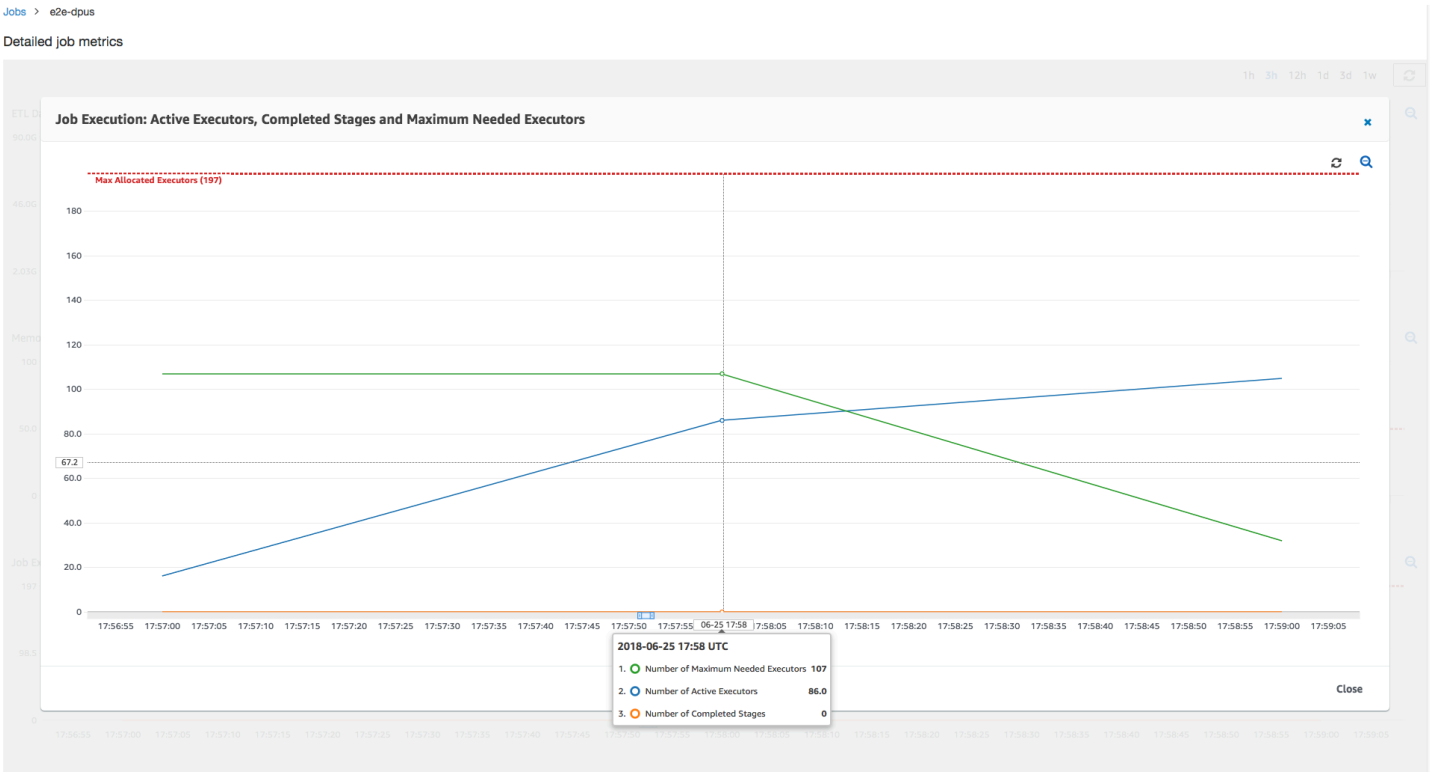

Comparar diferenças de tempo

As três execuções de trabalho mostradas na tabela a seguir resumem os tempos de execução de trabalho para 10 DPUs, 55 DPUs e 100 DPUs. Você pode ver que a capacidade da DPU melhora o tempo de execução do trabalho usando as estimativas estabelecidas ao monitorar a primeira execução do trabalho.

ID do trabalho	Número de DPUs	Tempo de execução
jr_c894524c8ef5048a4d9...	10	6 min.
jr_1a466cf2575e7ffe6856...	55	3 min.
jr_34fa1ed4c6aa9ff0a814...	100	3 min.

Solução de problemas de IA generativa para o Apache Spark no AWS Glue

A versão prévia de solução de problemas de IA generativa para Apache Spark está disponível para trabalhos executados no AWS Glue 4.0 e AWS Glue 5.0, e nas seguintes regiões da AWS:

- Leste dos EUA (Norte da Virgínia)
- Leste dos EUA (Ohio)
- Oeste dos EUA (Oregon)
- Oeste dos EUA (Norte da Califórnia)
- América do Sul (São Paulo)
- Canadá (Central)
- Europa (Irlanda)
- Europa (Londres)
- Europa (Paris)
- Europa (Estocolmo)
- Europa (Milão)
- Europa (Frankfurt)
- Oriente Médio (Bahrein)
- Oriente Médio (Emirados Árabes Unidos)
- África (Cidade do Cabo)
- Ásia-Pacífico (Tóquio)
- Ásia-Pacífico (Hong Kong)
- Asia Pacific (Mumbai)
- Ásia-Pacífico (Singapura)
- Ásia-Pacífico (Jacarta)
- Ásia-Pacífico (Seul)
- Asia Pacific (Osaka)
- Ásia-Pacífico (Sydney)

Os recursos de visualização prévia estão sujeitos a alterações.

A solução de problemas de IA generativa para trabalhos do Apache Spark no AWS Glue é um novo recurso que ajuda engenheiros e cientistas de dados a diagnosticar e corrigir problemas nas aplicações Spark com facilidade. Utilizando tecnologias de machine learning e IA generativa, esse recurso analisa problemas em trabalhos do Spark e fornece uma análise detalhada da causa raiz, com recomendações práticas para resolver estes problemas.

Como funciona a solução de problemas de IA generativa para o Apache Spark?

Para trabalhos do Spark que apresentam falha, a solução de problemas de IA generativa analisa os metadados do trabalho e as métricas e logs precisos associados à assinatura do erro do trabalho para gerar uma análise da causa raiz e recomenda soluções específicas e práticas recomendadas para ajudar a resolver falhas no trabalho.

Configuração da solução de problemas de IA generativa para trabalhos no Apache Spark

Configurar permissões do IAM

A concessão de permissões às APIs usadas pela solução de problemas do Spark para trabalhos no AWS Glue exige permissões apropriadas do IAM. Você pode obter permissões anexando a política da AWS a seguir personalizada à sua identidade do IAM (como usuário, perfil ou grupo).

```
{
"Version": "2012-10-17",
    "Statement": [
        {
"Effect": "Allow",
            "Action": [
                "glue:StartCompletion",
                "glue:GetCompletion"
            ],
            "Resource": [
                "arn:aws:glue:*:*:completion/*",
                "arn:aws:glue:*:*:job/*"
            ]
        }
    ]
}
```

> **Note**
>
> Durante a visualização prévia, a solução de problemas do Spark não tem APIs disponíveis por meio do AWS SDK que você possa usar de forma programática. As duas APIs a seguir são usadas na política do IAM para permitir essa experiência por meio do Console do AWS Glue Studio: `StartCompletion` e `GetCompletion`.

Atribuindo permissões

Para conceder acesso, adicione as permissões aos seus usuários, grupos ou perfis:

- Usuários e grupos no Centro de Identidade do IAM: criem um conjunto de permissões. Sigam as instruções em Criar um conjunto de permissões no Guia do usuário do Centro de Identidade do IAM.
- Usuários gerenciados no IAM por meio de um provedor de identidades: criem um perfil para federação de identidades. Sigam as instruções em Criar um perfil para um provedor de identidade de terceiros (federação) no Guia do Usuário do IAM.
- Usuários do IAM: criem um perfil que o usuário possa assumir. Sigam as instruções em Criar um perfil para um usuário do IAM no Guia do usuário do IAM.

Execução da análise de solução de problemas com base na execução de um trabalho com falha

Você pode acessar o recurso de solução de problemas por meio de vários caminhos no console do AWS Glue. Veja como começar:

Opção 1: na página Lista de trabalhos

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Trabalhos de ETL.
3. Localize o trabalho que apresentou falha na lista de trabalhos.
4. Selecione a guia Execuções na seção de detalhes do trabalho.
5. Clique na execução do trabalho que apresentou falha que você deseja analisar.
6. Escolha Solucionar problemas com IA para iniciar a análise.
7. Quando a análise da solução de problemas estiver concluída, você poderá visualizar a análise da causa raiz e as recomendações na guia Análise da solução de problemas na parte inferior da tela.

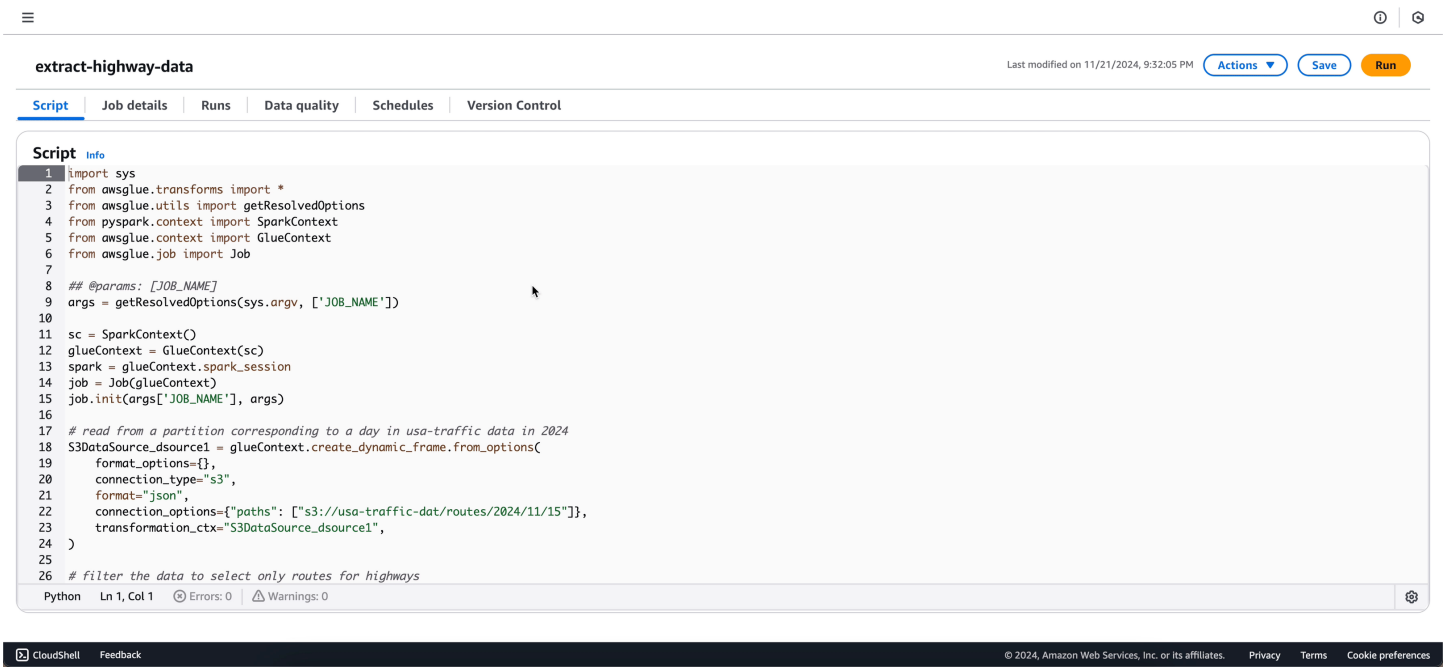

Opção 2: usando a página Monitoramento da execução do trabalho

1. Navegue até a página de Monitoramento da execução do trabalho.
2. Localize a execução do trabalho que apresentou falha.
3. Escolha o menu suspenso Ações.
4. Escolha Solucionar problemas com IA.

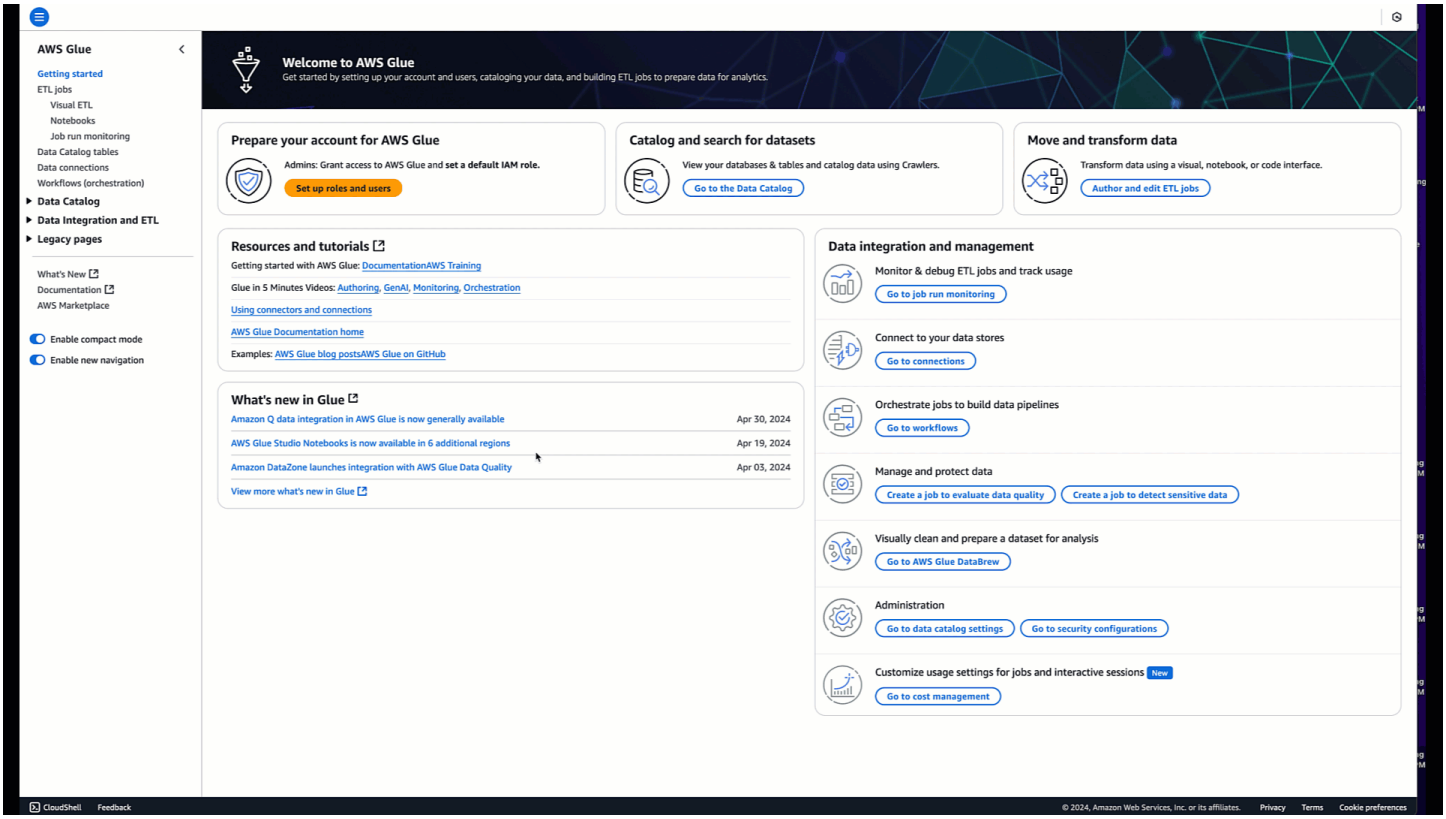

Opção 3: na página Detalhes da execução do trabalho

1. Navegue até a página de detalhes da execução do trabalho que apresentou falha clicando em Visualizar detalhes em uma execução com falha na guia Execuções ou selecionando a execução do trabalho na página Monitoramento da execução do trabalho.
2. Na página de detalhes da execução do trabalho, você encontrará a guia Análise da solução de problemas.

Categorias de solução de problemas compatíveis (visualização prévia)

Esse serviço se concentra em três categorias principais de problemas que engenheiros e desenvolvedores de dados frequentemente encontram em aplicações do Spark:

- Erros de configuração e acesso de recursos: ao executar aplicações do Spark no AWS Glue, os erros de configuração e acesso de recursos estão entre os problemas mais comuns, porém difíceis de diagnosticar. Esses erros muitas vezes ocorrem quando a aplicação do Spark tenta interagir com recursos da AWS, mas encontra problemas de permissão, de falta de recursos ou de configuração.

- Problemas de memória do driver e do executor do Spark: erros relacionados à memória em trabalhos do Apache Spark podem ser complexos de diagnosticar e resolver. Esses erros muitas vezes se manifestam quando os requisitos de processamento de dados excedem os recursos de memória disponíveis no nó do driver ou nos nós do executor.
- Problemas de capacidade de disco do Spark: erros relacionados a armazenamento em trabalhos do Spark no AWS Glue muitas vezes surgem durante operações de shuffle, vazamento de dados ou no caso de transformações de dados em grande escala. Esses erros podem ser particularmente complicados porque talvez não se manifestem até que o trabalho esteja em execução por algum tempo, podendo desperdiçar tempo e recursos de computação valiosos.

> **Note**
>
> Antes de implementar qualquer alteração sugerida no ambiente de produção, analise minuciosamente as alterações sugeridas. O serviço fornece recomendações com base em padrões e práticas recomendadas, mas seu caso de uso específico pode exigir considerações adicionais.

Trabalhos de transmissão de ETL no AWS Glue

É possível criar trabalhos de extração, transformação e carregamento (ETL) de transmissão que sejam executados continuamente e que consumam dados de fontes de transmissão, como o Amazon Kinesis Data Streams, Apache Kafka e Amazon Managed Streaming for Apache Kafka (Amazon MSK). Os trabalhos limpam e transformam os dados e, em seguida, carregam os resultados em data lakes do Amazon S3 ou armazenamentos de dados JDBC.

Além disso, você pode produzir dados para streams do Amazon Kinesis Data Streams. Esse atributo só está disponível ao escrever AWS Glue scripts. Para ter mais informações, consulte the section called “Conexões do Kinesis”.

Por padrão, o AWS Glue processa e grava dados em janelas de 100 segundos. Isso permite que os dados sejam processados de forma eficiente e que as agregações sejam realizadas em dados que chegam mais tarde do que o esperado. É possível modificar esse tamanho da janela para aumentar a pontualidade ou a precisão da agregação. Trabalhos de transmissão do AWS Glue usam pontos de verificação em vez de marcadores de trabalho para rastrear os dados que foram lidos.

> **Note**
>
> O AWS Glue cobra por hora por trabalhos de ETL de transmissão enquanto eles estão em execução.

Este vídeo discute os desafios de custo de ETL de streaming e os atributos de economia de custos do AWS Glue.

A criação de um trabalho de ETL de streaming envolve as seguintes etapas:

1. Para uma fonte de transmissão Apache Kafka, crie um conexão do AWS Glue com a origem do Kafka ou o cluster do Amazon MSK.
2. Crie manualmente uma tabela do Data Catalog para a fonte de transmissão.
3. Crie um trabalho de ETL para a fonte de dados de streaming. Defina propriedades de trabalho específicas de streaming e forneça seu próprio script ou, opcionalmente, modifique o script gerado.

Para ter mais informações, consulte ETL de streaming no AWS Glue.

Ao criar um trabalho de ETL de transmissão para o Amazon Kinesis Data Streams, você não precisa criar uma conexão do AWS Glue. No entanto, se houver uma conexão anexada ao trabalho de ETL de transmissão do AWS Glue que tenha o Kinesis Data Streams como origem, será necessário um endpoint de nuvem privada virtual (VPC) para o Kinesis. Para obter mais informações, consulte Criar um endpoint de interface no Guia do usuário da Amazon VPC. Ao especificar uma transmissão do Amazon Kinesis Data Streams em outra conta, você deve configurar as funções e políticas para permitir o acesso entre contas. Para obter mais informações, consulte Exemplo: Ler de uma transmissão do Kinesis em outra conta.

Os trabalhos de ETL do AWS Glue podem detectar automaticamente dados compactados, descompactar de forma transparente os dados de fluxo, realizar as transformações usuais na fonte de entrada e carregar no armazenamento de saída.

O AWS Glue oferece suporte à descompactação automática para os seguintes tipos de compactação, considerando o formato de entrada:

Tipo de compactação	Arquivo Avro	Dado Avro	JSON	CSV	Grok
BZIP2	Sim	Sim	Sim	Sim	Sim
GZIP	Não	Sim	Sim	Sim	Sim
SNAPPY	Sim (Snappy bruto)	Sim (Snappy com enquadramento)	Sim (Snappy com enquadramento)	Sim (Snappy com enquadramento)	Sim (Snappy com enquadramento)
XZ	Sim	Sim	Sim	Sim	Sim
ZSTD	Sim	Não	Não	Não	Não
DEFLATE	Sim	Sim	Sim	Sim	Sim

Tópicos

- Criar uma conexão do AWS Glue para um fluxo de dados do Apache Kafka
- Criar uma tabela do Data Catalog para uma fonte de transmissão
- Notas e restrições para fontes de transmissão Avro
- Aplicar padrões grok a fontes de transmissão
- Definir propriedades de trabalho para um trabalho de ETL de transmissão
- Notas e restrições sobre ETL de transmissão

Criar uma conexão do AWS Glue para um fluxo de dados do Apache Kafka

Para ler a partir de um stream do Apache Kafka, é necessário criar uma conexão do AWS Glue.

Como criar uma conexão do AWS Glue para uma fonte do Kafka (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em Data catalog (catálogo de dados), selecione Connections (Conexões).

3. Escolha Add connection (Adicionar conexão) e, na página Set up your connection's properties (Configurar propriedades da conexão) insira um nome de conexão.

   > **Note**
   >
   > Para obter mais informações sobre como especificar propriedades de conexão, consulte Propriedades de conexão do AWS Glue.

4. Em Tipo de conexão, escolha Kafka.
5. Para os URLs de servidores de bootstrap do Kafka, insira o host e o número da porta para o agente de bootstrap do cluster do Amazon MSK ou do Apache Kafka. Use somente endpoints de Transport Layer Security (TLS) para estabelecer a conexão inicial com o cluster do Kafka. Os endpoints plaintext não são compatíveis.

   Veja a seguir um exemplo de lista de pares de nome de host e de números de porta para um cluster do 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
   ```

   Para mais informações sobre como obter as informações do agente de bootstrap, consulte Obter os agentes de bootstrap para um cluster do Amazon MSK no Guia do desenvolvedor do Amazon Managed Streaming for Apache Kafka.
6. Se você quiser uma conexão segura com a origem dos dados do Kafka, selecione Require SSL connection (Exigir conexão SSL), e em Kafka private CA certificate location (Localização do certificado CA privado do Kafka), insira um caminho válido do Amazon S3 para um certificado SSL personalizado.

   Para uma conexão SSL com o Kafka autogerenciado, o certificado personalizado é obrigatório. Ele é opcional para o Amazon MSK.

   Para obter mais informações sobre como especificar um certificado personalizado para o Kafka, consulte the section called "Propriedades de conexão SSL".
7. Use o AWS Glue Studio ou a AWS CLI para especificar um método de autenticação de cliente do Kafka. Para acessar o AWS Glue Studio, selecione AWS Glue no menu ETL no painel de navegação esquerdo.

Para obter mais informações sobre métodos de autenticação do cliente Kafka, consulte Propriedades de conexão do AWS Glue Kafka para autenticação do cliente .

8. Opcionalmente, insira uma descrição e, em seguida, escolha Next (Próximo).
9. Para um cluster do Amazon MSK, especifique sua nuvem privada virtual (VPC), sub-rede e grupo de segurança. As informações da VPC são opcionais para o Kafka autogerenciado.
10. Selecione Next (Próximo) para rever todas as propriedades de conexão e, em seguida, escolha Finish (Finalizar).

Para obter mais informações sobre conexões do AWS Glue, consulte Conectar a dados.

Propriedades de conexão do AWS Glue Kafka para autenticação do cliente

Autenticação SASL/GSSAPI (Kerberos)

Escolher esse método de autenticação permitirá que você especifique propriedades Kerberos.

Kerberos Keytab

Escolha o local do arquivo keytab. Um keytab armazena chaves de longo prazo para um ou mais principais. Para obter mais informações, consulte Documentação do MIT Kerberos: Keytab.

Arquivo Kerberos krb5.conf

Escolha o arquivo krb5.conf. Ele contém o realm padrão (uma rede lógica, semelhante a um domínio, que define um grupo de sistemas sob o mesmo KDC) e a localização do servidor KDC. Para obter mais informações, consulte Documentação do MIT Kerberos: krb5.conf.

Entidade principal do Kerberos e nome do serviço Kerberos

Insira a entidade principal do Kerberos e nome do serviço. Para obter mais informações, consulte Documentação do MIT Kerberos: entidade principal do Kerberos.

Autenticação SASL/SCRAM-SHA-512

Escolher esse método de autenticação permitirá que você especifique credenciais de autenticação.

AWS Secrets Manager

Pesquise seu token na caixa Pesquisar digitando o nome ou o ARN.

Nome de usuário e senha do provedor diretamente

Pesquise seu token na caixa Pesquisar digitando o nome ou o ARN.

Autenticação de cliente SSL

Escolher esse método de autenticação permite que você selecione o local do keystore do cliente Kafka ao navegar no Amazon S3. Opcionalmente, você pode inserir a senha do keystore do cliente Kafka e a senha da chave do cliente Kafka.

Autenticação do IAM

O método de autenticação não requer especificações adicionais e só é aplicável quando a fonte do streaming é o MSK Kafka.

Autenticação SASL/PLAIN

Escolher esse método de autenticação permite a você especificar credenciais de autenticação.

Criar uma tabela do Data Catalog para uma fonte de transmissão

É possível criar manualmente uma tabela do Data Catalog que especifique as propriedades do fluxo de dados da fonte, incluindo o esquema de dados. Essa tabela é usada como fonte de dados para o trabalho de ETL de streaming.

Se você não souber o esquema dos dados no fluxo de dados de origem, poderá criar a tabela sem um esquema. Em seguida, quando você cria o trabalho ETL de transmissão, pode ativar a função de detecção de esquema do AWS Glue. O AWS Glue determina o esquema dos dados de transmissão.

Use o console do AWS Glue, a AWS Command Line Interface (AWS CLI) ou a API do AWS Glue para criar a tabela. Para obter informações sobre como criar uma tabela manualmente com o console do AWS Glue, consulte the section called “Criar tabelas”.

> **Note**
>
> Não é possível usar o console do AWS Lake Formation para criar a tabela; é necessário usar o console do AWS Glue.

Considere também as seguintes informações para fontes de transmissão no formato Avro ou para dados de log aos quais você pode aplicar padrões Grok.

- the section called “Notas e restrições para fontes de transmissão Avro”
- the section called “Aplicar padrões grok a fontes de transmissão”

Tópicos

- Fonte de dados do Kinesis
- Fonte de dados do Kafka
- Fonte da tabela do registro de esquemas do AWS Glue

Fonte de dados do Kinesis

Ao criar a tabela, defina as seguintes propriedades de ETL de transmissão (console).

Tipo de fonte

Kinesis

Para uma fonte do Kinesis na mesma conta:

Região

A região da AWS onde reside o serviço do Amazon Kinesis Data Streams. O nome da transmissão do Kinesis e da região são traduzidos juntos para um ARN de transmissão.

Exemplo: https://kinesis.us-east-1.amazonaws.com

Nome da transmissão do Kinesis

Nome do stream conforme descrito em Criar um stream no Guia do desenvolvedor do Amazon Kinesis Data Streams.

Para obter uma fonte do Kinesis em outra conta, consulte este exemplo para configurar as funções e políticas a fim de permitir o acesso entre contas. Defina estas configurações:

ARN da transmissão

O ARN do fluxo de dados do Kinesis no qual o consumidor está registrado. Para obter mais informações, consulte Nomes de recursos da Amazon (ARNs) e namespaces de serviço da AWS no Referência geral da AWS.

ARN da função assumida

O nome do recurso da Amazon (ARN) da função a ser assumida.

Nome da sessão (opcional)

Um identificador para a sessão de função assumida.

Use o nome da sessão de função para identificar exclusivamente uma sessão quando a mesma função for assumida por outras entidades principais ou por motivos diferentes. Em

cenários entre contas, o nome da sessão de função fica visível e pode ser acessado pela conta que possui a função. O nome da sessão de função também é usado no ARN da entidade principal da função assumida. Isso significa que solicitações subsequentes de API entre contas que usam as credenciais de segurança temporárias vão expor o nome da sessão de função à conta externa em seus logs do AWS CloudTrail.

Para definir propriedades de ETL de transmissão para o Amazon Kinesis Data Streams (API do AWS Glue ou AWS CLI)

- Para configurar as propriedades de ETL de transmissão para uma fonte do Kinesis na mesma conta, especifique os parâmetros `streamName` e `endpointUrl` na estrutura `StorageDescriptor` da operação da API `CreateTable` ou do comando da CLI `create_table`.

```
"StorageDescriptor": {
 "Parameters": {
  "typeOfData": "kinesis",
  "streamName": "sample-stream",
  "endpointUrl": "https://kinesis.us-east-1.amazonaws.com"
 }
 ...
}
```

  Ou especifique o `streamARN`.

  Example

```
"StorageDescriptor": {
 "Parameters": {
  "typeOfData": "kinesis",
  "streamARN": "arn:aws:kinesis:us-east-1:123456789:stream/sample-stream"
 }
 ...
}
```

- Para configurar as propriedades de ETL de transmissão para uma fonte do Kinesis na mesma conta, especifique os parâmetros `streamARN`, `awsSTSRoleARN` e `awsSTSSessionName` (opcional) na estrutura `StorageDescriptor` da operação da API `CreateTable` ou do comando da CLI `create_table`.

```
"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"
 }
 ...
}
```

Fonte de dados do Kafka

Ao criar a tabela, defina as seguintes propriedades de ETL de transmissão (console).

Tipo de fonte

Kafka

Para uma fonte do Kafka:

Nome do tópico

Nome do tópico conforme especificado no Kafka.

Conexão

Uma conexão do AWS Glue que faz referência a uma fonte do Kafka, conforme descrito em the section called “Criar uma conexão para um fluxo de dados do Kafka”.

Fonte da tabela do registro de esquemas do AWS Glue

Para usar o registro de esquemas do AWS Glue para trabalhos de transmissão, siga as instruções em Caso de uso: AWS Glue Data Catalog para criar ou atualizar uma tabela de registro de esquemas.

Atualmente, a transmissão do AWS Glue oferece suporte somente ao formato Avro de registro do esquemas do Glue com inferência de esquema definida como `false`.

Notas e restrições para fontes de transmissão Avro

As seguintes notas e restrições se aplicam a fontes de transmissão no formato Avro:

- Quando a detecção de esquema está ativada, o esquema Avro deve ser incluído na carga útil. Quando desligado, a carga útil deve conter apenas dados.
- Alguns tipos de dados Avro não são suportados em quadros dinâmicos. Você não pode especificar esses tipos de dados ao definir o esquema com a página Define a schema (Definir um esquema) no assistente de criação de tabela no console do AWS Glue. Durante a detecção de esquema, os tipos não suportados no esquema Avro são convertidos para tipos suportados da seguinte forma:
  - `EnumType => StringType`
  - `FixedType => BinaryType`
  - `UnionType => StructType`
- Se você definir o esquema de tabela usando a página Define a schema (Definir um esquema) no console, o tipo de elemento raiz implícito para o esquema será `record`. Se você quiser um tipo de elemento raiz diferente de `record`, por exemplo, `array` ou `map`, não deve especificar o esquema usando a página Define a schema (Definir um esquema). Em vez disso, você deve ignorar essa página e especificar o esquema como uma propriedade de tabela ou dentro do script de ETL.
  - Para especificar o esquema nas propriedades da tabela, conclua o assistente de criação de tabela, edite os detalhes da tabela e adicione um novo par de chave-valor em Table properties (Propriedades da tabela). Use a chave `avroSchema` e insira um objeto JSON de esquema para o valor, conforme mostrado na captura de tela a seguir.

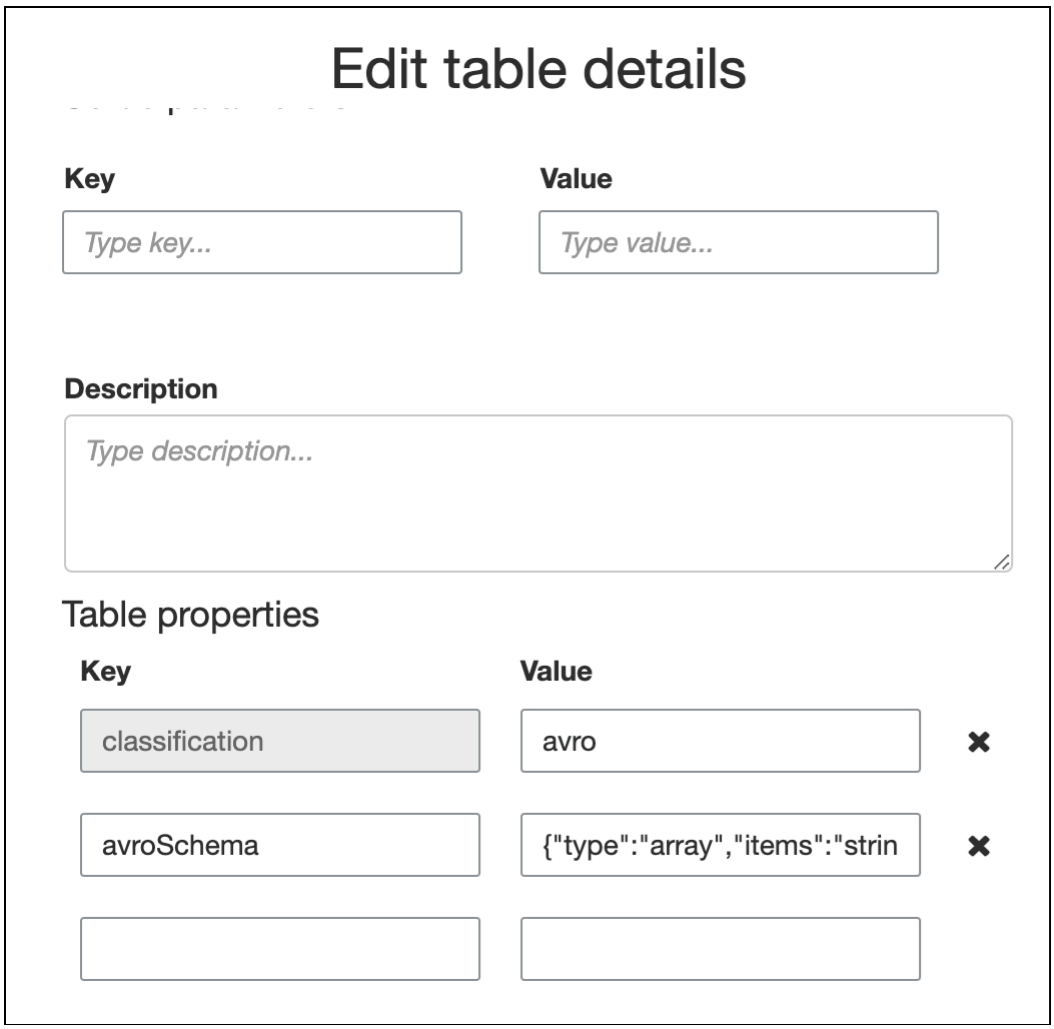

- Para especificar o esquema no script de ETL, modifique a instrução de atribuição `datasource0` e adicione a chave `avroSchema` ao argumento `additional_options`, conforme mostrado nos exemplos de Python e Scala a seguir.

  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()
```

Aplicar padrões grok a fontes de transmissão

Você pode criar um trabalho de ETL de transmissão para uma fonte dos dados de log e usar padrões Grok para converter os logs em dados estruturados. Em seguida, o trabalho de ETL processa os dados como uma fonte de dados estruturada. Você especifica os padrões Grok a serem aplicados ao criar a tabela do Data Catalog para a fonte de transmissão.

Para obter informações sobre padrões Grok e valores de string padrão personalizados, consulte Gravar classificadores grok personalizados.

Para adicionar padrões grok à tabela do Data Catalog (console)

- Use o assistente de criação de tabela e a crie com os parâmetros especificados em the section called “Criar uma tabela do Data Catalog para uma fonte de transmissão”. Especifique o formato de dados como Grok, preencha o campo Grok pattern (Padrão Grok) e, opcionalmente, adicione padrões personalizados em Custom patterns (optional) (Padrões personalizados [opcional]).

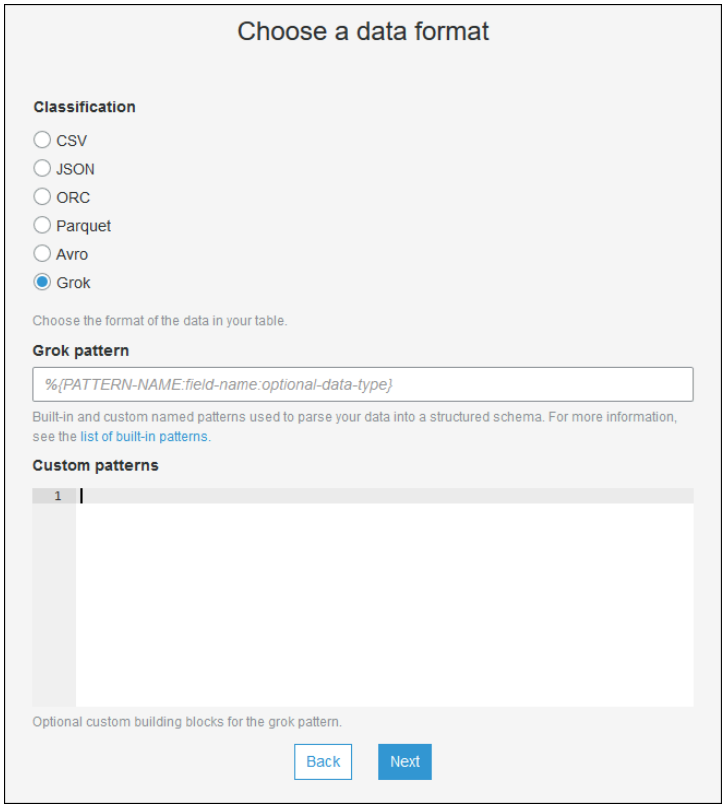

  Pressione Enter após cada padrão personalizado.

Para adicionar padrões grok à tabela do Data Catalog (API do AWS Glue ou AWS CLI)

- Adicionar o parâmetro `GrokPattern` e, opcionalmente, o parâmetro `CustomPatterns` à operação da API `CreateTable` ou comando da CLI `create_table`.

```
 "Parameters": {
...
    "grokPattern": "string",
    "grokCustomPatterns": "string",
...
},
```

Expresse `grokCustomPatterns` como uma string e use “\n” como o separador entre padrões.

Veja a seguir um exemplo desses parâmetros em um arquivo.

Example

```
"parameters": {
...
    "grokPattern": "%{USERNAME:username} %{DIGIT:digit:int}",
    "grokCustomPatterns": "digit \d",
...
}
```

Definir propriedades de trabalho para um trabalho de ETL de transmissão

Ao definir um trabalho de ETL de transmissão no console do AWS Glue, forneça as seguintes propriedades específicas de transmissão. Para descrições de propriedades de trabalhos adicionais, consulte Definir propriedades de trabalho para trabalhos do Spark.

Perfil do IAM

Especifique a função do AWS Identity and Access Management (IAM) usada para a autorização dos recursos necessários para executar o trabalho, acessar fontes de transmissão e armazenamentos de dados de destino.

Para obter acesso ao Amazon Kinesis Data Streams, associe a política `AmazonKinesisFullAccess` gerenciada pela AWS à função ou associe uma política do IAM

semelhante que permita um acesso mais granular. Para ver políticas de exemplo, consulte Controlar o acesso aos recursos do Amazon Kinesis Data Streams usando o IAM.

Para obter mais informações sobre permissões de execução de trabalho no AWS Glue, consulte Gerenciamento de identidade e acesso do AWS Glue.

Tipo

Escolha Spark streaming (Streaming do Spark).

Versão do AWS Glue

A versão do AWS Glue determina as versões do Apache Spark, e Python ou Scala, que estão disponíveis para o trabalho. Escolha uma seleção que especifique a versão do Python ou do Scala disponível para o trabalho. O AWS Glue Versão 2.0 com suporte a Python 3 é o padrão para trabalhos de ETL de transmissão.

Janela de manutenção

Especifica uma janela na qual um trabalho de streaming pode ser reiniciado. Consulte the section called “Janelas de manutenção”.

Tempo limite de trabalho

Opcionalmente, informe uma duração em minutos. O valor padrão é em branco.

- Os trabalhos de streaming devem ter valores de tempo limite inferiores a 7 dias ou 10.080 minutos.
- Quando o valor for deixado em branco, o trabalho será reiniciado após 7 dias caso você não tenha configurado uma janela de manutenção. Se você tiver uma janela de manutenção configurada, o trabalho será reiniciado durante a janela de manutenção após 7 dias.

Fonte de dados

Remova a tabela criada em the section called “Criar uma tabela do Data Catalog para uma fonte de transmissão”.

Destino de dados

Execute um destes procedimentos:

- Escolha Create tables in your data target (Criar tabelas no destino de dados) e especifique as propriedades do destino de dados a seguir.

  Datastore

  Escolha Amazon S3 ou JDBC.

Formato

Escolha qualquer formato. Todos são compatíveis com streaming.

- Escolha Use tables in the data catalog and update your data target (Usar tabelas no catálogo de dados e atualizar seu destino de dados) e escolha uma tabela para um datastore JDBC.

Definição do esquema de saída

Execute um destes procedimentos:

- Escolha Automatically detect schema of each record (Detectar automaticamente o esquema de cada registro) para ativar a detecção de esquemas. O AWS Glue determina o esquema dos dados de transmissão.
- Escolha Specify output schema for all records (Especificar esquema de saída para todos os registros) para usar a transformação Apply Mapping (Aplicar mapeamento) e definir o esquema de saída.

Script

Opcionalmente, forneça seu próprio script ou modifique o script gerado para executar operações compatíveis com o mecanismo do Apache Spark Structured Streaming. Para obter informações sobre as operações disponíveis, consulte Operações em streaming de DataFrames/conjuntos de dados.

Notas e restrições sobre ETL de transmissão

Tenha em mente as seguintes notas e restrições:

- A descompactação automática para trabalhos de ETL de fluxo do AWS Glue só está disponível para os tipos de compactação compatíveis. Observe o seguinte:
  - Snappy com enquadramento refere-se ao formato de enquadramento oficial para o Snappy.
  - Deflate é compatível com o Glue versão 3.0, mas não com o Glue versão 2.0.
- Ao usar a detecção de esquema, você não pode realizar junções de dados de transmissão.
- Os trabalhos de ETL de transmissão do AWS Glue não são compatíveis com o tipo de dados Union para registro de esquema do AWS Glue com o formato Avro.
- Seu script de ETL pode usar as transformações nativas do AWS Glue e as transformações nativas do Apache Spark Structured Streaming. Para obter mais informações, consulte Operations on streaming DataFrames/Datasets (Operações em transmissão de dataframes/conjuntos de dados) no website do Apache Spark ou Referência de transformações PySpark do AWS Glue.

- Os trabalhos de ETL de transmissão do AWS Glue usam pontos de verificação para acompanhar os dados que foram lidos. Portanto, um trabalho interrompido e reiniciado é retomado de onde parou no streaming. Se desejar reprocessar dados, você poderá excluir a pasta de ponto de verificação indicada no script.
- Marcadores de trabalho não são compatíveis.
- Para usar o atributo de distribuição avançada de fluxo de dados do Kinesis no trabalho, consulte the section called “Usar distribuição avançada nas tarefas de streaming do Kinesis”.
- Se você usar uma tabela de catálogo de dados criada a partir do registro de esquemas do AWS Glue, quando uma nova versão do esquema se tornar disponível, para refletir o novo esquema, você precisará fazer o seguinte:
  1. Pare os trabalhos associados à tabela.
  2. Atualize o esquema para a tabela do catálogo de dados.
  3. Reinicie os trabalhos associados à tabela.

Correspondência de registros com o FindMatches do AWS Lake Formation

> **Note**
>
> No momento, a correspondência de registros não está disponível nas seguintes regiões no console do AWS Glue: Oriente Médio (EAU), Europa (Espanha), Ásia-Pacífico (Jacarta) e Europa (Zurique).

O AWS Lake Formation fornece recursos de machine learning para criar transformações personalizadas para limpar seus dados. No momento, existe uma transformação disponível chamada FindMatches. A transformação FindMatches permite identificar registros duplicados ou correspondentes no seu conjunto de dados, mesmo quando os registros não têm um identificador exclusivo comum e quando não há campos com uma correspondência exata. Isso não exigirá escrever nenhum código ou saber como o machine learning funciona. A transformação FindMatches pode ser útil em muitos problemas diferentes, como:

- Matching customers (Correspondência de clientes): vinculação de registros de clientes em diferentes bancos de dados de clientes, mesmo quando muitos campos de clientes não correspondem exatamente entre os bancos de dados (por exemplo, grafia diferente do nome, diferenças de endereço, dados ausentes ou imprecisos etc.).

- Matching products (Correspondência de produtos): correspondência de produtos em seu catálogo com relação a outras fontes de produtos, como catálogo de produtos com relação ao catálogo de um concorrente, onde as entradas são estruturadas de outra forma.
- Improving fraud detection (Melhoria da detecção de fraudes): identificação de contas de clientes duplicadas, determinação de quando uma conta recém-criada é (ou pode ser) correspondente a um usuário fraudulento conhecido anteriormente.
- Other matching problems (Outros problemas de correspondência): correspondência de endereços, filmes, listas de peças etc. Em geral, se um ser humano conseguir olhar suas linhas de banco de dados e determinar se elas são uma correspondência, haverá uma boa chance de que a transformação FindMatches possa ajudá-lo.

É possível criar essas transformações ao criar uma tarefa. A transformação que você cria tem como base um esquema de datastore de origem e dados de exemplo da fonte de dados rotulados por você (chamamos esse processo de "ensinar" uma transformação). Os registros que você rotula devem estar presentes no conjunto de dados de origem. Nesse processo, geramos um arquivo que você rotula e carrega novamente, e que ajudaria a transformação a aprender. Depois de ensinar a transformação, você poderá chamá-la no trabalho do AWS Glue baseado no Spark (PySpark ou Scala Spark) e usá-la em outros scripts com um datastore de origem compatível.

Depois que a transformação é criada, ela é armazenada no AWS Glue. No console do AWS Glue, é possível gerenciar as transformações que você cria. No painel de navegação em Integração de dados e ETL, Ferramentas de classificação de dados > Correspondência de registros, você pode editar e continuar a ensinar a sua transformação de machine learning. Para obter mais informações sobre como gerenciar transformações no console, consulte Trabalhar com transformações de machine learning.

> **Note**
>
> Os trabalhos do FindMatches do AWS Glue versão 2.0 usam o `aws-glue-temp-<accountID>-<region>` do bucket do Amazon S3 para armazenar arquivos temporários enquanto a transformação está processando dados. Você pode excluir esses dados após a conclusão da execução, manualmente ou definindo uma regra de ciclo de vida do Amazon S3.

Tipos de transformações de machine learning

Você pode criar transformações de machine learning para limpar os dados. Você pode chamar essas transformações no seu script de ETL. Os seus dados passam de transformação para transformação em uma estrutura de dados chamada DynamicFrame, que é a extensão de uma `DataFrame` do Apache Spark SQL. O `DynamicFrame` contém os dados, e você referencia o esquema para processar os dados.

Os seguintes tipos de transformações de machine learning estão disponíveis:

Encontrar correspondências

Encontra registros duplicados nos dados de origem. Ensine essa transformação de machine learning rotulando exemplos de conjuntos de dados para indicar quais linhas são correspondentes. Quanto mais você ensina a transformação de machine learning com exemplos de dados rotulados, mais ela aprende quais linhas devem ser correspondências. Dependendo de como você configura a transformação, a saída será:

- Uma cópia da tabela de entrada, além de uma coluna `match_id` preenchida com valores que indicam conjuntos correspondentes de registros. A coluna `match_id` é um identificador arbitrário. Todos os registros que têm o mesmo `match_id` foram identificados como correspondentes entre si. Os registros com `match_id` diferente não são correspondentes.
- Uma cópia da tabela de entrada com as linhas duplicadas removidas. Se várias duplicatas forem encontradas, o registro com a menor chave primária será mantido.

Localização de correspondências incrementais

A transformação Find matches (Localizar correspondências) também pode ser configurada para localizar correspondências entre os quadros existentes e incrementais e retornar como saída uma coluna contendo um ID exclusivo por grupo de correspondência.

Para obter mais informações, consulte: Localizar correspondências incrementais

Usando a transformação FindMatches

É possível usar a transformação `FindMatches` para encontrar registros duplicados nos dados de origem. Um arquivo de rotulamento é gerado ou fornecido para ajudar a ensinar a transformação.

> **Note**
>
> No momento, não há suporte para transformações `FindMatches` que usem uma chave de criptografia personalizada nas seguintes regiões:
>
> - Asia Pacific (Osaka) - `ap-northeast-3`

Para começar com a transformação FindMatches, você pode seguir as etapas abaixo. Para um exemplo mais avançado e detalhado, consulte o blog de Big Data da AWS: Harmonize data using AWS Glue and AWS Lake Formation FindMatches ML to build a customer 360 view.

Conceitos básicos do uso da transformação Find Matches

Siga estas etapas para começar a usar a transformação `FindMatches`:

1. Crie uma tabela no AWS Glue Data Catalog para os dados de origem que devem ser limpos. Para obter informações sobre como criar um crawler, consulte Trabalhar com crawlers no console do AWS Glue.

   Se os seus dados de origem forem um arquivo baseado em texto, como um arquivo de valores separados por vírgulas (CSV), considere o seguinte:

   - Mantenha o arquivo CSV de registros de entrada e o arquivo de rotulamento em pastas separadas. Caso contrário, o crawler do AWS Glue poderá considerá-los como várias partes da mesma tabela e criar tabelas no Data Catalog de maneira incorreta.
   - A menos que o arquivo CSV inclua somente caracteres ASCII, garanta que a codificação UTF-8 sem BOM (marca de ordem de byte) seja usada para os arquivos CSV. Geralmente, o Microsoft Excel adiciona uma BOM no início dos arquivos CSV em UTF-8. Para removê-la, abra o arquivo CSV em um editor de texto e salve novamente o arquivo como UTF-8 without BOM (UTF-8 sem BOM).
2. No console do AWS Glue, crie uma tarefa e selecione o tipo de transformação Find matches (Encontrar correspondências).

   > **Important**
   >
   > A tabela da fonte de dados que você escolher para a tarefa não pode ter mais de 100 colunas.

3. Instrua o AWS Glue a gerar um arquivo de rotulamento selecionando Generate labeling file (Gerar arquivo de rotulamento). O AWS Glue dá o primeiro passo no agrupamento de registros semelhantes para cada `labeling_set_id`, de maneira que você possa revisar esses agrupamentos. Rotule correspondências de rótulos na coluna `label`.
   - Se você já tiver um arquivo de rotulagem, ou seja, um exemplo de registros que indicam linhas correspondentes, faça upload do arquivo no Amazon Simple Storage Service (Amazon S3). Para obter informações sobre o formato do arquivo de rotulamento, consulte Formato do arquivo de rotulagem. Prossiga para a etapa 4.
4. Faça download do arquivo de rotulamento e rotule-o conforme descrito na seção Rótulo.
5. Faça upload do arquivo de rotulamento corrigido. O AWS Glue executa tarefas para ensinar a transformação a encontrar correspondências.

   Na página da lista Machine learning transforms (Transformações de machine learning), selecione a guia History (Histórico). Essa página indica quando o AWS Glue realiza as seguintes tarefas:
   - Import labels (Importar rótulos)
   - Export labels (Exportar rótulos)
   - Generate labels (Gerar rótulos)
   - Estimate quality (Estimar qualidade)
6. Para criar uma transformação melhor, é possível fazer download, rotular e fazer upload do arquivo rotulado de maneira iterativa. Nas execuções iniciais, pode haver muito mais correspondências incorretas. No entanto, o AWS Glue aprende à medida que você continua a ensiná-lo ao verificar o arquivo de rotulamento.
7. Avalie e ajuste a transformação avaliando a performance e os resultados da localização de correspondências. Para obter mais informações, consulte Ajustar transformações de machine learning no AWS Glue.

Rótulo

Quando a `FindMatches` gera um arquivo de rotulamento, os registros são selecionados da tabela de origem. Com base no treinamento anterior, a `FindMatches` identifica os registros mais valiosos dos quais deve aprender.

A ação de rotulamento consiste na edição de um arquivo de rotulamento (sugerimos usar uma planilha como o Microsoft Excel) e na adição de identificadores, ou rótulos, na coluna `label` que identifica registros correspondentes e não correspondentes. É importante ter uma definição clara e consistente de uma correspondência nos dados de origem. A `FindMatches` aprende dos registros

que você designa como correspondências (ou não) e usa suas decisões para aprender a encontrar registros duplicados.

Quando um arquivo de rotulamento é gerado pela `FindMatches`, são gerados aproximadamente 100 registros. Geralmente, esses 100 registros são divididos em 10 conjuntos de rotulagem, nos quais cada conjunto de rótulos é identificado por um `labeling_set_id` exclusivo gerado pela `FindMatches`. Cada conjunto de rótulos deve ser visto como uma tarefa de rotulagem separada e independente dos demais conjuntos de rótulos. A sua tarefa é identificar os registros correspondentes e não correspondentes dentro de cada conjunto de rótulos.

Dicas para editar arquivos de rotulagem em uma planilha

Ao editar o arquivo de rotulamento em um aplicativo de planilha, considere o seguinte:

- O arquivo pode não abrir com os campos de coluna totalmente expandidos. Pode ser necessário expandir as colunas `labeling_set_id` e `label` para ver o conteúdo dessas células.
- Se a coluna de chave primária for um número, como um tipo de dados `long`, a planilha poderá interpretá-la como um número e alterar o valor. Esse valor de chave deve ser tratado como texto. Para corrigir esse problema, formate todas as células da coluna de chave primária como Text data (Dados de texto).

Formato do arquivo de rotulagem

O arquivo de rotulamento gerado pelo AWS Glue para ensinar a transformação `FindMatches` usa o formato a seguir. Se você gerar o seu próprio arquivo para o AWS Glue, ele também deve seguir este formato:

- É um arquivo de valores separados por vírgulas (CSV).
- Deve estar codificado em `UTF-8`. Se você editar o arquivo usando o Microsoft Windows, ele poderá ser codificado com `cp1252`.
- Ele deve estar em um local do Amazon S3 para ser transmitido ao AWS Glue.
- Use uma quantidade moderada de linhas para cada tarefa de rotulagem. Recomenda-se 10 a 20 linhas por tarefa, embora 2 a 30 linhas por tarefa seja aceitável. Tarefas com mais de 50 linhas não são recomendadas e podem gerar resultados insatisfatórios ou uma falha no sistema.
- Caso já tenha dados rotulados que consistam em pares de registros rotulados como “correspondência” ou “não correspondência”, não há problema. Esses pares rotulados podem ser representados como conjuntos de rótulos de tamanho 2. Nesse caso, rotule ambos os registros

com, por exemplo, uma letra “A” caso haja correspondência, e rotule um como “A” e outro como “B” caso não haja correspondência.

> **Note**
>
> Como ele tem colunas adicionais, o arquivo de rotulamento tem um esquema diferente de um arquivo que contém os dados de origem. Coloque o arquivo de rotulagem em uma pasta diferente de qualquer arquivo CSV de entrada da transformação, para que o crawler do AWS Glue não o considere ao criar tabelas no Data Catalog. Caso contrário, a tabela criada pelo crawler do AWS Glue poderá não representar seus dados de maneira correta.

- As duas primeiras colunas (`labeling_set_id` e `label`) são exigidas pelo AWS Glue. As colunas restantes devem corresponder ao esquema dos dados a serem processados.
- Para cada `labeling_set_id`, identifique todos os registros correspondentes usando o mesmo rótulo. Um rótulo é uma string exclusiva colocada na coluna `label`. Recomendamos o uso de rótulos que contenham caracteres simples, como A, B, C e assim por diante. Os rótulos diferenciam letras maiúsculas de minúsculas e são inseridos na coluna `label`.
- As linhas que contêm o mesmo `labeling_set_id` e o mesmo rótulo são rotuladas como uma correspondência.
- As linhas que contêm o mesmo `labeling_set_id` e um rótulo diferente são rotuladas como uma não correspondência.
- As linhas que contêm um `labeling_set_id` diferente não têm informações que confirmam ou rejeitam a correspondência.

Veja a seguir um exemplo de rotulamento dos dados:

labeling_set_id	rótulo	first_name	last_name	Aniversário
ABC123	A	John	Doe	01/04/1980
ABC123	B	Jane	Smith	03/04/1980
ABC123	A	Johnny	Doe	01/04/1980
ABC123	A	Jon	Doe	01/04/1980
DEF345	A	Richard	Jones	11/12/1992

labeling_set_id	rótulo	first_name	last_name	Aniversário
DEF345	A	Rich	Jones	12/11/1992
DEF345	B	Sara	Jones	11/12/1992
DEF345	C	Richie	Jones Jr.	06/05/2017
DEF345	B	Sara	Jones-Walker	11/12/1992
GHI678	A	Robert	Miller	03/01/1999
GHI678	A	Bob	Miller	03/01/1999
XYZABC	A	William	Robinson	05/02/2001
XYZABC	B	Andrew	Robinson	05/02/1971

- No exemplo acima, identificamos John/Johnny/Jon Doe como sendo uma correspondência e ensinamos o sistema que esses registros não correspondem a Jane Smith. Separadamente, ensinamos ao sistema que Richard e Rich Jones são a mesma pessoa, mas esses registros não correspondem a Sarah Jones/Jones-Walker e Richie Jones Jr.
- Como pode ver, o escopo dos rótulos está limitado ao `labeling_set_id`. Portanto, os rótulos não cruzam os limites de `labeling_set_id`. Por exemplo, um rótulo "A" em `labeling_set_id` 1 não tem nenhuma relação com o rótulo "A" em `labeling_set_id` 2.
- Se um registro não tiver correspondências dentro de um conjunto de rótulos, atribua um rótulo exclusivo ao registro. Por exemplo, Jane Smith não corresponde a qualquer registro no conjunto de rótulos ABC123, portanto, é o único registro nesse conjunto com o rótulo B.
- O conjunto de rótulos “GHI678” mostra que um conjunto de rótulos pode consistir em apenas dois registros, que recebem o mesmo rótulo para indicar a correspondência. Da mesma forma, “XYZABC” mostra dois registros com rótulos diferentes para indicar que não são correspondentes.
- Observe que, às vezes, um conjunto de rótulos pode não conter correspondências (ou seja, você atribui um rótulo diferente para cada registro dentro do conjunto de rótulos) ou todos os registros do conjunto de rótulos são “iguais” (todos recebem o mesmo rótulo). Isso não é um problema, contanto que os conjuntos de rótulos coletivamente contenham exemplos de registros que sejam e que não sejam “iguais” de acordo com seus critérios.

> **Important**
>
> Confirme se a função do IAM transmitida ao AWS Glue tem acesso ao bucket do Amazon S3 que contém o arquivo de rotulagem. Por convenção, as políticas do AWS Glue concedem permissão às pastas ou aos buckets do Amazon S3 cujos nomes têm como prefixo aws-glue-. Se os arquivos de rotulagem estiverem em um local diferente, adicione uma permissão a essa localização na função do IAM.

Ajustar transformações de machine learning no AWS Glue

Você pode ajustar suas transformações de machine learning no AWS Glue para aprimorar os resultados de seus trabalhos de limpeza de dados e atender aos seus objetivos. Para melhorar sua transformação, você pode ensiná-la gerando um conjunto de rotulamento, adicionando rótulos e repetindo essas etapas várias vezes até obter os resultados desejados. Você também pode ajustá-las alterando alguns parâmetros de machine learning.

Para obter mais informações sobre transformações de machine learning, consulte Correspondência de registros com o FindMatches do AWS Lake Formation.

Tópicos

- Medições de machine learning
- Escolher entre precisão e recuperação
- Decidir entre acurácia e custo
- Estimação da qualidade das correspondências usando pontuações de confiança de correspondência
- Ensinar a transformação Find Matches

Medições de machine learning

Para compreender as medições que são usadas para ajustar a transformação de machine learning, você deve estar familiarizado com a seguinte terminologia:

Verdadeiro positivo (TP)

Uma correspondência nos dados que a transformação encontrou corretamente, também denominada como um acerto.

Verdadeiro negativo (TN)

Uma falta de correspondência nos dados que a transformação rejeitou corretamente.

Falsos positivo (FP)

Uma falta de correspondência nos dados que a transformação classificou incorretamente como correspondente, também denominada como um alarme falso.

Falso negativo (FN)

Uma correspondência nos dados que a transformação não detectou, também denominada como um erro.

Para obter mais informações sobre a terminologia de machine learning, consulte Confusion matrix (em inglês) na Wikipédia.

Para ajustar as transformações de machine learning, você pode alterar o valor das seguintes medidas nas Advanced properties (Propriedades avançadas) da transformação.

- Precision (Precisão) mede o quão bem a transformação encontra verdadeiros positivos entre o número total de registros que identifica como positivos (verdadeiros positivos e falsos positivos). Para obter mais informações, consulte Precisão e revocação na Wikipédia.
- A revocação mede quão bem a transformação encontra verdadeiros positivos do total de registros nos dados de origem. Para obter mais informações, consulte Precisão e revocação na Wikipédia.
- A acurácia mede quão bem a transformação encontra verdadeiros positivos e verdadeiros negativos. Aumentar a acurácia exige mais recursos de máquina e eleva os custos. Mas isso também resulta em um aumento da revocação. Para obter mais informações, consulte Accuracy and precision (em inglês) na Wikipédia.
- O custo mede quantos recursos de computação (logo, dinheiro) são consumidos para executar a transformação.

Escolher entre precisão e recuperação

Toda transformação `FindMatches` tem um parâmetro `precision-recall`. Você usa esse parâmetro para especificar o seguinte:

- Caso esteja mais preocupado com a possibilidade da transformação detectar a correspondência de dois registros que, na verdade, não correspondem, favoreça a precisão.

- Caso esteja mais preocupado com a transformação falhar na detecção de registros que correspondem, favoreça a revocação.

Você pode ajustar esse equilíbrio no console do AWS Glue ou usando as operações da API de machine learning do AWS Glue.

Quando favorecer a precisão

Dê preferência para a precisão se você estiver mais preocupado com o risco de `FindMatches` corresponder registros que, na verdade, não correspondem. Para favorecer a precisão, escolha um valor mais alto de equilíbrio entre precisão e recall. Com um valor mais alto, a transformação `FindMatches` precisa de mais evidências para decidir se dois registros devem corresponder. A transformação será ajustada para corresponder menos registros.

Por exemplo, suponha que você esteja usando `FindMatches` para detectar itens duplicados em um catálogo de filmes e fornece um valor de precisão-revocação mais alto para a transformação. Se a sua transformação detecta incorretamente que Star Wars: Uma Nova Esperança é o mesmo que Star Wars: O Império Contra-Ataca, um cliente que procurando Uma Nova Esperança poderá ver O Império Contra-Ataca. Isso resultaria em uma experiência do cliente insatisfatória.

No entanto, se a transformação não detectar que Star Wars: Uma Nova Esperança e Star Wars: Episódio IV - Uma Nova Esperança são o mesmo item, o cliente pode ficar confuso, mas reconhecerá os dois como iguais. Isso seria um erro, mas menos prejudicial que o primeiro caso.

Quando favorecer a recuperação

Dê preferência para a revocação se você estiver mais preocupado com o risco da transformação `FindMatches` não detectar pares de registros que, na verdade, são correspondentes. Para favorecer o recall, escolha um valor mais baixo de equilíbrio entre precisão e recall. Com um valor mais baixo, a transformação `FindMatches` precisa de menos evidências para decidir se dois registros devem corresponder. A transformação será ajustada para tender a corresponder mais registros.

Por exemplo, isso pode ser uma prioridade em uma organização de segurança. Suponha que você está comparando a lista de clientes com uma lista de falsificadores, e deve determinar se cada cliente é um falsificador ou não. Você vai usar `FindMatches` para corresponder a lista de falsificadores com a lista de clientes. Sempre que `FindMatches` detectar uma correspondência entre as duas listas, um auditor humano é atribuído para verificar se aquela pessoa é realmente um falsificador. Sua organização pode preferir revocação ao invés de precisão. Ou seja, você prefere

que os auditores revisem e rejeitem manualmente os casos nos quais o cliente não é um falsificador à transformação falhar ao identificar se um cliente está na lista de falsificadores.

Como favorecer tanto a precisão como a recuperação

A melhor maneira de aprimorar a precisão e a revocação é rotulando mais dados. Conforme você rotula mais dados, a acurácia geral da transformação `FindMatches` melhora, aprimorando, por sua vez, a precisão e a revocação. No entanto, até com a maior acurácia possível em uma transformação, você sempre precisará experimentar entre favorecer precisão ou revocação, ou manter um valor equilibrado.

Decidir entre acurácia e custo

Cada transformação `FindMatches` contém um parâmetro `accuracy-cost`. Você pode usar esse parâmetro para especificar o seguinte:

- Caso esteja mais preocupado com a transformação corresponder dois registros corretamente, favoreça a acurácia.
- Caso esteja mais preocupado com o custo ou a velocidade de executar a transformação, favoreça baixo custo.

Você pode ajustar esse equilíbrio no console do AWS Glue ou usando as operações da API de machine learning do AWS Glue.

Quando favorecer a acurácia

Dê preferência para a acurácia se você estiver mais preocupado com o risco dos resultados de `find matches` não terem correspondências. Para favorecer a acurácia, escolha um valor de equilíbrio entre acurácia e custo mais alto. Com um valor mais alto, a transformação `FindMatches` precisa de mais tempo para fazer uma pesquisa mais aprofundada e corresponder registros corretamente. Observe que esse parâmetro não diminui a probabilidade de erro na correspondência de dois registros que, na verdade, não correspondem. A transformação será ajustada para gastar mais tempo detectando correspondências.

Quando favorecer o custo

Dê preferência para o custo se estiver mais preocupado com os gastos de execução da transformação `find matches` e menos com a quantidade de correspondências encontradas. Para favorecer o custo, escolha um valor de equilíbrio entre acurácia e custo mais baixo. Com um

valor mais baixo, a transformação `FindMatches` exige menos recursos para ser executada. A transformação será ajustada para tender a detectar menos correspondências. Se os resultados forem aceitáveis ao favorecer baixo custo, use essa configuração.

Como favorecer tanto a acurácia como o baixo custo

A máquina leva mais tempo para determinar se mais pares de registros correspondem. Você pode executar as seguintes ações para reduzir os gastos, mas manter a qualidade:

- Elimine registros da fonte de dados que não são relevantes para as correspondências.
- Elimine colunas da fonte de dados as quais você não tem certeza se são úteis para a identificação de correspondências. Uma boa maneira de decidir isso é eliminando as colunas que você acredita não afetarem sua própria decisão sobre um conjunto de registros ser "o mesmo".

Estimação da qualidade das correspondências usando pontuações de confiança de correspondência

As pontuações de confiança de correspondência fornecem uma estimativa da qualidade das correspondências encontradas pelo FindMatches para distinguir entre registros correspondentes nos quais o modelo de machine learning é altamente confiante, incerto ou improvável. Uma pontuação de confiança na partida ficará entre 0 e 1, onde uma pontuação mais alta significa maior semelhança. O exame das pontuações de confiança da correspondência permite distinguir entre clusters de correspondências em que o sistema é altamente confiante (que você pode decidir mesclar), clusters sobre os quais o sistema é incerto (que você pode decidir que seja revisado por um humano) e clusters que o sistema considera improváveis (que você pode decidir rejeitar).

Você pode querer ajustar seus dados de treinamento em situações em que veja uma pontuação de confiança de correspondência alta, mas determine que não há correspondências ou onde você vê uma pontuação baixa, mas determina que existem, de fato, correspondências.

As pontuações de confiança são particularmente úteis quando há conjuntos de dados industriais de grande porte, nos quais é inviável revisar todas as decisões do FindMatches.

As pontuações de confiança de correspondência estão disponíveis no AWS Glue versão 2.0 ou posterior.

Geração de pontuações de confiança de correspondência

Você pode gerar pontuações de confiança de correspondência definindo o valor booleano de `computeMatchConfidenceScores` para True (Verdadeiro) ao chamar `FindMatches` ou a API `FindIncrementalMatches`.

O AWS Glue adiciona um novo `column match_confidence_score` para a saída.

Exemplos de pontuação de correspondência

Por exemplo, considere os registros correspondentes a seguir:

Pontuação >= 0,9

Resumo dos registros correspondentes:

```
  primary_id  |   match_id  | match_confidence_score

3281355037663    85899345947   0.9823658302132061
1546188247619    85899345947   0.9823658302132061
```

Detalhes:

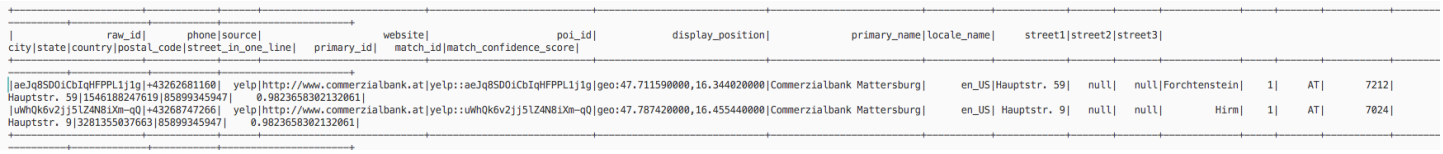

```
|aeJq8SDOiCbIqHFPPL1j1g|+43262681160|  yelp|http://www.commerzialbank.at|yelp::aeJq8SDOiCbIqHFPPL1j1g|geo:47.711590000,16.344020000|Commerzialbank Mattersburg|      en_US|Hauptstr. 59|   null|   null|Forchtenstein|    1|     AT|       7212|
Hauptstr. 59|1546188247619|85899345947|    0.9823658302132061|
|uWhQk6v2jj5lZ4N8iXm-qQ|+43268747266|  yelp|http://www.commerzialbank.at|yelp::uWhQk6v2jj5lZ4N8iXm-qQ|geo:47.787420000,16.455440000|Commerzialbank Mattersburg|      en_US| Hauptstr. 9|   null|   null|         Hirm|    1|     AT|       7024|
Hauptstr. 9|3281355037663|85899345947|    0.9823658302132061|
```

A partir deste exemplo, podemos ver que dois registros são muito semelhantes e compartilham `display_position`, `primary_name`, e `street name`.

Pontuação >= 0,8 e pontuação < 0,9

Resumo dos registros correspondentes:

```
  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
```

Detalhes:

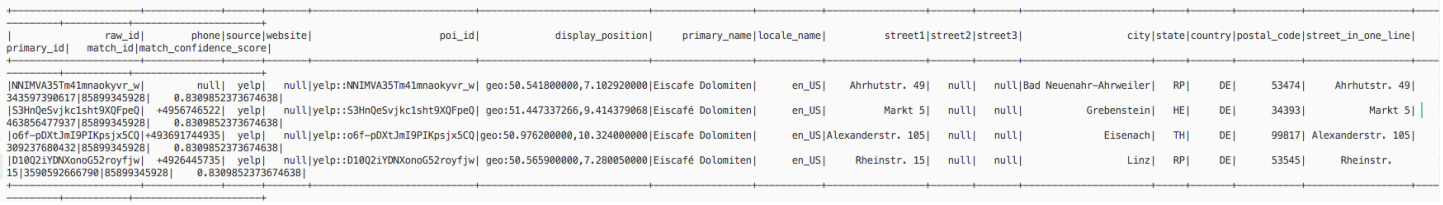

```
|NNIMVA35Tm41mnaokyvr_w|        null|  yelp|   null|yelp::NNIMVA35Tm41mnaokyvr_w| geo:50.541800000,7.102920000|Eiscafe Dolomiten|      en_US|    Ahrhutstr. 49|   null|   null|Bad Neuenahr-Ahrweiler|   RP|     DE|      53474|     Ahrhutstr. 49|
343597390617|85899345928|    0.8309852373674638|
|S3HnQeSvjkc1sht9XQFpeQ|  +4956746522|  yelp|   null|yelp::S3HnQeSvjkc1sht9XQFpeQ| geo:51.447337266,9.414379068|Eiscafé Dolomiten|      en_US|         Markt 5|   null|   null|           Grebenstein|   HE|     DE|      34393|          Markt 5|
463856477937|85899345928|    0.8309852373674638|
|o6f-pDXtJmI9PIKpsjx5CQ|+493691744935|  yelp|   null|yelp::o6f-pDXtJmI9PIKpsjx5CQ|geo:50.976200000,10.324000000|Eiscafe Dolomiten|      en_US|Alexanderstr. 105|   null|   null|             Eisenach|   TH|     DE|      99817| Alexanderstr. 105|
309237680432|85899345928|    0.8309852373674638|
|D10Q2iYDNXonoG52royfjw|  +4926445735|  yelp|   null|yelp::D10Q2iYDNXonoG52royfjw| geo:50.565900000,7.280050000|Eiscafé Dolomiten|      en_US|     Rheinstr. 15|   null|   null|                Linz|   RP|     DE|      53545|      Rheinstr.
15|3590592666790|85899345928|    0.8309852373674638|
```

A partir deste exemplo, podemos ver que esses registros compartilham o mesmo `primary_name`, e `country`.

Pontuação >= 0,6 e pontuação < 0,7

Resumo dos registros correspondentes:

```
  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
```

Detalhes:

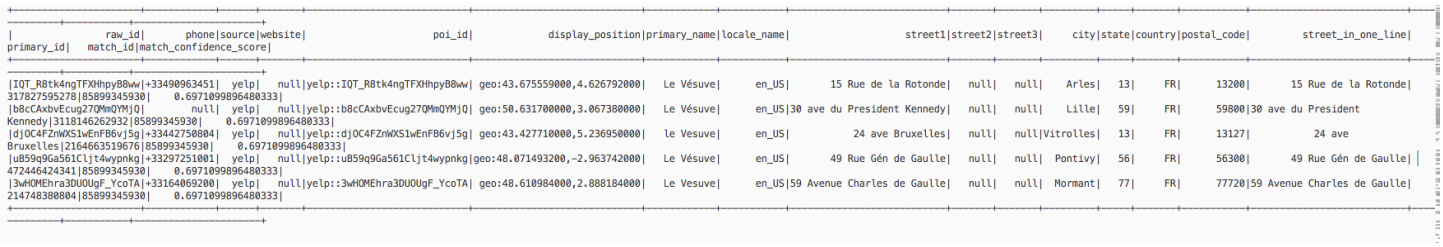

```
+------------+------------+------+--------+-----------------------
```

Você pode orquestrar esse rotulamento no console do AWS Glue ou usando as operações da API de machine learning do AWS Glue.

Quantas vezes devo adicionar rótulos? Quantos rótulos são necessários?

As respostas para essas perguntas dependem de você. Você deve avaliar se `FindMatches` está fornecendo o nível de acurácia de que você precisa e se o esforço adicional de rotulamento vale a pena. A melhor maneira de decidir isso é analisando as métricas “Precision (Precisão)”, “Recall (Revocação)” e “Area under the precision recall curve (Área sob a curva de precisão e revocação)” que você pode gerar selecionando Estimate quality (Estimativa de qualidade) no console do AWS Glue. Depois de rotular mais conjuntos de tarefas, execute essas métricas novamente e verifique se foram aprimoradas. Caso, depois de rotular alguns conjuntos de tarefas, você não veja uma melhoria na métrica em que está focando, a qualidade da transformação pode ter atingido seu auge.

Qual é a necessidade de ter ambos os rótulos verdadeiro positivo e verdadeiro negativo?

A transformação `FindMatches` precisa de exemplos positivos e negativos para aprender o que você considera como correspondência. Se você estiver rotulando dados de treinamento gerados por `FindMatches` (por exemplo, usando a opção I do not have labels (Eu não tenho rótulos)), a transformação `FindMatches` tentará gerar um conjunto de "label set ids" (IDs de conjunto de rótulo) para você. Em cada tarefa, você atribui o mesmo “rótulo” a alguns registros e “rótulos” diferentes a outros registros. Em outras palavras, as tarefas não costumam ser completamente iguais ou completamente diferentes (porém, não há problema se uma tarefa específica for tudo “igual” ou tudo “diferente”).

Se você estiver ensinando a sua transformação `FindMatches` usando a opção Upload labels from S3 (Fazer upload de rótulos do S3), tente incluir os exemplos de registros correspondentes e não correspondentes. Ter apenas um tipo é aceitável. Esses rótulos ajudam a aumentar a acurácia da transformação `FindMatches`, mas você ainda precisa rotular alguns registros que gerou com a opção Generate labeling file (Gerar arquivo de rotulamento).

Como posso garantir que a transformação faça correspondências conforme ensinei?

A transformação `FindMatches` aprende com os rótulos que você fornece, portanto, pode gerar pares de registros que não seguem os rótulos fornecidos. Para garantir que a transformação `FindMatches` siga seus rótulos, selecione EnforceProvidedLabels em FindMatchesParameter.

Quais técnicas podem ser usadas quando uma transformação de ML identifica como correspondentes itens que não são uma correspondência verdadeira?

Você pode usar as seguintes técnicas:

- Aumente o valor de `precisionRecallTradeoff`. Isso resultará eventualmente em menos correspondências encontradas, mas também deve dividir seu grande cluster quando atingir um valor alto o suficiente.
- Execute as linhas de saída correspondentes aos resultados incorretos e reformate-as como um conjunto de rotulamento (removendo a coluna `match_id` e adicionando uma coluna `labeling_set_id` e `label`). Se necessário, quebre-as (subdivida-as) em vários conjuntos de rotulamento para garantir que o rotulador possa ter todos os conjuntos em mente ao atribuir rótulos. Depois, rotule corretamente os conjuntos correspondentes, faça upload do arquivo de rótulo e anexe-o aos rótulos existentes. Isso pode ajudar a ensinar o transformador sobre o que deve procurar para entender o padrão.
- (Avançado) Por fim, observe os dados para ver se há um padrão que você pode detectar, mas o sistema não está observando. Pré-processe esses dados usando funções padrão do AWS Glue para normalizá-los. Destaque o que deseja que o algoritmo aprenda separando os dados que você considera importante em suas próprias colunas. Ou crie colunas combinadas de colunas cujos dados são relacionados.

Trabalhar com transformações de machine learning

É possível usar o AWS Glue para criar transformações personalizadas de machine learning que podem ser usadas para limpar seus dados. É possível criar essas transformações ao criar um trabalho no console do AWS Glue.

Para obter informações sobre como criar uma transformação de machine learning, consulte Correspondência de registros com o FindMatches do AWS Lake Formation.

Tópicos

- Propriedades da transformação
- Adicionar e editar transformações de machine learning
- Visualizar detalhes da transformação
- Ensine transformações usando rótulos

Propriedades da transformação

Para visualizar uma transformação de machine learning existente, faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/. No painel de

navegação em Integração de dados e ETL, escolha Ferramentas de classificação de dados > Correspondência de registros.

As propriedades de cada transformação:

Nome da transformação

O nome exclusivo que você atribuiu à transformação ao criá-la.

ID

Um identificador exclusivo da transformação.

Contagem de rótulos

O número de rótulos no arquivo de rotulamento fornecido para ajudar a ensinar a transformação.

Status

Indica se a transformação está Ready (Pronta) ou Needs training (Precisa de treinamento). Para executar uma transformação de machine learning com êxito em um trabalho, ela deve estar Ready (Pronta).

Criado

A data em que a transformação foi criada.

Modificado

A data em que a transformação foi atualizada pela última vez.

Descrição

A descrição fornecida para a transformação, se uma foi fornecida.

Versão do AWS Glue

A versão do AWS Glue usado.

ID da execução

O nome exclusivo que você atribuiu à transformação ao criá-la.

Tipo de tarefa

O tipo de transformação de machine learning. Por exemplo, Find matching records (Encontrar registros correspondentes).

Status

Indica o status da execução da tarefa. Os status possíveis causas incluem:

- Starting
- Executando
- Parando
- Interrompida
- Bem-sucedida
- Failed (Falha)
- Timeout (Tempo limite)

Erro

Se o status for Falha, uma mensagem descrevendo o motivo da falha será exibida.

Adicionar e editar transformações de machine learning

É possível visualizar, excluir, configurar e ensinar ou ajustar uma transformação no console do AWS Glue. Marque a caixa de seleção ao lado da transformação na lista, selecione Action (Ação) e escolha a ação que deseja realizar.

Criar uma nova transformação de ML

Para adicionar uma nova transformação de machine learning, escolha Criar transformação. Siga as instruções no assistente Adicionar trabalho. Para ter mais informações, consulte Correspondência de registros com o FindMatches do AWS Lake Formation.

Etapa 1. Defina as propriedades da transformação.

1. Insira um nome e uma descrição (opcional).
2. Opcionalmente, defina a configuração de segurança. Consulte Usar criptografia de dados com transformações de machine learning.
3. Opcionalmente, defina as configurações de execução da tarefa. As configurações de execução de tarefas permitem que você personalize a forma como a tarefa é executada. Selecione o tipo de operador, o número de operadores, o tempo limite da tarefa (em minutos), o número de tentativas e a versão do AWS Glue.

4. Opcionalmente, defina as tags. Tags são rótulos que você pode atribuir a um recurso da AWS. Cada tag consiste em uma chave e um valor opcional. As tags podem ser usadas para pesquisar e filtrar os recursos ou monitorar os custos na AWS.

Etapa 2. Escolha a tabela e a chave primária.

1. Escolha o banco de dados e a tabela do catálogo do AWS Glue.
2. Escolha uma chave primária na tabela selecionada. A coluna da chave primária normalmente contém um identificador exclusivo para cada registro da fonte de dados.

Etapa 3. Selecione as opções de ajuste.

1. Em Recuperação versus precisão, escolha o valor de ajuste para ajustar a transformação de modo a favorecer a recuperação ou a precisão. Por padrão, Balanceado está selecionado, mas você pode optar por favorecer a recuperação ou a precisão, ou escolher Personalizado e inserir um valor entre 0,0 e 1,0 (inclusive).
2. Para Menor custo versus precisão, escolha o valor de ajuste para favorecer o menor custo ou a precisão, ou escolha Personalizado e insira um valor entre 0,0 e 1,0 (inclusive).
3. Em Aplicação de correspondência, escolha Forçar a saída a corresponder aos rótulos se quiser ensinar a transformação de ML forçando a saída a corresponder aos rótulos usados.

Etapa 4. Revisar e criar.

1. Revise as opções das etapas de 1 a 3.
2. Escolha Editar para qualquer etapa que precise ser modificada. Escolha Criar transformação para concluir o assistente de criação de transformação.

Usar criptografia de dados com transformações de machine learning

Ao adicionar uma transformação de machine learning ao AWS Glue, você pode especificar opcionalmente uma configuração de segurança associada à origem dos dados ou ao destino dos dados. Se o bucket do Amazon S3 usado para armazenar os dados for criptografado com uma configuração de segurança, especifique a mesma configuração de segurança ao criar a transformação.

Você também pode optar por usar a criptografia do lado do servidor com o AWS KMS (SSE-KMS) para criptografar o modelo e os rótulos a fim de evitar que pessoas não autorizadas os inspecionem. Se você escolher essa opção, receberá uma solicitação para escolher uma AWS KMS key pelo nome, ou você poderá escolher Enter a key ARN (Inserir um ARN de chave). Se você optar por inserir o ARN para a chave do KMS, um segundo campo será exibido onde você poderá inserir o ARN da chave do KMS.

> **Note**
>
> No momento, transformações de ML que usem uma chave de criptografia personalizada não são compatíveis com as seguintes regiões:
>
> - Asia Pacific (Osaka) - `ap-northeast-3`

Visualizar detalhes da transformação

Visualizar as propriedades da transformação

A página de propriedades da transformação inclui os atributos da sua transformação. Ela mostra os detalhes sobre a definição da transformação, incluindo o seguinte:

- Transform name (Nome da transformação) mostra o nome da transformação.
- Type (Tipo) lista o tipo da transformação.
- Status exibe se a transformação está pronta para ser usada em um script ou em uma tarefa.
- Force output to match labels (Forçar a saída para corresponder rótulos) exibe se a transformação força a saída a corresponder os rótulos fornecidos pelo usuário.
- Spark version (Versão do Spark) está relacionada à versão do AWS Glue que você escolheu em Task run properties (Propriedades de execução de tarefa) ao adicionar a transformação. O AWS Glue 1.0 e o Spark 2.4 são recomendados para a maioria dos clientes. Para obter mais informações, consulte versões do AWS Glue.

Abas Histórico, Estimativa de qualidade e Tags

Os detalhes da transformação incluem as informações definidas quando ela foi criada. Para visualizar os detalhes de uma transformação, selecione a transformação na lista Machine learning transforms (Transformações de machine learning) e revise as informações das seguintes guias:

- Histórico
- Estimar qualidade
- Tags

Histórico

A guia History (Histórico) mostra o histórico de execução das tarefas da transformação. Vários tipos de tarefas são executadas para ensinar uma transformação. Para cada tarefa, as métricas de execução incluem o seguinte:

- Run ID (ID da execução) é um identificador criado pelo AWS Glue para cada execução dessa tarefa.
- Task type (Tipo de tarefa) mostra o tipo da tarefa executada.
- Status mostra o êxito de cada tarefa listada com a execução mais recente na parte superior.
- Error (Erro) mostra os detalhes de uma mensagem de erro se a execução apresentar falha.
- Start time (Hora de início) mostra a data e a hora (hora local) em que a tarefa foi iniciada.
- Hora de término mostra a data e a hora (hora local) em que a tarefa foi concluída.
- Logs links para os logs gravados em `stdout` para esta execução de trabalho.

  O link Logs direciona você para o Amazon CloudWatch Logs. Nesse serviço, é possível visualizar os detalhes sobre as tabelas que foram criadas no AWS Glue Data Catalog e qualquer erro encontrado. Você pode gerenciar seu período de retenção de logs no console do CloudWatch. A retenção de log padrão é `Never Expire`. Para obter mais informações sobre como alterar o período de retenção, consulte Alterar a retenção dos dados de log no CloudWatch Logs no Manual do usuário do Amazon CloudWatch Logs.
- Arquivo de rótulo mostra um link para o Amazon S3 de um arquivo de rótulo gerado.

Estimar qualidade

A guia Estimate quality (Estimar qualidade) mostra as métricas usadas para medir a qualidade da transformação. As estimativas são calculadas comparando as previsões de correspondência de transformação que usam um subconjunto dos dados rotulados com relação aos rótulos fornecidos. Essas estimativas são aproximadas. É possível invocar a execução de uma tarefa Estimate quality (Estimar qualidade) nessa guia.

A guia Estimate quality (Estimar qualidade) mostra as métricas da última execução de Estimate quality (Estimar qualidade), incluindo as seguintes propriedades:

- AArea under the Precision-Recall curve (Área na curva de precisão-revocação) é um único número que estima o limite máximo da qualidade geral da transformação. Ele é independente da escolha feita para o parâmetro de precisão-revocação. Valores mais altos indicam que você tem uma compensação de precisão-revocação mais atrativa.
- Precision (Precisão) estima a frequência de acertos da transformação ao prever uma correspondência.
- Recall upper limit (Limite máximo de revocação) estima com que frequência a transformação prevê uma correspondência real.
- F1 estima a precisão da transformação entre 0 e 1, em que 1 é a maior precisão. Para obter mais informações, consulte F1 score na Wikipédia.
- A tabela Column importance (Importância da coluna) mostra os nomes das colunas e a pontuação de importância para cada uma. A importância da coluna ajuda você a entender como as colunas contribuem para o seu modelo, identificando quais colunas em seus registros estão sendo mais usadas para fazer a correspondência. Esses dados podem solicitar que você adicione ou altere seu conjunto de rótulos para aumentar ou diminuir a importância das colunas.

  A coluna Importance (Importância) fornece uma pontuação numérica para cada coluna, como um decimal não superior a 1,0.

Para obter informações sobre como entender as estimativas de qualidade com relação à qualidade verdadeira, consulte Diferença entre estimativas de qualidade e qualidade de ponta a ponta (verdadeira).

Para obter mais informações sobre como ajustar a transformação, consulte Ajustar transformações de machine learning no AWS Glue.

Diferença entre estimativas de qualidade e qualidade de ponta a ponta (verdadeira)

O AWS Glue estima a qualidade da transformação apresentando ao modelo de machine learning interno vários pares de registros para os quais você forneceu rótulos correspondentes, mas que o modelo ainda não tinha visto. Essas estimativas de qualidade são uma função da qualidade do modelo de machine learning (que é influenciado pelo número de registros que você rotula para "ensinar" a transformação). A recuperação de ponta a ponta, ou verdadeira (que não é calculada automaticamente pela `ML transform`), também é influenciada pelo mecanismo de filtragem da

`ML transform` que propõe uma ampla variedade de possíveis correspondências ao modelo de machine learning.

É possível ajustar esse método de filtragem principalmente especificando o valor de ajuste como Menor precisão de custos. À medida que o valor de ajuste tende mais a favorecer a Precisão, o sistema faz uma busca mais detalhada e cara de pares de registros que podem ser correspondências. Mais pares de registros são alimentados no modelo de machine learning e a recuperação de ponta a ponta, ou verdadeira da `ML transform` se aproxima da métrica de recuperação estimada. Como resultado, as alterações na qualidade de ponta a ponta das correspondências resultantes de alterações na compensação de custo/precisão das correspondências normalmente não serão refletidas na estimativa de qualidade.

Tags

Tags são rótulos que você pode atribuir a um recurso da AWS. Cada tag consiste em uma chave e um valor opcional. As tags podem ser usadas para pesquisar e filtrar os recursos ou monitorar os custos na AWS.

Ensine transformações usando rótulos

Você pode ensinar a transformação de ML usando rótulos (exemplos) escolhendo Ensinar a transformação na página de detalhes da transformação de ML. Ao ensinar seu algoritmo de machine learning fornecendo exemplos (denominados rótulos), você pode escolher usar rótulos existentes ou criar um arquivo de rótulo.

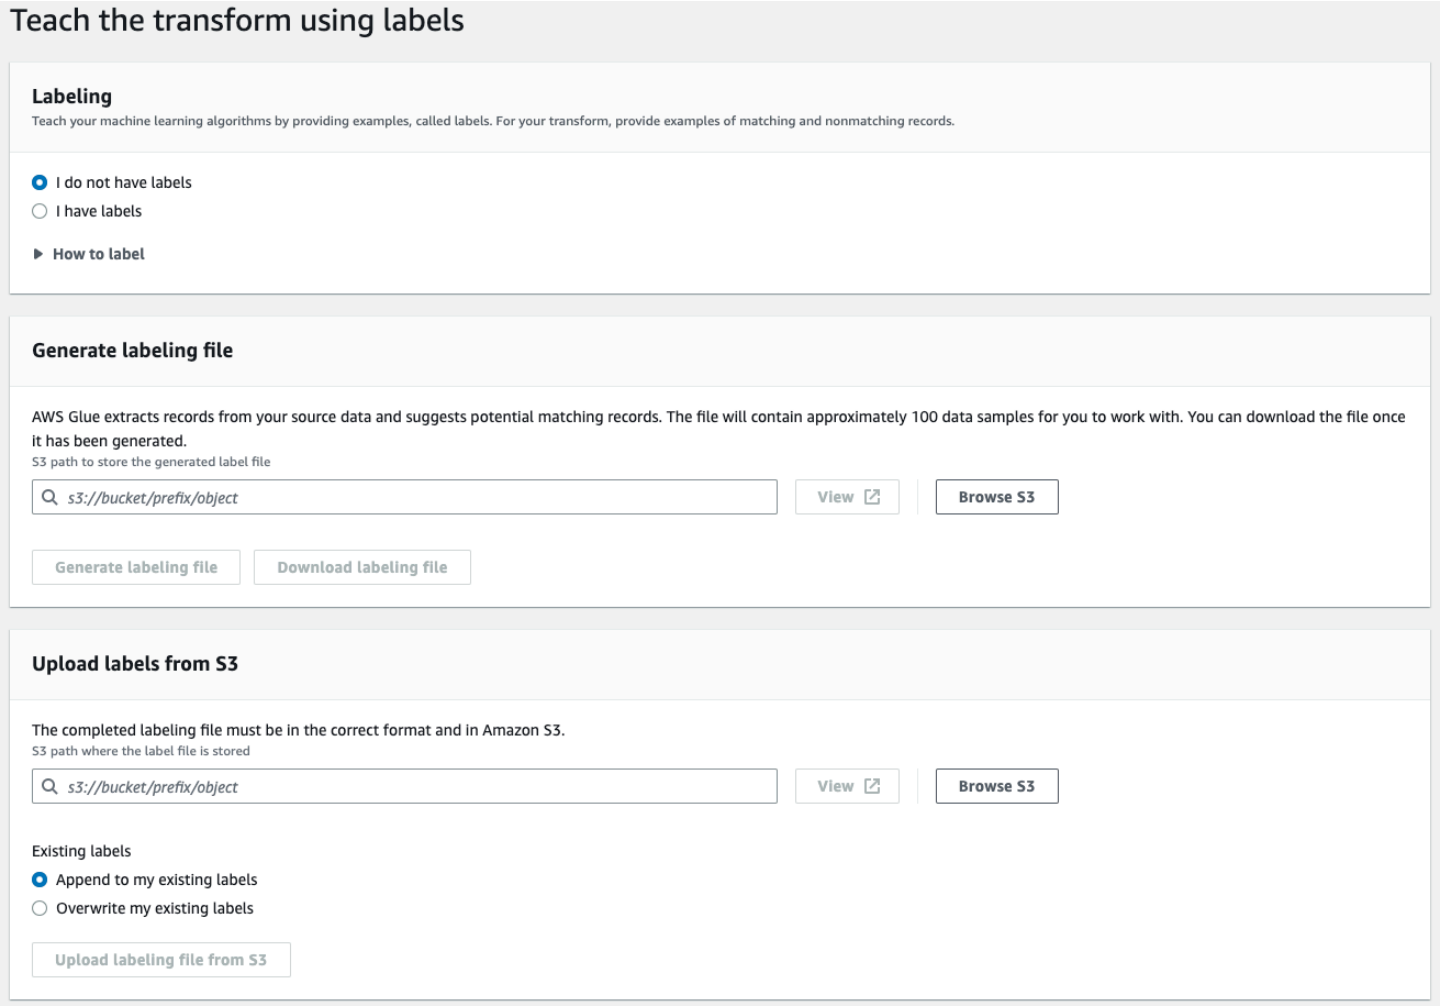

- Rótulagem: se você tiver rótulos escolha Eu tenho rótulos. Se você não tiver rótulos, ainda poderá continuar na próxima etapa gerando de um arquivo de rótulo.
- Gerar arquivo de rotulagem: o AWS Glue extrai os registros dos dados de origem e sugere possíveis registros correspondentes. Você escolhe o bucket do Amazon S3 para armazenar o arquivo de rótulo gerado. Escolha Gerar arquivo de rotulagem para iniciar o processo. Quando terminar, escolha Baixar arquivo de rotulagem. O arquivo baixado terá uma coluna para rótulos que você poderá preencher com os rótulos.
- Carregar rótulos do Amazon S3: escolha o arquivo de rotulo completo do bucket do Amazon S3 em que o arquivo de rótulo está armazenado. Depois, escolha entre anexar os rótulos aos rótulos existentes ou substituir os rótulos existentes. Escolha Carregar arquivo de rotulagem do Amazon S3.

Tutorial: como criar uma transformação de machine learning com o AWS Glue

Este tutorial orienta você sobre as ações para criar e gerenciar uma transformação de machine learning (ML) usando o AWS Glue. Antes de usar este tutorial, você deverá familiarizar-se com o uso do console do AWS Glue para adicionar crawlers a trabalhos e editar scripts. Você também deve se familiarizar com a localização e o download de arquivos no console do Amazon Simple Storage Service (Amazon S3).

Neste exemplo, você vai criar uma transformação `FindMatches` para encontrar registros correspondentes, ensiná-la como identificar registros correspondentes e não correspondentes e usá-la em um trabalho do AWS Glue. O trabalho do AWS Glue grava um novo arquivo do Amazon S3 com uma coluna adicional chamada `match_id`.

Os dados de origem usados por este tutorial é um arquivo chamado `dblp_acm_records.csv`. Esse arquivo é uma versão modificada de publicações acadêmicas (DBLP e ACM) disponíveis no Conjunto de dados de DBLP ACM original. O arquivo `dblp_acm_records.csv` é um arquivo de valores separados por vírgula (CSV) no formato UTF-8 sem marca de ordem de bytes (BOM).

Um segundo arquivo, `dblp_acm_labels.csv`, é um exemplo de arquivo de rotulagem que contém registros correspondentes e não correspondentes usados para ensinar a transformação como parte do tutorial.

Tópicos

- Etapa 1: rastrear os dados de origem
- Etapa 2: adicionar uma transformação de machine learning
- Etapa 3: ensinar sua transformação de machine learning
- Etapa 4: estimar a qualidade de sua transformação de machine learning
- Etapa 5: adicionar e executar um trabalho com sua transformação de machine learning
- Etapa 6: verificar os dados de saída do Amazon S3

Etapa 1: rastrear os dados de origem

Primeiro, rastreie o arquivo CSV de origem do Amazon S3 para criar uma tabela de metadados correspondente no Data Catalog.

> **Important**
>
> Para direcionar o crawler a criar uma tabela somente para o arquivo CSV, armazene os dados de origem do CSV em uma pasta do Amazon S3 separada de outros arquivos.

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Crawlers, Add crawler (Adicionar crawler).
3. Siga o assistente para criar e executar um crawler chamado `demo-crawl-dblp-acm` com a saída para o banco de dados `demo-db-dblp-acm`. Ao executar o assistente, crie o banco de dados, `demo-db-dblp-acm` se ele ainda não existir. Escolha um caminho de inclusão do Amazon S3 para os dados de exemplo na região da AWS atual. Por exemplo, para `us-east-1`, o caminho de inclusão do Amazon S3 para o arquivo de origem será `s3://ml-transforms-public-datasets-us-east-1/dblp-acm/records/dblp_acm_records.csv`.

   Se for bem-sucedido, o crawler criará a tabela `dblp_acm_records_csv` com as seguintes colunas: id, título, autores, local, ano e origem.

Etapa 2: adicionar uma transformação de machine learning

Em seguida, adicione uma transformação de machine learning que se baseia no esquema da tabela de fonte de dados criada pelo crawler chamado `demo-crawl-dblp-acm`.

1. No console do AWS Glue, no painel de navegação em Integração de dados e ETL, escolha Ferramentas de classificação de dados > Correspondência de registros e depois Adicionar transformação. Siga o assistente para criar uma transformação `Find matches` com as propriedades a seguir.

   a. Em Transform name (Nome da transformação), insira **`demo-xform-dblp-acm`**. Este é o nome da transformação que é usada para localizar correspondências nos dados de origem.

   b. Em IAM role (Função do IAM), escolha uma função do IAM que tenha permissão para os dados de origem do Amazon S3, o arquivo de rotulagem e as operações da API do AWS Glue. Para obter mais informações, consulte Criar uma função do IAM para o AWS Glue no Guia do desenvolvedor do AWS Glue.

   c. Em Data source (Fonte de dados), escolha a tabela chamada dblp_acm_records_csv no banco de dados demo-db-dblp-acm.

d. Em Primary key (Chave primária), escolha a coluna de chave primária da tabela id.

2. No assistente, escolha Finish (Concluir) e retorne à lista ML transforms (Transformações de ML).

Etapa 3: ensinar sua transformação de machine learning

Em seguida, você ensina sua transformação de machine learning usando o arquivo de rotulagem de exemplo do tutorial.

Não é possível usar uma transformação de linguagem de máquina em um trabalho de extração, transformação e carga (ETL) até que o status dela seja Ready for use (Pronta para uso). Para que sua transformação fique pronta, você deve ensiná-la como identificar registros correspondentes e não correspondentes fornecendo exemplos desses registros. Para ensinar a transformação, você pode Generate a label file (Gerar um arquivo de rótulos), adicionar rótulos e Upload label file (Fazer upload do arquivo de rótulos). Neste tutorial, você poderá usar o arquivo de rotulagem de exemplo chamado `dblp_acm_labels.csv`. Para obter mais informações sobre o processo de rotulagem, consulte Rótulo.

1. No console do AWS Glue, no painel de navegação, escolha Correspondência de registros.
2. Escolha a transformação `demo-xform-dblp-acm` e escolha Action (Ação), Teach (Ensinar). Siga o assistente para ensinar a transformação `Find matches`.
3. Na página de propriedades da transformação, escolha I have labels (Tenho rótulos). Escolha um caminho do Amazon S3 para o arquivo de rotulagem de exemplo na região da AWS atual. Por exemplo, para `us-east-1`, faça upload do arquivo de rotulagem fornecido no caminho do Amazon S3 `s3://ml-transforms-public-datasets-us-east-1/dblp-acm/labels/dblp_acm_labels.csv` com a opção de overwrite (substituir) os rótulos existentes. O arquivo de rotulagem deve estar localizado no Amazon S3 na mesma região que o console do AWS Glue.

   Quando você faz upload de um arquivo de rotulagem, uma tarefa é iniciada no AWS Glue para adicionar ou substituir os rótulos usados para ensinar a transformação como processar a fonte de dados.
4. Na página final do assistente, escolha Finish (Concluir) e retorne à lista de ML transforms (Transformações de ML).

Etapa 4: estimar a qualidade de sua transformação de machine learning

É possível estimar a qualidade de sua transformação de machine learning. A qualidade depende da quantidade de rotulagem que você tiver feito. Para obter mais informações sobre como estimar a qualidade, consulte Estimar qualidade.

1. No console do AWS Glue, no painel de navegação em Integração de dados e ETL, escolha Ferramentas de classificação de dados > Correspondência de registros.
2. Escolha a transformação `demo-xform-dblp-acm` e escolha a guia Estimate quality (Estimar qualidade). Essa guia exibe as estimativas de qualidade atuais, se disponível, para a transformação.
3. Escolha Estimate quality (Estimar qualidade) para iniciar uma tarefa para estimar a qualidade da transformação. A precisão da estimativa da qualidade é baseada na rotulagem dos dados de origem.
4. Navegue até a guia History (Histórico). Nesse painel, estão listadas as execuções de tarefa para a transformação, incluindo a tarefa Estimating quality (Estimar qualidade). Para obter mais detalhes sobre a execução, escolha Logs. Verifique se o status da execução é Succeeded (Bem-sucedido) após a conclusão.

Etapa 5: adicionar e executar um trabalho com sua transformação de machine learning

Nesta etapa, você usará a transformação de machine learning para adicionar e executar um trabalho no AWS Glue. Quando a transformação `demo-xform-dblp-acm` estiver Ready for use (Pronta para uso), você poderá usá-la em um trabalho de ETL.

1. No console do AWS Glue, no painel de navegação, escolha Jobs (Trabalhos).
2. Escolha Add job (Adicionar trabalho), e siga as etapas do assistente para criar um trabalho de ETL do Spark com um script gerado. Escolha os seguintes valores de propriedade para sua transformação:

    a. Em Name (Nome), escolha o trabalho de exemplo neste tutorial, demo-etl-dblp-acm.

    b. Em IAM role (Função do IAM), escolha uma função do IAM com permissão para os dados de origem do Amazon S3, o arquivo de rotulagem e as operações da API do AWS Glue. Para obter mais informações, consulte Criar uma função do IAM para o AWS Glue no Guia do desenvolvedor do AWS Glue.

    c. Em ETL language (Linguagem de ETL), escolha Scala. Esta será a linguagem de programação no script de ETL.

d. Em Script file name (Nome do arquivo de script), escolha demo-etl-dblp-acm. Este é o nome do arquivo do script Scala (igual ao nome do trabalho).

e. Em Data source (Fonte de dados), escolha dblp_acm_records_csv. A fonte de dados que você escolher deve corresponder ao esquema da fonte de dados da transformação de machine learning.

f. Em Transform type (Tipo de transformação), escolha Find matching records (Encontrar registros correspondentes) para criar um trabalho usando uma transformação de machine learning.

g. Desmarque Remove duplicate records (Remover registros duplicados). Não remova os registros duplicados porque os registros de saída de gravados têm um campo extra `match_id` adicionado.

h. Em Transform (Transformação), escolha a transformação de machine learning demo-xform-dblp-acm usada pelo trabalho.

i. Em Create tables in your data target (Criar tabelas em seu destino de dados), escolha criar tabelas com as seguintes propriedades:

- Data store type (Tipo de armazenamento de dados): **`Amazon S3`**
- Format (Formato): **`CSV`**
- Compression type (Tipo de compactação): **`None`**
- Target path (Caminho de destino): o caminho do Amazon S3 onde a saída do trabalho é gravada (no console da região da AWS atual)

3. Escolha Save job and edit script (Salvar trabalho e editar script) para exibir a página do editor de script.

4. Edite o script para adicionar uma instrução para fazer com que a saída do trabalho para o Target path (Caminho de destino) seja gravado em um único arquivo de partição. Adicione essa instrução imediatamente após a instrução que executa a transformação `FindMatches`. A instrução é semelhante ao seguinte.

```
val single_partition = findmatches1.repartition(1)
```

Você deve modificar a instrução `.writeDynamicFrame(findmatches1)` para gravar a saída como `.writeDynamicFrame(single_partion)`.

5. Depois de editar o script, escolha Save (Salvar). O script modificado é similar ao código a seguir, mas personalizado para seu ambiente.

```
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. Escolha Run job (Executar trabalho) para iniciar a execução do trabalho. Verifique o status do trabalho na lista de trabalhos. Quando o trabalho terminar, em ML transform (Transformação de ML), guia History (Histórico), haverá uma nova linha adicionada Run ID (ID de execução) do tipo ETL job (Trabalho de ETL).
7. Navegue até Jobs (Trabalhos), guia History (Histórico). Nesse painel, estão listadas as execuções de trabalho. Para obter mais detalhes sobre a execução, escolha Logs. Verifique se o status da execução é Succeeded (Bem-sucedido) após a conclusão.

Etapa 6: verificar os dados de saída do Amazon S3

Nesta etapa, verifique a saída da execução do trabalho no bucket do Amazon S3 que você escolheu quando adicionou o trabalho. Você pode fazer download do arquivo de saída em sua máquina local e verificar se os registros correspondentes foram identificados.

1. Abra o console do Amazon S3 em https://console.aws.amazon.com/s3/.
2. Faça download do arquivo de saída de destino do trabalho `demo-etl-dblp-acm`. Abra o arquivo em um aplicativo de planilha (talvez seja necessário adicionar uma extensão de arquivo `.csv` para que o arquivo abra corretamente).

   A imagem a seguir mostra um trecho da saída no Microsoft Excel.

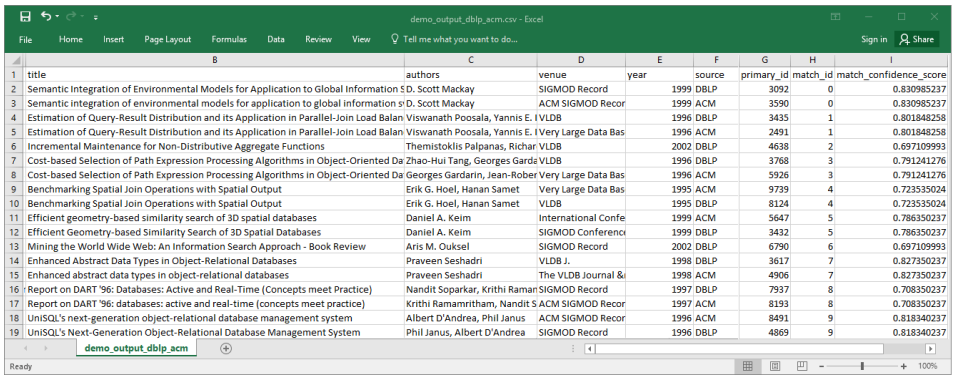

	B	C	D	E	F	G	H	I
1	title	authors	venue	year	source	primary_id	match_id	match_confidence_score
2	Semantic Integration of Environmental Models for Application to Global Information S	D. Scott Mackay	SIGMOD Record	1999	DBLP	3092	0	0.830985237
3	Semantic integration of environmental models for application to global information s	D. Scott Mackay	ACM SIGMOD Recor	1999	ACM	3590	0	0.830985237
4	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
5	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
6	Incremental Maintenance for Non-Distributive Aggregate Functions	Themistoklis Palpanas, Richar	VLDB	2002	DBLP	4638	2	0.697109993
7	Cost-based Selection of Path Expression Processing Algorithms in Object-Oriented Da	Zhao-Hui Tang, Georges Garda	VLDB	1996	DBLP	3768	3	0.791241276
8	Cost-based Selection of Path Expression Processing Algorithms in Object-Oriented Da	Georges Gardarin, Jean-Rober	Very Large Data Bas	1996	ACM	5926	3	0.791241276
9	Benchmarking Spatial Join Operations with Spatial Output	Erik G. Hoel, Hanan Samet	Very Large Data Bas	1995	ACM	9739	4	0.723535024
10	Benchmarking Spatial Join Operations with Spatial Output	Erik G. Hoel, Hanan Samet	VLDB	1995	DBLP	8124	4	0.723535024
11	Efficient geometry-based similarity search of 3D spatial databases	Daniel A. Keim	International Confe	1999	ACM	5647	5	0.786350237
12	Efficient Geometry-based Similarity Search of 3D Spatial Databases	Daniel A. Keim	SIGMOD Conferenc	1999	DBLP	3432	5	0.786350237
13	Mining the World Wide Web: An Information Search Approach - Book Review	Aris M. Ouksel	SIGMOD Record	2002	DBLP	6790	6	0.697109993
14	Enhanced Abstract Data Types in Object-Relational Databases	Praveen Seshadri	VLDB J.	1998	DBLP	3617	7	0.827350237
15	Enhanced abstract data types in object-relational databases	Praveen Seshadri	The VLDB Journal &	1998	ACM	4906	7	0.827350237
16	Report on DART '96: Databases: Active and Real-Time (Concepts meet Practice)	Nandit Soparkar, Krithi Raman	SIGMOD Record	1997	DBLP	7937	8	0.708350237
17	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
18	UniSQL's next-generation object-relational database management system	Albert D'Andrea, Phil Janus	ACM SIGMOD Recor	1996	ACM	8491	9	0.818340237
19	UniSQL's Next-Generation Object-Relational Database Management System	Phil Janus, Albert D'Andrea	SIGMOD Record	1996	DBLP	4869	9	0.818340237

O arquivo da fonte de dados e o arquivo do destino têm 4.911 registros. No entanto, a transformação `Find matches` adiciona outra coluna chamada `match_id` para identificar registros correspondentes na saída. As linhas com o mesmo `match_id` são consideradas registros correspondentes. O `match_confidence_score` é um número entre 0 e 1 que fornece uma estimativa da qualidade das correspondências encontradas por `Find matches`.

3. Classifique o arquivo de saída por `match_id` para ver facilmente quais registros são correspondentes. Compare os valores nas outras colunas para ver se você concorda com os resultados da transformação `Find matches`. Se você não concordar, poderá continuar a ensinar a transformação adicionando mais rótulos.

   Também é possível classificar o arquivo por outro campo, como `title`, para ver se os registros com títulos semelhantes têm o mesmo `match_id`.

Localizar correspondências incrementais

O recurso Find matches permite identificar registros duplicados ou correspondentes no seu conjunto de dados, mesmo quando os registros não tenham um identificador exclusivo comum e quando não houver campos com uma correspondência exata. A versão inicial da transformação Find matches identificava registros correspondentes em um único conjunto de dados. Quando você adiciona novos dados ao conjunto de dados, você precisava mesclá-los com o conjunto de dados limpo existente e executar novamente a correspondência com o conjunto de dados mesclado completo.

O recurso de correspondência incremental facilita a correspondência com registros incrementais em relação a conjuntos de dados correspondentes existentes. Vamos supor que você queira combinar dados de clientes potenciais com conjuntos de dados de clientes existentes. O recurso de correspondência incremental oferece a flexibilidade de combinar centenas de milhares de novos clientes potenciais com um banco de dados existente de clientes potenciais e clientes, mesclando os resultados em um único banco de dados ou tabela. Ao fazer a correspondência somente entre os conjuntos de dados novos e existentes, a otimização da localização de correspondências incrementais reduz o tempo de computação, o que também reduz o custo.

O uso de correspondência incremental é semelhante a Find matches conforme descrito em Tutorial: como criar uma transformação de machine learning com o AWS Glue. Este tópico identifica apenas as diferenças com correspondência incremental.

Para obter mais informações, consulte a postagem do blog em Correspondências de dados incrementais.

Execução de um trabalho de correspondência incremental

Para o procedimento a seguir, suponha o seguinte:

- Você rastreou o conjunto de dados existente até a tabela first_records. O conjunto de dados first_records deve ser um conjunto de dados correspondente ou a saída do trabalho correspondente.
- Você criou e treinou uma transformação de Find matches com o AWS Glue versão 2.0. Essa é a única versão do AWS Glue com suporte a correspondências incrementais.
- A linguagem de ETL é Scala. Observe que também há suporte para Python.
- O modelo já gerado é chamado de `demo-xform`.

1. Rastreie o conjunto de dados incremental até a tabela second_records.
2. No console do AWS Glue, no painel de navegação, escolha Jobs (Trabalhos).
3. Escolha Add job (Adicionar trabalho), e siga as etapas do assistente para criar um trabalho de ETL do Spark com um script gerado. Escolha os seguintes valores de propriedade para sua transformação:

   a. Em Name (Nome), escolhademo-etl.

   b. Em IAM role (Função do IAM), escolha uma função do IAM com permissão para os dados de fonte do Amazon S3, o arquivo de rotulagem e as operações de API do AWS Glue.

   c. Em ETL language (Linguagem de ETL), escolha Scala.

   d. Em Script file name (Nome do arquivo de script), escolha demo-etl. Esse é o nome do arquivo do script Scala.

   e. Em Data source (Fonte de dados), escolha first_records. A fonte de dados que você escolher deve corresponder ao esquema da fonte de dados da transformação de machine learning.

   f. Em Transform type (Tipo de transformação), escolha Find matching records (Encontrar registros correspondentes) para criar um trabalho usando uma transformação de machine learning.

   g. Selecione a opção de correspondência incremental e para Data Source (Fonte de dados), selecione a tabela chamada second_records.

   h. Em Transform (Transformação), escolha demo-xform, a transformação de machine learning usada pelo trabalho.

   i. Escolha Create tables in your data target (Criar tabelas em seu destino de dados) ou Use tables in the data catalog and update your data target (Usar tabelas no catálogo de dados e atualizar seu destino de dados).
4. Escolha Save job and edit script (Salvar trabalho e editar script) para exibir a página do editor de script.
5. Escolha Run job (Executar trabalho) para iniciar a execução do trabalho.

Usar FindMatches em um trabalho visual

Para usar a transformação FindMatches no AWS Glue Studio, você pode usar o nó Transformação personalizada que invoca a API FindMatches. Para obter mais informações sobre como usar uma transformação personalizada, consulte Criar uma transformação personalizada

> **Note**
>
> Atualmente, a API FindMatches só funciona com o `Glue 2.0`. Para executar um trabalho com a transformação personalizada que invoca a API FindMatches, verifique se a versao do AWS Glue é **`Glue 2.0`** na guia Detalhes do trabalho. Se a versão do AWS Glue não for `Glue 2.0`, o trabalho falhará no runtime com a seguinte mensagem de erro: “não é possível importar o nome 'FindMatches' de 'awsglueml.transforms'”.

Pré-requisitos

- Para usar a transformação Find Matches, abra o console do AWS Glue Studio no https://console.aws.amazon.com/gluestudio/.
- Cria uma transformação de machine learning. Quando criada, um transformId é gerado. Você precisará desse ID nas etapas abaixo. Para obter mais informações sobre como criar uma transformação de machine learning, consulte Adicionar e editar transformações de machine learning.

Adicionar uma transformação FindMatches

Para adicionar uma transformação FindMatches:

1. No editor de trabalho do AWS Glue Studio, abra o painel Recurso clicando no símbolo de cruz no canto superior esquerdo do gráfico visual do trabalho e escolha uma fonte de dados

selecionando a guia Dados. Essa é a fonte de dados na qual você deseja verificar se há correspondências.

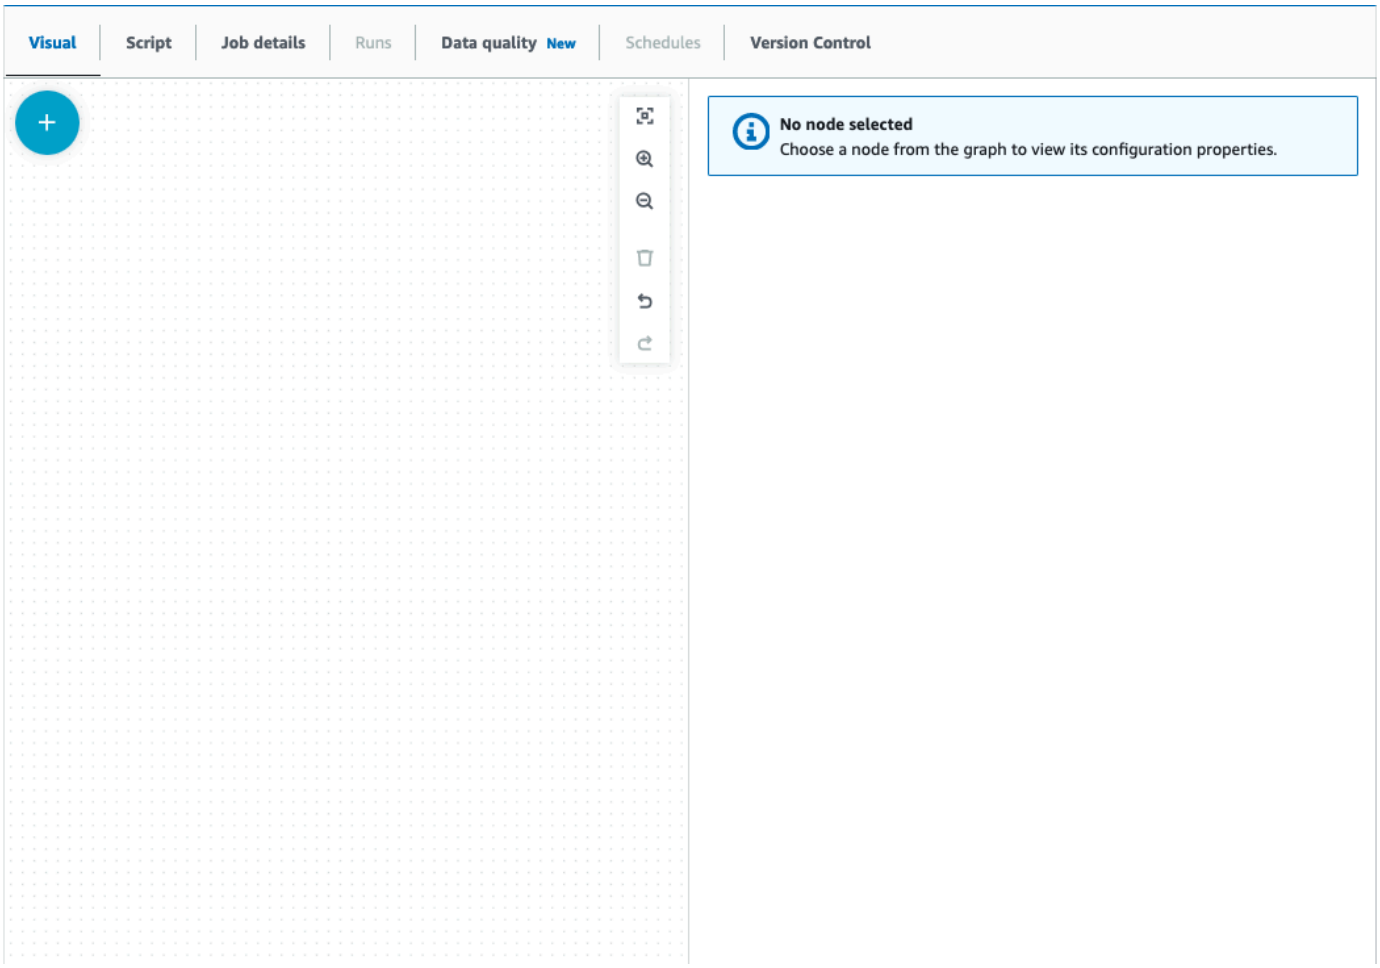

2. Escolha o nó da fonte de dados e abra o painel Recurso clicando no símbolo de cruz no canto superior esquerdo do gráfico visual do trabalho e procure “transformação personalizada”. Escolha o nó Transformação personalizada para adicioná-lo ao gráfico. A transformação personalizada é vinculada ao nó da fonte de dados. Caso contrário, você pode clicar no nó Transformação personalizada e escolher a guia Propriedades do nó e, em Superiores do nó, escolher a fonte de dados.
3. Clique no nó Transformação personalizada no gráfico visual, depois escolha a guia Propriedades do nó e dê um nome para a transformação personalizada. É recomendável renomear a transformação para que o nome da transformação seja facilmente identificável no gráfico visual.
4. Escolha a guia Transformar, na qual você pode editar o bloco de código. É aqui que o código para invocar a API FindMatches pode ser adicionado.

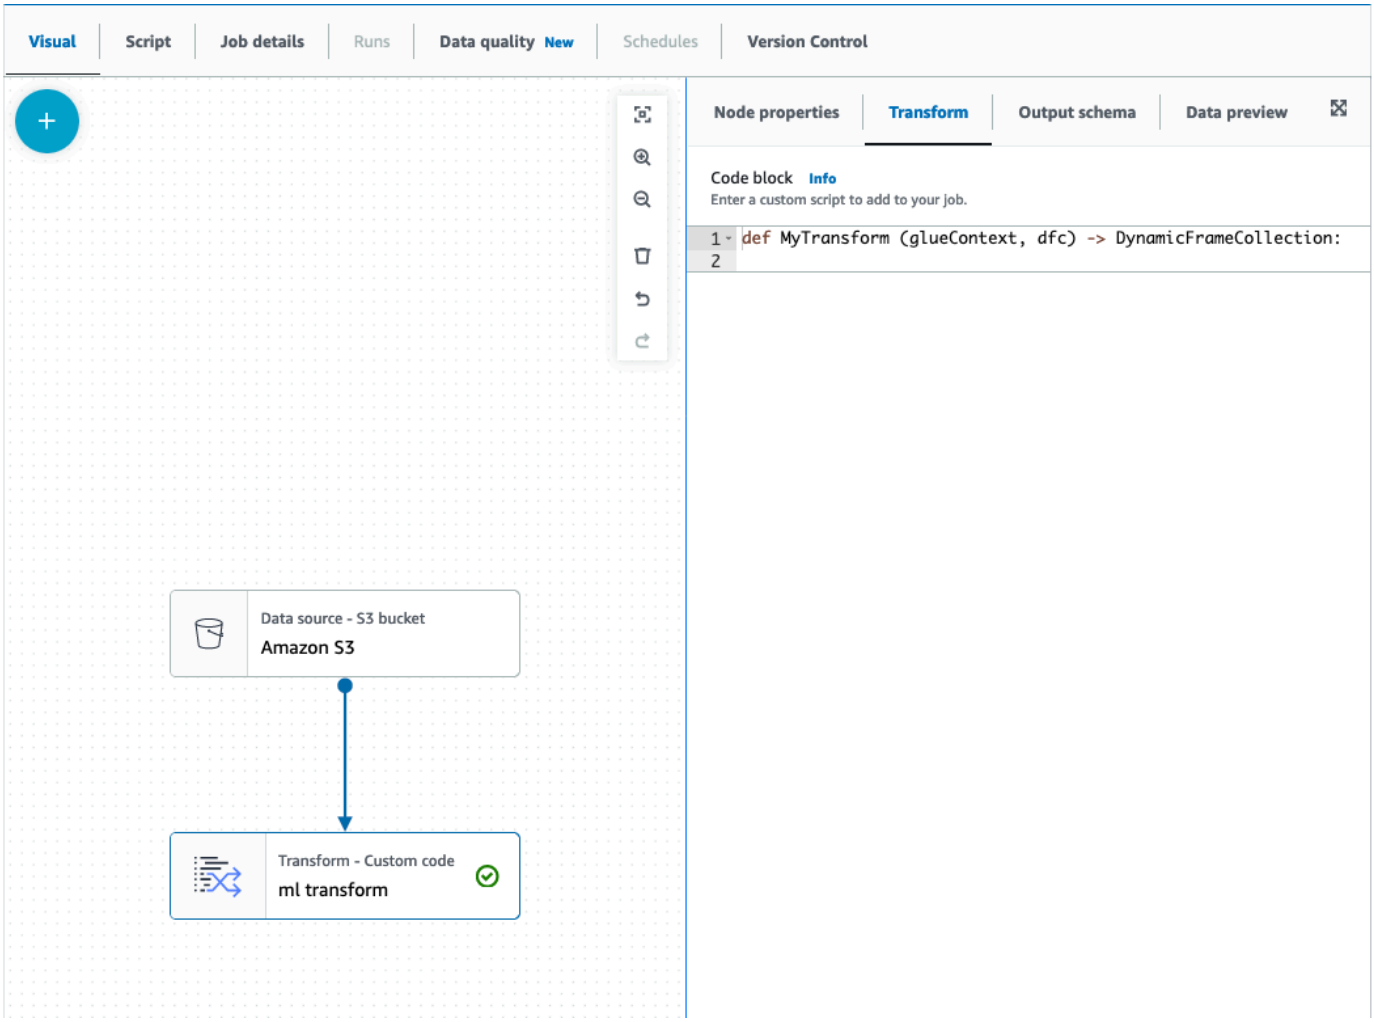

O bloco de código contém código já preenchido para você começar. Substitua o código já preenchido pelo modelo abaixo. O modelo tem um espaço reservado para o transformId, o qual você pode fornecer.

```
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. Clique no nó Transformação personalizada no gráfico visual, abra o painel Recurso clicando no símbolo de cruz no canto superior esquerdo do gráfico visual do trabalho e procure “transformação personalizada”. Não há necessidade de alterar a seleção padrão, pois há somente um DynamicFrame no conjunto.

6. Você pode continuar adicionando transformações ou armazenar o resultado, que agora está enriquecido com as colunas adicionais de descoberta de correspondências. Se você quiser referenciar essas novas colunas em transformações posteriores, precisará adicioná-las ao esquema de saída da transformação. A maneira mais fácil de fazer isso é escolher a guia Visualização de dados e, na guia Esquema, escolher “Usar esquema de visualização de dados”.
7. Para personalizar findMatches, você pode adicionar outros parâmetros para passar para o método 'aplicar'. Consulte Classe FindMatches.

Adicionar uma transformação incremental FindMatches

No caso de correspondências incrementais, o processo é o mesmo que Adicionar uma transformação FindMatches com as seguintes diferenças:

- Em vez de um nó superior para a transformação personalizada, você precisará de dois nós superiores.
- O primeiro nó superior deve ser o conjunto de dados.
- O segundo nó superior deve ser o conjunto de dados incrementais.

  Substitua o `transformId` pelo seu `transformId` no bloco de código do modelo:

```
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))
```

- Para obter parâmetros opcionais, consulte a classe FindIncrementalMatches.

Migrar programas do Apache Spark para o AWS Glue

O Apache Spark é uma plataforma de código aberto para workloads de computação distribuída executadas em grandes conjuntos de dados. O AWS Glue utiliza os recursos do Spark para fornecer uma experiência otimizada para ETL. Você pode migrar programas Spark para o AWS Glue para

utilizar nossos recursos. O AWS Glue fornece os mesmos aprimoramentos de performance que você esperaria do Apache Spark no Amazon EMR.

Executar o código Spark

O código nativo do Spark pode ser executado em um ambiente AWS Glue pronto para uso. Os scripts muitas vezes são desenvolvidos alterando iterativamente um trecho de código, um fluxo de trabalho adequado para uma sessão interativa. No entanto, convém executar o código existente em um trabalho do AWS Glue, que permite agendar e obter consistentemente logs e métricas para cada execução de script. Você pode carregar e editar um script existente pelo console.

1. Adquira a origem de seu script. Para este exemplo, você usará um script de exemplo do repositório do Apache Spark. Exemplo de binarizador
2. No console do AWS Glue, expanda o painel de navegação do lado esquerdo e selecione ETL > Jobs (Trabalhos)

   No painel Create job (Criar trabalho), selecione Spark script editor (Editor de scripts Spark). Será exibida a seção Options (Opções). Em Options (Opções), clique em Upload and edit an existing script (Carregar e editar um script existente).

   Será exibida a seção File upload (Carregamento de arquivo). Em File upload (Carregamento de arquivo), clique em Choose file (Escolher arquivo). Será exibido seletor de arquivos do sistema. Navegue até o local em que você salvou `binarizer_example.py`, selecione-o e confirme a seleção.

   Será exibido um botão Create (Criar) no cabeçalho do painel Create job (Criar trabalho). Clique.

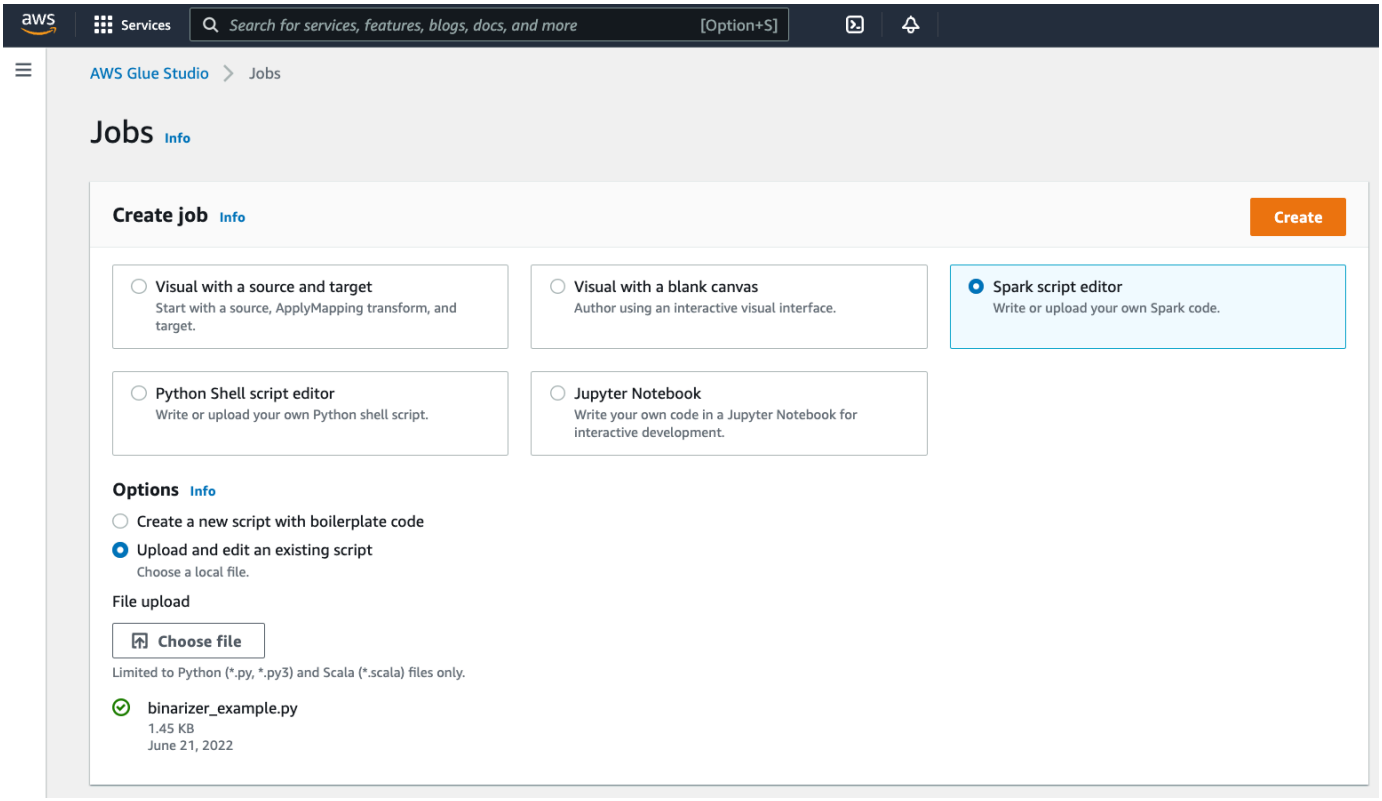

3. Seu navegador conduzirá até o editor de scripts. No cabeçalho, clique na guia Job details (Detalhes do trabalho). Defina o nome e o perfil do IAM. Para obter orientação sobre perfis do IAM do AWS Glue, consultethe section called “Configurar permissões do IAM”.

   Opcionalmente: defina Requested number of workers (Número solicitado de operadores) para 2 e Number of retries (Número de repetições) para 1. Essas opções são proveitosas para executar trabalhos de produção, mas recusá-las simplificará sua experiência ao testar um recurso.

   Na barra de título, clique em Save (Salvar) e depois em Run (Executar)

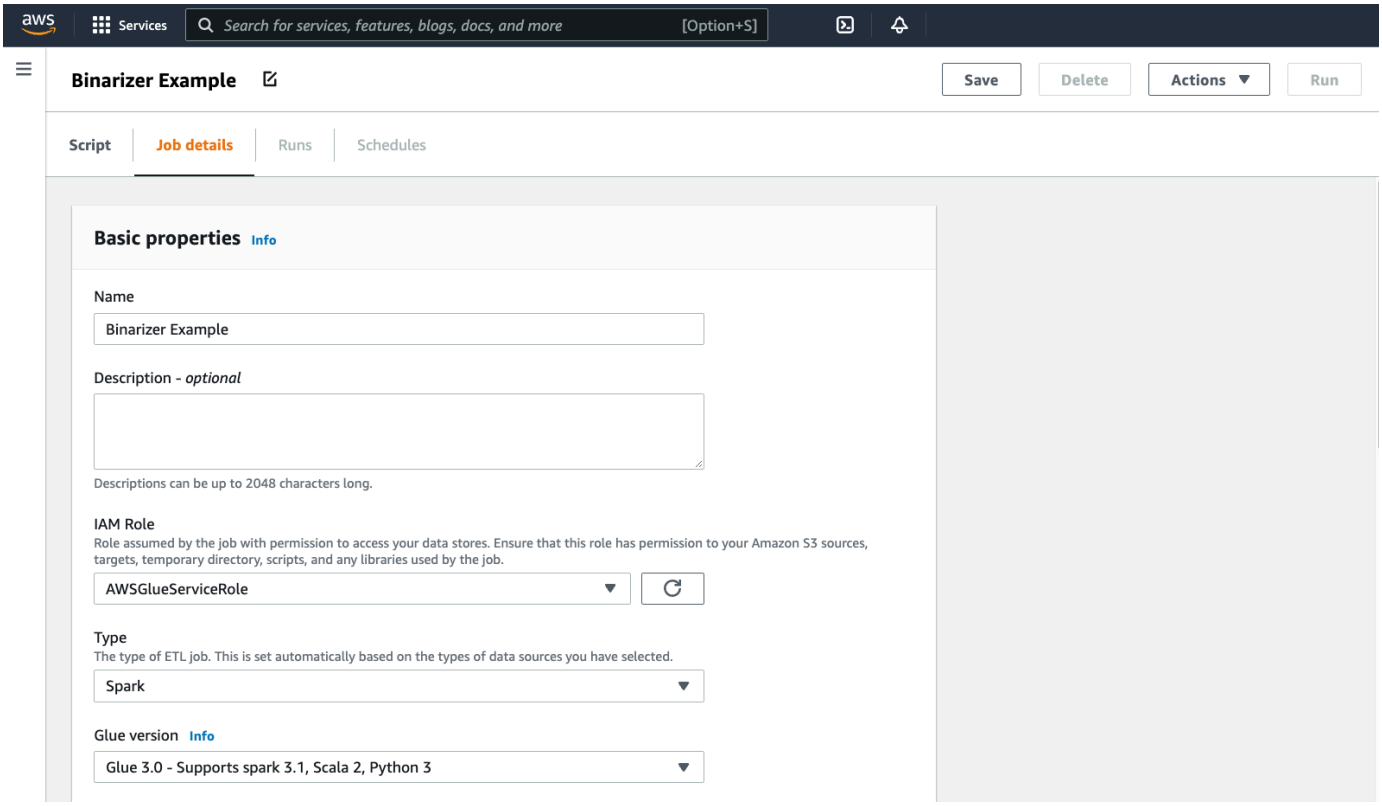

4. Navegue até a guia Runs (Execuções). Você verá um painel correspondente à execução do trabalho. Aguarde alguns instantes, e a página deverá atualizar automaticamente para exibir Succeeded (Êxito) em Run status (Status da execução).

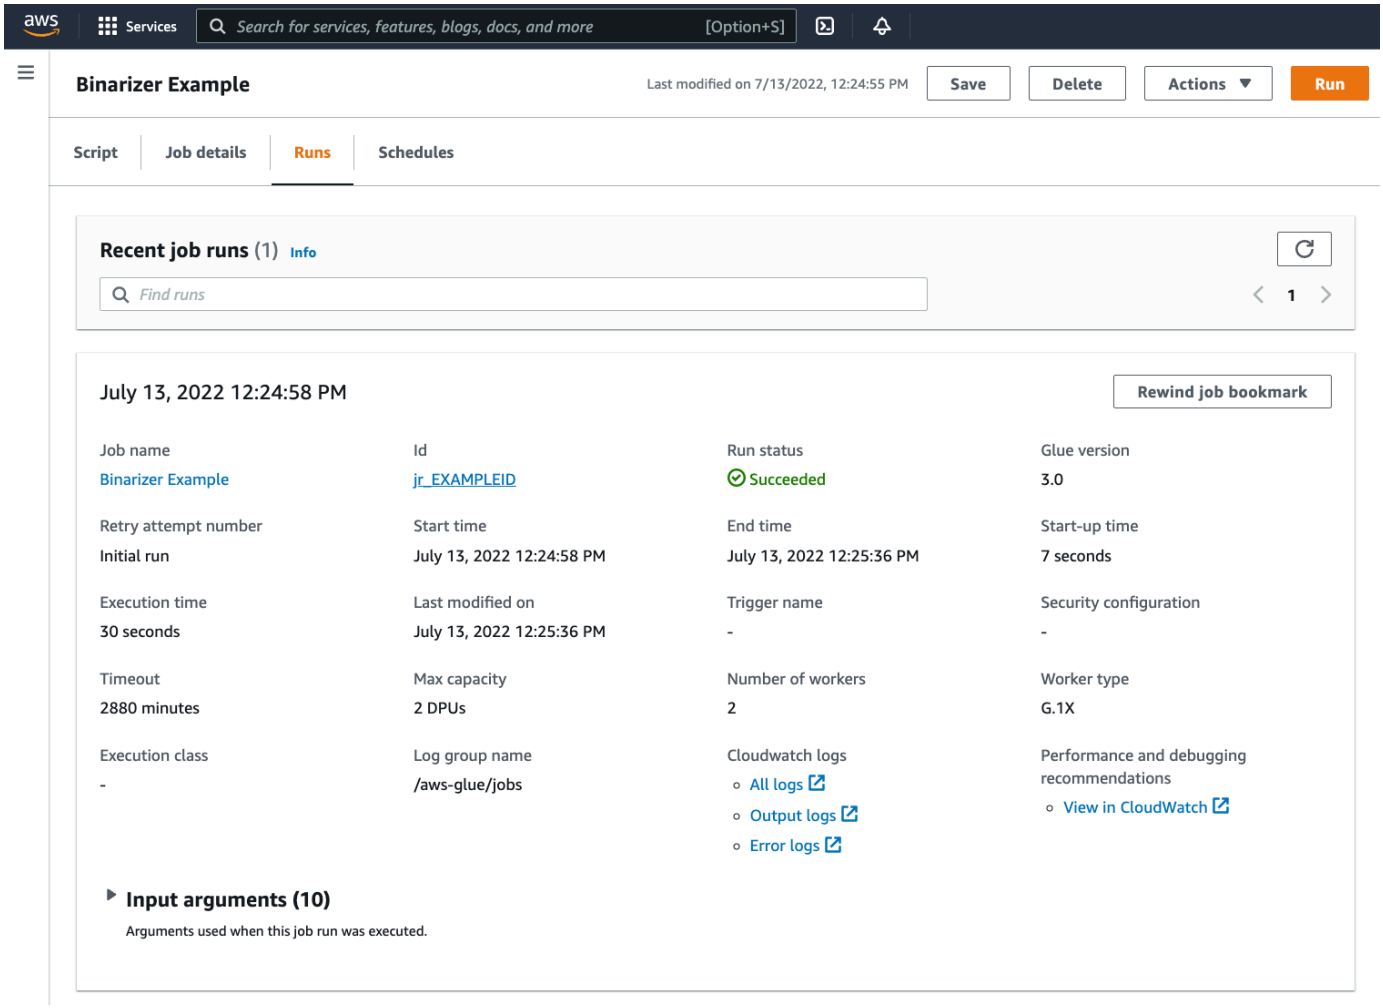

5. Convém examinar sua saída para confirmar que o script Spark foi executado conforme o esperado. Esse script de amostra do Apache Spark deve gravar uma cadeia de caracteres no fluxo de saída. Você pode descobrir isso navegando até Output logs (Logs de saída) em Logs no painel para a execução bem-sucedida do trabalho. Observe o ID de execução do trabalho, que é um ID gerado no rótulo Id começando com `jr_`.

   Isso abrirá o console do CloudWatch, definido para visualizar o conteúdo do grupo de logs padrão `/aws-glue/jobs/output` do AWS Glue, filtrado para o conteúdo dos fluxos de logs para o ID de execução do trabalho. Cada operador terá gerado um fluxo de logs, mostrado como linhas em Log streams (Fluxos de log). Um operador deverá ter executado o código solicitado. Você precisará abrir todos os fluxos de logs para identificar o operador correto. Depois de encontrar o operador certo, você deverá ver a saída do script, como é exibido na imagem a seguir:

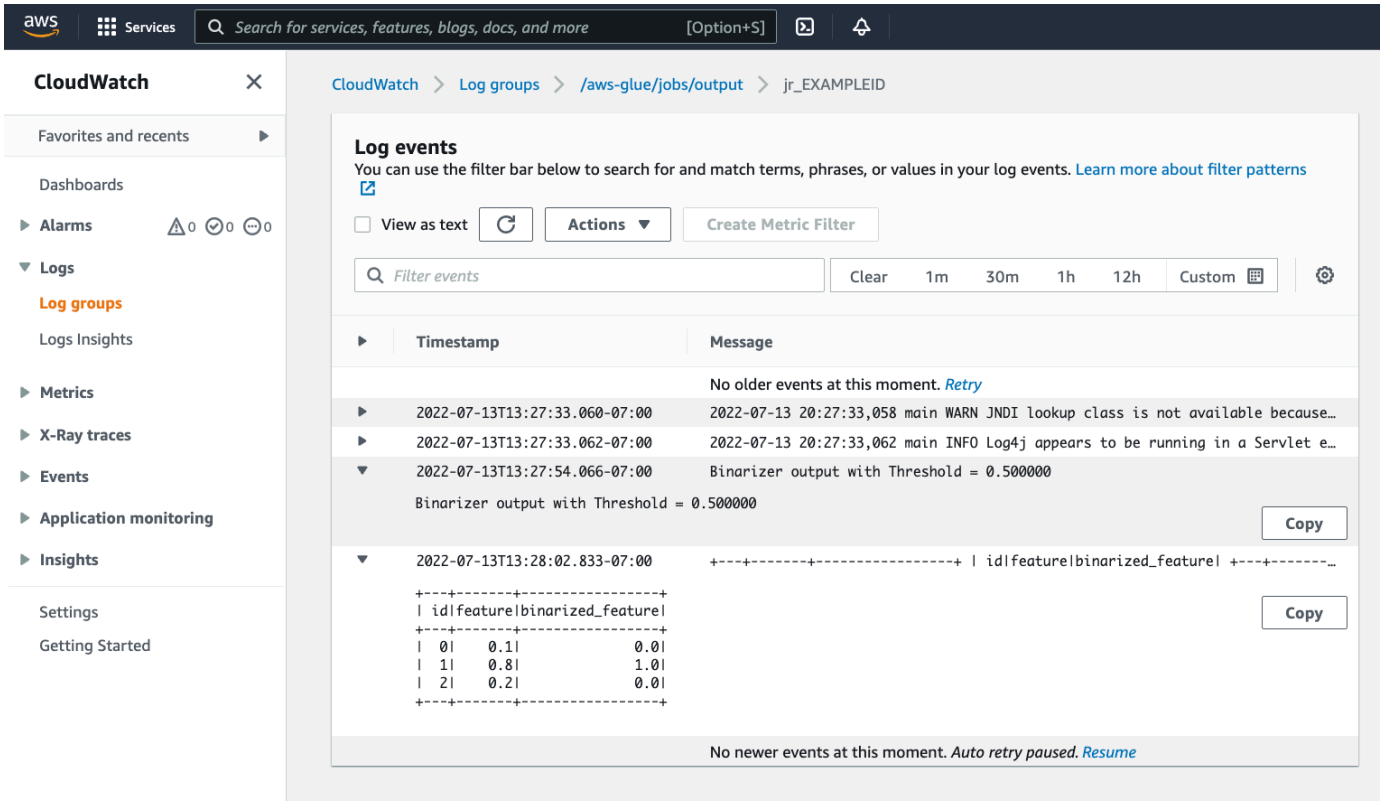

Procedimentos comuns necessários para migrar programas Spark

Avalie a compatibilidade com a versão do Spark

As versões do AWS Glue determinam a versão do Apache Spark e Python que estão disponíveis para o trabalho do AWS Glue. Você encontra nossas versões do AWS Glue e a compatibilidade delas em the section called “Versões do AWS Glue”. Pode ser necessário atualizar seu programa Spark para que seja compatível com uma versão mais recente do Spark para acessar determinados recursos do AWS Glue.

Incluir bibliotecas de terceiros

Muitos programas Spark existentes terão dependências, tanto em artefatos privados como públicos. O AWS Glue é compatível com dependências de estilo JAR para trabalhos Scala, bem como dependências Wheel e Python puro para trabalhos Python.

Python: para obter informações sobre dependências do Python, consulte the section called “Bibliotecas Python”

As dependências comuns do Python são fornecidas no ambiente do AWS Glue, inclusive a popular biblioteca Pandas. As dependências estão incluídas no AWS Glue versão 2.0+. Para obter mais

informações sobre os módulos fornecidos, consulte the section called “Módulos do Python já fornecidos no AWS Glue”. Se você precisar fornecer a um trabalho uma versão diferente de uma dependência incluída por padrão, você pode usar `--additional-python-modules`. Para obter mais informações sobre argumentos de trabalho, consulte the section called “Parâmetros de trabalho”.

Você pode fornecer dependências adicionais do Python com o argumento de trabalho `--extra-py-files`. Se você estiver migrando um trabalho de um programa Spark, esse parâmetro é uma boa opção, pois é funcionalmente equivalente ao sinalizador `--py-files` no PySpark e está sujeito às mesmas limitações. Para obter mais informações sobre o parâmetro `--extra-py-files`, consulte the section called “Inclusão de arquivos Python com recursos nativos do PySpark”

Para novos trabalhos, é possível gerenciar dependências do Python com o argumento de trabalho `--additional-python-modules`. Usar esse argumento permite uma experiência mais completa de gerenciamento de dependências. Esse parâmetro é compatível com dependências do estilo Wheel, inclusive aquelas com vinculações de código nativas compatíveis com o Amazon Linux 2.

Scala

Você pode fornecer dependências adicionais do Scala com o argumento de trabalho `--extra-jars`. As dependências devem ser hospedadas no Amazon S3, e o valor do argumento deve ser uma lista delimitada por vírgulas de caminhos do Amazon S3 sem espaços. Talvez seja mais fácil gerenciar sua configuração reagrupando suas dependências antes de hospedá-las e configurá-las. AWS Glue As dependências JAR contêm bytecode Java, que pode ser gerado de qualquer linguagem JVM. É possível usar outras linguagens JVM, como Java, para escrever dependências personalizadas.

Gerenciar credenciais da fonte de dados

Os programas Spark existentes podem vir com configurações complexas ou personalizadas para extrair dados das fontes de dados. Fluxos de autenticação de fonte de dados comuns são compatíveis com conexões do AWS Glue. Para obter mais informações sobre conexões do AWS Glue, consulte Conectar a dados.

As conexões do AWS Glue permitem a conexão do trabalho a uma variedade de tipos de armazenamentos de dados, principalmente de duas maneiras: por meio de chamadas de método para nossas bibliotecas e definindo Additional network connection (Conexão de rede adicional) no console do AWS. Também é possível chamar o SDK da AWS de dentro do trabalho para recuperar informações de uma conexão.

Chamadas de método: as conexões do AWS Glue são totalmente integradas ao AWS Glue Data Catalog, um serviço que permite selecionar informações sobre seus conjuntos de dados, e os métodos disponíveis para interagir com conexões do AWS Glue refletem isso. Se houver uma configuração de autenticação existente que você gostaria de reutilizar, para conexões JDBC, é possível acessar a configuração de conexão do AWS Glue pelo método `extract_jdbc_conf` em `GlueContext`. Para obter mais informações, consulte the section called “extract_jdbc_conf”

Configuração do console: o uso de trabalhos do AWS Glue associados a conexões do AWS Glue para configurar conexões com sub-redes da Amazon VPC. Se você gerencia diretamente seus materiais de segurança, talvez seja necessário fornecer um tipo `NETWORK` para Additional network connection (Conexão de rede adicional) no console do AWS para configurar o roteamento. Para obter mais informações sobre a conexão de APIs do AWS Glue, consulte the section called “Conexões”

Se seus programas Spark tiverem um fluxo de autenticação personalizado ou incomum, talvez seja necessário gerenciar seus materiais de segurança na prática. Se as conexões do AWS Glue não parecerem uma boa opção, você poderá hospedar seguramente materiais de segurança no Secrets Manager e acessá-los pelo boto3 ou pelo SDK da AWS, que são fornecidos no trabalho.

Configurar o Apache Spark

As migrações complexas geralmente alteram a configuração do Spark para acomodar suas workloads. As versões modernas do Apache Spark permitem que a configuração do runtime seja definida com o `SparkSession`. AWS Glue Trabalhos 3.0+ recebem `SparkSession`, que pode ser modificado para definir a configuração do runtime. Configuração do Apache Spark. Ajustar o Spark é complexo, e o AWS Glue não garante suporte para definir todas as configurações do Spark. Se sua migração necessitar de uma configuração substancial no nível do Spark, entre em contato com o suporte.

Definir uma configuração personalizada

Os programas Spark migrados podem ser projetados de modo a ter configurações personalizadas. O AWS Glue permite que a configuração seja definida no nível do trabalho e da execução do trabalho, por meio dos argumentos do trabalho. Para obter mais informações sobre argumentos de trabalho, consulte the section called “Parâmetros de trabalho”. É possível acessar argumentos de trabalho dentro do contexto de um trabalho por meio de nossas bibliotecas. O AWS Glue fornece uma função de utilitário que proporciona uma visão consistente entre os argumentos definidos no trabalho e os argumentos definidos na execução do trabalho. Consulte the section called “getResolvedOptions” em Python e the section called “GlueArgParser” em Scala.

Migrar código Java

Conforme explicado em the section called “Bibliotecas de terceiros”, suas dependências podem conter classes geradas por linguagens JVM, como Java ou Scala. Suas dependências podem incluir um método `main`. Você pode usar um método `main` em uma dependência como o ponto de entrada para um trabalho Scala do AWS Glue. Isso permite escrever o método `main` em Java ou reutilizar um método `main` empacotado de acordo com seus próprios padrões de biblioteca.

Para usar um método `main` de uma dependência, execute este procedimento: limpe o conteúdo do painel de edição fornecendo o objeto `GlueApp` padrão. Forneça o nome totalmente qualificado de uma classe em uma dependência como argumento de trabalho com a chave `--class`. Então, você deverá ser capaz de acionar uma execução de trabalho.

Não é possível configurar a ordem ou a estrutura dos argumentos. O AWS Glue passa para o método `main`. Se o código existente precisar ler a configuração definida no AWS Glue, isso provavelmente causará incompatibilidade com o código anterior. Se você usar `getResolvedOptions`, também não terá um bom lugar para chamar esse método. Considere invocar sua dependência diretamente de um método principal gerado pelo AWS Glue. O script de ETL do AWS Glue a seguir é um exemplo disso.

```
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()
  }
}
```

Trabalhar com trabalhos do Ray no AWS Glue

Esta seção fornece informações sobre o uso do AWS Glue para Ray. Para obter mais informações sobre escrever scripts do AWS Glue para Ray, consulte a seção the section called “AWS Glue para Ray”.

Tópicos

- Conceitos básicos do AWS Glue para Ray
- Ambientes de runtime do Ray compatíveis
- Explicar os operadores em trabalhos do Ray
- Usar parâmetros de trabalho em trabalhos do Ray
- Monitorar trabalhos do Ray com métricas

Conceitos básicos do AWS Glue para Ray

Para trabalhar com o AWS Glue para Ray, você usa os mesmos trabalhos e sessões interativas do AWS Glue que usaria com o AWS Glue para Spark. Os trabalhos do AWS Glue foram criados para executar o mesmo script em uma cadência recorrente, enquanto as sessões interativas foram criadas para permitir que você execute trechos de código sequencialmente nos mesmos recursos provisionados.

O AWS Glue ETL e o Ray são diferentes internamente, portanto, em seu script, você terá acesso a diferentes ferramentas, atributos e configurações. Como uma nova estrutura de computação gerenciada pelo AWS Glue, o Ray tem uma arquitetura diferente e usa um vocabulário diferente para descrever o que faz. Para obter mais informações, consulte Architecture Whitepapers (Documentos técnicos de arquitetura) na documentação do Ray.

> **Note**
>
> O AWS Glue for Ray está disponível em Leste dos EUA (Norte da Virgínia), Leste dos EUA (Ohio), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio) e Europa (Irlanda).

Trabalhos do Ray no console do AWS Glue Studio

Na página Trabalhos no console do AWS Glue Studio, você pode selecionar uma nova opção ao criar um trabalho no AWS Glue Studio - editor de script do Ray. Escolha essa opção para criar um

trabalho do Ray no console. Para obter mais informações sobre trabalhos e sobre como eles são usados, consulte Criar trabalhos ETL visuais com o AWS Glue Studio.

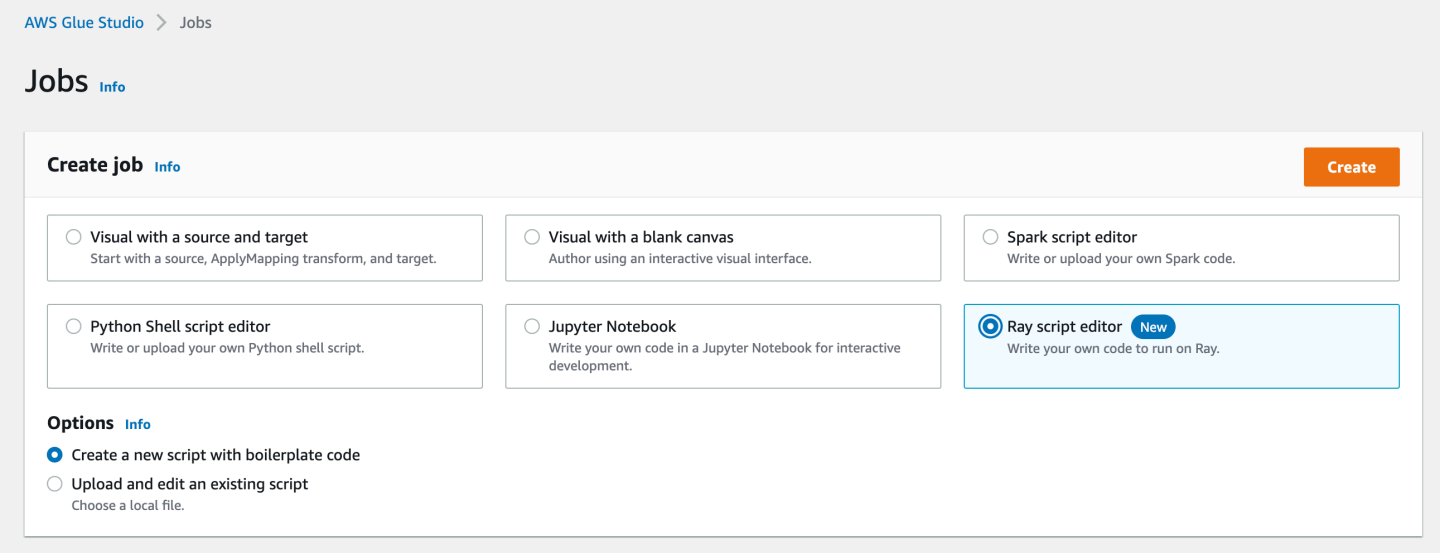

Os trabalhos do Ray na AWS CLI e SDK

Os trabalhos do Ray na AWS CLI usam as mesmas ações e parâmetros do SDK dos outros trabalhos. O AWS Glue para Ray introduz novos valores para determinados parâmetros. Para obter mais informações sobre a API de trabalhos, consulte the section called “Tarefas”.

Ambientes de runtime do Ray compatíveis

Em trabalhos do Spark, o `GlueVersion` determina as versões do Apache Spark e do Python disponíveis em um trabalho do AWS Glue para Spark. A versão do Python indica a versão compatível com trabalhos do tipo Spark. Não é assim que os ambientes de runtime do Ray são configurados.

Os trabalhos do Ray, você deve definir `GlueVersion` como `4.0` ou mais. Porém, as versões do Ray, do Python e das bibliotecas adicionais disponíveis no seu trabalho do Ray são determinadas pelo campo `Runtime` na definição do trabalho.

O ambiente de runtime to `Ray2.4` estará disponível por no mínimo 6 meses após o lançamento. À medida que o Ray evolui rapidamente, você poderá incorporar atualizações e melhorias do Ray por meio de versões futuras do runtime.

Valores válidos: `Ray2.4`

Valor do runtime	Versões do Ray e Python
`Ray2.4` (para AWS Glue 4.0+)	Ray 2.4.0 Python 3.9

Informações adicionais

- Para obter as notas de versão que acompanham os lançamentos do AWS Glue para Ray, consulte the section called “Versões do AWS Glue”.
- Para bibliotecas do Python que são fornecidas em um runtime, consulte the section called “Módulos fornecidos com trabalhos do Ray”.

Explicar os operadores em trabalhos do Ray

O AWS Glue executa trabalhos do Ray em novos tipos de operadores EC2 baseados em Graviton, que só estão disponíveis para trabalhos do Ray. Para provisionar adequadamente esses trabalhadores para workloads para os quais o Ray foi projetado, fornecemos uma proporção diferente de recursos de computação e recursos de memória da maioria dos operadores. Para processar esses recursos, usamos a unidade de processamento de dados otimizada para memória (M-DPU) em vez da unidade de processamento de dados padrão (DPU).

- Uma M-DPU corresponde a 4 vCPUs e 32 GB de memória.
- Uma DPU corresponde a 4 vCPUs e 16 GB de memória. As DPUs são usadas para contabilizar os recursos no AWS Glue com trabalhos do Spark e os operadores correspondentes.

Trabalhos do Ray têm acesso a um tipo de operador, `Z.2X`. O operador `Z.2X` mapeia para 2 M-DPUs (8 vCPUs, 64 GB de memória) e tem 128 GB de espaço em disco. Uma máquina `Z.2X` fornece 8 operadores Ray (um por vCPU).

O número de M-DPUs que você pode usar de forma concorrente em uma conta está sujeito a uma cota de serviço. Para obter mais informações sobre os limites da sua conta do AWS Glue, consulte endpoints e cotas do AWS Glue.

Você especifica o número de nós de processamento que estão disponíveis para um trabalho do Ray com `--number-of-workers (NumberOfWorkers)` na definição do trabalho. Para obter mais informações sobre os valores do Ray na API de trabalhos, consulte the section called “Tarefas”.

Você também pode especificar um número mínimo de operadores que um trabalho do Ray deve alocar com o parâmetro do trabalho `--min-workers`. Para obter mais informações sobre parâmetros de trabalho, consulte the section called “Referência”.

Usar parâmetros de trabalho em trabalhos do Ray

Você define os argumentos para os trabalhos do Ray no AWS Glue da mesma forma que define os argumentos no AWS Glue para trabalhos do Spark. Para obter mais informações sobre a API do AWS Glue, consulte the section called “Tarefas”. Você pode configurar trabalhos do Ray no AWS Glue com argumentos diferentes, que estão listados nesta referência. Você também pode fornecer seus próprios argumentos.

É possível configurar um trabalho pelo do console, na guia Job details (Detalhes do trabalho), no cabeçalho Job Parameters (Parâmetros do trabalho). Você também pode configurar um trabalho usando a AWS CLI definindo `DefaultArguments` em um trabalho ou definindo `Arguments` em uma execução de trabalho. Os argumentos padrão e os parâmetros do trabalho serão mantidos com o trabalho durante várias execuções.

Por exemplo, veja a seguir a sintaxe para a execução de um trabalho usando `--arguments` para definir um parâmetro especial.

```
$ aws glue start-job-run --job-name "CSV to CSV" --arguments='--scriptLocation="s3://
my_glue/libraries/test_lib.py",--test-environment="true"'
```

Depois de definir os argumentos, você pode acessar os parâmetros do trabalho de dentro do trabalho do Ray por meio das variáveis de ambiente. Essa é uma forma de configurar o trabalho para cada execução. O nome da variável de ambiente será o nome do argumento do trabalho sem o prefixo `--`.

No exemplo anterior, os nomes das variáveis seriam `scriptLocation` e `test-environment`. Depois, você recuperaria o argumento por meio dos métodos disponíveis na biblioteca padrão: `test_environment = os.environ.get('test-environment')`. Para obter mais informações sobre como acessar variáveis de ambiente com o Python, consulte módulo de sistema operacional na documentação do Python.

Configurar a forma como os trabalhos do Ray geram logs

Por padrão, os trabalhos do Ray geram logs e métricas que são enviados para o CloudWatch e para o Amazon S3. É possível usar o parâmetro `--logging_configuration` para alterar a forma como os logs são gerados. No momento, você pode usá-lo para impedir que os trabalhos do Ray gerem diversos tipos de logs. Este parâmetro usa um objeto em JSON, cujas chaves correspondem aos logs ou aos comportamentos que você gostaria de alterar. Ele oferece suporte para as seguintes chaves:

- `CLOUDWATCH_METRICS`: configura as séries de métricas do CloudWatch que podem ser usadas para visualizar a integridade do trabalho. Para obter mais informações sobre métricas, consulte the section called “Métricas de trabalho do Ray”.
- `CLOUDWATCH_LOGS`: configura os logs do CloudWatch que fornecem detalhes no nível da aplicação do Ray sobre o status de execução do trabalho. Para obter mais informações sobre logs, consulte the section called “Solucionar problemas de erros do Ray”.
- `S3`: configura o que o AWS Glue grava no Amazon S3, principalmente em relação a informações semelhantes aos logs do CloudWatch, mas como arquivos em vez de fluxos de logs.

Para desabilitar um comportamento de registro em log do Ray, forneça o valor `{\"IS_ENABLED\": \"False\"}`. Por exemplo, para desabilitar as métricas e os logs do CloudWatch, forneça a seguinte configuração:

```
"--logging_configuration": "{\"CLOUDWATCH_METRICS\": {\"IS_ENABLED\": \"False\"},
 \"CLOUDWATCH_LOGS\": {\"IS_ENABLED\": \"False\"}}"
```

Referência

Os trabalhos do Ray reconhecem os seguintes nomes de argumento que podem ser usados para configurar o ambiente de script para os trabalhos e execuções de trabalhos do Ray:

- `--logging_configuration`: é usado para interromper a geração de diversos logs criados por trabalhos do Ray. Esses logs são gerados por padrão em todos os trabalhos do Ray. Formato: objeto em JSON com escape de string. Para ter mais informações, consulte the section called “Configurar a forma como os trabalhos do Ray geram logs”.
- `--min-workers`: o número mínimo de nós de processamento alocados a um trabalho do Ray. Um nó de processamento pode executar várias réplicas, uma por cada CPU virtual. Formato: número inteiro. Mínimo: 0. Máximo: valor especificado em `--number-of-workers`

(`NumberOfWorkers`) na definição do trabalho. Para obter mais informações sobre a contabilização de nó de processamento, consulte the section called “Explicar os operadores em trabalhos do Ray”.

- `--object_spilling_config`: o AWS Glue para Ray permite o uso do Amazon S3 como forma de ampliar o espaço disponível para o armazenamento de objetos do Ray. Para habilitar esse comportamento, você pode fornecer ao Ray um objeto de configuração JSON Object spilling com esse parâmetro. Para obter mais informações sobre a configuração de object spilling do Ray, consulte Object Spilling na documentação do Ray. Formato: objeto JSON.

  O AWS Glue para Ray só permite spilling para o disco ou para o Amazon S3 de uma só vez. Você pode fornecer vários locais para spilling, desde que respeitem essa limitação. Ao fazer o spilling para o Amazon S3, você também precisará adicionar permissões do IAM ao trabalho para esse bucket.

  Ao fornecer um objeto JSON como configuração com a CLI, você deve fornecê-lo como uma string, com o objeto JSON escapado por string. Por exemplo, um valor de string para spilling para um caminho do Amazon S3 seria assim: `"{\"type\": \"smart_open\", \"params\": {\"uri\":\"s3path\"}}"`. No AWS Glue Studio, forneça esse parâmetro como um objeto JSON sem formatação extra.

- `--object_store_memory_head`: a memória alocada para o armazenamento de objetos Plasma no nó principal do Ray. Essa instância executa serviços de gerenciamento de cluster, bem como réplicas de processador. O valor representa uma porcentagem da memória livre na instância após uma inicialização a quente. Use esse parâmetro para ajustar as workloads com uso intenso de memória; os valores padrão são aceitáveis para a maioria dos usuários. Formato: número inteiro positivo. Mínimo: 1. Máximo: 100.

  Para obter mais informações sobre o Plasma, consulte The Plasma In-Memory Object Store (Armazenamento de objeto em memória do Plasma) na documentação do Ray.

- `--object_store_memory_worker`: a memória alocada para o armazenamento de objetos do Plasma no nó principal do Ray. Essas instâncias executam apenas réplicas de processador. O valor representa uma porcentagem da memória livre na instância após uma inicialização a quente. Esse parâmetro é usado para ajustar as workloads com uso intenso de memória; os valores padrão são aceitáveis para a maioria dos usuários. Formato: número inteiro positivo. Mínimo: 1. Máximo: 100.

  Para obter mais informações sobre o Plasma, consulte The Plasma In-Memory Object Store (Armazenamento de objeto em memória do Plasma) na documentação do Ray.

- `--pip-install`: um conjunto de pacotes do Python a serem instalados. Você pode instalar pacotes do PyPI usando esse argumento. Formato: lista delimitada por vírgulas.

  Uma entrada de pacote PyPI tem o formato de `package==version`, com o nome PyPI e a versão do pacote de destino. As entradas usam a correspondência de versões do Python para combinar o pacote com a versão, como ==, não um único sinal de igual =. Existem outros operadores que correspondem à versão. Para obter mais informações, consulte PEP 440 no site da Python. Você também pode fornecer os módulos personalizados com os `--s3-py-modules`.

- `--s3-py-modules`: um conjunto de caminhos do Amazon S3 que hospedam distribuições de módulos do Python. Formato: lista delimitada por vírgulas.

  Você pode usar essa opção para distribuir seus próprios módulos para o seu trabalho do Ray. Você também pode fornecer os módulos do PyPi com `--pip-install`. Ao contrário de ETL do AWS Glue, os módulos personalizados não são configurados por pip, mas são passados para o Ray para distribuição. Para ter mais informações, consulte the section called “Módulos adicionais do Python para trabalhos do Ray”.

- `--working-dir`: um caminho para um arquivo.zip hospedado no Amazon S3 que contém arquivos a serem distribuídos a todos os nós que executam o trabalho do Ray. Formato: string. Para ter mais informações, consulte the section called “Fornecer arquivos para o trabalho do Ray”.

Monitorar trabalhos do Ray com métricas

É possível monitorar trabalhos do Ray usando o AWS Glue Studio e o Amazon CloudWatch. O CloudWatch coleta e processa métricas brutas do AWS Glue com o Ray, o que as torna disponíveis para análise. Essas métricas são visualizadas no console do AWS Glue Studio, para que você possa monitorar o trabalho enquanto ele é executado.

Para obter uma visão geral de como monitorar o AWS Glue, consulte the section called “Usar métricas do Amazon CloudWatch”. Para obter uma visão geral de como usar as métricas do CloudWatch publicadas pelo AWS Glue, consulte the section called “Monitoramento com CloudWatch”.

Monitorar tarefas do Ray no console do AWS Glue

Na página de detalhes de uma execução de trabalho, abaixo da seção Detalhes da execução, você pode ver gráficos agregados pré-montados que mostram as métricas de trabalho disponíveis. O AWS Glue Studio envia as métricas de trabalho para o CloudWatch para toda execução de trabalho.

Com elas, você pode criar um perfil do cluster e das tarefas, bem como acessar informações detalhadas sobre cada nó.

Para obter mais informações sobre métricas gráficas disponíveis, consulte the section called "Visualizar métricas do Amazon CloudWatch para uma execução de trabalho do Ray".

Visão geral das métricas de trabalhos do Ray no CloudWatch

Publicamos métricas do Ray quando o monitoramento detalhado está ativado no CloudWatch. As métricas são publicadas no namespace `Glue/Ray` do CloudWatch.

- Métricas de instância

  Publicamos métricas sobre a utilização de CPU, memória e disco das instâncias designadas para uma tarefa. Essas métricas são identificadas por recursos como `ExecutorId`, `ExecutorType` e `host`. Essas métricas são um subconjunto das métricas padrão do agente Linux CloudWatch. Você pode encontrar informações sobre nomes e recursos de métricas na documentação do CloudWatch. Para obter mais informações, consulte Métricas coletadas pelo atendente do CloudWatch.

- Métricas de cluster do Ray

  Encaminhamos as métricas dos processos do Ray que executam o script nesse namespace, depois fornecemos a você as mais vitais. As métricas disponíveis podem diferir segundo a versão do Ray. Para obter mais informações sobre qual versão do Ray seu trabalho está executando, consulte the section called "Versões do AWS Glue".

  O Ray coleta métricas no nível da instância. Ele também fornece métricas para tarefas e para o cluster. Para obter mais informações sobre a estratégia de métricas subjacente do Ray, consulte Metrics na documentação do Ray.

> **Note**
>
> Não publicamos métricas de Ray no namespace do `Glue/Job Metrics/`, que é usado apenas para trabalhos do AWS Glue ETL.

Configurar propriedades de trabalho para trabalhos de shell Python no AWS Glue

É possível usar um trabalho de shell do Python para executar scripts do Python como um shell no AWS Glue. Com uma tarefa de shell do Python, é possível executar scripts compatíveis com Python 3.6 ou Python 3.9.

> **Note**
>
> O suporte para o Pyshell v3.6 terminará em 1º de março de 2026. Para migrar as workloads, consulte Migrate from AWS Glue Python shell jobs. Caso deseje continuar usando o shell Python v3.9, consulte Migração do shell Python 3.6 para o shell Python 3.9.

Tópicos

- Limitações
- Definir propriedades de trabalho para trabalhos de shell Python
- Bibliotecas compatíveis com trabalhos de shell Python
- Fornecer sua própria biblioteca Python
- Use AWS CloudFormation com trabalhos de shell Python no AWS Glue
- Migração do shell Python 3.6 para o shell Python 3.9
- Migrar dos trabalhos de shell Python no AWS Glue

Limitações

Observe as seguintes limitações de trabalhos do shell do Python:

- Não é possível usar marcadores de trabalho com trabalhos de shell de Python.
- Não é possível empacotar bibliotecas do Python como arquivos `.egg` no Python 3.9+. Em seu lugar, use `.whl`.
- A opção `--extra-files` não pode ser usada devido a uma limitação de cópias temporárias de dados do S3.

Definir propriedades de trabalho para trabalhos de shell Python

Estas seções descrevem a definição das propriedades de trabalho no AWS Glue Studio ou usando a AWS CLI.

AWS Glue Studio

Ao definir o trabalho de shell do Python no AWS Glue Studio, você fornece algumas das seguintes propriedades:

Perfil do IAM

Especifique a função do AWS Identity and Access Management (IAM) usada para a autorização de recursos necessários para a execução do trabalho e acesso ao datastore. Para obter mais informações sobre permissões de execução de trabalho no AWS Glue, consulte Gerenciamento de identidade e acesso do AWS Glue.

Tipo

Selecione Python shell (Shell do Python) para executar um script do Python com o comando de trabalho chamado `pythonshell`.

Versão do Python

Escolha a versão do Python. O padrão é o Python 3.9. As versões válidas são Python 3.6 e Python 3.9.

Carregar bibliotecas comuns de analytics (recomendado)

Escolha essa opção para incluir bibliotecas comuns para Python 3.9 no shell do Python.

Se suas bibliotecas forem personalizadas ou entrarem em conflito com as bibliotecas pré-instaladas, você poderá optar por não instalar bibliotecas comuns. No entanto, é possível instalar bibliotecas adicionais além das bibliotecas comuns.

Ao marcar essa opção, a opção `library-set` fica definida como `analytics`. Ao desmarcar essa opção, a opção `library-set` fica definida como `none`.

Nome do arquivo de script e caminho do script

O código no script define a lógica processual do trabalho. É possível fornecer o nome e o local do script no Amazon Simple Storage Service (Amazon S3). Confirme se não existe um arquivo com o mesmo nome que o diretório do script no caminho. Para saber mais sobre como usar scripts, consulte Guia de programação do AWS Glue.

Script

O código no script define a lógica processual do trabalho. Você pode codificar o script em Python 3.6 ou Python 3.9. Você pode editar um script no AWS Glue Studio.

Unidades de processamento de dados

O número máximo de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando esse trabalho for executado. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte Preços do AWS Glue.

Você pode definir o valor como 0,0625 ou 1. O padrão é 0.0625. Em ambos os casos, o disco local da instância será de 20 GB.

CLI

Também é possível criar um trabalho de Python shell (Shell do Python) usando a AWS CLI, como no exemplo a seguir.

```
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**
>
> Você não precisa especificar a versão do AWS Glue, pois o parâmetro `--glue-version` não se aplica a trabalhos de shell do AWS Glue. Qualquer versão especificada será ignorada.

Por padrão, os trabalhos que você cria com a AWS CLI são definidos para Python 3. As versões válidas do Python são 3 (correspondendo à versão 3.6) e 3.9. Para especificar o Python 3.6, adicione a seguinte tupla ao parâmetro `--command`: `"PythonVersion":"3"`

Para especificar o Python 3.9, adicione a seguinte tupla ao parâmetro `--command`: `"PythonVersion":"3.9"`

Para definir a capacidade máxima usada por um trabalho de shell do Python, forneça o parâmetro `--max-capacity`. Para trabalhos de shell do Python, o parâmetro `--allocated-capacity` não pode ser usado.

Bibliotecas compatíveis com trabalhos de shell Python

Ao usar o Python 3.9, você pode escolher no shell do Python o conjunto de bibliotecas para usar conjuntos pré-empacotados de bibliotecas conforme suas necessidades. Você pode usar a opção `library-set` para escolher o conjunto de bibliotecas. Os valores válidos são `analytics` e `none`.

O ambiente para executar um trabalho de shell de Python é compatível com as seguintes bibliotecas:

Versão do Python	Python 3.6	Python 3.9	
Conjunto de bibliotecas	N/D	analytics	none
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	

Versão do Python	Python 3.6	Python 3.9	
pyodbc		4.0.32	
pyorc		0.6.0	
redshift-connector		2.0.907	
solicitações	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	

Você pode usar a biblioteca NumPy em um trabalho de shell do Python para computação científica. Para obter mais informações, consulte NumPy. O exemplo a seguir mostra um script NumPy que pode ser usado em um trabalho de shell do Python. O script imprime "Hello world" e os resultados de vários cálculos matemáticos.

```
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)
```

Fornecer sua própria biblioteca Python

Usar o PIP

Ao usar o Python 3.9, o shell do Python permite que você forneça módulos adicionais ou versões diferentes do Python por trabalho. Você pode usar a opção `--additional-python-modules` com uma lista de módulos do Python separados por vírgulas para adicionar um novo módulo ou alterar a versão de um existente. Você não pode fornecer módulos Python personalizados hospedados no Amazon S3 com esse parâmetro ao usar trabalhos de shell do Python.

Por exemplo, para atualizar ou adicionar um novo módulo `scikit-learn`, use o seguinte par de chave e valor: `"--additional-python-modules", "scikit-learn==0.21.3"`.

O AWS Glue usa o Python Package Installer (pip3) para instalar os módulos adicionais. Você pode passar opções adicionais de pip3 dentro do valor `--additional-python-modules`. Por exemplo, .`"scikit-learn==0.21.3 -i https://pypi.python.org/simple/"` Quaisquer incompatibilidades ou limitações do pip3 se aplicam.

> **Note**
>
> Para evitar incompatibilidades futuras, recomendamos o uso de bibliotecas compiladas para o Python 3.9.

Usar um arquivo Egg ou Whl

Talvez você já tenha uma ou mais bibliotecas Python empacotadas como um arquivo `.egg` ou `.whl`. Se esse for o caso, você poderá especificá-las para o trabalho usando a AWS Command Line Interface (AWS CLI) no sinalizador `"--extra-py-files"`, como no exemplo a seguir.

```
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"]}'
```

Se você não tiver certeza de como criar um arquivo `.egg` ou `.whl` de uma biblioteca Python, use as etapas a seguir. Este exemplo é aplicável a macOS, Linux e Windows Subsystem for Linux (WSL).

Como criar um arquivo .egg ou .whl em Python

1. Crie um cluster do Amazon Redshift em uma nuvem privada virtual (VPC) e adicione alguns dados a uma tabela.
2. Crie uma conexão do AWS Glue para a combinação VPC-GrupodeSegurança-Sub-rede que você usou para criar o cluster. Teste se a conexão foi bem-sucedida.
3. Crie um diretório chamado `redshift_example` e crie um arquivo chamado `setup.py`. Cole o seguinte código em `setup.py`.

```
from setuptools import setup

setup(
    name="redshift_module",
    version="0.1",
    packages=['redshift_module']
)
```

4. No diretório `redshift_example`, crie um diretório `redshift_module`. No diretório `redshift_module`, crie os arquivos `__init__.py` e `pygresql_redshift_common.py`.
5. Deixe o campo `__init__.py` vazio. Em `pygresql_redshift_common.py`, cole o seguinte código: Substitua *`port`* (porta), *`db_name`* (nome do bd), *`user`* (usuário) e *`password_for_user`* (senha do usuário) por detalhes específicos do seu cluster do Amazon Redshift. Substitua *`table_name`* (nome da tabela) pelo nome da tabela no 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. Se você ainda não estiver lá, altere para o diretório `redshift_example`.
7. Execute um destes procedimentos:

   - Execute o seguinte comando para criar um arquivo `.egg`.

     ```
     python setup.py bdist_egg
     ```

   - Execute o seguinte comando para criar um arquivo `.whl`.

     ```
     python setup.py bdist_wheel
     ```

8. Instale as dependências necessárias para o comando anterior.
9. O comando cria um arquivo no diretório `dist`:

   - Se você criou um arquivo egg, ele se chama `redshift_module-0.1-py2.7.egg`.
   - Se você criou um arquivo wheel, ele se chama `redshift_module-0.1-py2.7-none-any.whl`.

   Faça upload desse arquivo no Amazon S3.

   Neste exemplo, o caminho do arquivo carregado é *`s3://amzn-s3-demo-bucket/EGG-FILE`* ou *`s3://amzn-s3-demo-bucket/WHEEL-FILE`*.

10. Crie um arquivo Python para ser usado como um script para o trabalho do AWS Glue e adicione o seguinte código ao arquivo.

    ```
    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. Faça o upload do arquivo anterior no Amazon S3. Neste exemplo, o caminho do arquivo carregado é *`s3://amzn-s3-demo-bucket/scriptname.py`*.

12. Crie um trabalho de shell do Python usando esse script. No console do AWS Glue, na página Job properties (Propriedades do trabalho), especifique o caminho para o arquivo `.egg/.whl` na caixa Python library path (Caminho da biblioteca Python). Se você tiver vários arquivos `.egg/.whl` e arquivos Python, forneça uma lista separada por vírgulas nesta caixa.

    Ao modificar ou renomear arquivos `.egg`, os nomes de arquivo devem usar os nomes padrão gerados pelo comando "python setup.py bdist_egg" ou devem aderir às convenções de nomenclatura do módulo Python. Para obter mais informações, consulte o Style Guide for Python Code.

    Usando a AWS CLI, crie um trabalho com um comando, como no exemplo a seguir.

    ```
    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"]}'
    ```

    Quando o trabalho é executado, o script imprime as linhas criadas na tabela *`table_name`* no cluster do Amazon Redshift.

Use AWS CloudFormation com trabalhos de shell Python no AWS Glue

Você pode usar AWS CloudFormation com trabalhos de shell Python no AWS Glue. Veja um exemplo a seguir:

```
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
```

O grupo do Amazon CloudWatch Logs para a saída de trabalhos de shell do Python é `/aws-glue/python-jobs/output`. Para erros, consulte o grupo de logs `/aws-glue/python-jobs/error`.

Migração do shell Python 3.6 para o shell Python 3.9

Para migrar seus trabalhos do shell Python para a versão mais recente do AWS Glue:

1. No console do AWS Glue (https://console.aws.amazon.com/glue/), escolha seu trabalho de shell Python existente.
2. Na guia de detalhes do Trabalho, defina a versão do Python como `Python 3.9` e clique em Salvar.
3. Certifique-se de que o script do trabalho seja compatível com o Python 3.9 e que ele pode ser executado com êxito.

Migrar dos trabalhos de shell Python no AWS Glue

A AWS lançou os trabalhos do shell Python do AWS Glue em 2018 A AWS lançou os trabalhos do shell Python do AWS Glue em 2018 para oferecer aos clientes uma maneira fácil de executar scripts Python para trabalhos de ETL pequenos e médios e de acionar consultas em SQL. Porém, agora existem opções mais modernas e flexíveis para lidar com as cargas de trabalho executadas atualmente no PythonShell. Este tópico explica como migrar suas cargas de trabalho dos trabalhos do shell Python do AWS Glue para uma dessas opções alternativas a fim de aproveitar os novos recursos disponíveis.

Este tópico explica como migrar de trabalhos do shell Python do AWS Glue para opções alternativas.

Migrar workload para trabalhos do AWS Glue Spark

Os trabalhos do AWS Glue Spark e do PySpark permitem que você execute as cargas de trabalho de forma distribuída. Como os trabalhos do shell Python do AWS Glue e do AWS Glue Spark são executados na mesma plataforma, é fácil migrar, e você pode continuar usando os recursos existentes do AWS Glue que está usando com os trabalhos do shell Python, como workflows do AWS Glue, gatilhos do AWS Glue, a integração do Amazon EventBridge do AWS Glue, instalação de pacotes baseados em\ Pip e assim por diante.

Porém, os trabalhos do AWS Glue Spark foram desenhados para executar as workload do Spark, e o número mínimo de operadores é 2. Se você migrar de trabalhos do Python Shell sem modificar

os scripts, apenas um operador será realmente usado e os outros permanecerão ociosos. Isso aumentará o custo.

Para que isso seja eficiente, reescreva o script de trabalho Python para utilizar os recursos do Spark e distribuir a workload entre vários operadores. Se o script Python for baseado no Pandas, será fácil migrar usando a nova API do Pandas no Spark. Informe-se mais sobre isso no AWS Big Data Blog: Dive deep into AWS Glue 4.0 for Apache Spark.

Migrar workloads para o AWS Lambda

O AWS Lambda é um serviço de computação com tecnologia sem servidor que permite executar código sem provisionar nem gerenciar servidores. Como o AWS Lambda tem tempos de startup menores e opções mais flexíveis de capacidade computacional, você pode aproveitar essas vantagens. Para gerenciar bibliotecas Python adicionais, os trabalhos de shell Python do AWS Glue usam instalação baseada em PIP. Porém, para o AWS Lambda, você precisa escolher uma das seguintes opções: um arquivo zip, uma imagem de contêiner ou camadas do Lambda.

Por outro lado, o tempo limite máximo do AWS Lambda é de 900 segundos (15 minutos). Se a duração do trabalho de sua workload existente do shell Python do AWS Glue for maior que isso, ou se sua workload tiver um padrão de picos que possa causar durações de trabalho mais longas, recomendamos explorar outras opções em vez do AWS Lambda.

Migrar a workload para o Amazon ECS/Fargate

O Amazon Elastic Container Service (Amazon ECS) é um serviço totalmente gerenciado que simplifica a implantação, o gerenciamento e a escalabilidade de aplicações conteinerizadas. O AWS Fargate é um mecanismo de computação com tecnologia sem servidor para workloads conteinerizadas sendo executadas no Amazon ECS e no Amazon Elastic Kubernetes Service (Amazon EKS). Não há tempo limite máximo no Amazon ECS e no Fargate, portanto, essa é uma boa opção para trabalhos de longa duração. Como você tem controle total sobre a imagem do contêiner, pode trazer seu script Python e bibliotecas Python adicionais para o contêiner e usá-los. Porém, você precisa containerizar o script Python para usar essa abordagem.

Migrar workload para o Amazon Managed Workflows para operador do Apache Airflow Python

O Amazon Managed Workflows para o Apache Airflow (Managed Workflows para o Apache Airflow) é um serviço de orquestração gerenciado para o Apache Airflow que facilita a configuração e a operação de ponta a ponta de pipelines de dados na nuvem em larga escala. Se você já tiver um

ambiente do MWAA, será fácil usar o operador Python em vez dos trabalhos do shell Python do AWS Glue. O operador do Python é um operador que executa código do Python dentro de um fluxo de trabalho do Airflow. Porém, se você não tiver um ambiente do MWAA já existente, recomendamos que explore outras opções.

Migrar workload para trabalhos de treinamento de IA do Amazon SageMaker AI

O Amazon SageMaker AI Training é um serviço de machine learning (ML) totalmente gerenciado oferecido pelo Amazon SageMaker AI que ajuda você a treinar com eficiência uma grande variedade de modelos de ML em larga escala. A essência dos trabalhos de IA do Amazon SageMaker AI é a conteinerização das workloads de ML e a capacidade de gerenciar recursos de computação da AWS. Se você preferir um ambiente de tecnologia sem servidor onde não haja tempo limite máximo, os trabalhos de treinamento de IA do Amazon SageMaker AI podem ser uma boa opção para você. Porém, a latência de startup tende a ser maior do que nos trabalhos do shell Python do AWS Glue. Para trabalhos sensíveis à latência, recomendamos explorar outras opções.

Como monitorar o AWS Glue

O monitoramento é uma parte importante para manter a confiabilidade, a disponibilidade e a performance do AWS Glue e das suas outras soluções da AWS. O AWS fornece ferramentas de monitoramento que você pode usar para observar o AWS Glue, informar quando algo está errado e realizar uma ação automaticamente quando apropriado:

Você pode usar as seguintes ferramentas de monitoramento automatizadas para observar o AWS Glue e gerar relatórios quando algo estiver errado:

- O Amazon CloudWatch Events oferece uma transmissão quase em tempo real de eventos do sistema que descrevem as mudanças nos recursos da AWS. O CloudWatch Events permite a computação automatizada baseada em eventos. Você pode escrever regras que observam certos eventos e acionam ações automatizadas em outros serviços da AWS quando esses eventos ocorrem. Para obter mais informações, consulte o Manual do usuário do Amazon CloudWatch Events.
- O Amazon CloudWatch Logs permite monitorar, armazenar e acessar os arquivos de log de instâncias do Amazon EC2, do AWS CloudTrail e de outras fontes. O CloudWatch Logs pode monitorar informações nos arquivos de log e notificar você quando determinados limites forem atingidos. É possível também arquivar seus dados de log em armazenamento resiliente. Para obter mais informações, consulte o Guia do usuário do Amazon CloudWatch Logs.

- O AWS CloudTrail captura chamadas de API e eventos relacionados feitos por, ou em nome de, sua conta da AWS e entrega os arquivos de log a um bucket do Amazon S3 que você especificar. Você pode identificar quais usuários e contas chamaram a AWS, o endereço IP de origem do qual as chamadas foram feitas e quando elas ocorreram. Para obter mais informações, consulte o Guia do usuário do AWS CloudTrail.

Além disso, você tem acesso aos seguintes insights no console do AWS Glue para ajudar você a depurar e criar perfis de trabalho:

- Trabalhos do Spark: é possível visualizar séries de métricas selecionadas do CloudWatch, e trabalhos mais recentes têm acesso à interface do usuário do Spark. Para ter mais informações, consulte the section called “Monitorar trabalhos Spark”.
- Trabalhos do Ray: é possível visualizar séries de métricas selecionadas do CloudWatch. Para ter mais informações, consulte the section called “Métricas de trabalho do Ray”.

Tópicos

- Etiquetas da AWS no AWS Glue
- Automação do AWS Glue com o EventBridge
- Monitorar recursos do AWS Glue
- Registrar em log chamadas de API do AWS Glue com o AWS CloudTrail

Etiquetas da AWS no AWS Glue

Para ajudar você a gerenciar seus recursos do AWS Glue, você pode, opcionalmente, atribuir suas próprias tags para alguns tipos de recursos do AWS Glue. Uma tag um rótulo atribuído a um recurso AWS. Cada tag consiste em uma chave e um valor opcional, ambos definidos por você. Use tags no AWS Glue para organizar e identificar seus recursos. As tags podem ser usadas para criar relatórios de contabilidade de custos e restringir o acesso aos recursos. Se você estiver usando o AWS Identity and Access Management, pode controlar quais usuários na sua conta da AWS têm permissão para criar, editar ou excluir tags. Além das permissões para chamar as APIs relacionadas a tags, você também precisa da permissão `glue:GetConnection` para chamar APIs de marcação em conexões e da permissão `glue:GetDatabase` para chamar APIs de marcação em bancos de dados. Para ter mais informações, consulte ABACcom AWS Glue.

No AWS Glue, você pode marcar os seguintes recursos:

- Conexão
- Banco de dados
- Crawler
- Sessão interativa
- Endpoint de desenvolvimento
- Trabalho
- Trigger
- Fluxo de trabalho
- Blueprint
- Transformação de machine learning
- Regras de qualidade de dados
- Esquemas de fluxo
- Registros do esquema de fluxo

> **Note**
>
> Como uma das melhores práticas, para permitir a marcação desses recursos do AWS Glue, sempre inclua a ação `glue:TagResource` em suas políticas.

Considere o seguinte ao usar tags no AWS Glue.

- Uma entidade suporta um máximo de 50 tags.
- No AWS Glue, você especifica as tags como uma lista de pares de chave-valor no formato `{"string": "string" ...}`
- Quando você cria uma tag em um objeto, a chave da tag é obrigatória, e o valor da tag é opcional.
- A chave e o valor da tag diferenciam maiúsculas de minúsculas.
- A chave da tag e o valor da tag não devem conter o prefixo aws. Nenhuma operação é permitida nessas tags.
- O comprimento máximo da chave da tag é de 128 caracteres Unicode em UTF-8. A chave da tag não pode estar vazia nem ser nula.
- O comprimento máximo do valor da tag é de 256 caracteres Unicode em UTF-8. O valor da tag pode estar vazio ou ser nulo.

Suporte para marcação para conexões do AWS Glue

Você pode restringir as permissões das ações `CreateConnection`, `UpdateConnection`, `GetConnection` e `DeleteConnection` com base na marcação de recurso. Isso permite que você implemente o controle de acesso de privilégio mínimo em trabalhos do AWS Glue com fontes de dados JDBC que precisam buscar informações de conexão JDBC no catálogo de dados.

Exemplo de uso

Crie uma conexão do AWS Glue com a marcação ["connection-category", "dev-test"].

Especifique a condição da marcação para a ação `GetConnection` na política do IAM.

```
{
   "Effect": "Allow",
   "Action": [
     "glue:GetConnection"
     ],
   "Resource": "*",
   "Condition": {
     "ForAnyValue:StringEquals": {
       "aws:ResourceTag/tagKey": "dev-test"
     }
   }
 }
```

Exemplos

Os exemplos a seguir criam um trabalho com tags atribuídas.

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
```

JSON do AWS CloudFormation

```
{
  "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"
           }
        }
      }
    }
  }
}
```

YAML do AWS CloudFormation

```
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
```

Para obter mais informações, consulte Estratégias de marcação da AWS.

Para obter informações sobre como controlar o acesso usando tags, consulte ABACcom AWS Glue.

Automação do AWS Glue com o EventBridge

É possível usar o Amazon EventBridge para automatizar os serviços da AWS e responder automaticamente a eventos do sistema, como problemas de disponibilidade de aplicações ou alterações em recursos. Os eventos dos serviços da AWS são entregues ao EventBridge quase em tempo real. Você pode escrever regras simples para indicar quais eventos são do seu interesse, e as ações automatizadas a serem tomadas quando um evento corresponder à regra. As ações que podem ser automaticamente acionadas incluem as seguintes:

- Invocar uma função do AWS Lambda
- Invocar o comando de execução do Amazon EC2
- Transmitir o evento Amazon Kinesis Data Streams
- Ativação de uma máquina de estado do AWS Step Functions
- Notificar um tópico do Amazon SNS ou uma fila do Amazon SQS

Alguns exemplos de uso do EventBridge em conjunto com o AWS Glue incluem os seguintes:

- Ativar uma função Lambda quando um trabalho de ETL é executado com sucesso

- Notificar um tópico do Amazon SNS quando um trabalho de ETL apresentar falha

Os eventos do EventBridge apresentados a seguir são gerados pelo AWS Glue.

- Os eventos de `"detail-type":"Glue Job State Change"` são gerados para `SUCCEEDED`, `FAILED`, `TIMEOUT` e `STOPPED`.
- Os eventos de `"detail-type":"Glue Job Run Status"` são gerados para execuções de trabalho de `RUNNING` e de `STARTINGSTOPPING`, quando elas excedem o limite da notificação de atraso do trabalho. Você deve definir a propriedade de limite de notificação de atraso de trabalho para receber esses eventos.

  Quando o limite de notificação de atraso de trabalho é excedido, apenas um único evento é gerado por status de execução de trabalho.
- Os eventos de `"detail-type":"Glue Crawler State Change"` são gerados por `Started`, `Succeeded` e `Failed`.
- Os eventos com `“detail_type”:“Glue Scheduled Crawler Invocation Failure”` são gerados quando ocorre uma falha na inicialização de um crawler programado. Nos detalhes da notificação:
  - `customerId` contém o ID da conta do cliente.
  - `crawlerName` contém o nome do crawler com falha na inicialização.
  - `errorMessage` contém a mensagem de exceção gerada pela falha na invocação.
- Os eventos com `“detail_type”:“Glue Auto Statistics Invocation Failure“` são gerados quando ocorre uma falha na inicialização da execução da tarefa de estatísticas de colunas gerenciadas automaticamente. Nos detalhes da notificação:
  - `catalogId` contém o ID associado a um catálogo.
  - `databaseName` contém o nome do banco de dados afetado.
  - `tableName` contém o nome da tabela afetada.
  - `errorMessage` contém a mensagem de exceção gerada pela falha na invocação.
- Os eventos com `“detail_type”:“Glue Scheduled Statistics Invocation Failure”` são gerados quando ocorre uma falha na inicialização da execução da tarefa de estatísticas de colunas programadas (cron). Nos detalhes da notificação:
  - `catalogId` contém o ID associado a um catálogo.
  - `databaseName` contém o nome do banco de dados afetado.
  - `tableName` contém o nome da tabela afetada.

  - `errorMessage` contém a mensagem de exceção gerada pela falha na invocação.
- Os eventos com `“detail_type”:“Glue Statistics Task Started”` são gerados quando ocorre uma inicialização da execução da tarefa de estatísticas de colunas.
- Os eventos com `“detail_type”:“Glue Statistics Task Succeeded”` são gerados quando ocorre uma execução da tarefa de estatísticas de colunas obtém êxito.
- Os eventos com `“detail_type”:“Glue Statistics Task Failed”` são gerados quando ocorre uma execução da tarefa de estatísticas de colunas apresenta falhas.
- Os eventos de `"detail-type":"Glue Data Catalog Database State Change"` são gerados para `CreateDatabase`, `DeleteDatabase`, `CreateTable`, `DeleteTable` e `BatchDeleteTable`. Por exemplo, se uma tabela for criada ou excluída, uma notificação será enviada ao EventBridge. Observe que não é possível escrever um programa que depende da ordem ou da existência de eventos de notificação, já que eles podem estar fora de sequência ou ausentes. Os eventos são emitidos com base no melhor esforço. Nos detalhes da notificação:
  - O `typeOfChange` contém o nome da operação da API.
  - O `databaseName` contém o nome do banco de dados afetado.
  - O `changedTables` contém até 100 nomes de tabelas afetadas por notificação. Quando os nomes das tabelas forem muito longos, poderão ser criadas várias notificações.
- Os eventos de `"detail-type":"Glue Data Catalog Table State Change"` são gerados para `UpdateTable`, `CreatePartition`, `BatchCreatePartition`, `UpdatePartition`, `DeletePartition`, `BatchUpdatePartition` e `BatchDeletePartition`. Por exemplo, se uma tabela ou partição for atualizada, uma notificação será enviada ao EventBridge. Observe que não é possível escrever um programa que depende da ordem ou da existência de eventos de notificação, já que eles podem estar fora de sequência ou ausentes. Os eventos são emitidos com base no melhor esforço. Nos detalhes da notificação:
  - O `typeOfChange` contém o nome da operação da API.
  - O `databaseName` contém o nome do banco de dados que contém os recursos afetados.
  - O `tableName` contém o nome da tabela afetada.
  - O `changedPartitions` especifica até 100 partições afetadas em uma notificação. Quando os nomes das partições forem muito longos, poderão ser criadas várias notificações.

    Por exemplo, se houver duas chaves de partição, `Year` e `Month`, `"2018,01", "2018,02"` modificará a partição em que `"Year=2018" and "Month=01"` e a partição em que `"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"
        }
}
```

Para obter mais informações, consulte o Manual do usuário do Amazon CloudWatch Events. Para eventos específicos do AWS Glue, consulte Eventos do AWS Glue.

Monitorar recursos do AWS Glue

O AWS Glue tem limites de serviço para proteger os clientes de provisionamento excessivo inesperado e de ações maliciosas destinadas a aumentar sua fatura. Os limites também protegem o serviço. Ao fazer login no console do AWS Service Quota, os clientes podem visualizar seus limites atuais de recursos e solicitar um aumento (quando apropriado).

O AWS Glue permite que você visualize o uso de recursos do serviço como uma porcentagem no Amazon CloudWatch e configure alarmes do CloudWatch para monitorar o uso. O Amazon CloudWatch fornece monitoramento de recursos da AWS e de aplicações dos clientes sem execução na infraestrutura da Amazon. As métricas são gratuitas para você. As seguintes métricas têm suporte:

- Número de fluxos de trabalho por conta
- Número de gatilhos por conta
- Número de jobs por conta

- Número de execuções de trabalho simultâneas por conta
- Número de esquemas por conta
- Número de sessões interativas por conta

Configurar e usar métricas de recursos

Para usar esse atributo, você pode acessar o console do Amazon CloudWatch para visualizar as métricas e configurar os alarmes. As métricas estão no namespace AWS/Glue e são uma porcentagem da contagem real de uso do recurso dividida pela cota do recurso. As métricas do CloudWatch são entregues às suas contas, e não terão nenhum custo para você. Por exemplo, se você tiver 10 fluxos de trabalho criados e sua cota de serviço permitir que você tenha 200 fluxos de trabalho no máximo, seu uso será 10/200 = 5% e, no gráfico, você verá um ponto de dados de 5 como porcentagem. Para ser mais específico:

```
Namespace: AWS/Glue
Metric name: ResourceUsage
Type: Resource
Resource: Workflow (or Trigger, Job, JobRun, Blueprint, InteractiveSession)
Service: Glue
Class: None
```

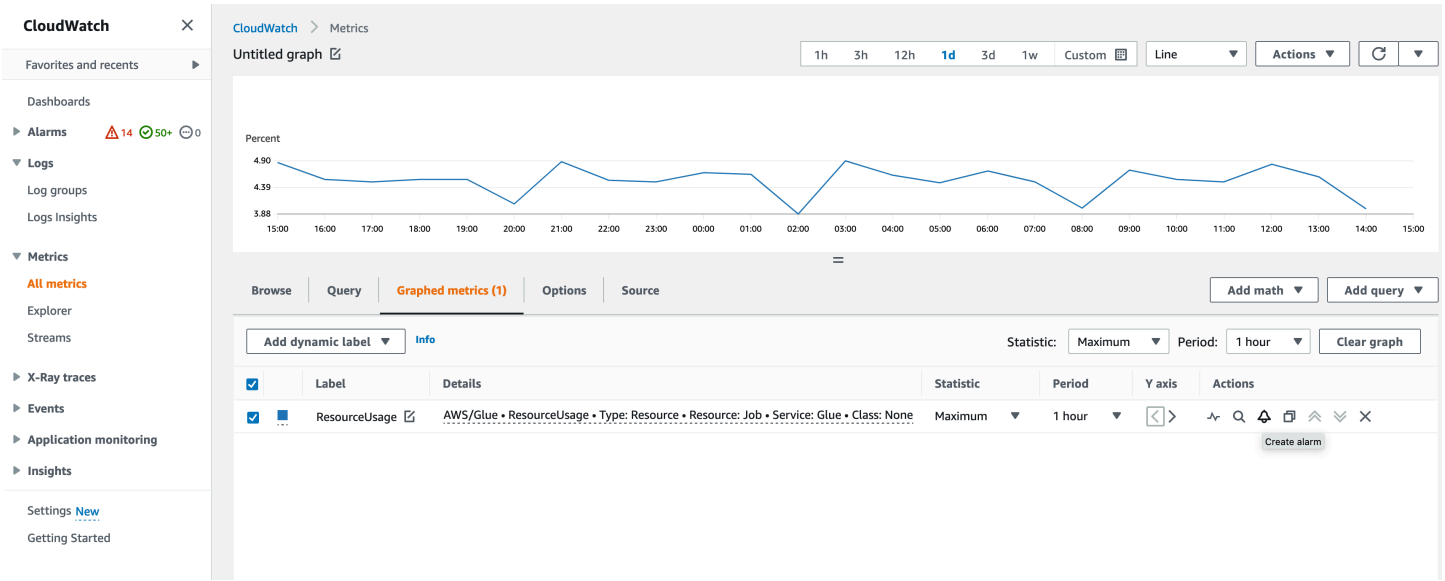

Para criar um alarme com base em uma métrica no console do CloudWatch:

1. Depois de localizar a métrica, acesse Métricas em gráfico.

2. Clique em Criar alarme em Ações.
3. Configure o alarme conforme necessário.

Nós emitimos métricas sempre que seu uso de recursos sofrer uma alteração (como um aumento ou diminuição). Mas se o uso de seus recursos não mudar, emitimos métricas de hora em hora, para que você tenha um gráfico contínuo do CloudWatch. Para evitar a perda de pontos de dados, não recomendamos que você configure um período inferior a 1 hora.

Você também pode configurar alarmes usando o AWS CloudFormation como no exemplo a seguir. Neste exemplo, quando o uso de recursos do fluxo de trabalho atinge 80%, ele aciona um alarme para enviar uma mensagem para o tópico existente do SNS, onde você pode se inscrever para receber notificações.

```
{
 "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"
  }
}
```

Registrar em log chamadas de API do AWS Glue com o AWS CloudTrail

O AWS Glue é integrado a AWS CloudTrail, serviço que fornece um registro das ações realizadas por um usuário, perfil ou AWS serviço em AWS Glue. O CloudTrail captura todas as chamadas API para AWS Glue como eventos. As chamadas capturadas incluem as aquelas do AWS Glue console e chamadas de código para operações API da AWS Glue. Caso crie uma trilha, voce pode habilitar a entrega contínua de eventos CloudTrail para um bucket Amazon S3, inclusive eventos para AWS Glue. Mesmo que não configure uma trilha, você ainda pode visualizar os eventos mais recentes no console CloudTrail em Histórico de Eventos. Ao fazer uso das informações coletadas pelo CloudTrail, é possível determinar a solicitação feita a AWS Glue, o endereço IP no qual a solicitação foi feita, quem fez a solicitação e quando foi feita, além de detalhes adicionais.

Para saber mais sobre o CloudTrail, consulte o AWS CloudTrail Guia de Usuário.

Informações do AWS Glue no CloudTrail

O CloudTrail é habilitado em sua AWS conta ao criá-la. Quando ocorre uma atividade no AWS Glue, essa atividade é registrada em um evento do CloudTrail com outros eventos de produtos da AWS em Histórico do evento. Você pode visualizar, pesquisar e baixar eventos recentes em sua AWS conta. Para mais informações, consulte Visualizando Eventos com Histórico de Eventos CloudTrail.

Para um registro contínuo de eventos em sua AWS conta, inclusive eventos para AWS Glue, crie uma trilha. Uma trilha permite que o CloudTrail entregue arquivos de log a um bucket Amazon S3. Por padrão, ao criar uma trilha no console, a mesma é aplicada a todas as AWSRegiões. A trilha registra logs de eventos de todas as Regiões na AWS divisória e entrega os arquivos do log para o bucket Amazon S3 especificado. Além disso, é possível configurar outros AWS serviços para melhor analisar e agir de acordo com dados coletados do evento nos logs CloudTrail. Para mais informações, consulte:

- Criar uma trilha para sua conta da AWS
- Serviços e integrações compatíveis com o CloudTrail
- Configurando Notificações Amazon SNS para CloudTrail
- Receber arquivos de log do CloudTrail de várias regiões e receber arquivos de log do CloudTrail de várias contas

Todas as ações do AWS Glue são registradas pelo CloudTrail e são documentadas em API AWS Glue. Por exemplo, as chamadas às ações `CreateDatabase`, `CreateTable` e `CreateScript` geram entradas nos arquivos de log do CloudTrail.

Cada entrada de log ou evento contém informações sobre quem gerou a solicitação. As informações de identidade ajudam a determinar:

- Se a solicitação foi feita com credenciais de usuário raiz ou usuário do IAM.
- Se a solicitação foi feita com credenciais de segurança temporárias para um perfil ou usuário federado.
- Se a solicitação foi feita por outro AWS serviço.

Para obter mais informações, consulte o Elemento userIdentity do CloudTrail.

No entanto, o CloudTrail não registra em log todas as informações relacionadas às chamadas. Por exemplo, ele não registra em log certas informações confidenciais, como `ConnectionProperties` usadas com as solicitações e, em vez disso, registra o valor `null` nas respostas retornadas pelas seguintes APIs:

```
BatchGetPartition       GetCrawlers          GetJobs          GetTable
CreateScript            GetCrawlerMetrics    GetJobRun        GetTables
GetCatalogImportStatus  GetDatabase          GetJobRuns       GetTableVersions
GetClassifier           GetDatabases         GetMapping       GetTrigger
GetClassifiers          GetDataflowGraph     GetObjects       GetTriggers
GetConnection           GetDevEndpoint       GetPartition     GetUserDefinedFunction
GetConnections          GetDevEndpoints      GetPartitions    GetUserDefinedFunctions
GetCrawler              GetJob               GetPlan
```

Noções básicas sobre entradas de arquivos de log do AWS Glue

Uma trilha é uma configuração que permite a entrega de eventos como arquivos de log a um bucket Amazon S3 especificado. Os arquivos de log CloudTrail contêm uma ou mais entradas de log.

Um evento representa uma única solicitação de qualquer fonte, e inclui informações sobre a ação solicitada, data e hora da ação, parâmetros de solicitação e assim por diante. Os arquivos de log do CloudTrail não são um rastreamento de pilha ordenada de chamadas de API pública, portanto não são exibidos em uma ordem específica.

O exemplo a seguir mostra uma entrada de log CloudTrail que demonstra a `DeleteCrawler` ação.

```
{
  "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 botocore/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"
}
```

O exemplo mostra uma entrada de log do CloudTrail que demonstra a ação `CreateConnection`.

```
{
  "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"
}
```

Status de execução de trabalhos do AWS Glue

Você pode visualizar o status de um trabalho de extração, transformação e carregamento (ETL) do AWS Glue enquanto ele está em execução ou após a interrupção. Você pode visualizar o status usando o console do AWS Glue, a AWS Command Line Interface (AWS CLI) ou a ação GetJobRun na API do AWS Glue.

Os possíveis status de execução de trabalho são `STARTING`, `RUNNING`, `STOPPING`, `STOPPED`, `SUCCEEDED`, `FAILED`, `ERROR`, `WAITING` e `TIMEOUT`.

A tabela a seguir relaciona os status que indicam o término incomum de um trabalho.

Status de execução de trabalho	Descrição
`FAILED`	O trabalho excedeu suas execuções simultâne as máximas permitidas ou terminou com um código de saída desconhecido.
`ERROR`	Um fluxo de trabalho, um acionador de programação ou de evento tentou executar um trabalho excluído.
`TIMEOUT`	O tempo de execução do trabalho excedeu seu valor de tempo limite especificado.
`WAITING`	Uma execução de trabalho que está aguardand o recursos.

O status `WAITING` indica que a execução de um trabalho está aguardando recursos. A tabela a seguir descreve o comportamento de espera para diferentes classes de trabalhos.

Tipo de trabalho	Comportamento
Trabalhos do Spark (padrão)	Os trabalhos podem entrar no estado WAITING se você optar pelo enfileiramento de execução de trabalhos do AWS Glue, conforme descrito em Configurar propriedades de trabalho para trabalhos do Spark no AWS Glue. Uma execução de trabalho poderá estar no estado WAITING devido às cotas de serviço da sua conta ou aos limites de capacidade em sua região encontrarem um dos seguintes casos de erro: • O máximo de execuções simultâneas de trabalhos por conta foi excedido • Máximo de execuções simultâneas de trabalhos por trabalho foi excedido (inclui a cota de serviço no nível da conta, bem

Tipo de trabalho	Comportamento
	como o limite especificado no trabalho com `MaxConcurrentRuns`) • Computação simultânea máxima (uso de DPU) excedida • Recurso indisponível Os trabalhos também poderão ser colocados no estado WAITING se não houver recursos suficientes para iniciar a execução do trabalho, independentemente das cotas de serviço.
Trabalhos do Spark (Flex)	Uma nova execução de trabalho ficará no estado WAITING (AGUARDANDO) se o serviço não conseguir adquirir recursos suficientes para iniciar a execução, o que atrasará o início da execução. A execução ficará no estado WAITING (AGUARDANDO) por até 20 minutos (tempo limite controlad o pelo serviço). Após 15 minutos, o serviço tentará fazer uma inicialização forçada e, dependendo da capacidade disponível, a execução poderá iniciar ou falhar com uma mensagem de erro adequada.
Trabalhos de shell Python	Mesmo comportamento dos trabalhos padrão usando o Spark.

O diagrama de estado a seguir descreve as transições de estado esperadas ao longo do ciclo de vida de um trabalho do AWS Glue. Essas informações são aplicáveis a todos os tipos de trabalho.

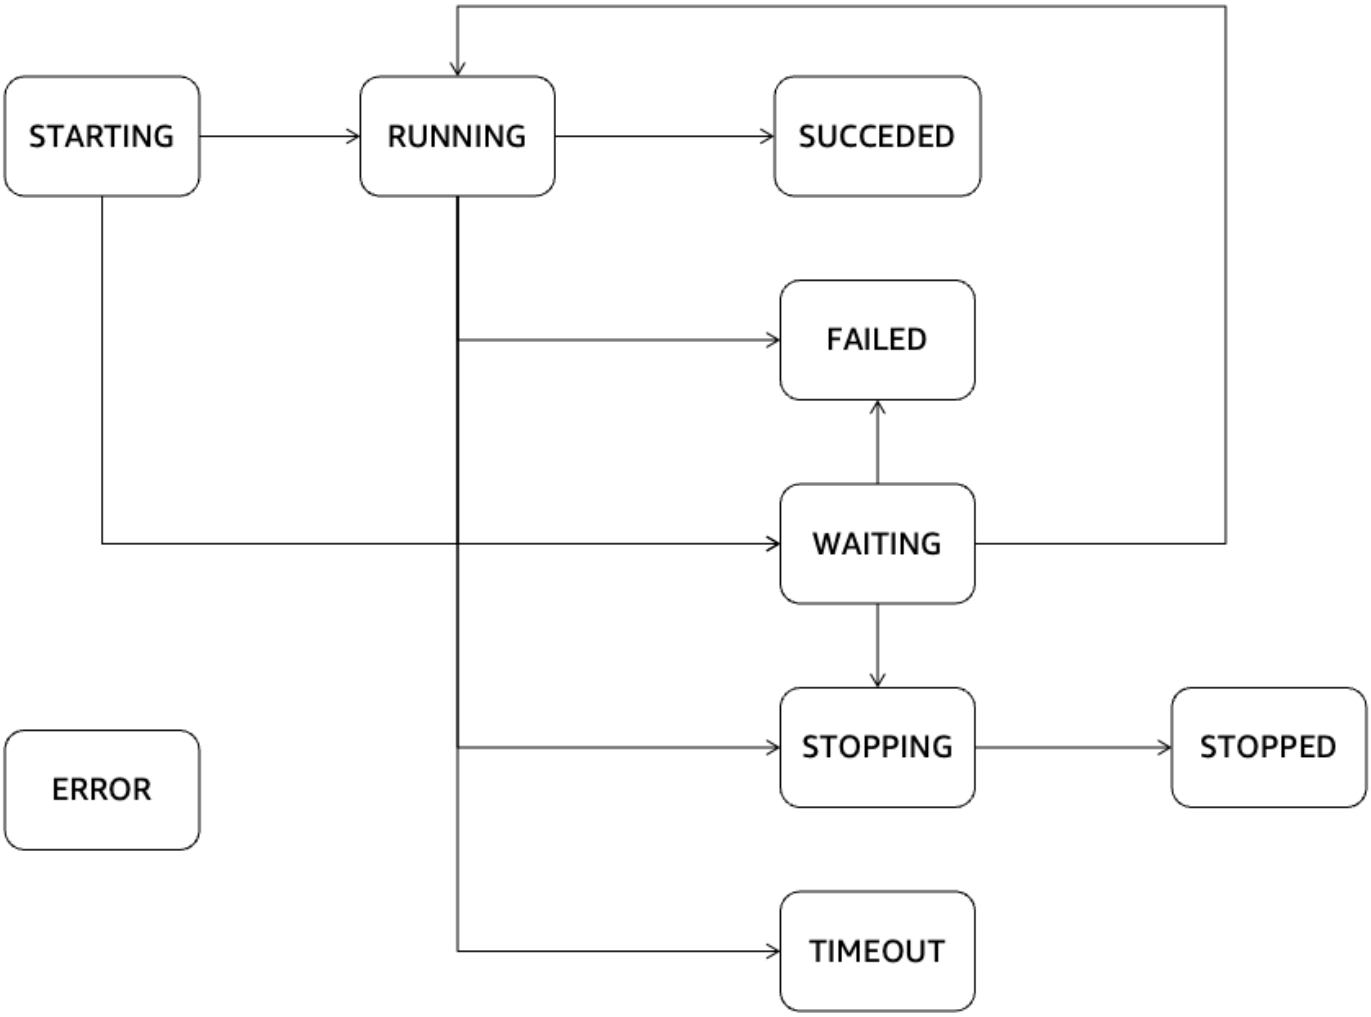
STARTING
RUNNING
SUCCEDED
FAILED
WAITING
STOPPING
STOPPED
ERROR
TIMEOUT

AWS Glue Streaming

O AWS Glue Streaming, um componente do AWS Glue, possibilita que você lide com dados de streaming quase em tempo real com eficiência, capacitando-o a realizar tarefas cruciais, como a ingestão de dados, o processamento e o machine learning. Ao usar a estrutura do Apache Spark Streaming, o AWS Glue Streaming fornece um serviço sem servidor que pode lidar com dados de streaming em escala. O AWS Glue disponibiliza diversas otimizações além do Apache Spark, como infraestrutura sem servidor, ajuste de escala automático, desenvolvimento visual de trabalhos, cadernos instantâneos para trabalhos de streaming e outros aprimoramentos de performance.

Casos de uso para o streaming

Alguns casos de uso comuns para o AWS Glue Streaming incluem:

Processamento de dados quase em tempo real: o AWS Glue Streaming permite que as organizações processem dados de streaming quase em tempo real, permitindo-lhes obter insights e tomar decisões oportunas com base nas informações mais recentes.

Detecção de fraudes: é possível utilizar o AWS Glue Streaming para realizar análises em tempo real de dados de streaming, tornando-o valioso para a detecção de atividades fraudulentas, como a fraude de um cartão de crédito, a invasão de rede ou as fraudes on-line. Ao processar e analisar continuamente os dados de entrada, você pode identificar rapidamente padrões ou anomalias suspeitas.

Análise de mídia social: o AWS Glue Streaming pode processar dados de mídia social em tempo real, como tweets, publicações ou comentários, possibilitando que as organizações monitorem tendências, analisem sentimentos e gerenciem a reputação da marca em tempo real.

Análise da Internet das Coisas (IoT): o AWS Glue Streaming é adequado para analisar e lidar com fluxos de dados de alta velocidade gerados por dispositivos de IoT, sensores e máquinas conectadas. Ele permite o monitoramento em tempo real, a detecção de anomalias, a manutenção preditiva e outros casos de uso de análise da IoT.

Análise de fluxo de cliques: o AWS Glue Streaming pode processar e analisar dados de fluxo de cliques em tempo real de sites ou de aplicações móveis. Isso possibilita que as empresas obtenham insights sobre o comportamento do usuário, personalizem as experiências do usuário e otimizem campanhas de marketing com base em dados de fluxo de cliques em tempo real.

Monitoramento e análise de log: o AWS Glue Streaming pode processar e analisar continuamente os dados de log de servidores, aplicações ou dispositivos de rede em tempo real. Isso ajuda a detectar anomalias, solucionar problemas e monitorar a integridade e a performance do sistema.

Sistemas de recomendação: o AWS Glue Streaming pode processar dados de atividades do usuário em tempo real e atualizar os modelos de recomendação de forma dinâmica. Isso permite recomendações personalizadas e em tempo real com base no comportamento e nas preferências do usuário.

Esses são alguns exemplos da diversidade de casos de uso em que o AWS Glue Streaming pode ser aplicado. Sua integração com o ecossistema e os serviços gerenciados da AWS o torna uma escolha conveniente para o processamento e para a análise de fluxo em tempo real na nuvem.

Quais são os benefícios do uso do AWS Glue Streaming?

Os benefícios do uso do AWS Glue Streaming são os seguintes:

- Tecnologia sem servidor: o AWS Glue Streaming tem tecnologia sem servidor, o que elimina a necessidade de gerenciamento da infraestrutura. Isso reduz a sobrecarga operacional e permite que os usuários se concentrem nas tarefas de processamento e de análise de dados, em vez de no gerenciamento da infraestrutura.
- Ajuste de escala automático: o AWS Glue Streaming fornece recursos de ajuste de escala automático, ajustando dinamicamente a capacidade de processamento com base na workload. Ele aumenta ou reduz a escala horizontalmente de forma automática para lidar com as flutuações no volume de dados, garantindo uma performance e uma utilização de recursos ideais.
- Desenvolvimento visual: o desenvolvimento do trabalho de streaming pode ser complexo. O AWS Glue Streaming aborda esse desafio ao disponibilizar o AWS Glue Studio, uma ferramenta de criação visual. O AWS Glue Studio simplifica o processo de criação de fluxos de trabalho de streaming e possibilita que os desenvolvedores projetem e gerenciem aplicações de streaming visualmente, reduzindo a curva de aprendizado e aumentando a produtividade.
- Econômico: como um serviço sem servidor, o AWS Glue Streaming oferece uma relação custo-benefício vantajosa ao eliminar a necessidade de provisionamento e manutenção de infraestrutura. Os usuários são cobrados com base nos recursos consumidos durante a execução de trabalhos de streaming, permitindo a otimização de custos e a escalabilidade com base no uso real.
- Tratamento de workloads complexas: o AWS Glue Streaming foi projetado para lidar com workloads de streaming complexas. Ele pode processar e analisar grandes volumes de dados em

tempo real, oferecer suporte a transformações avançadas e se integrar a outros serviços da AWS, possibilitando pipelines de dados de streaming e fluxos de trabalho de análises sofisticados.

- Sem aprisionamento tecnológico: o AWS Glue Streaming oferece flexibilidade e evita o aprisionamento tecnológico do fornecedor. Os usuários podem aproveitar o AWS Glue Streaming como parte do ecossistema mais amplo da AWS, integrando-o sem complicações a outros serviços da AWS. Isso permite a fácil integração com fontes de dados, aplicações e serviços existentes, sem a necessidade de estar vinculado a uma tecnologia ou plataforma específica.

Quando devo usar o AWS Glue Streaming?

Existem muitas opções quando se trata de casos de uso de streaming. Recomendamos o uso do streaming do AWS Glue nos cenários apresentados a seguir.

1. Se você já usa o AWS Glue ou o Spark para realizar o processamento em lote, o AWS Glue Streaming é a escolha ideal para você. Ele fornece uma transição sem complicação para o desenvolvimento de trabalhos de streaming sem a necessidade de aprender uma nova linguagem ou estrutura. Aproveitando o conhecimento e a infraestrutura existentes, o AWS Glue Streaming simplifica o processo de desenvolvimento de trabalhos e permite ampliar os recursos de processamento de dados com facilidade para cenários de streaming em tempo real.
2. Se você precisar de um serviço ou de um produto unificado para lidar com workloads em lote, de streaming e orientadas a eventos, o AWS Glue Streaming é a solução para você. Com o AWS Glue Streaming, é possível consolidar suas necessidades de processamento de dados em uma única estrutura, eliminando a complexidade do gerenciamento de vários sistemas. Isso possibilita o desenvolvimento e a manutenção eficientes de diversos fluxos de trabalho de dados, ao mesmo tempo em que garante consistência e compatibilidade entre diferentes tipos de workloads.
3. O AWS Glue Streaming é adequado para cenários que envolvem volumes de dados de streaming extremamente grandes e transformações complexas, como junções entre fluxos ou bancos de dados relacionais. Ele pode processar e analisar fluxos massivos de dados com eficiência, possibilitando que você lide com workloads complexas com facilidade. Quer se trate de ingestão de dados em alta velocidade ou de manipulações complexas de dados, a escalabilidade e os recursos avançados de processamento do AWS Glue Streaming garantem performance ideal e resultados precisos.
4. Se você preferir uma abordagem visual para desenvolver trabalhos de streaming, o AWS Glue oferece o AWS Glue Studio, com o qual você pode projetar e gerenciar visualmente as aplicações de streaming, simplificando o processo de desenvolvimento. Essa interface intuitiva possibilita que

os desenvolvedores criem, configurem e monitorem fluxos de trabalho de streaming usando uma interface visual, o que reduz a curva de aprendizado e aumenta a produtividade.

5. O AWS Glue Streaming é uma excelente opção para casos de uso quase em tempo real, nos quais existem SLAs (Acordos de Serviço) rigorosos superiores a dez segundos.
6. Se você estiver desenvolvendo um data lake transacional usando o Apache Iceberg, o Apache Hudi ou o Delta Lake, o AWS Glue Streaming fornecerá suporte nativo para esses formatos de tabela aberta. Essa integração sem complicações possibilita o processamento de dados de streaming diretamente desses data lakes transacionais, garantindo integridade, compatibilidade e consistência de dados.
7. Ao precisar ingerir dados de streaming para uma variedade de destinos de dados, o AWS Glue Streaming disponibiliza destinos nativos para uma variedade de destinos de dados, como o Amazon Redshift, o Amazon RDS, o Amazon Aurora, o Oracle, o SQL Server e outros destinos.

Fonte de dados compatíveis

O AWS Glue Streaming oferece suporte às seguintes fontes de dados:

- Amazon Kinesis
- Amazon MSK (Managed Streaming for Apache Kafka)
- Apache Kafka autogerenciado

Destinos de dados com suporte

O AWS Glue Streaming oferece suporte para uma variedade de destinos de dados, como:

- Destinos de dados compatíveis com o Catálogo de Dados do AWS Glue
- Amazon S3
- Amazon Redshift
- MySQL
- PostgreSQL
- Oracle
- Microsoft SQL Server
- Snowflake
- Qualquer banco de dados que possa ser conectado usando JDBC

- Apache Iceberg, Delta e Apache Hudi
- Conectores do AWS Glue Marketplace

Tutorial: desenvolvimento da sua primeira workload de streaming usando o AWS Glue Studio

Neste tutorial, você aprenderá como criar um trabalho de streaming usando o AWS Glue Studio. O AWS Glue Studio corresponde a uma interface visual para a criação de trabalhos do AWS Glue.

É possível criar trabalhos de extração, transformação e carregamento (ETL) de streaming que são executados continuamente e consomem dados de fontes de streaming no Amazon Kinesis Data Streams, no Apache Kafka e no Amazon Managed Streaming for Apache Kafka (Amazon MSK).

Pré-requisitos

Para seguir este tutorial, você precisará de um usuário com permissões do Console da AWS para usar o AWS Glue, o Amazon Kinesis, o Amazon S3, o Amazon Athena, o AWS CloudFormation, o AWS Lambda e o Amazon Cognito.

Consumo de dados de streaming do Amazon Kinesis

Tópicos

- Geração de dados de simulação com o Kinesis Data Generator
- Criação de um trabalho de streaming do AWS Glue com o AWS Glue Studio
- Execução de uma transformação e armazenamento do resultado transformado no Amazon S3

Geração de dados de simulação com o Kinesis Data Generator

Você pode gerar dados de amostra sinteticamente no formato JSON usando o Kinesis Data Generator (KDG). É possível encontrar instruções completas e detalhes na documentação da ferramenta.

1. Para começar, clique em

   para executar um modelo do AWS CloudFormation em seu ambiente da AWS.

> **Note**
>
> Pode ocorrer uma falha no modelo do CloudFormation porque alguns recursos, como o usuário do Amazon Cognito para o Kinesis Data Generator, já existem em sua conta da AWS. Isso pode acontecer porque você já configurou esses recursos seguindo outro tutorial ou outra publicação de blog. Para resolver isso, é possível experimentar o modelo em uma nova conta da AWS para começar do zero ou explorar uma região da AWS diferente. Essas opções permitem que você execute o tutorial sem entrar em conflito com os recursos existentes.

O modelo provisiona um fluxo de dados do Kinesis e uma conta do Kinesis Data Generator para você. Além disso, ele cria um bucket do Amazon S3 para armazenar os dados e um perfil de serviço do Glue com a permissão necessária para a execução deste tutorial.

2. Digite um Nome de usuário e uma Senha que o KDG usará para realizar a autenticação. Anote o nome de usuário e a senha para uso posterior.
3. Selecione Próximo até a última etapa. Reconheça a criação de recursos do IAM. Verifique se há erros na parte superior da tela, como a senha não atender aos requisitos mínimos, e implante o modelo.
4. Navegue até a guia Saídas da pilha. Depois que o modelo for implantado, ele exibirá a propriedade gerada KinesisDataGeneratorUrl. Clique nesse URL.
5. Digite o Nome de usuário e a Senha que você anotou.
6. Selecione a região que você está usando e selecione o fluxo do Kinesis `GlueStreamTest-{AWS::AccountId}`.
7. Insira o seguinte modelo:

```
{
    "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"]
    )}}"
}
```

Agora, é possível visualizar dados de simulação com Testar modelo e ingerir os dados de simulação no Kinesis com Enviar dados.

8. Clique em Enviar dados e gere de cinco a dez mil registros para o Kinesis.

Criação de um trabalho de streaming do AWS Glue com o AWS Glue Studio

1. Navegue até AWS Glue no console da mesma região.
2. Selecione Trabalhos de ETL na barra de navegação do lado esquerdo em Integração de dados e ETL.
3. Crie um trabalho do AWS Glue usando Elemento visual com uma tela em branco.

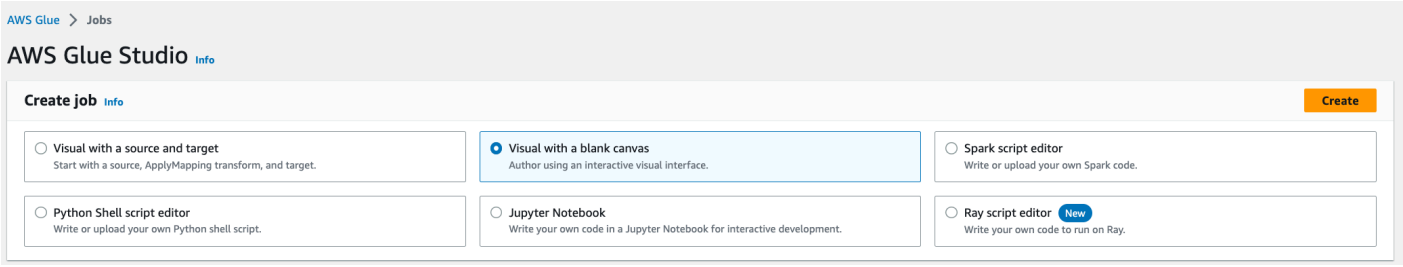

4. Navegue até a guia Detalhes do trabalho.
5. Para o nome do trabalho do AWS Glue, insira `DemoStreamingJob`.
6. Para o Perfil do IAM, selecione o perfil provisionado pelo modelo do CloudFormation, `glue-tutorial-role-${AWS::AccountId}`.

7. Para a Versão do Glue, selecione Glue 3.0. Deixe todas as outras opções conforme o padrão.

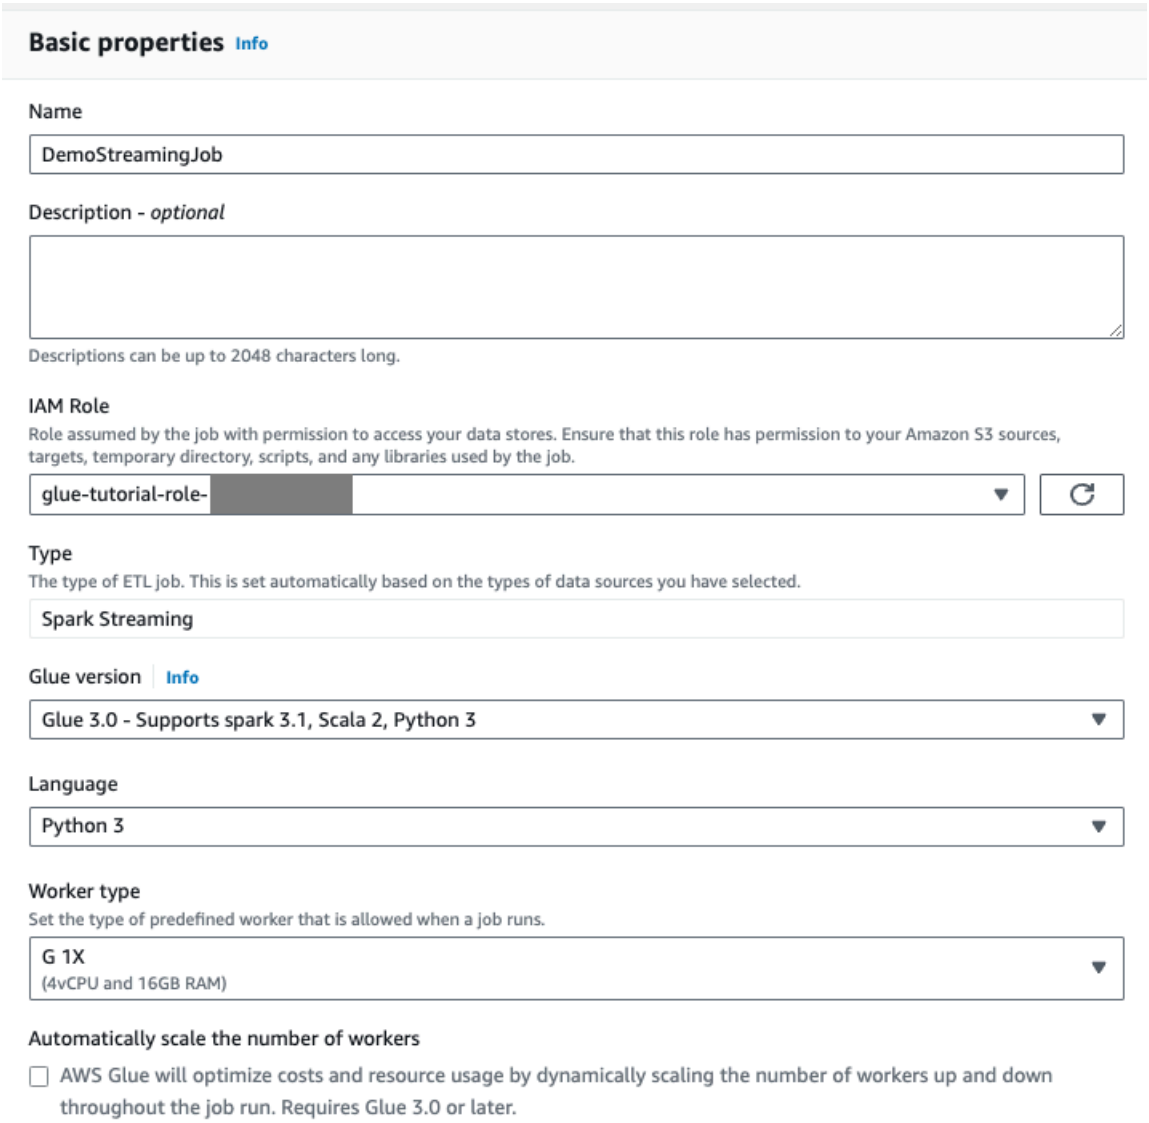

8. Navegue até a guia Elemento visual.
9. Clique no ícone de adição. Digite Kinesis na barra de pesquisa. Selecione a fonte de dados do Amazon Kinesis.

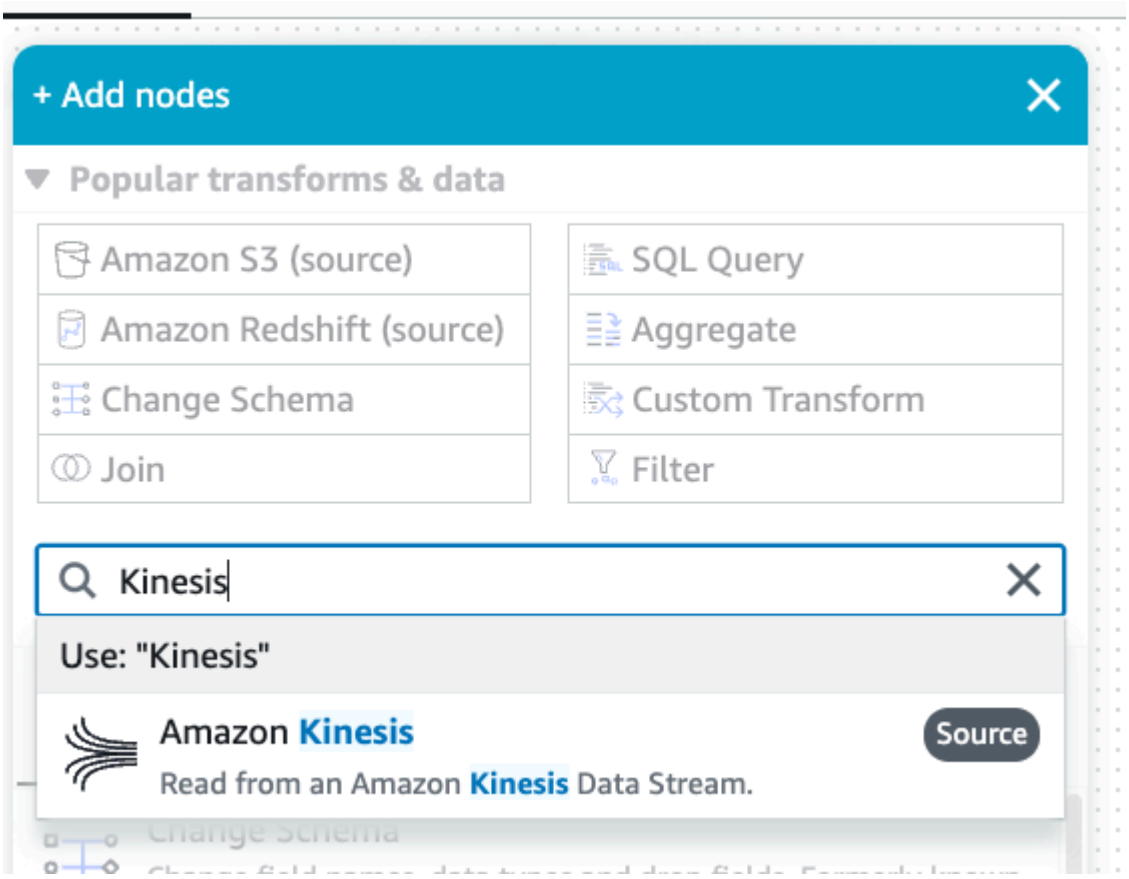

10. Selecione Detalhes do fluxo para a Fonte do Amazon Kinesis na guia Propriedades da fonte de dados: fluxo do Kinesis.
11. Selecione O fluxo está localizado em minha conta para Localização do fluxo de dados.
12. Selecione a região que você está usando.
13. Selecione o fluxo `GlueStreamTest-{AWS::AccountId}`.
14. Mantenha todas as outras configurações conforme o padrão.

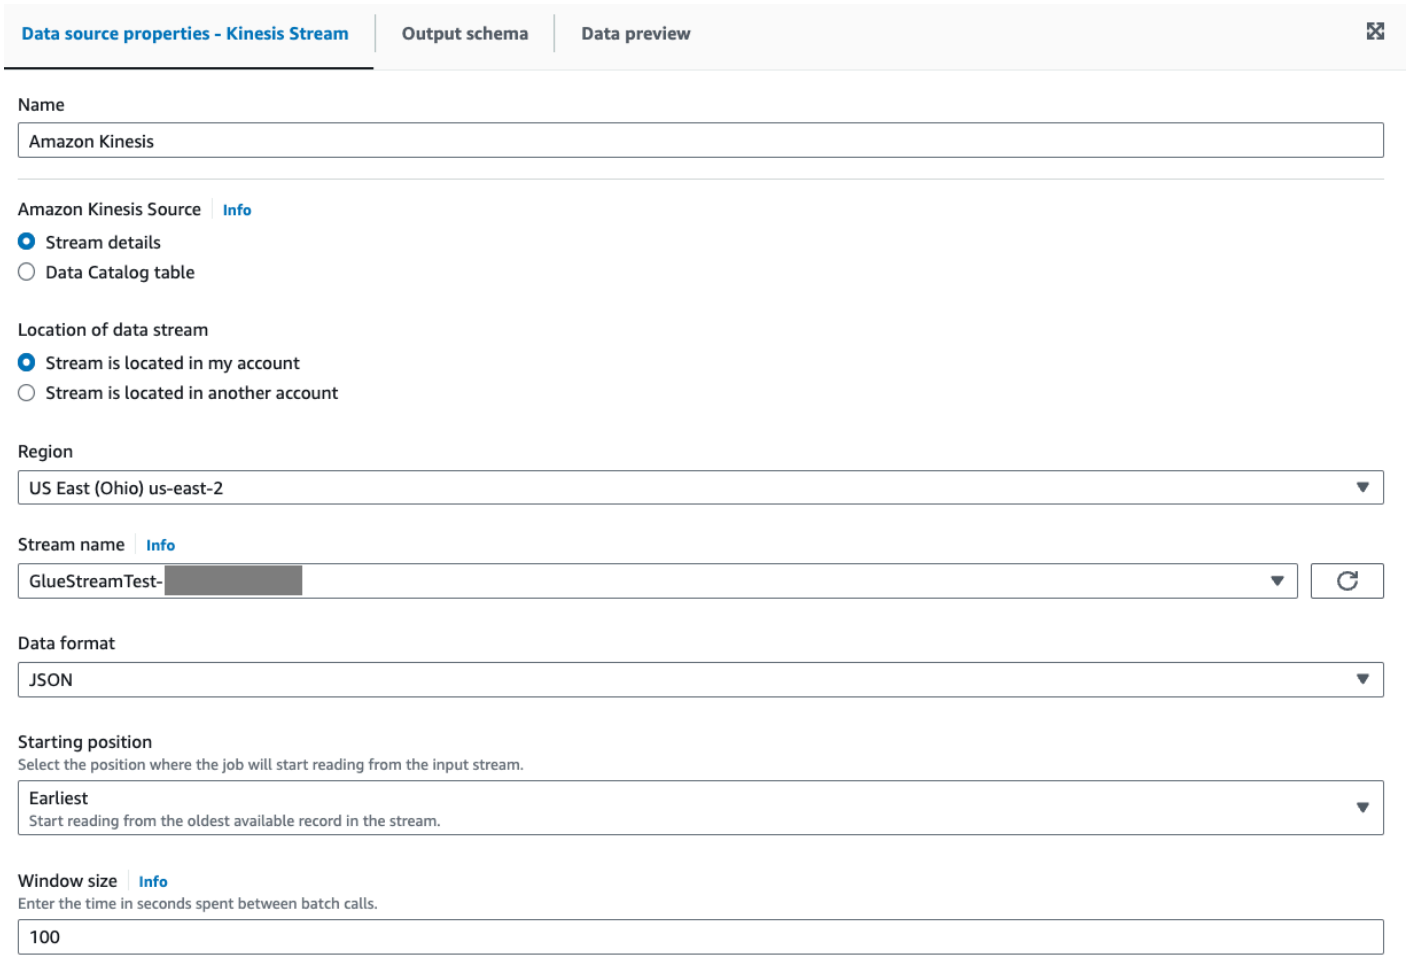

15. Navegue até a guia Pré-visualização de dados.
16. Clique em Iniciar sessão de pré-visualização de dados, que visualiza previamente os dados de simulação gerados pelo KDG. Escolha o perfil de serviço do Glue que você criou anteriormente para o trabalho do AWS Glue Streaming.

    Demora de 30 a 60 segundos para que os dados de pré-visualização sejam mostrados. Se aparecer Não há dados a serem exibidos, clique no ícone de engrenagem e altere o Número de linhas para amostra para `100`.

    Você pode visualizar os dados de amostra, como apresentado abaixo:

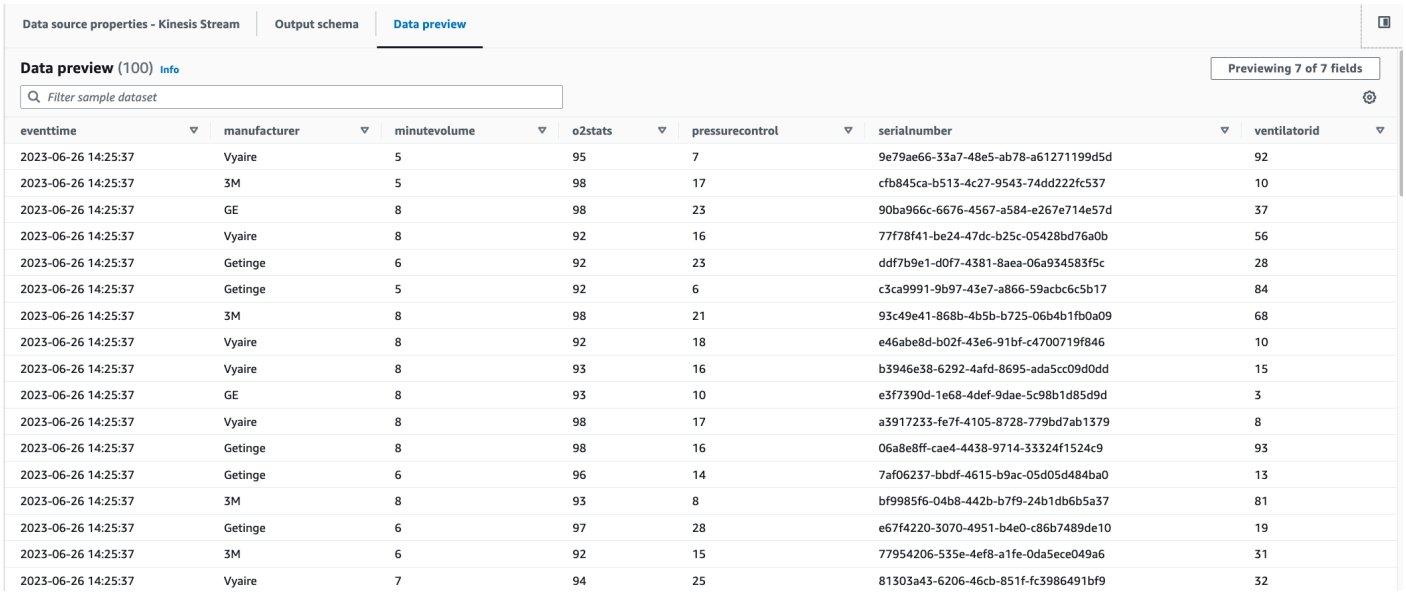

Data source properties - Kinesis Stream | Output schema | Data preview

Data preview (100) Info

Previewing 7 of 7 fields

Filter sample dataset

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

Além disso, é possível visualizar o esquema inferido na guia Esquema de saída.

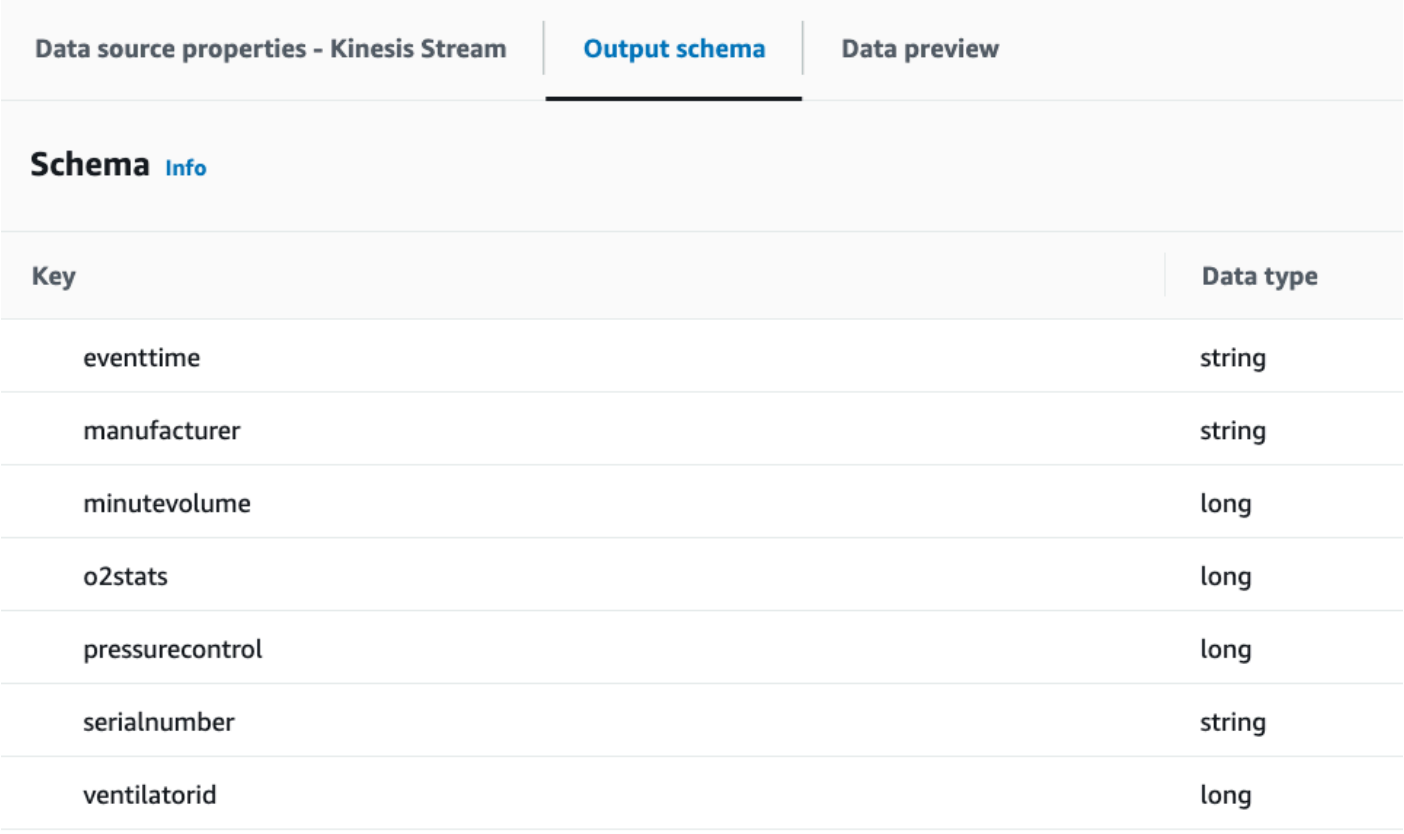

Data source properties - Kinesis Stream | Output schema | Data preview

Schema Info

Key	Data type
eventtime	string
manufacturer	string
minutevolume	long
o2stats	long
pressurecontrol	long
serialnumber	string
ventilatorid	long

Execução de uma transformação e armazenamento do resultado transformado no Amazon S3

1. Com o nó de origem selecionado, clique no ícone de adição no canto superior esquerdo para adicionar uma etapa de Transformação.
2. Selecione a etapa Alterar esquema.

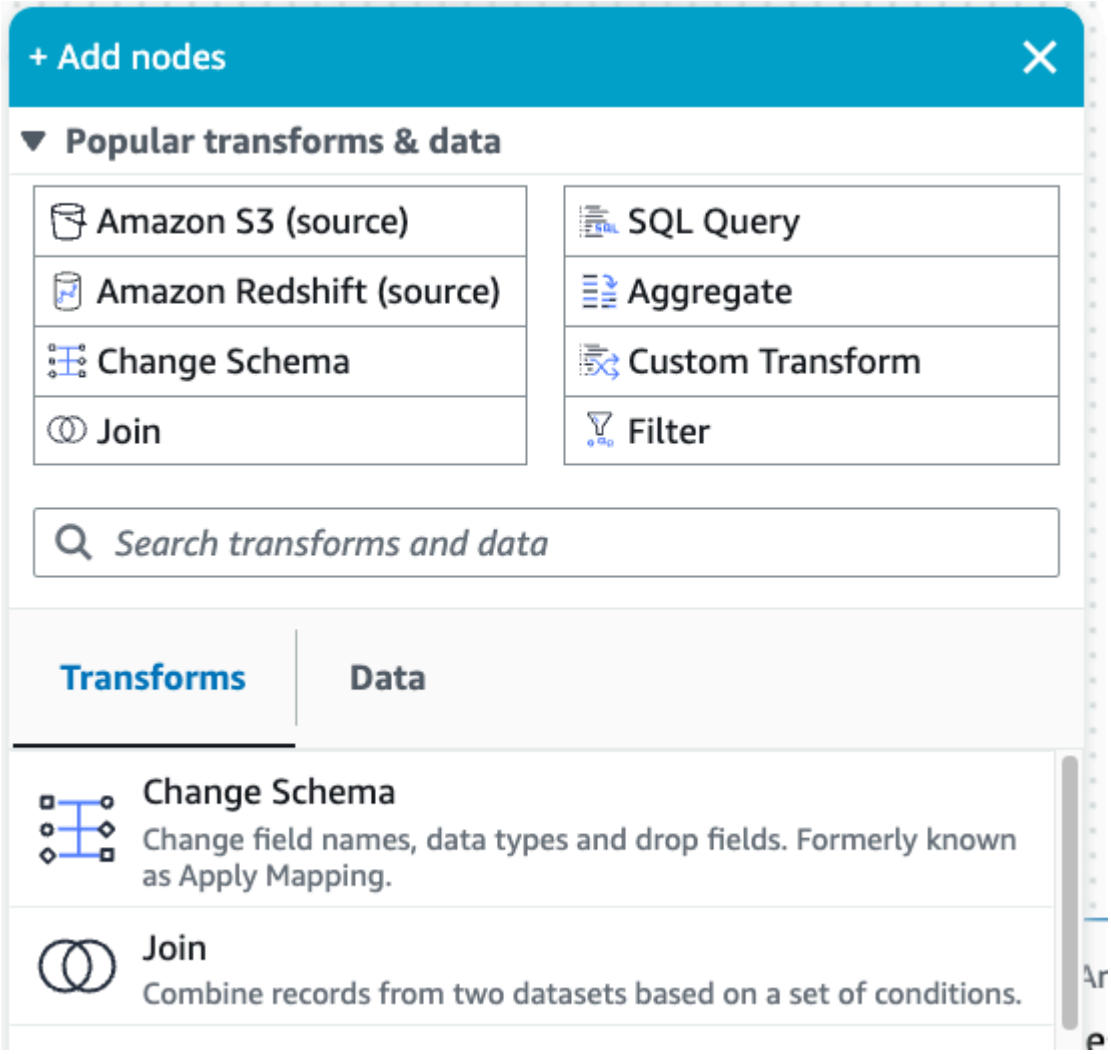

3. É possível renomear campos e converter o tipo de dados dos campos nesta etapa. Renomeie a coluna `o2stats` para `OxygenSaturation` e converta todos os tipos de dados `long` para `int`.

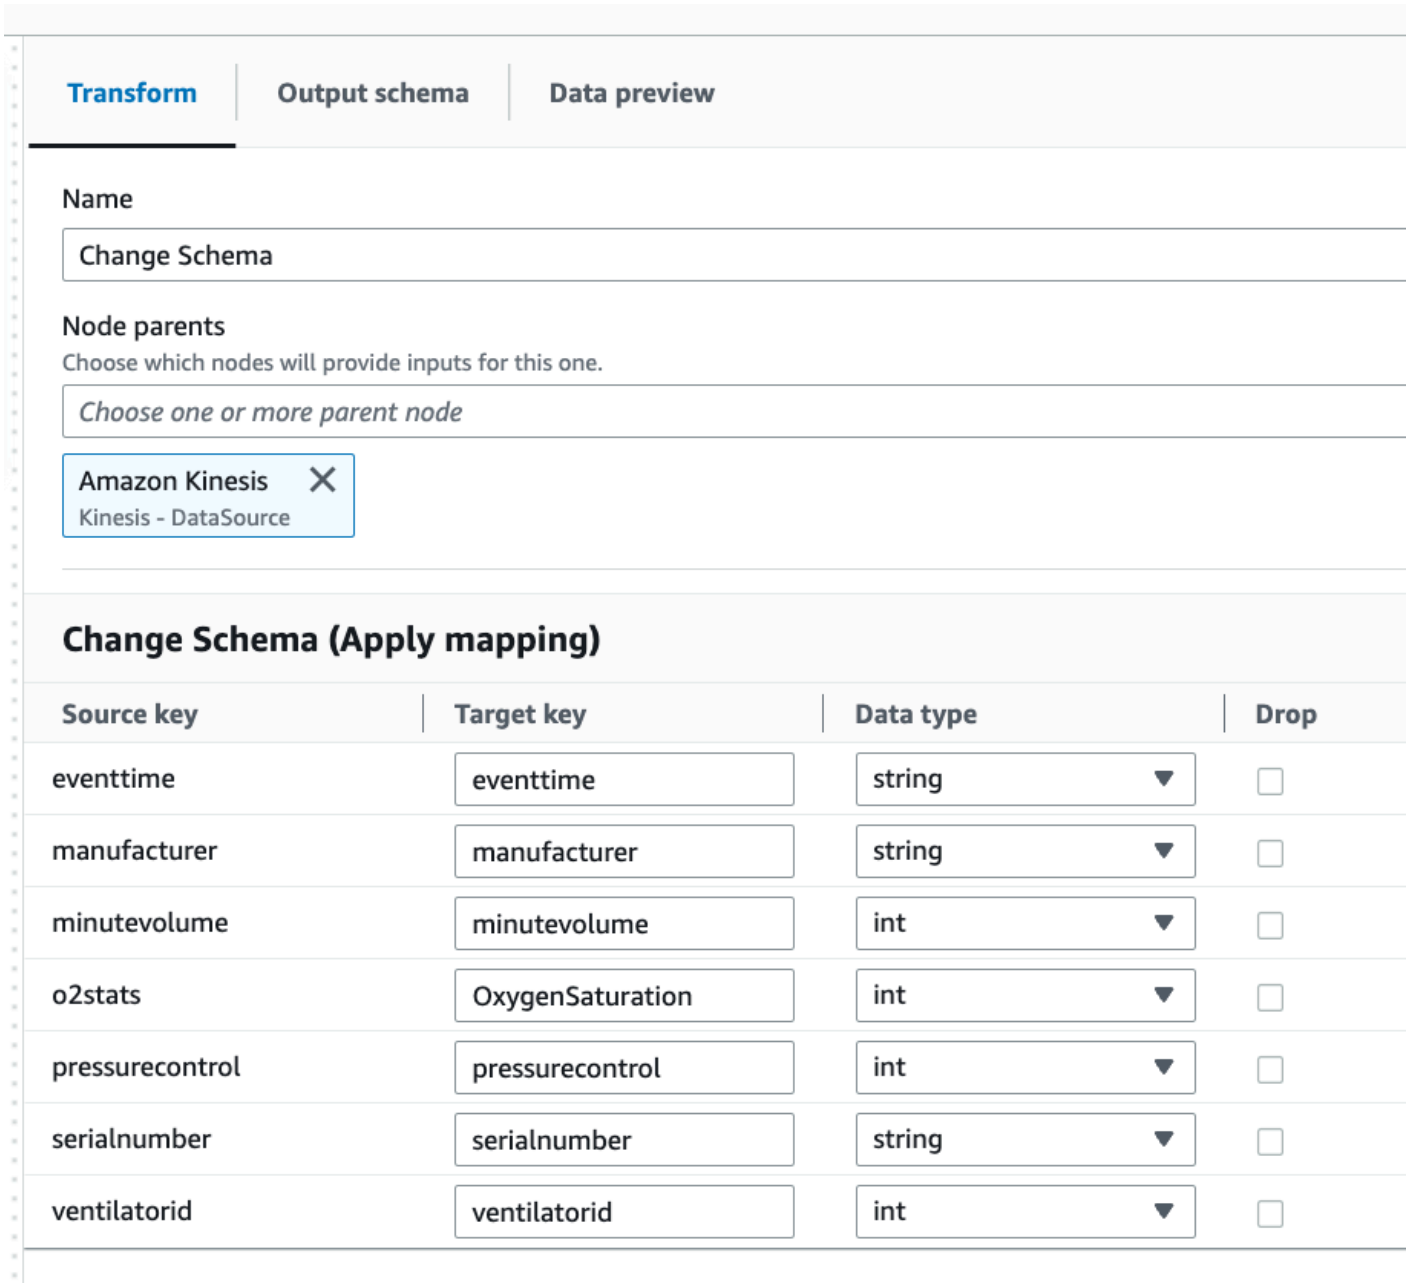

4. Clique no ícone de adição para adicionar um destino do Amazon S3. Insira S3 na caixa de pesquisa e selecione a etapa de transformação Amazon S3: destino.

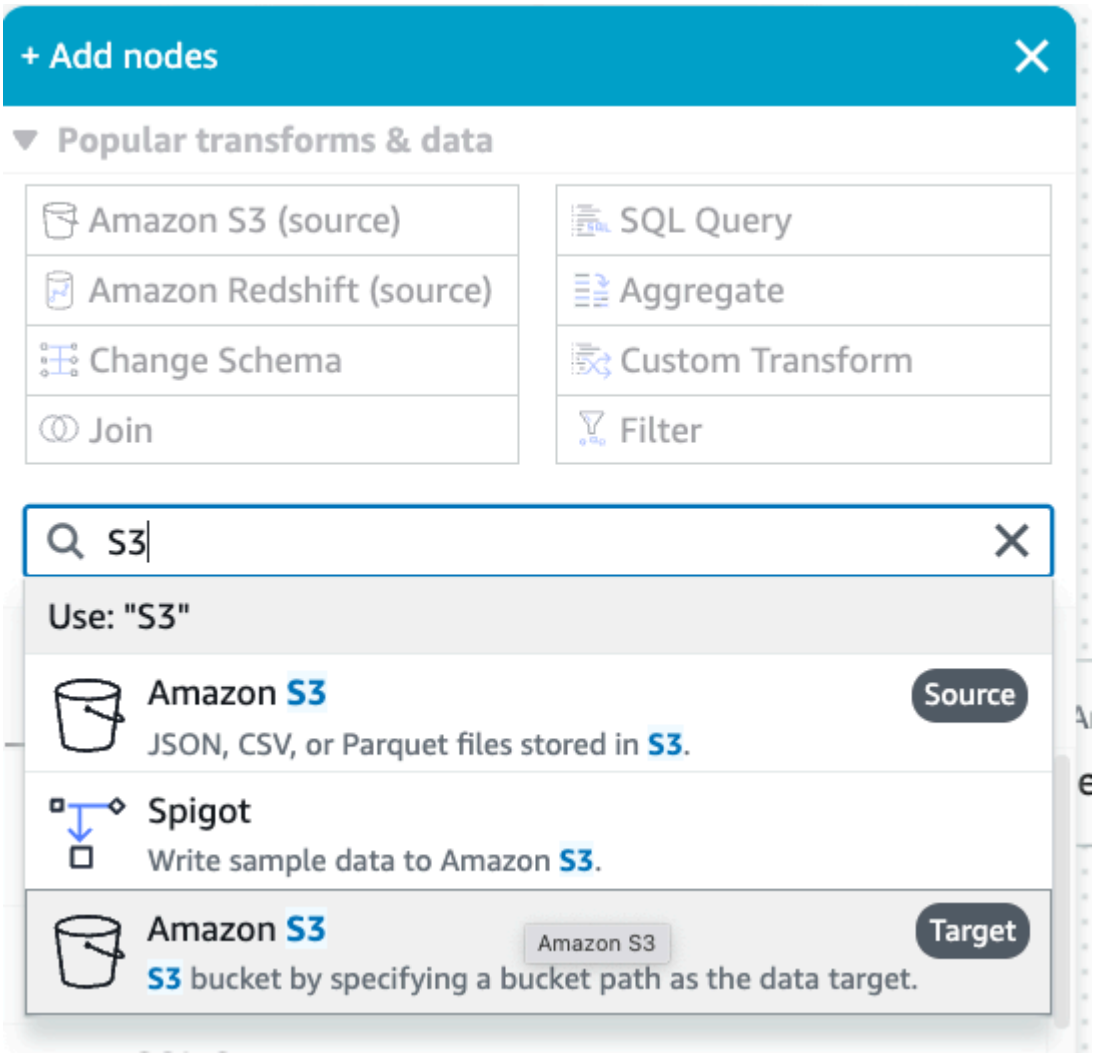

5. Selecione Parquet como o formato do arquivo de destino.
6. Selecione Snappy como o tipo de compactação.
7. Insira um Local de destino do S3 criado pelo modelo do CloudFormation, `streaming-tutorial-s3-target-{AWS::AccountId}`.
8. Selecione Criar uma tabela no Catálogo de Dados e, em execuções subsequentes, atualizar o esquema e adicionar novas partições.
9. Insira o nome do Banco de dados e da Tabela de destino para armazenar o esquema da tabela de destino do Amazon S3.

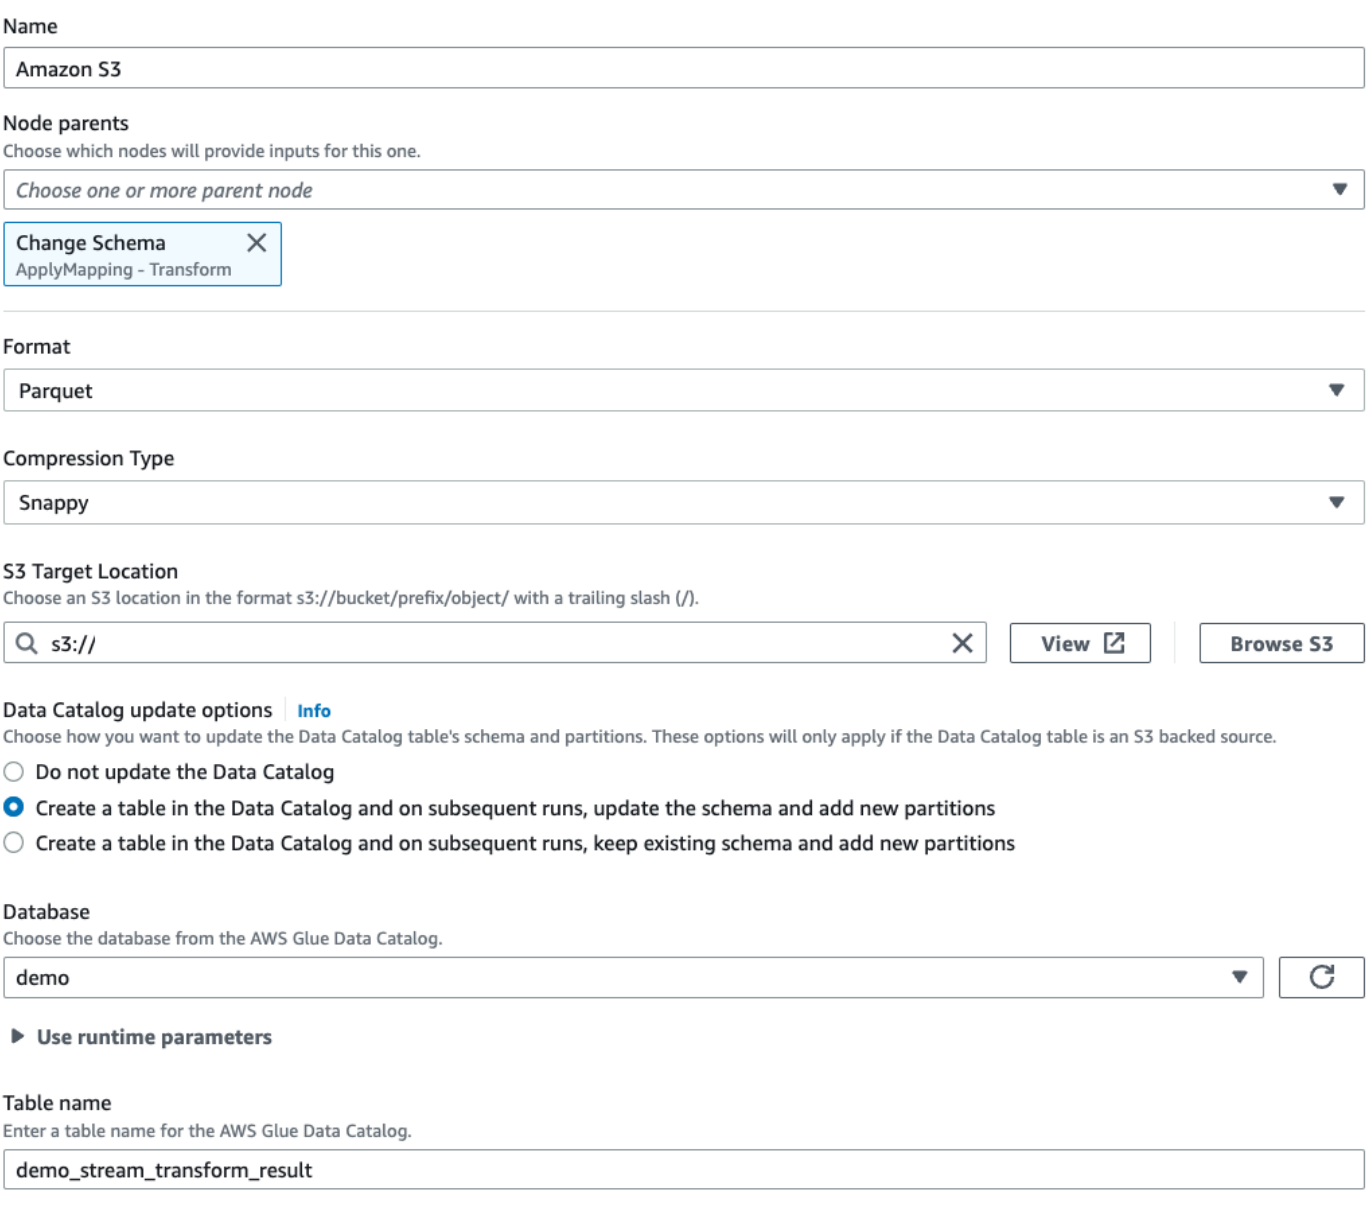

10. Clique na guia Script para visualizar o código gerado.
11. Clique em Salvar no canto superior direito para salvar o código de ETL e, em seguida, clique em Executar para iniciar o trabalho de streaming do AWS Glue.

    É possível encontrar o Status de execução na guia Execuções. Deixe o trabalho ser executado entre três e cinco minutos e, em seguida, interrompa-o.

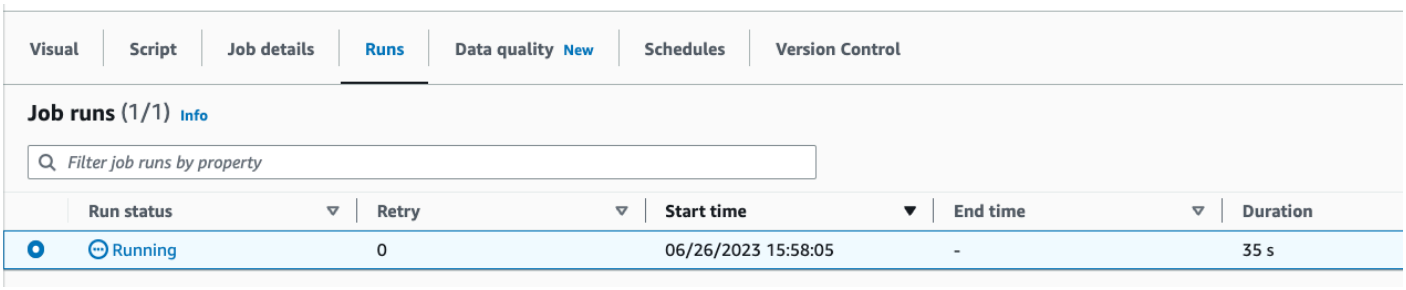

12.Verifique a nova tabela criada no Amazon Athena.

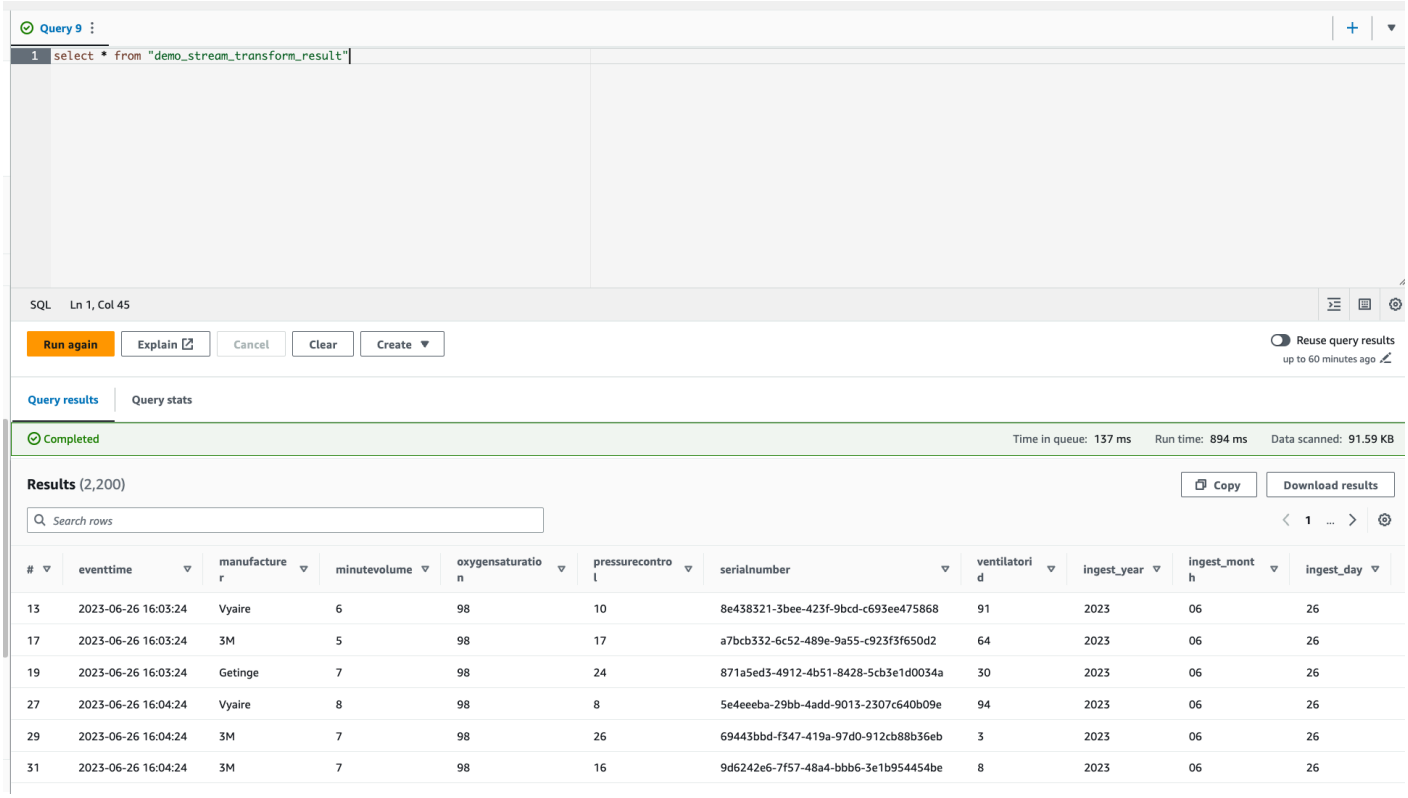

Tutorial: desenvolvimento da sua primeira workload de streaming usando cadernos do AWS Glue Studio

Neste tutorial, você explorará como aproveitar os cadernos do AWS Glue Studio para desenvolver e otimizar, de forma interativa, os trabalhos de ETL para o processamento de dados quase em tempo real. Quer essa seja sua primeira experiência com o AWS Glue ou você esteja procurando aprimorar seu conjunto de habilidades, este guia orientará você durante o processo, possibilitando o aproveitamento de todo o potencial dos cadernos de sessão interativa do AWS Glue.

Com o AWS Glue Streaming, é possível criar trabalhos de extração, transformação e carregamento (ETL) de streaming que são executados continuamente e consomem dados de fontes de streaming, como o Amazon Kinesis Data Streams, o Apache Kafka e o Amazon Managed Streaming for Apache Kafka (Amazon MSK).

Pré-requisitos

Para seguir este tutorial, você precisará de um usuário com permissões do Console da AWS para usar o AWS Glue, o Amazon Kinesis, o Amazon S3, o Amazon Athena, o AWS CloudFormation, o AWS Lambda e o Amazon Cognito.

Consumo de dados de streaming do Amazon Kinesis

Tópicos

- Geração de dados de simulação com o Kinesis Data Generator
- Criação de um trabalho de streaming do AWS Glue com o AWS Glue Studio
- Limpeza
- Conclusão

Geração de dados de simulação com o Kinesis Data Generator

> **Note**
>
> Se você já concluiu a etapa anterior apresentada em Tutorial: desenvolvimento da sua primeira workload de streaming usando o AWS Glue Studio, já tem o Kinesis Data Generator instalado em sua conta e pode pular as etapas de 1 a 8 abaixo e avançar para a seção Criação de um trabalho de streaming do AWS Glue com o AWS Glue Studio.

Você pode gerar dados de amostra sinteticamente no formato JSON usando o Kinesis Data Generator (KDG). É possível encontrar instruções completas e detalhes na documentação da ferramenta.

1. Para começar, clique em

   para executar um modelo do AWS CloudFormation em seu ambiente da AWS.

> **Note**
>
> Pode ocorrer uma falha no modelo do CloudFormation porque alguns recursos, como o usuário do Amazon Cognito para o Kinesis Data Generator, já existem em sua conta da AWS. Isso pode acontecer porque você já configurou esses recursos seguindo outro tutorial ou outra publicação de blog. Para resolver isso, é possível experimentar o modelo em uma nova conta da AWS para começar do zero ou explorar uma região da AWS diferente. Essas opções permitem que você execute o tutorial sem entrar em conflito com os recursos existentes.

O modelo provisiona um fluxo de dados do Kinesis e uma conta do Kinesis Data Generator para você.

2. Digite um Nome de usuário e uma Senha que o KDG usará para realizar a autenticação. Anote o nome de usuário e a senha para uso posterior.
3. Selecione Próximo até a última etapa. Reconheça a criação de recursos do IAM. Verifique se há erros na parte superior da tela, como a senha não atender aos requisitos mínimos, e implante o modelo.
4. Navegue até a guia Saídas da pilha. Depois que o modelo for implantado, ele exibirá a propriedade gerada KinesisDataGeneratorUrl. Clique nesse URL.
5. Digite o Nome de usuário e a Senha que você anotou.
6. Selecione a região que você está usando e selecione o fluxo do Kinesis `GlueStreamTest-{AWS::AccountId}`.
7. Insira o seguinte modelo:

```
{
    "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"]
    )}}"
}
```

Agora, é possível visualizar dados de simulação com Testar modelo e ingerir os dados de simulação no Kinesis com Enviar dados.

8. Clique em Enviar dados e gere de cinco a dez mil registros para o Kinesis.

Criação de um trabalho de streaming do AWS Glue com o AWS Glue Studio

O AWS Glue Studio corresponde a uma interface visual que simplifica o processo de criação, orquestração e monitoramento de pipelines de integração de dados. Ele possibilita que os usuários desenvolvam pipelines de transformação de dados sem a necessidade de escrever códigos extensos. Além da experiência de criação de trabalhos visuais, o AWS Glue Studio também inclui um caderno Jupyter apoiado por sessões interativas do AWS Glue, que você usará no restante deste tutorial.

Configuração do trabalho de sessões interativas do AWS Glue Streaming

1. Faça download do arquivo do caderno fornecido e salve-o em um diretório local.
2. Abra o console do AWS Glue e, no painel esquerdo, clique em Cadernos > Caderno Jupyter > Fazer upload e editar um caderno existente. Faça upload do caderno usando a etapa anterior e clique em Criar.

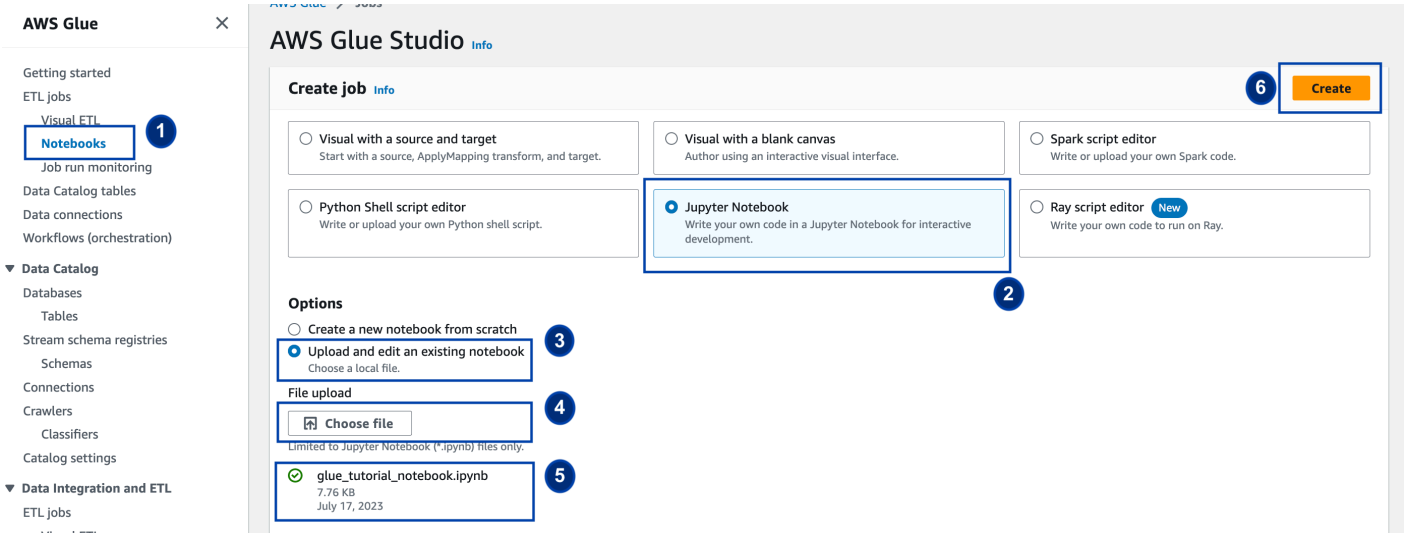

3. Forneça um nome e um perfil ao trabalho e selecione o kernel padrão do Spark. Em seguida, clique em Iniciar caderno. Para o Perfil do IAM, selecione o perfil provisionado pelo modelo do CloudFormation. É possível visualizar isso na guia Saídas do CloudFormation.

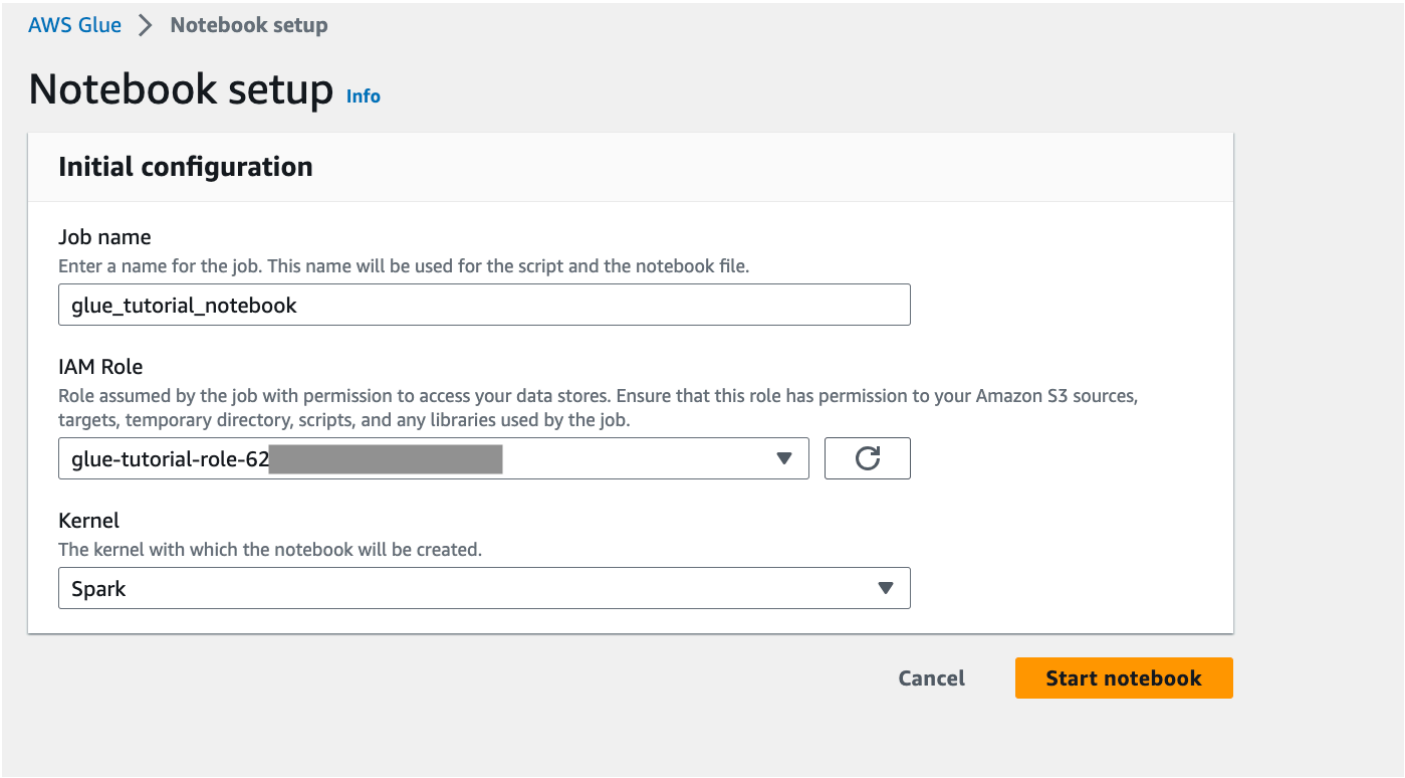

O caderno contém todas as instruções necessárias para continuar o tutorial. É possível executar as instruções no caderno ou seguir este tutorial para continuar com o desenvolvimento do trabalho.

Execução das células do caderno

1. (Opcional) A primeira célula de código, `%help`, lista todas as mágicas disponíveis para o caderno. É possível pular essa célula por enquanto, mas fique à vontade para explorá-la.
2. Comece com o próximo bloco de código, `%streaming`. Essa mágica define o tipo de trabalho para o streaming, o que permite desenvolver, depurar e implantar um trabalho de ETL de streaming do AWS Glue.
3. Execute a próxima célula para criar uma sessão interativa do AWS Glue. A célula de saída tem uma mensagem que confirma a criação da sessão.

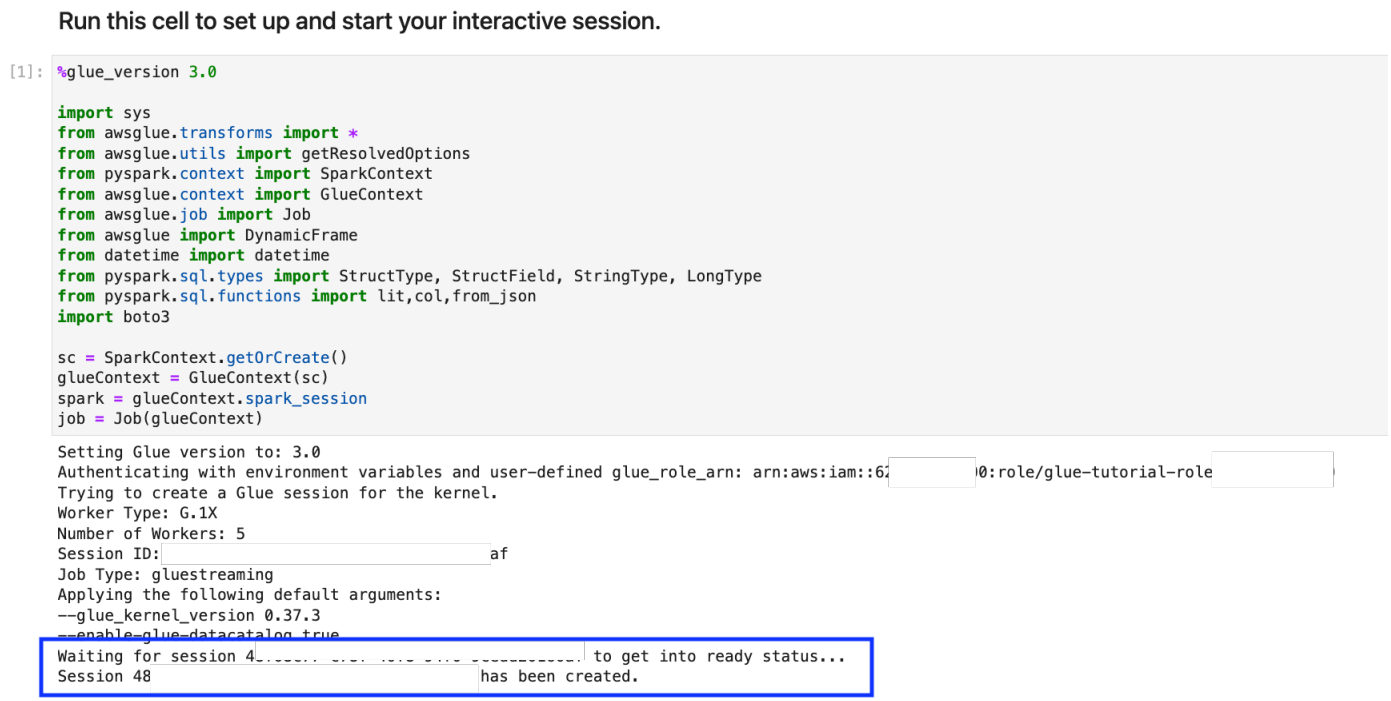

4. A próxima célula define as variáveis. Substitua os valores pelos valores apropriados para o seu trabalho e execute a célula. Por exemplo:

```
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. Como os dados já estão sendo transmitidos para o Kinesis Data Streams, a próxima célula consumirá os resultados do fluxo. Execute a próxima célula. Como não há instruções de impressão, não existe uma saída esperada para essa célula.

6. Na célula apresentada a seguir, você explora o fluxo de entrada ao utilizar um conjunto de amostra e imprimir o esquema e os dados reais dele. Por exemplo:

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. A seguir, defina a lógica real de transformação de dados. A célula consiste no método `processBatch`, que é acionado durante cada micro lote. Execute a célula. Em um nível superior, fazemos o seguinte com o fluxo de entrada:

   a. Selecione um subconjunto das colunas de entrada.

   b. Renomeie uma coluna (o2stats para oxygen_stats).

   c. Derive novas colunas (serial_identifier, ingest_year, ingest_month e ingest_day).

   d. Armazene os resultados em um bucket do Amazon S3 e também crie uma tabela do catálogo particionada do AWS Glue.

8. Na última célula, você aciona o lote do processo a cada dez segundos. Execute a célula e aguarde cerca de 30 segundos para que ela preencha o bucket do Amazon S3 e a tabela de catálogo do AWS Glue.

9. Por fim, navegue pelos dados armazenados usando o editor de consultas do Amazon Athena. É possível visualizar a coluna renomeada e também as novas partições.

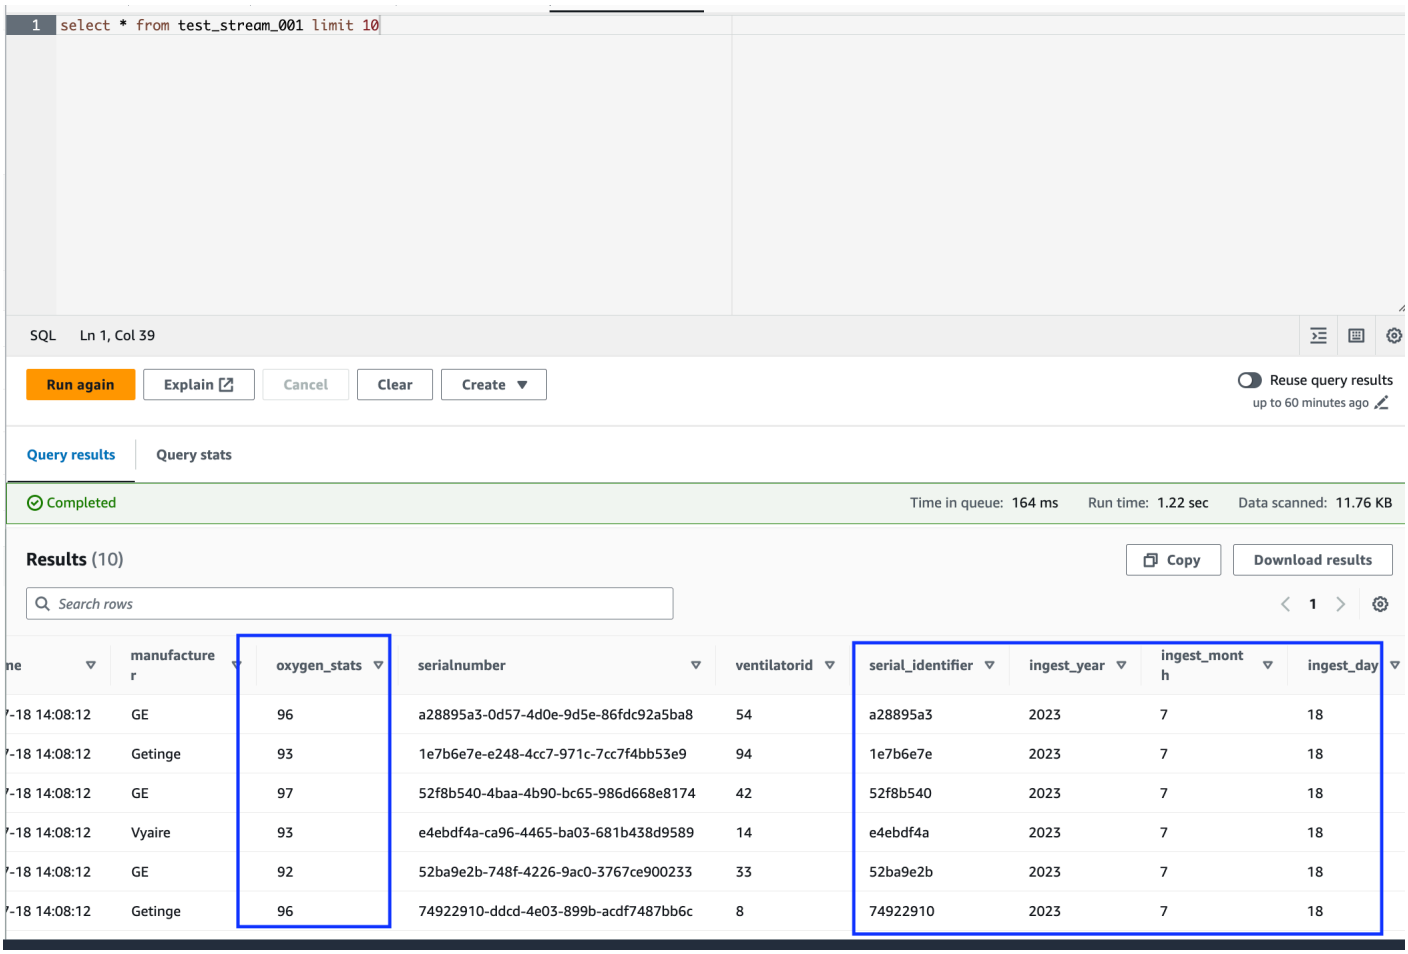

O caderno contém todas as instruções necessárias para continuar o tutorial. É possível executar as instruções no caderno ou seguir este tutorial para continuar com o desenvolvimento do trabalho.

Salvamento e execução do trabalho do AWS Glue

Com o desenvolvimento e o teste da aplicação concluídos usando o caderno de sessões interativas, clique em Salvar na parte superior da interface do caderno. Depois de salva, também é possível executar a aplicação como um trabalho.

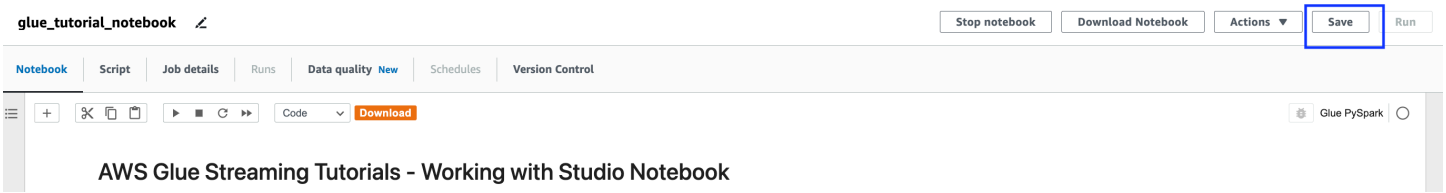

Limpeza

Para evitar cobranças adicionais em sua conta, interrompa o trabalho de streaming que você iniciou como parte das instruções. É possível fazer isso ao interromper o caderno, o que encerrará a sessão. Esvazie o bucket do Amazon S3 e exclua a pilha do AWS CloudFormation provisionada anteriormente.

Conclusão

Neste tutorial, demonstramos como fazer o seguinte usando o caderno do AWS Glue Studio:

- Criar um trabalho de ETL de streaming usando cadernos;
- Pré-visualizar os fluxos de dados de entrada;
- Codificar e corrigir problemas sem a necessidade de publicar trabalhos do AWS Glue;
- Analisar o código de trabalho de ponta a ponta, remover qualquer depuração e imprimir instruções ou células do caderno;
- Publicar o código como um trabalho do AWS Glue.

O objetivo deste tutorial é proporcionar a você uma experiência prática de trabalho com o AWS Glue Streaming e com as sessões interativas. Recomendamos que você o use como referência para seus casos de uso individuais do AWS Glue Streaming. Para ter mais informações, consulte Conceitos básicos das sessões interativas do AWS Glue.

Conceitos do AWS Glue Streaming

As seções apresentadas a seguir fornecem informações sobre os conceitos do AWS Glue Streaming.

Tópicos

- Anatomia de um trabalho de streaming do AWS Glue

Anatomia de um trabalho de streaming do AWS Glue

Os trabalhos de streaming do AWS Glue operam no paradigma de streaming do Spark e aproveitam o streaming estruturado da estrutura do Spark. Os trabalhos de streaming pesquisam constantemente a fonte de dados de streaming, em um intervalo de tempo específico, para buscar

registros como micro lotes. As seções apresentadas a seguir examinam as diferentes partes de um trabalho de streaming do AWS Glue.

forEachBatch

O método `forEachBatch` é o ponto de entrada de uma execução de trabalho de streaming do AWS Glue. Os trabalhos de streaming do AWS Glue usam o método `forEachBatch` para pesquisar dados. Ele funciona como um iterador que permanece ativo durante o ciclo de vida do trabalho de streaming e pesquisa regularmente a fonte de streaming em busca de novos dados, além de processar os dados mais recentes em micro lotes.

```
glueContext.forEachBatch(
    frame=dataFrame_AmazonKinesis_node1696872487972,
    batch_function=processBatch,
    options={
        "windowSize": "100 seconds",
        "checkpointLocation": args["TempDir"] + "/" + args["JOB_NAME"] + "/
checkpoint/",
    },
)
```

Configure a propriedade `frame` de `forEachBatch` para especificar uma fonte de streaming. Neste exemplo, o nó de origem que você criou na tela em branco durante a criação do trabalho é preenchido com o DataFrame padrão do trabalho. Configure a propriedade `batch_function` como a `function` que você decide invocar para cada operação de micro lote. Você deve definir uma função para tratar da transformação em lote relacionada aos dados de entrada.

Origem

Na primeira etapa da função `processBatch`, o programa verifica a contagem de registros do DataFrame que você definiu como a propriedade frame de `forEachBatch`. O programa acrescenta um carimbo de data/hora de ingestão a um DataFrame que não está vazio. A cláusula `data_frame.count()>0` determina se o micro lote mais recente não está vazio e se está pronto para o processamento adicional.

```
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",
        )
```

Mapeamento

A próxima seção do programa corresponde à aplicação do mapeamento. O método `Mapping.apply` em um DataFrame do Spark permite definir regras de transformação em torno de elementos de dados. Normalmente, é possível renomear, alterar o tipo de dados ou aplicar uma função personalizada na coluna de dados da fonte e mapeá-los para as colunas de destino.

```
    #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

Nesta seção, o conjunto de dados de entrada da fonte de streaming é armazenado em um local de destino. Neste exemplo, gravaremos os dados em um local do Amazon S3. Os detalhes da propriedade `AmazonS3_node_path` são preenchidos previamente, conforme determinado pelas configurações usadas durante a criação do trabalho na tela em branco. É possível definir `updateBehavior` com base em seu caso de uso e decidir Não atualizar a tabela do catálogo de dados ou Criar um catálogo de dados e atualizar o esquema do catálogo de dados em execuções subsequentes, ou criar uma tabela do catálogo e não atualizar a definição do esquema em execuções subsequentes.

A propriedade `partitionKeys` define a opção de partição de armazenamento. O comportamento padrão é particionar os dados de acordo com o `ingestion_time_columns` que foi disponibilizado na seção da fonte. A propriedade `compression` permite definir o algoritmo de compactação a ser aplicado durante a gravação de destino. Você tem as opções Snappy, LZO ou GZIP para definir uma técnica de compactação. A propriedade `enableUpdateCatalog` controla se a tabela do catálogo do AWS Glue precisa ser atualizada. As opções disponíveis para essa propriedade são `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",
    )
```

Coletor do catálogo do AWS Glue

Esta seção do trabalho controla o comportamento de atualização da tabela do catálogo do AWS Glue. Defina as propriedades `catalogDatabase` and `catalogTableName` de acordo com o nome do banco de dados do Catálogo do AWS Glue e o nome da tabela associada ao trabalho do AWS Glue que você está projetando. É possível definir o formato do arquivo dos dados de destino por meio da propriedade `setFormat`. Neste exemplo, armazenaremos os dados no formato Parquet.

Depois de configurar e executar o trabalho de streaming do AWS Glue referente a este tutorial, os dados de streaming produzidos no Amazon Kinesis Data Streams serão armazenados no local do Amazon S3 em formato Parquet com compactação rápida. Em execuções com êxito do trabalho de streaming, será possível consultar os dados por meio do Amazon Athena.

```
AmazonS3_node1696872743449 = setCatalogInfo(
    catalogDatabase =  "demo", catalogTableName = "demo_stream_transform_result"
)
AmazonS3_node1696872743449.setFormat("glueparquet")
AmazonS3_node1696872743449.writeFormat("ChangeSchema_node16986872679326")
)
```

Conexões de streaming do AWS Glue

As seções apresentadas a seguir fornecem informações sobre como usar as conexões no streaming do AWS Glue.

Tópicos

- Trabalhar com conexões do Kafka
- Trabalhar com conexões do Kinesis

Trabalhar com conexões do Kafka

É possível usar uma conexão do Kafka para ler e gravar fluxos de dados do Kafka usando informações armazenadas em uma tabela do Catálogo de Dados ou fornecendo informações para acessar diretamente o fluxo de dados. A conexão é compatível com um cluster do Kafka ou um cluster do Amazon Managed Streaming for Apache Kafka. Você pode ler informações do Kafka em um Spark DataFrame e depois convertê-las em um AWS Glue DynamicFrame. É possível gravar DynamicFrames no Kafka em um formato JSON. Se você acessar diretamente o fluxo de dados, use essas opções para fornecer as informações sobre como acessar o fluxo de dados.

Se você usar `getCatalogSource` ou `create_data_frame_from_catalog` para consumir registros de uma fonte de streaming do Kafka, ou `getCatalogSink` ou `write_dynamic_frame_from_catalog` para gravar registros no Kafka, e o trabalho tiver o banco de dados do catálogo de dados e as informações de nome da tabela, e poderá usá-los para obter alguns parâmetros básicos para leitura da fonte de streaming do Kafka. Se você usar `getSource`, `getCatalogSink`, `getSourceWithFormat`, `getSinkWithFormat`, `createDataFrameFromOptions`, `create_data_frame_from_options` ou `write_dynamic_frame_from_catalog`, será necessário especificar esses parâmetros básicos usando as opções de conexão descritas aqui.

Você pode especificar as opções de conexão para o Kafka usando os seguintes argumentos para os métodos especificados na classe `GlueContext`.

- Scala
  - `connectionOptions`: usar com `getSource`, `createDataFrameFromOptions`, `getSink`
  - `additionalOptions`: usar com `getCatalogSource`, `getCatalogSink`
  - `options`: usar com `getSourceWithFormat`, `getSinkWithFormat`
- Python
  - `connection_options`: usar com `create_data_frame_from_options`, `write_dynamic_frame_from_options`
  - `additional_options`: usar com `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
  - `options`: usar com `getSource`, `getSink`

Para notas e restrições sobre trabalhos de ETL de streaming, consulte the section called “Notas e restrições sobre ETL de transmissão”.

Configurar o Kafka

Não há pré-requisitos da AWS para se conectar aos fluxos do Kafka disponíveis pela Internet.

Você pode criar uma conexão do AWS Glue Kafka para gerenciar suas credenciais de conexão. Para ter mais informações, consulte the section called “Criar uma conexão para um fluxo de dados do Kafka”. Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional e depois na chamada do método, forneça *connectionName* para o parâmetro `connectionName`.

Em certos casos, você precisará configurar pré-requisitos adicionais:

- Se estiver usando o Amazon Managed Streaming for Apache Kafka com autenticação do IAM, você precisará da configuração apropriada do IAM.
- Se estiver usando o Amazon Managed Streaming for Apache Kafka com uma Amazon VPC, você precisará da configuração apropriada do Amazon VPC. Você precisará criar uma conexão do AWS Glue que forneça informações de conexão com o Amazon VPC. Você precisará que a configuração do trabalho inclua a conexão do AWS Glue como uma conexão de rede adicional.

Para obter mais informações sobre pré-requisitos de trabalho de ETL de streaming, consulte the section called “Trabalhos de transmissão de ETL”.

Exemplo: leitura de fluxos do Kafka

Usado em conjunto com the section called “forEachBatch”.

Exemplo para fonte de transmissão do 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)
```

Exemplo: gravação em fluxos do Kafka

Exemplos de gravação no Kafka:

Exemplo com o método `getSink`:

```
data_frame_datasource0 =
glueContext.getSink(
 connectionType="kafka",
 connectionOptions={
  JsonOptions("""{
   "connectionName": "ConfluentKafka",
   "classification": "json",
   "topic": "kafka-auth-topic",
   "typeOfData": "kafka"}
  """)},
 transformationContext="dataframe_ApacheKafka_node1711729173428")
 .getDataFrame()
```

Exemplo com o método `write_dynamic_frame.from_options`:

```
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)
```

Referência de opções de conexão do Kafka

Ao ler, use as seguintes opções de conexão com `"connectionType": "kafka"`:

- `"bootstrap.servers"` (obrigatório) uma lista de URLs do servidor de bootstrap, por exemplo, como `b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Essa opção deve ser especificada na chamada de API ou definida nos metadados da tabela no Data Catalog.
- `"security.protocol"` (obrigatório) O protocolo usado para se comunicar com os agentes. Os valores possíveis são `"SSL"` ou `"PLAINTEXT"`.
- `"topicName"` (Obrigatório): uma lista separada por vírgulas de tópicos para assinar. É necessário especificar um e apenas um de `"topicName"`, `"assign"` ou `"subscribePattern"`.
- `"assign"` (Obrigatório): uma string JSON para especificar o `TopicPartitions` a ser consumido. É necessário especificar um e apenas um de `"topicName"`, `"assign"` ou `"subscribePattern"`.

Exemplo: '{"topicA":[0,1],"topicB":[2,4]}'

- `"subscribePattern"`: (obrigatório) uma string regex Java que identifica a lista de tópicos para assinar. É necessário especificar um e apenas um de `"topicName"`, `"assign"` ou `"subscribePattern"`.

  Exemplo: 'topic.*'

- `"classification"` (Obrigatório) O formato de arquivo usado pelos dados no registro. Obrigatório, a menos que fornecido por meio do catálogo de dados.
- `"delimiter"` (Opcional) O separador de valores usado quando a `classification` é CSV. O padrão é `","`.
- `"startingOffsets"`: (opcional) a posição inicial no tópico do Kafka de onde ler os dados. Os valores possíveis são `"earliest"` ou `"latest"`. O valor padrão é `"latest"`.
- `"startingTimestamp"`: (opcional, compatível somente com o AWS Glue versão 4.0 ou posterior) O timestamp do registro no tópico do Kafka do qual ler os dados. O valor possível é uma string de timestamp no formato UTC no padrão `yyyy-mm-ddTHH:MM:SSZ` (onde `Z` representa um desvio do fuso horário UTC com +/-). Por exemplo: "2023-04-04T08:00:00-04:00").

  Observação: somente um dos 'startingOffsets' ou 'startingTimestamp' pode estar presente na lista de opções de conexão do script de streaming do AWS Glue. A inclusão de ambas as propriedades resultará em falha no trabalho.

- `"endingOffsets"`: (opcional) o ponto final quando uma consulta em lote é encerrada. Os valores possíveis são `"latest"` ou uma string JSON que especifica um deslocamento final para cada `TopicPartition`.

  Para a string JSON, o formato é `{"topicA":{"0":23,"1":-1},"topicB":{"0":-1}}`. O valor `-1` como um deslocamento representa `"latest"`.

- `"pollTimeoutMs"`: (opcional) o tempo limite em milissegundos para sondar dados do Kafka em executores de trabalho do Spark. O valor padrão é `600000`.
- `"numRetries"`: (opcional) o número de novas tentativas antes de falhar em obter os deslocamentos do Kafka. O valor padrão é `3`.
- `"retryIntervalMs"`: (opcional) o tempo em milissegundos a se esperar antes de tentar novamente buscar os deslocamentos do Kafka. O valor padrão é `10`.
- `"maxOffsetsPerTrigger"`: (opcional) o limite de taxa no número máximo de deslocamentos que são processados por intervalo do acionador. O número total especificado de deslocamentos

é dividido proporcionalmente entre `topicPartitions` de diferentes volumes. O valor padrão é nulo, o que significa que o consumidor lê todos os deslocamentos até o deslocamento mais recente conhecido.

- `"minPartitions"`: (opcional) o número mínimo desejado de partições a serem lidas do Kafka. O valor padrão é nulo, o que significa que o número de partições do Spark é igual ao número de partições do Kafka.
- `"includeHeaders"`: (opcional) informa se deve incluir os cabeçalhos do Kafka. Quando a opção estiver definida como "true", a saída de dados conterá uma coluna adicional chamada "glue_streaming_kafka_headers" com o tipo `Array[Struct(key: String, value: String)]`. O valor padrão é “false”. Essa opção está disponível no AWS Glue versão 3.0 ou posterior.
- `"schema"` (Obrigatório quando inferSchema é definido como false): o esquema a ser usado para processar a carga útil. Se a classificação for `avro`, o esquema fornecido deverá estar no formato de esquema Avro. Se a classificação não for `avro`, o esquema fornecido deverá estar no formato de esquema DDL.

  Veja a seguir alguns exemplos de esquema.

  Example 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"` (Opcional): o valor padrão é "false". Se definido como “true”, o esquema será detectado em runtime com base na carga útil em `foreachbatch`.
- `"avroSchema"` (Descontinuado): parâmetro usado para especificar um esquema de dados Avro quando o formato Avro é usado. Esse parâmetro foi descontinuado. Use o parâmetro `schema`.
- `"addRecordTimestamp"`: (opcional) quando essa opção for definida como “true“, a saída de dados conterá uma coluna adicional denominada “__src_timestamp” que indica a hora em que o registro correspondente foi recebido pelo tópico. O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.
- `"emitConsumerLagMetrics"`: (opcional) quando a opção for definida como "true", para cada lote, serão emitidas métricas durante o período entre a hora que o registro mais antigo é recebido pelo tópico e a hora que ele chega ao AWS Glue para o CloudWatch. O nome da métrica é "glue.driver.streaming.maxConsumerLagInMs". O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.

Ao gravar, use as seguintes opções de conexão com o `"connectionType": "kafka"`:

- `"connectionName"` (Obrigatório) Nome da conexão do AWS Glue usada para se conectar ao cluster do Kafka (semelhante à origem do Kafka).
- `"topic"` (Obrigatório) Se uma coluna de tópico existir, seu valor será usado como tópico ao gravar a linha especificada no Kafka, a menos que a opção de configuração do tópico esteja definida. Ou seja, a opção de configuração `topic` substitui a coluna do tópico.
- `"partition"` (Opcional) Se um número de partição válido for especificado, essa `partition` será usada no envio do registro.

  Se nenhuma partição for especificada, mas uma `key` estiver presente, uma partição será escolhida usando um hash da chave.

Se nem `key` nem `partition` estiverem presentes, uma partição será escolhida com base no particionamento fixo dessas alterações quando pelo menos bytes batch.size forem produzidos na partição.

- `"key"` (Opcional) Usado para particionar se `partition` for nulo.
- `"classification"` (Opcional) O formato de arquivo usado pelos dados no registro. Só oferecemos suporte a JSON, CSV e Avro.

  Com o formato Avro, podemos fornecer um avroSchema personalizado para serializar, mas observe que isso também precisa ser fornecido na fonte para desserialização. Caso contrário, por padrão, ele usa o Apache AvroSchema para serializar.

Além disso, você pode ajustar o coletor Kafka conforme necessário atualizando os parâmetros de configuração do produtor Kafka. Observe que não há nenhuma lista de permissões nas opções de conexão. Todos os pares de chave-valor são mantidos no coletor como estão.

No entanto, há uma pequena lista de opções negadas que não entrarão em vigor. Para obter mais informações, consulte Configurações específicas do Kafka.

Trabalhar com conexões do Kinesis

É possível usar uma conexão do Kinesis para ler e gravar o Amazon Kinesis Data Streams usando informações armazenadas em uma tabela do Data Catalog ou fornecendo informações para acessar diretamente o fluxo de dados. Você pode ler informações do Kinesis em um Spark DataFrame e depois convertê-las em um Glue DynamicFrame AWS. Você pode gravar DynamicFrames no Kinesis em um formato JSON. Se você acessar diretamente o fluxo de dados, use essas opções para fornecer as informações sobre como acessar o fluxo de dados.

Se você usar `getCatalogSource` ou `create_data_frame_from_catalog` para consumir registros de uma fonte de transmissão do Kinesis, o trabalho tem o banco de dados do catálogo de dados e as informações de nome da tabela, e pode usá-los para obter alguns parâmetros básicos para leitura da fonte de transmissão do Kinesis. Se você usar `getSource`, `getSourceWithFormat`, `createDataFrameFromOptions` ou `create_data_frame_from_options`, será necessário especificar esses parâmetros básicos usando as opções de conexão descritas aqui.

Você pode especificar as opções de conexão para o Kinesis usando os seguintes argumentos para os métodos especificados na classe `GlueContext`.

- Scala
  - `connectionOptions`: usar com `getSource`, `createDataFrameFromOptions`, `getSink`
  - `additionalOptions`: usar com `getCatalogSource`, `getCatalogSink`
  - `options`: usar com `getSourceWithFormat`, `getSinkWithFormat`
- Python
  - `connection_options`: usar com `create_data_frame_from_options`, `write_dynamic_frame_from_options`
  - `additional_options`: usar com `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
  - `options`: usar com `getSource`, `getSink`

Para notas e restrições sobre trabalhos de ETL de streaming, consulte the section called “Notas e restrições sobre ETL de transmissão”.

Configurar o Kinesis

Para ler um fluxo de dados do Kinesis em uma trabalho do AWS Glue Spark, você precisará de alguns pré-requisitos:

- Se for leitura, o trabalho do AWS Glue deve ter permissões IAM do nível de acesso de leitura ao fluxo de dados do Kinesis.
- Se for gravação, o trabalho do AWS Glue deve ter permissões IAM do nível de acesso de gravação ao fluxo de dados do Kinesis.

Em certos casos, você precisará configurar pré-requisitos adicionais:

- Se o trabalho do AWS Glue estiver configurado com conexões de rede adicionais (normalmente para se conectar a outros conjuntos de dados) e uma dessas conexões fornecer opções de rede da Amazon VPC, isso direcionará o trabalho para se comunicar pela Amazon VPC. Nesse caso, você também precisará configurar o fluxo de dados do Kinesis para se comunicar pela Amazon VPC. É possível fazer isso criando um endpoint da VPC de interface entre a Amazon VPC e o fluxo de dados do Kinesis. Para obter mais informações, consulte Using Kinesis Data Streams with Interface VPC Endpoints.

- Ao especificar Amazon Kinesis Data Streams em outra conta, você deve configurar os perfis e políticas para permitir o acesso entre contas. Para obter mais informações, consulte Exemplo: Ler de uma transmissão do Kinesis em outra conta.

Para obter mais informações sobre pré-requisitos de trabalho de ETL de streaming, consulte the section called “Trabalhos de transmissão de ETL”.

Ler no Kinesis

Exemplo: ler de fluxos do Kinesis

Usado em conjunto com the section called “forEachBatch”.

Exemplo para fonte de transmissão do 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)
```

Gravar no Kinesis

Exemplo: gravação em streams do Kinesis

Usado em conjunto com the section called “forEachBatch”. Seu DynamicFrame será gravado no stream em um formato JSON. Se o trabalho não puder ser gravado após várias tentativas, ele falhará. Por padrão, cada registro do DynamicFrame será enviado para o stream do Kinesis individualmente. Você pode configurar esse comportamento usando `aggregationEnabled` parâmetros associados.

Exemplo de gravação para o Amazon Kinesis a partir de um trabalho de streaming:

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)
```

Parâmetros de conexão do Kinesis

Designa opções de conexão para o Amazon Kinesis Data Streams.

Use as seguintes opções de conexão para fontes de dados de transmissão do Kinesis:

- `"streamARN"` (obrigatório) usado para leitura/gravação. O ARN do fluxo de dados do Kinesis.
- `"classification"` (Obrigatório para leitura) Usado para leitura. O formato de arquivo usado pelos dados no registro. Obrigatório, a menos que fornecido por meio do catálogo de dados.
- `"streamName"` (opcional) usado para leitura. O nome de um fluxo de dados do Kinesis de onde ler. Usado com `endpointUrl`.
- `"endpointUrl"` (opcional) usado para leitura. Padrão: “https://kinesis.us-east-1.amazonaws.com” O endpoint AWS do stream do Kinesis. Você não precisa alterar isso, a menos que esteja se conectando a uma região especial.
- `"partitionKey"` (opcional) usado para gravação. A chave de partição do Kinesis usada na produção de registros.
- `"delimiter"` (opcional) usado para leitura. O separador de valores usado quando a `classification` é CSV. O padrão é `","`.

- `"startingPosition"`: (opcional) usado para leitura. A posição inicial no fluxo de dados do Kinesis de onde ler os dados. Os valores possíveis são `"latest"`, `"trim_horizon"`, `"earliest"` ou uma string de timestamp no formato UTC no padrão `yyyy-mm-ddTHH:MM:SSZ` (onde `Z` representa um desvio do fuso horário UTC com +/-). Por exemplo: "2023-04-04T08:00:00-04:00"). O valor padrão é `"latest"`. Observação: a string de timestamp no formato UTC para `"startingPosition"` é compatível somente com a versão 4.0 ou posterior do AWS Glue.
- `"failOnDataLoss"`: (Opcional) Falha na tarefa se algum fragmento ativo estiver ausente ou expirado. O valor padrão é `"false"`.
- `"awsSTSRoleARN"`: (opcional) usado para leitura/gravação. O nome de recurso da Amazon (ARN) da função a ser assumida com o uso do AWS Security Token Service (AWS STS). Essa função deve ter permissões para descrever ou ler operações de registro para o fluxo de dados do Kinesis. Você deve usar esse parâmetro ao acessar um fluxo de dados em uma conta diferente. Usado em conjunto com `"awsSTSSessionName"`.
- `"awsSTSSessionName"`: (opcional) usado para leitura/gravação. Um identificador para a sessão que assume a função usando o AWS STS. Você deve usar esse parâmetro ao acessar um fluxo de dados em uma conta diferente. Usado em conjunto com `"awsSTSRoleARN"`.
- `"awsSTSEndpoint"`: (Opcional) O AWS STS endpoint a ser usado ao se conectar ao Kinesis com uma função assumida. Isso permite usar o AWS STS endpoint regional em uma VPC, o que não é possível com o endpoint global padrão.
- `"maxFetchTimeInMs"`: (opcional) usado para leitura. O tempo máximo para o executor do trabalho ler registros referentes ao lote atual do fluxo de dados do Kinesis especificado em milissegundos (ms). Várias chamadas de API `GetRecords` podem ser feitas nesse período. O valor padrão é `1000`.
- `"maxFetchRecordsPerShard"`: (opcional) usado para leitura. O número máximo de registros a serem obtidos por fragmento no fluxo de dados do Kinesis por microlote. Observação: o cliente poderá exceder esse limite se o trabalho de streaming já tiver lido registros extras do Kinesis (na mesma chamada get-records). Se `maxFetchRecordsPerShard` precisa ser rigoroso, então precisa ser um múltiplo de `maxRecordPerRead`. O valor padrão é `100000`.
- `"maxRecordPerRead"`: (opcional) usado para leitura. O número máximo de registros a serem obtidos por fragmento no fluxo de dados do Kinesis em cada operação `getRecords`. O valor padrão é `10000`.
- `"addIdleTimeBetweenReads"`: (opcional) usado para leitura. Adiciona um atraso de tempo entre duas operações `getRecords`. O valor padrão é `"False"`. Essa opção só pode ser configurada para o Glue versão 2.0 e posterior.

- `"idleTimeBetweenReadsInMs"`: (opcional) usado para leitura. O atraso mínimo entre duas operações , especificado em ms. O valor padrão é `1000`. Essa opção só pode ser configurada para o Glue versão 2.0 e posterior.
- `"describeShardInterval"`: (opcional) usado para leitura. O intervalo de tempo mínimo entre duas chamadas de API `ListShards` para que seu script considere a refragmentação. Para obter mais informações, consulte Estratégias para refragmentação no Guia do desenvolvedor do Amazon Kinesis Data Streams. O valor padrão é `1s`.
- `"numRetries"`: (opcional) usado para leitura. O número máximo de novas tentativas para solicitações de API do Kinesis Data Streams. O valor padrão é `3`.
- `"retryIntervalMs"`: (opcional) usado para leitura. O período de espera (especificado em ms) antes de repetir a chamada da API Kinesis Data Streams. O valor padrão é `1000`.
- `"maxRetryIntervalMs"`: (opcional) usado para leitura. O período de espera máximo (especificado em ms) entre duas tentativas de uma chamada de API Kinesis Data Streams. O valor padrão é `10000`.
- `"avoidEmptyBatches"`: (opcional) usado para leitura. Evita a criação de um trabalho de micro lote vazio verificando se há dados não lidos no fluxo de dados do Kinesis antes de o lote ser iniciado. O valor padrão é `"False"`.
- `"schema"`: (Obrigatório quando inferSchema é definido como false): usado para leitura. O esquema a ser usado para processar a carga. Se a classificação for `avro`, o esquema fornecido deverá estar no formato de esquema Avro. Se a classificação não for `avro`, o esquema fornecido deverá estar no formato de esquema DDL.

  Veja a seguir alguns exemplos de esquema.

  Example 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"`: (opcional) usado para leitura. O valor padrão é "false". Se definido como “true”, o esquema será detectado em runtime com base na carga útil em `foreachbatch`.
- `"avroSchema"`: (Obsoleto) Usado para leitura. Parâmetro usado para especificar um esquema de dados Avro quando o formato Avro é usado. Esse parâmetro foi descontinuado. Use o parâmetro `schema`.
- `"addRecordTimestamp"`: (opcional) usado para leitura. Quando essa opção for definida como "true", a saída de dados conterá uma coluna adicional denominada "__src_timestamp" que indica a hora que o registro correspondente é recebido pelo fluxo. O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.
- `"emitConsumerLagMetrics"`: (opcional) usado para leitura. Quando a opção for definida como "true" (verdadeira), para cada lote, serão emitidas métricas durante o período entre a hora que o registro mais antigo é recebido pelo tópico e a hora que ele chega ao AWS Glue para o CloudWatch. O nome da métrica é "glue.driver.streaming.maxConsumerLagInMs". O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.
- `"fanoutConsumerARN"`: (opcional) usado para leitura. O ARN de um consumidor de fluxo do Kinesis para o fluxo especificado em `streamARN`. Usado para habilitar o modo de distribuição avançada para a conexão do Kinesis. Para obter mais informações sobre como consumir um fluxo do Kinesis com distribuição avançada, consulte the section called “Usar distribuição avançada nas tarefas de streaming do Kinesis”.
- `"recordMaxBufferedTime"` (opcional) usado para gravação. Padrão: 1000 (ms). Tempo máximo em que um registro é armazenado em buffer enquanto espera para ser gravado.

- `"aggregationEnabled"` (opcional) usado para gravação. Padrão: true. Especifica se os registros devem ser agregados antes de serem enviados para o Kinesis.
- `"aggregationMaxSize"` (opcional) usado para gravação. Padrão: 51200 (bytes) Se um registro for maior que esse limite, ele ignorará o agregador. Nota: O Kinesis impõe um limite de 50 KB no tamanho do registro. Se você definir isso além de 50 KB, registros grandes serão rejeitados pelo Kinesis.
- `"aggregationMaxCount"` (opcional) usado para gravação. Padrão: 4294967295. O número máximo de itens a serem retornados em um registro agregado.
- `"producerRateLimit"` (opcional) usado para gravação. Padrão: 150 (%). Limita o throughput por fragmento enviado por um único produtor (como seu trabalho), como uma porcentagem do limite de back-end.
- `"collectionMaxCount"` (opcional) usado para gravação. Padrão: 500. Número máximo de itens a serem compactados em uma solicitação PutRecords.
- `"collectionMaxSize"` (opcional) usado para gravação. Padrão: 5242880 (bytes) Quantidade máxima de dados a serem enviados com uma solicitação PutRecords.

Ajuste de escala automático de streaming do AWS Glue

Os trabalhos de ETL de streaming do AWS Glue consomem continuamente dados de fontes de streaming, limpam e transformam os dados em andamento e os disponibilizam para análise. Ao monitorar cada etapa da execução do trabalho, o escalonamento automático do AWS Glue pode desativar os trabalhadores quando eles estão ociosos ou adicionar trabalhadores se for possível o processamento paralelo adicional.

As seções apresentadas a seguir fornecem informações sobre o ajuste de escala automático de streaming do AWS Glue.

Habilitar Auto Scaling no AWS Glue Studio

Na guia Job details (Detalhes do trabalho) no AWS Glue Studio, escolha o tipo Spark ou Spark Streaming (Streaming do Spark) e a Glue version (Versão do Glue) como **`Glue 3.0`** ou **`Glue 4.0`**. Uma caixa de seleção será exibida abaixo de Worker type (Tipo de operador).

- Selecione a opção Automatically scale the number of workers (Dimensionar automaticamente o número de operadores).

- Defina Maximum numer of workers (Número máximo de operadores) para estabelecer o número máximo de operadores que podem ser transferidos para a execução do trabalho.

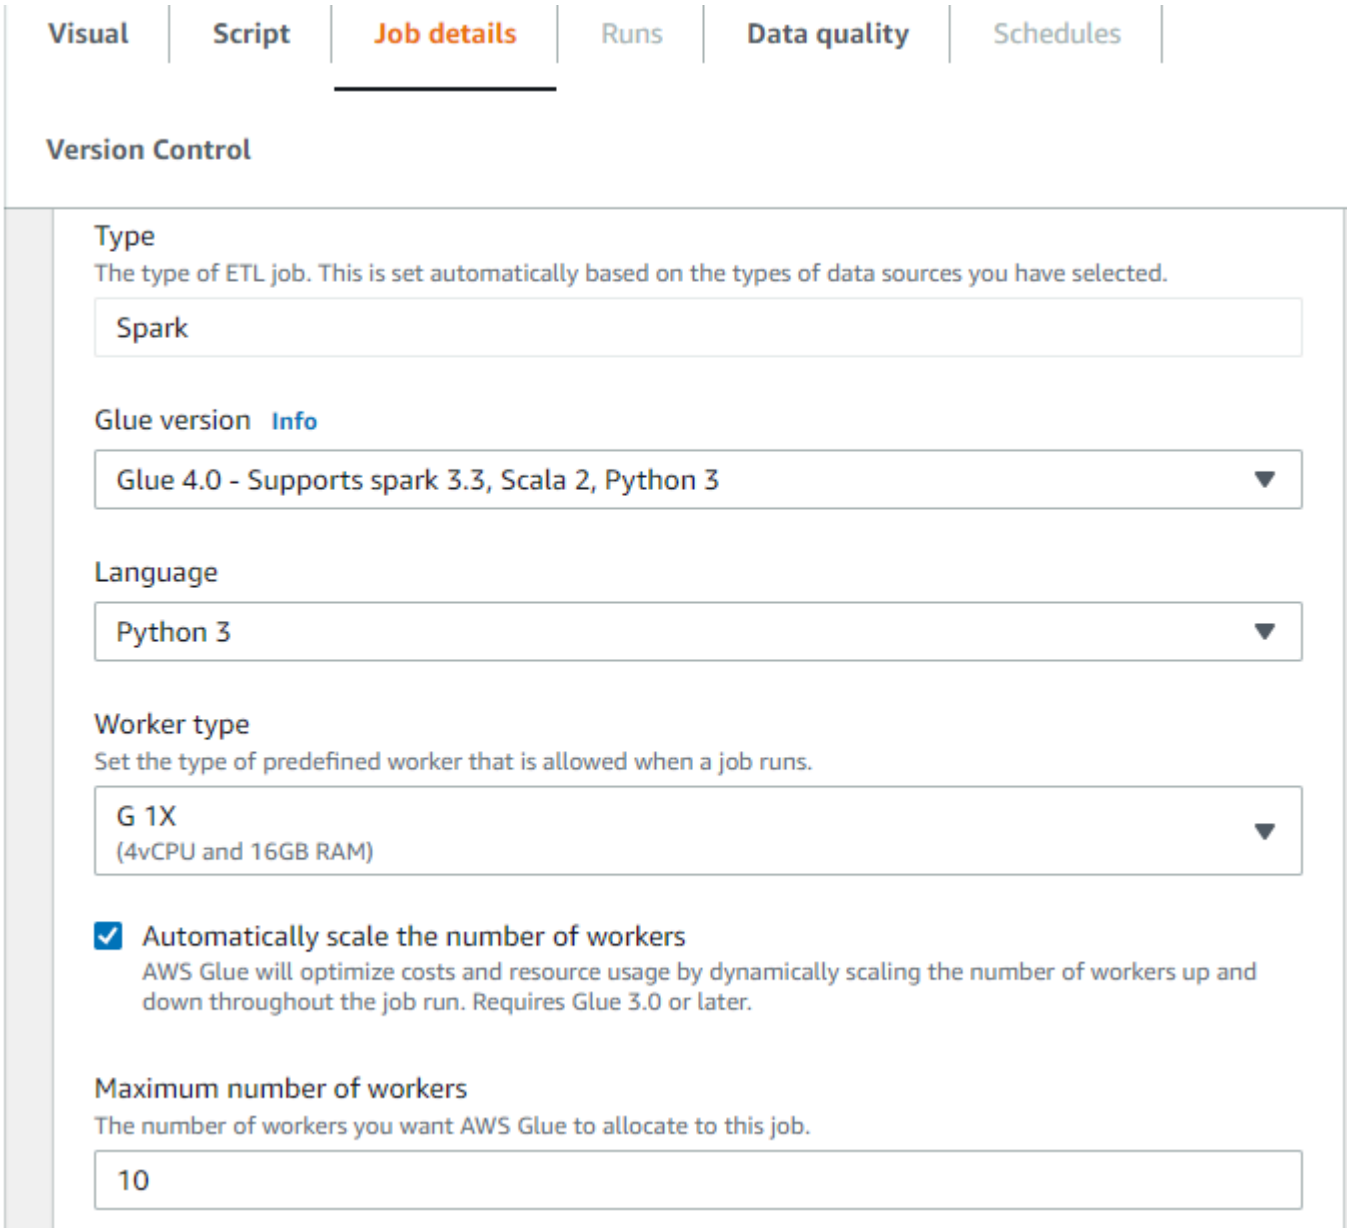

Habilitar o Auto Scaling com a AWS CLI ou SDK

Para habilitar o Auto Scaling diretamente da AWS CLI para sua execução de trabalho, execute `start-job-run` com a seguinte configuração:

```
{
    "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...
}
```

Quando a execução do trabalho de ETL estiver concluída, também será possível chamar `get-job-run` para verificar o uso efetivo de recurso da execução de trabalho em segundos de DPU. Observação: o novo campo DPUSeconds só aparecerá para trabalhos em lote no AWS Glue 3.0 ou posterior habilitado com o Auto Scaling. Esse campo não é compatível com trabalhos de transmissão.

```
$ 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
    }
}
```

Você também pode configurar execuções de tarefas com o Auto Scaling usando o AWS Glue SDK com a mesma configuração.

Como funciona

Escalar entre micro lotes

O exemplo apresentado a seguir é usado para descrever como funciona o ajuste de escala automático.

- Você tem um trabalho do AWS Glue que começa com 50 DPUs.
- O ajuste de escala automático está habilitado.

Neste exemplo, o AWS Glue analisa a métrica “batchProcessingTimeInMs” para alguns micro lotes e determina se os trabalhos estão sendo concluídos dentro do tamanho da janela que você

estabeleceu. Se os trabalhos forem concluídos com antecedência e, com base em quanto tempo forem concluídos, o AWS Glue poderá reduzir a escala verticalmente. Essa métrica, plotada com “numberAllExecutors”, pode ser monitorada no Amazon CloudWatch para visualizar como funciona o ajuste de escala automático.

O número de executores aumenta ou reduz a escala verticalmente de forma exponencial somente após a conclusão de cada micro lote. Como você pode visualizar no log de monitoramento do Amazon CloudWatch, o AWS Glue analisa o número de executores necessários (linha laranja) e escala os executores (linha azul) para corresponder a eles automaticamente.

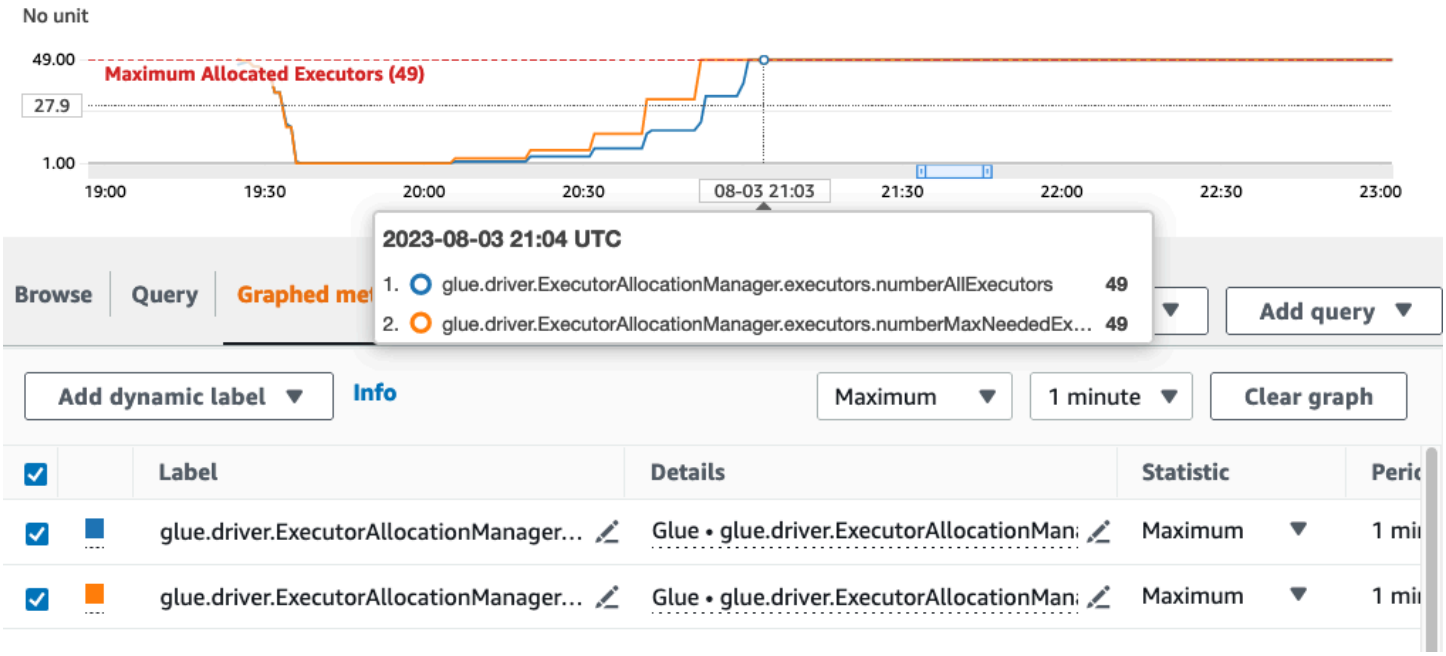

Depois que o AWS Glue reduzir a escala verticalmente para o número de executores e observar que os volumes de dados aumentam, consequentemente aumentando o tempo de processamento do micro lote, o AWS Glue aumentará a escala verticalmente para 50 DPUs, que é o limite superior especificado.

Escalar em micro lotes

No exemplo acima, o sistema monitora alguns micro lotes concluídos para tomar uma decisão sobre reduzir ou aumentar a escala verticalmente. Janelas mais longas requerem um ajuste de escala automático para responder mais rapidamente dentro do micro lote, em vez de esperar por alguns micro lotes. Para estes casos, você pode usar uma configuração adicional `--auto-scaIe-within-microbatch` como `true`. É possível adicionar essa configuração às propriedades do trabalho do AWS Glue no AWS Glue Studio, conforme mostrado abaixo.

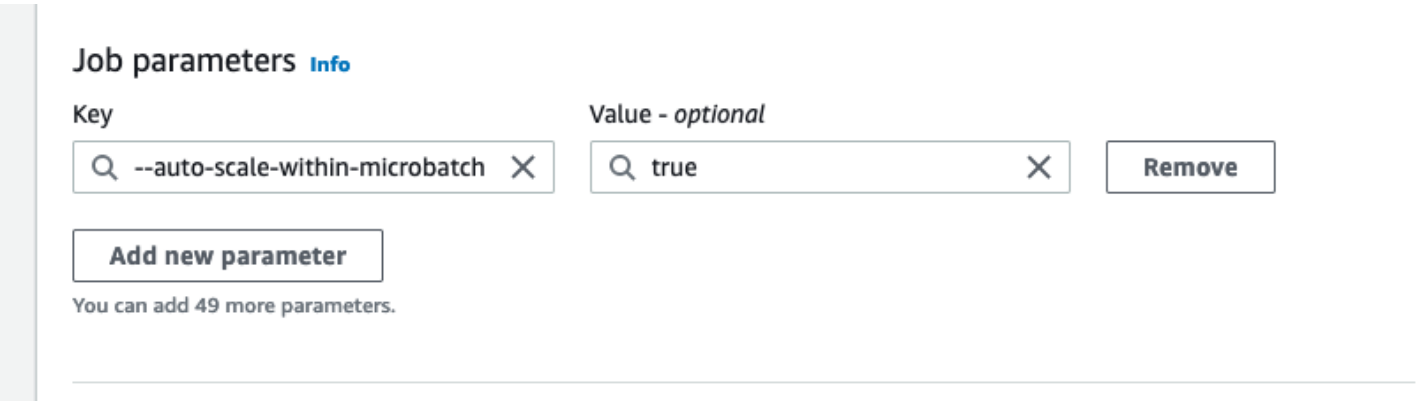

Janelas de manutenção do AWS Glue Streaming

O AWS Glue realiza periodicamente atividades de manutenção. Durante essas janelas de manutenção, o AWS Glue precisará reiniciar seus trabalhos de streaming. É possível controlar quando os trabalhos são reiniciados especificando janelas de manutenção. Nesta seção, descrevemos onde configurar a janela de manutenção e os comportamentos específicos que você deve considerar.

Tópicos

- Configurar uma janela de manutenção
- Comportamento da janela de manutenção
- Monitorar trabalhos
- Como tratar perda de dados

Configurar uma janela de manutenção

Você pode configurar uma janela de manutenção usando o AWS Glue Studio ou as APIs.

Configurar uma janela de manutenção no AWS Glue Studio

Especifique uma janela de manutenção na página Detalhes do trabalho do seu trabalho do AWS Glue Streaming. É possível especificar o dia e a hora em GMT. o AWS Glue reiniciará o trabalho dentro da janela de tempo especificada.

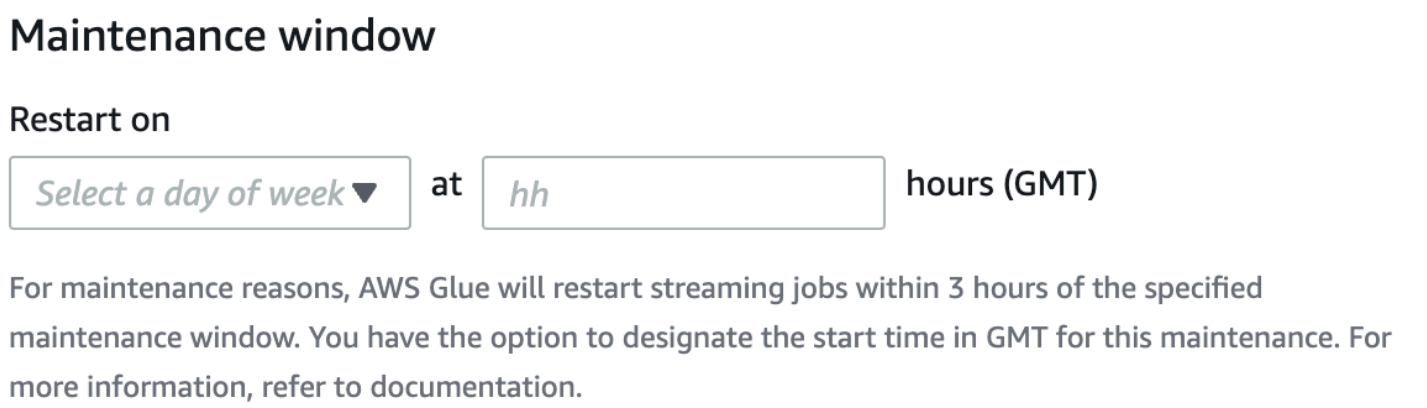

Configurar uma janela de manutenção na API

Como alternativa, é possível configurar a janela de manutenção na API Create Job. Este é um exemplo de configuração de janelas de manutenção por meio da API.

```
aws glue create-job –name jobName –role roleArnForTheJob –command
 Name=gluestreaming,ScriptLocation=s3-path-to-the-script --maintenance-window="Sun:10"
```

O comando a seguir é um exemplo:

```
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
```

Comportamento da janela de manutenção

O AWS Glue passa por uma série de etapas para decidir quando reiniciar um trabalho:

1. Quando um novo trabalho de streaming é iniciado, o AWS Glue primeiro verifica se há um tempo limite associado à execução. Um tempo limite permite configurar a hora de término do trabalho. Se o tempo limite for inferior a 7 dias, o trabalho não será reiniciado.
2. Se o tempo limite for superior a 7 dias, o AWS Glue verifica se a janela de manutenção está configurada para o trabalho. Se estiver, essa janela será selecionada e a janela será atribuída à execução do trabalho. O AWS Glue reiniciará o trabalho dentro das 3 horas da janela de manutenção especificada. Por exemplo, se você configurar a janela de manutenção para segunda-feira às 10h (GMT), seus trabalhos serão reiniciados entre 10h (GMT) e 13h (GMT).

3. Se a janela de manutenção não estiver configurada, o AWS Glue definirá automaticamente o horário de reinicialização para 7 dias após o horário de início da execução do trabalho. Por exemplo, se você iniciou o trabalho em 01/07/2024, às 12h GMT, e não especificou janelas de manutenção, o trabalho será configurado para reiniciar em 7/8/2024, às 12h GMT.

> **Note**
>
> Se já estiver executando trabalhos de streaming, essa alteração afetará você a partir de 1º de julho de 2024. Você terá até 30 de junho para configurar as janelas de manutenção. Depois de 1º de julho, todos os trabalhos de streaming que iniciar serão reiniciados de acordo com esta documentação. Se precisar de mais suporte, entre em contato com o AWS Support.

4. Às vezes, pode não ser possível para o AWS Glue reiniciar o trabalho, especialmente quando o microlote em andamento não está processado. Nesses casos, o trabalho não será interrompido. O AWS Glue reiniciará o trabalho após 14 dias, e a janela de manutenção não será respeitada.

Monitorar trabalhos

Você pode monitorar os trabalhos na página Monitoramento do AWS Glue Studio.

Para ver o horário esperado para a próxima reinicialização dos trabalhos de streaming, mostre a coluna na tabela Execuções de trabalho na página Monitoramento.

1. Clique no ícone de engrenagem na parte superior direita da tabela.

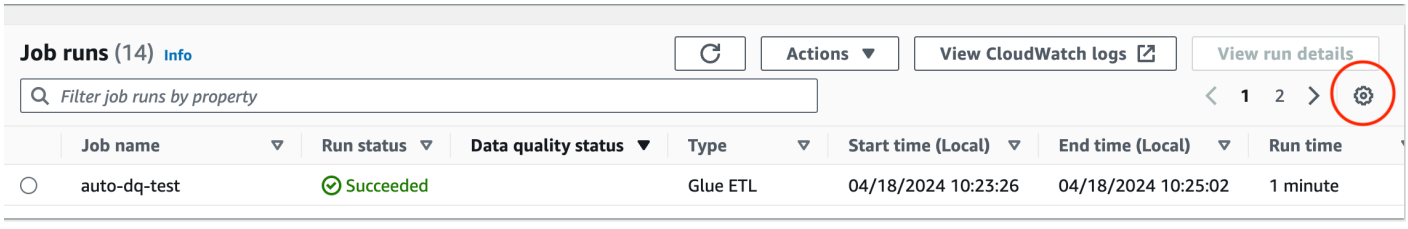

2. Role para baixo e ative a coluna Hora esperada da reinicialização. As opções de horário UTC e local estão disponíveis.

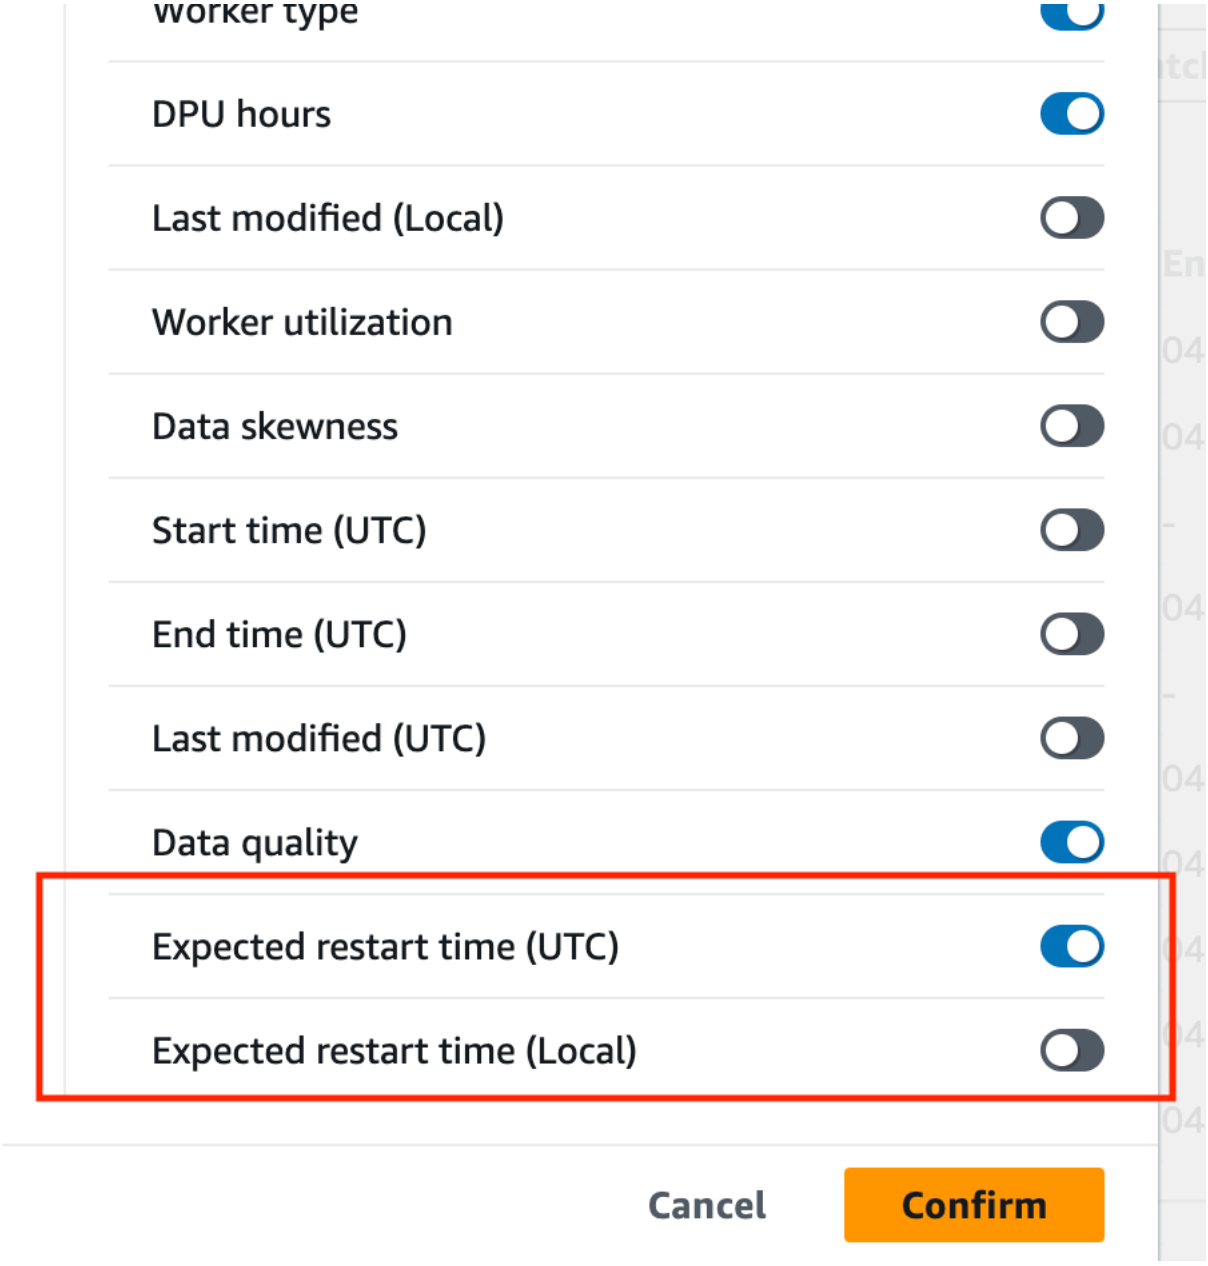

3. Em seguida, você poderá visualizar as colunas na tabela.

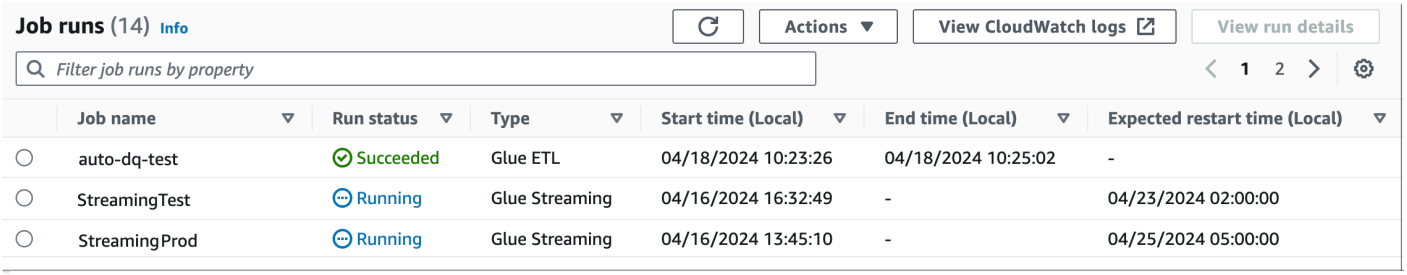

O trabalho original terá o status "EXPIRADO", e a nova instância do trabalho terá o status "EM EXECUÇÃO". A ID de execução da nova execução da tarefa que foi reiniciada será uma concatenação do ID de execução inicial da tarefa mais o prefixo "restart_", representando a contagem de reinicializações. Por exemplo, se o ID de execução inicial da tarefa for `jr_1234`, a execução da tarefa reiniciada terá o ID `jr1234_restart_1` da primeira reinicialização. A segunda reinicialização será `jr1234_restart_2` para a segunda reinicialização, e assim por diante.

Sua nova tentativa não será afetada pelas reinicializações. Se uma execução falhar e uma nova execução for iniciada devido a uma nova tentativa automática, o contador de reinicialização começará novamente em 1. Por exemplo, se uma execução falhar em `jr_1234_attempt_3_restart_5`, uma nova tentativa automática iniciará uma nova execução com ID: `jr_id1_attempt_4`, e, quando essa tentativa for reiniciada após 7 dias, o novo ID de execução será `jr_id1_attempt_4_restart_1`.

Como tratar perda de dados

Durante a reinicialização da manutenção, o AWS Glue Streaming segue um processo que garante a integridade e a consistência dos dados entre a execução do trabalho anterior e do trabalho reiniciado. Observe que oAWS Glue não garante a integridade e a consistência dos dados entre as reinicializações dos trabalhos. Recomendamos considerar a arquitetura para lidar com dados duplicados nos trabalhos de streaming.

1. Detectar condições de reinicialização da manutenção: o AWS Glue Streaming monitora as condições que indicam quando uma reinicialização da manutenção deve ser acionada, como quando uma janela de manutenção é atingida após 7 dias ou uma reinicialização forçada é necessária após 14 dias.
2. Invocar um encerramento normal: quando as condições de reinicialização da manutenção são atendidas, o AWS Glue Streaming inicia um processo de encerramento normal para o trabalho em execução no momento. O processo inclui as seguintes etapas:
   a. Interromper a ingestão de novos dados: o trabalho de streaming para de consumir novos dados das fontes de entrada (por exemplo, tópicos do Kafka, streams do Kinesis ou arquivos).
   b. Processar dados pendentes: o trabalho continua processando todos os dados que já estão presentes em buffers ou filas internas.
   c. Confirmar compensações e pontos de verificação: o trabalho transfere as compensações ou pontos de verificação mais recentes para sistemas externos (por exemplo, Kafka, Kinesis ou Amazon S3) para garantir que o trabalho reiniciado possa continuar de onde o trabalho anterior parou.

3. Reiniciar o trabalho: após a conclusão do processo de encerramento normal, o AWS Glue Streaming reinicia o trabalho usando o estado preservado e os pontos de verificação. A tarefa reiniciada retoma o processamento do último offset ou ponto de verificação confirmado, garantindo que nenhum dado seja perdido ou duplicado.
4. Retomar o processamento de dados: o trabalho reiniciado retoma o processamento de dados a partir do ponto em que o trabalho anterior parou. Ele continua ingerindo novos dados das fontes de entrada, a partir do último offset ou ponto de verificação confirmado, e os processa de acordo com a lógica de ETL definida.

Conceitos avançados de streaming do AWS Glue

Em aplicações contemporâneas orientadas a dados, a importância dos dados diminui ao longo do tempo e o seu valor passa de preditivo a reativo. Como resultado, os clientes desejam processar dados em tempo real para tomar decisões mais rápidas. Ao lidar com feeds de dados em tempo real, como os provenientes de sensores de IoT, os dados podem ser apresentados de forma desordenada ou sofrer atrasos no processamento devido à latência da rede e outras falhas relacionadas à fonte durante a ingestão. Como parte da plataforma do AWS Glue, o AWS Glue Streaming aproveita essas funcionalidades para fornecer ETL de streaming escalável e com tecnologia sem servidor, com base no streaming estruturado do Apache Spark, capacitando os usuários com processamento de dados em tempo real.

Neste tópico, exploraremos as funcionalidades e os conceitos avançados de streaming do AWS Glue Streaming.

Considerações sobre o tempo ao processar fluxos

Existem quatro noções de tempo no momento do processamento de fluxos:

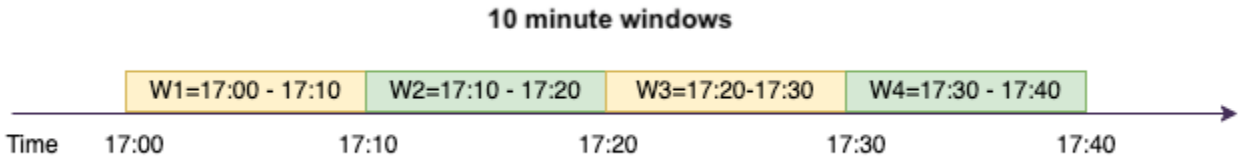

- Horário do evento: o horário em que o evento ocorreu. Na maioria dos casos, este campo está incorporado aos próprios dados do evento, na fonte.

- Janela de horário do evento: o intervalo entre dois horários de eventos. Conforme mostrado no diagrama acima, W1 é uma janela de horário do evento das 17h às 17h10. Cada janela de horário do evento corresponde a um agrupamento de vários eventos.
- Horário do acionamento: o horário do acionamento controla a frequência com que ocorre o processamento dos dados e a atualização dos resultados. Este é o horário em que o processamento do micro lote foi iniciado.
- Horário da ingestão: o horário em que os dados de fluxo foram ingeridos no serviço de streaming. Se o horário do evento não estiver incorporado no próprio evento, esse horário poderá ser usado para a geração de janelas em alguns casos.

Geração de janelas

A geração de janelas é uma técnica em que você agrupa e agrega vários eventos por janela de horário do evento. Exploraremos, nos exemplos a seguir, os benefícios da geração de janelas e quando você poderia usá-la.

Dependendo do caso de uso de negócio, existem três tipos de janelas de horários com suporte do Spark.

- Janela em cascata: uma série de janelas de horário do evento com tamanho fixo e não sobrepostas sobre as quais você realiza agregações.
- Janela deslizante: semelhante às janelas em cascata em relação a terem um “tamanho fixo”, mas as janelas podem se sobrepor ou deslizar desde que a duração do deslizamento seja menor que a duração da própria janela.
- Janela de sessão: começa com um evento de dados de entrada e continua a se expandir enquanto recebe entradas dentro de um intervalo ou período de inatividade. Uma janela de sessão pode ter um tamanho estático ou dinâmico da dimensão da janela, dependendo das entradas.

Janela em cascata

A janela em cascata corresponde a uma série de janelas de horário do evento com tamanho fixo e não sobrepostas sobre as quais você realiza agregações. Vamos entender isso com um exemplo real.

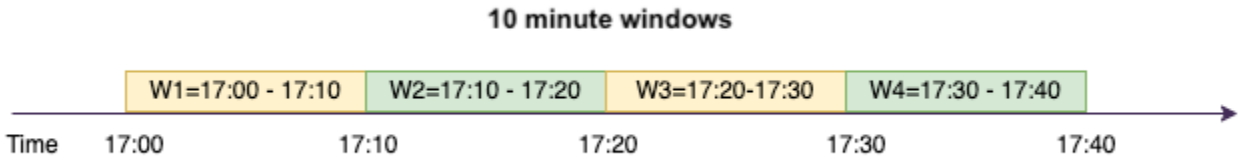

A empresa ABC Auto deseja realizar uma campanha de marketing para uma nova marca de carros esportivos. Eles desejam escolher uma cidade na qual haja um grande número de fãs de carros esportivos. Para atingir esse objetivo, a empresa mostra um pequeno anúncio de 15 segundos apresentando o carro em seu site. Todos os “cliques” e a “cidade” correspondente são registrados e transmitidos para o Amazon Kinesis Data Streams. Desejamos contabilizar o número de cliques em uma janela de dez minutos e agrupá-los por cidade para visualizar qual cidade tem a maior demanda. Veja a seguir a saída da agregação.

window_start_time	window_end_time	city	total_clicks
10-7-2023 17:00:00	10-7-2023 17:10:00	Dallas	75
10-7-2023 17:00:00	10-7-2023 17:10:00	Chicago	10
10-7-2023 17:20:00	10-7-2023 17:30:00	Dallas	20
10-7-2023 17:20:00	10-7-2023 17:30:00	Chicago	50

Conforme explicado acima, essas janelas de horário do evento são diferentes dos intervalos de horário do acionamento. Por exemplo, mesmo que o horário do acionamento seja a cada minuto, os resultados de saída mostrarão somente janelas de agregação não sobrepostas de dez minutos. Para obter otimização, é melhor ter o intervalo de acionamento alinhado com a janela de horário do evento.

Na tabela acima, Dallas realizou 75 cliques na janela das 17h às 17h10, enquanto Chicago realizou dez cliques. Além disso, não há dados para a janela das 17h10 às 17h20 para nenhuma cidade; portanto, essa janela é omitida.

Agora, é possível executar análise aprofundadas nesses dados na aplicação de analytics downstream para determinar a cidade mais exclusiva para executar a campanha de marketing.

Uso de janelas em cascata no AWS Glue

1. Crie um DataFrame do Amazon Kinesis Data Streams e faça a leitura nesse serviço. Exemplo:

```
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. Processe dados em uma janela em cascata. No exemplo abaixo, os dados são agrupados com base no campo de entrada “event_time” em janelas em cascata de dez minutos e a saída é gravada em um data lake do 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()
```

Janela deslizante

As janelas deslizantes são semelhantes às janelas em cascata em relação a terem um “tamanho fixo”, mas as janelas podem se sobrepor ou deslizar desde que a duração do deslizamento seja menor que a duração da própria janela. Devido à natureza do deslizamento, uma entrada pode ser vinculada a múltiplas janelas.

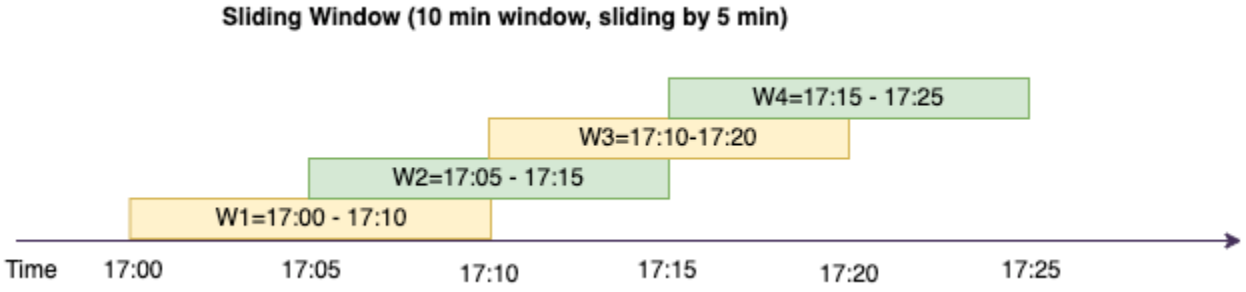

Para uma melhor compreensão, vamos considerar o exemplo de um banco que deseja detectar possíveis fraudes relacionadas a cartões de crédito. Uma aplicação de streaming poderia monitorar um fluxo contínuo de transações de cartões de crédito. Essas transações poderiam ser agregadas em janelas de dez minutos de duração e, a cada cinco minutos, a janela avançaria, eliminando os cinco minutos de dados mais antigos e adicionando os cinco minutos de novos dados mais recentes. Dentro de cada janela, as transações poderiam ser agrupadas por país, verificando padrões suspeitos, como uma transação nos Estados Unidos imediatamente seguida por outra na Austrália. Para simplificar, categorizaremos essas transações como fraude quando o valor total das transações for superior a USD 100. Se esse padrão for detectado, uma possível fraude será sinalizada e o cartão poderá ser congelado.

O sistema de processamento de cartões de crédito está enviando uma série de eventos de transação ao Kinesis para cada identificação de cartão em conjunto com o país. Um trabalho do AWS Glue executa a análise e produz a saída agregada apresentada a seguir.

window_start_time	window_end_time	card_last_four	country	total_amount
10-7-2023 17:00:00	10-7-2023 17:10:00	6544	EUA	85
10-7-2023 17:00:00	10-7-2023 17:10:00	6544	Austrália	10

window_start_time	window_end_time	card_last_four	country	total_amount
10-7-2023 17:05:45	10-7-2023 17:15:45	6544	EUA	50
10-7-2023 17:10:45	10-7-2023 17:20:45	6544	EUA	50
10-7-2023 17:10:45	10-7-2023 17:20:45	6544	Austrália	150

Com base na agregação acima, você pode visualizar a janela de dez minutos deslizando a cada cinco minutos, somada pelo valor da transação. A anomalia é detectada na janela das 17h10 às 17h20, na qual há um ponto fora da curva, que é uma transação de USD 150 na Austrália. O AWS Glue pode detectar essa anomalia e enviar um evento de alarme com a chave do infrator para um tópico do SNS usando o Boto3. Além disso, uma função do Lambda pode se inscrever nesse tópico e executar ações.

Processamento de dados em uma janela deslizante

A cláusula `group-by` e a função de janela são usadas para implementar a janela deslizante, conforme mostrado abaixo.

```
grouped_df = parsed_df \
            .groupBy(window(col("event_time"), "10 minute", "5 min"), "country",
 "card_last_four") \
            .agg(sum("tx_amount").alias("total_amount"))
```

Janela de sessão

Ao contrário das duas janelas apresentadas acima, que possuem tamanho fixo, a janela de sessão pode ter um tamanho estático ou dinâmico da dimensão da janela com base nas entradas. Uma janela de sessão começa com um evento de dados de entrada e continua a se expandir enquanto recebe entradas dentro de um intervalo ou período de inatividade.

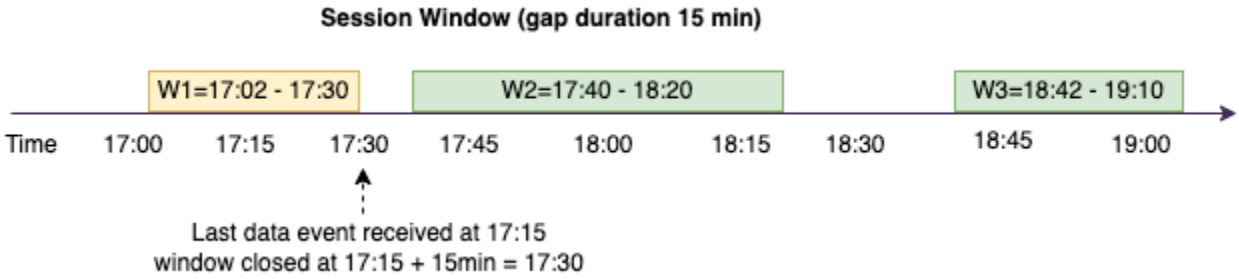

Vamos analisar um exemplo. A empresa ABC Hotel deseja descobrir qual é o horário de maior movimento em uma semana e apresentar melhores ofertas para seus hóspedes. Assim que um hóspede realiza o check-in, uma janela de sessão é iniciada e o Spark mantém um estado com agregação para essa janela de horário do evento. Cada vez que um hóspede realiza o check-in, um evento é gerado e enviado ao Amazon Kinesis Data Streams. O hotel decide que se não houver realização de check-in por um período de 15 minutos, a janela de horário do evento poderá ser fechada. A próxima janela de horário do evento começará novamente quando houver uma nova realização de check-in. A saída é semelhante à apresentada a seguir.

window_start_time	window_end_time	city	total_checkins
10-7-2023 17:02:00	10-7-2023 17:30:00	Dallas	50
10-7-2023 17:02:00	10-7-2023 17:30:00	Chicago	25
10-07-2023 17:40:00	10-7-2023 18:20:00	Dallas	75
10-7-2023 18:50:45	10-7-2023 19:15:45	Dallas	20

A primeira realização de check-in ocorreu em event_time=17h02. A janela de horário do evento de agregação começará às 17h02. Essa agregação continuará enquanto recebermos eventos com intervalos de até 15 minutos. No exemplo acima, o último evento que recebemos foi às 17h15 e, em seguida, nos 15 minutos seguintes não houve eventos. Como resultado, o Spark fechou a janela de horário do evento às 17h15 e acrescentou os 15 minutos, totalizando 17h30, e a definiu como 17h02 a 17h30. Ele iniciou uma nova janela de horário do evento às 17h47, quando recebeu um novo evento de dados de realização de check-in.

Processamento de dados em uma janela de sessão

A cláusula `group-by` e a função de janela são usadas para implementar a janela deslizante.

```
grouped_df = parsed_df \
            .groupBy(session_window(col("event_time"), "10 minute"), "city") \
            .agg(count("check_in").alias("total_checkins"))
```

Modos de saída

O modo de saída corresponde ao modo no qual os resultados da tabela ilimitada são gravados no coletor externo. Existem três modos disponíveis. No exemplo apresentado a seguir, você está contabilizando as ocorrências de uma palavra à medida que as linhas de dados são transmitidas e processadas em cada micro lote.

- Modo completo: toda a tabela de resultados será gravada no coletor após cada processamento de micro lote, mesmo que a contagem de palavras não tenha sido atualizada na janela de horário do evento atual.
- Modo de acréscimo: esse é o modo padrão, em que somente as novas palavras e as novas linhas adicionadas à tabela de resultados desde o último acionamento serão gravadas no coletor. Esse modo é bom para o streaming sem estado para consultas, por exemplo, as funções map, flatMap, filter etc.
- Modo de atualização: somente as palavras e as linhas na Tabela de Resultados que foram atualizadas ou adicionadas desde o último acionamento serão gravadas no coletor.

> **Note**
>
> O modo de saída = “atualização” não é compatível com as janelas de sessão.

Tratamento de dados atrasados e de marcas d’água

Ao trabalhar com dados em tempo real, pode haver atrasos na chegada dos dados devido à latência da rede e falhas upstream e precisamos de um mecanismo para realizar a agregação novamente na janela de horário do evento perdido. No entanto, para fazer isso, o estado precisa ser mantido. Ao mesmo tempo, os dados mais antigos precisam ser limpos para limitar o tamanho do estado. A versão 2.1 do Spark adicionou suporte para um recurso, chamado marca d’água, que mantém o estado e permite ao usuário especificar o limite para os dados atrasados.

Com referência ao nosso exemplo de cotações da bolsa acima, consideraremos o limite permitido para os dados atrasados como não superior a dez minutos. Para simplificar, assumiremos uma janela deslizante em que as cotações serão marcadas como AMZ e as negociações como BUY.

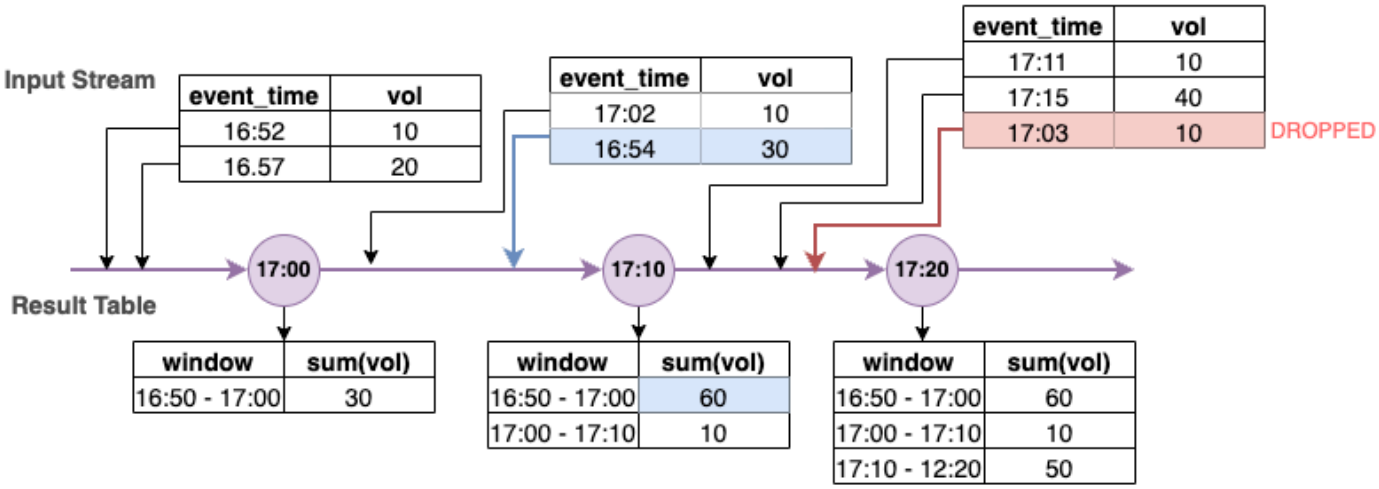

No diagrama acima, estamos calculando o volume total em uma janela deslizante de dez minutos. Temos o acionamento às 17h00, 17h10 e 17h20. Acima da seta da linha do tempo, temos o fluxo de dados de entrada e abaixo está a tabela ilimitada de resultados.

Na primeira janela deslizante de dez minutos, realizamos as agregações com base em event_time e o total_volume foi calculado como 30. Na segunda janela de horário do evento, o Spark obteve o primeiro evento de dados com event_time=17h02. Como esse é o event_time máximo obtido até o momento pelo Spark, o limite da marca d'água é definido 10 minutos atrás (ou seja, watermark_event_time=16h52). Qualquer evento de dados com um event_time após 16h52 será considerado para a agregação com limite de tempo e qualquer evento de dados anterior será descartado. Isso permite que o Spark mantenha um estado intermediário por mais dez minutos para acomodar dados atrasados. Por volta das 17h08, o Spark recebeu um evento com event_time=16h54, que estava dentro do limite. Como consequência, o Spark calculou novamente a janela de horário do evento de "16h50 a 17h00" e o volume total foi atualizado de 30 para 60.

No entanto, no horário de acionamento 17h20, quando o Spark recebeu o evento com event_time=17h15, ele definiu watermark_event_time=17h05. Como consequência, o evento de dados atrasado com event_time=17h03 foi considerado "tarde demais" e ignorado.

```
Watermark Boundary = Max(Event Time) - Watermark Threshold
```

Uso de marcas d'água no AWS Glue

O Spark só emitirá ou gravará os dados no coletor externo quando o limite da marca d'água for ultrapassado. Para implementar uma marca d'água no AWS Glue, consulte o exemplo abaixo.

```
grouped_df = parsed_df \
                .withWatermark("event_time", "10 minutes") \
                .groupBy(window("event_time", "5 minutes"), "ticker") \
                .agg(sum("volume").alias("total_volume"))
```

Sobre o monitoramento de trabalhos do AWS Glue Streaming

O monitoramento do trabalho de streaming corresponde a uma parte crítica do desenvolvimento do pipeline de ETL. Além de usar a interface de usuário do Spark, você também pode usar o Amazon CloudWatch para monitorar as métricas. Abaixo é apresentada uma lista de métricas de streaming emitidas pela estrutura do AWS Glue. Para obter uma lista completa de todas as métricas do AWS Glue, consulte Monitorar o AWS Glue usando métricas do Amazon CloudWatch.

O AWS Glue usa uma estrutura de streaming articulada para processar os eventos de entrada. É possível usar a API do Spark diretamente em seu código ou aproveitar o `ForEachBatch` fornecido por `GlueContext`, que publica essas métricas. Para compreender essas métricas, primeiro, é necessário compreender `windowSize`.

windowSize: `windowSize` corresponde ao intervalo de micro lote que você fornece. Se você especificar um tamanho da janela de 60 segundos, o trabalho de streaming do AWS Glue aguardará 60 segundos (ou mais, se o lote anterior ainda não tiver sido concluído) antes de ler os dados em um lote da fonte de streaming e aplicar as transformações fornecidas em `ForEachBatch`. Isso também é conhecido como intervalo de acionamento.

Analisaremos as métricas com mais detalhes para compreender as características de integridade e de performance.

> **Note**
>
> As métricas são emitidas a cada 30 segundos. Se o `windowSize` tiver menos de 30 segundos, as métricas relatadas corresponderão a uma agregação. Por exemplo, suponhamos que o `windowSize` tenha dez segundos e você esteja processando

20 registros por micro lote de forma contínua. Neste cenário, o valor da métrica emitida para numRecords seria 60.
Uma métrica não será emitida se não houver dados disponíveis para ela. Além disso, no caso de uma métrica de atraso do consumidor, é necessário habilitar o recurso para obter métricas para ela.

Visualizar métricas de streaming do AWS Glue

Para traçar métricas visuais:

1. Acesse Métricas no console do Amazon CloudWatch e, em seguida, escolha a guia Procurar. Em seguida, selecione Glue em "Namespaces personalizados".

2. Escolha Métricas de trabalho para que as métricas de todos os seus trabalhos sejam apresentadas.
3. Filtre as métricas com base em JobName=glue-feb-monitoring e, em seguida, em JobRunId=ALL. É possível clicar no sinal “+”, conforme mostrado na figura abaixo, para fazer adições ao filtro de pesquisa.
4. Selecione a caixa de seleção das métricas nas quais você tem interesse. Na figura abaixo, selecionamos `numberAllExecutors` e `numberMaxNeededExecutors`.

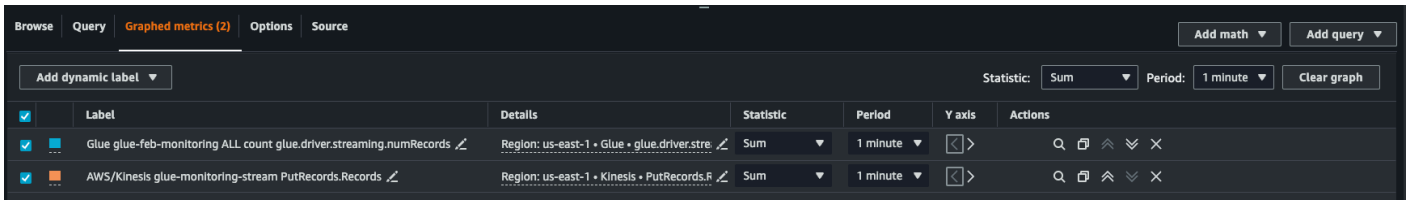

5. Depois de selecionar essas métricas, é possível acessar a guia Métricas em gráficos e aplicar suas estatísticas.
6. Como as métricas são emitidas a cada minuto, você pode aplicar a “média” ao longo de um minuto para `batchProcessingTimeInMs` e `maxConsumerLagInMs`. Para `numRecords`, é possível aplicar a “soma” ao longo de cada minuto.

7. Você pode adicionar uma anotação horizontal `windowSize` à sua representação em gráfico usando a guia Opções.

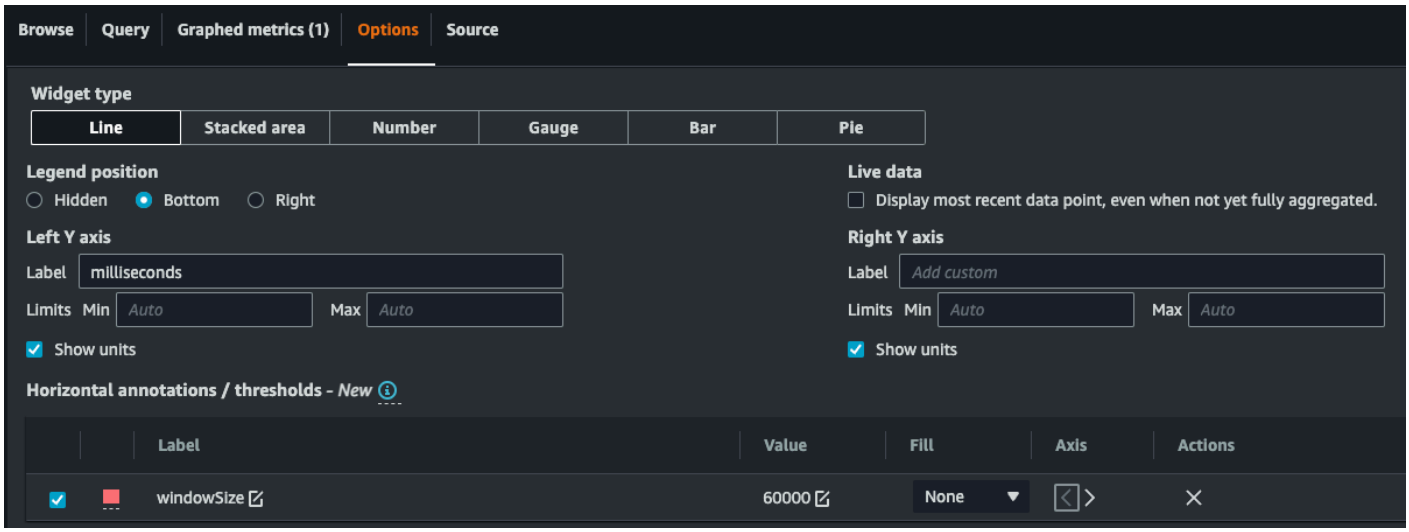

8. Depois de selecionar as métricas, crie um painel e realize as adições. Veja a seguir um painel de amostra.

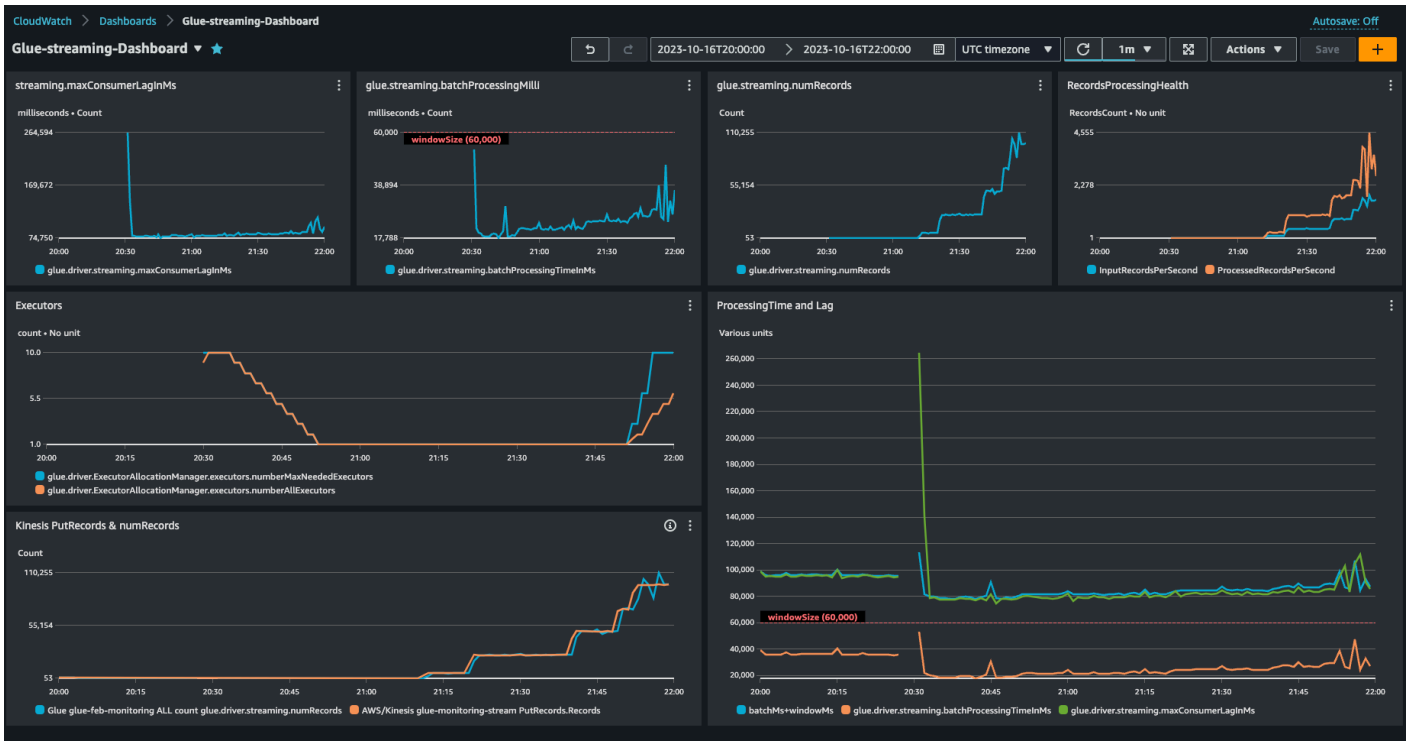

Usar métricas do AWS Glue Streaming

Essa seção descreve cada uma das métricas e como elas se correlacionam entre si.

Número de registros (métrica: streaming.numRecords)

Essa métrica indica quantos registros estão sendo processados.

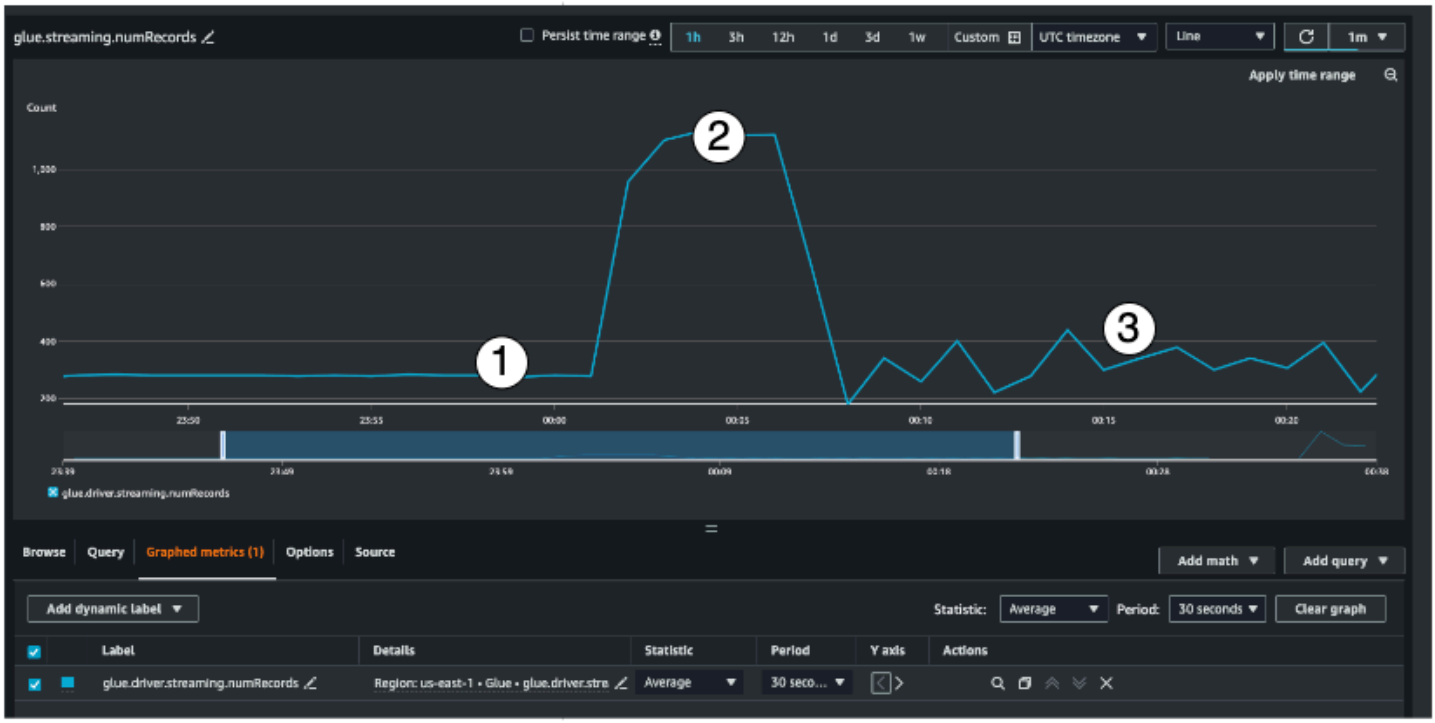

Essa métrica de streaming fornece visibilidade sobre o número de registros que você está processando em uma janela. Além do número de registros que estão sendo processados, ela ajudará você a compreender o comportamento do tráfego de entrada.

- O indicador n.º 1 mostra um exemplo de tráfego estável sem aumentos. Normalmente, serão aplicações, como sensores de IoT, que coletam dados em intervalos regulares e os enviam para a fonte de streaming.
- O indicador n.º 2 mostra um exemplo de um aumento repentino no tráfego em uma carga estável. Isso pode acontecer em uma aplicação de fluxo de cliques quando há um evento de marketing, como a Black Friday, e ocorre um aumento no número de cliques.
- O indicador n.º 3 mostra um exemplo de tráfego imprevisível. O tráfego imprevisível significa que há um problema. É somente a natureza dos dados de entrada. Ao retornarmos ao exemplo do sensor de IoT, é possível imaginar centenas de sensores que enviam eventos de mudanças climáticas para a fonte de streaming. Como a mudança climática não é previsível, os dados também não o são. A compreensão do padrão de tráfego é fundamental para dimensionar seus executores. Se a entrada tiver um amplo aumento, considere usar o ajuste de escala automático (falaremos mais sobre isso posteriormente).

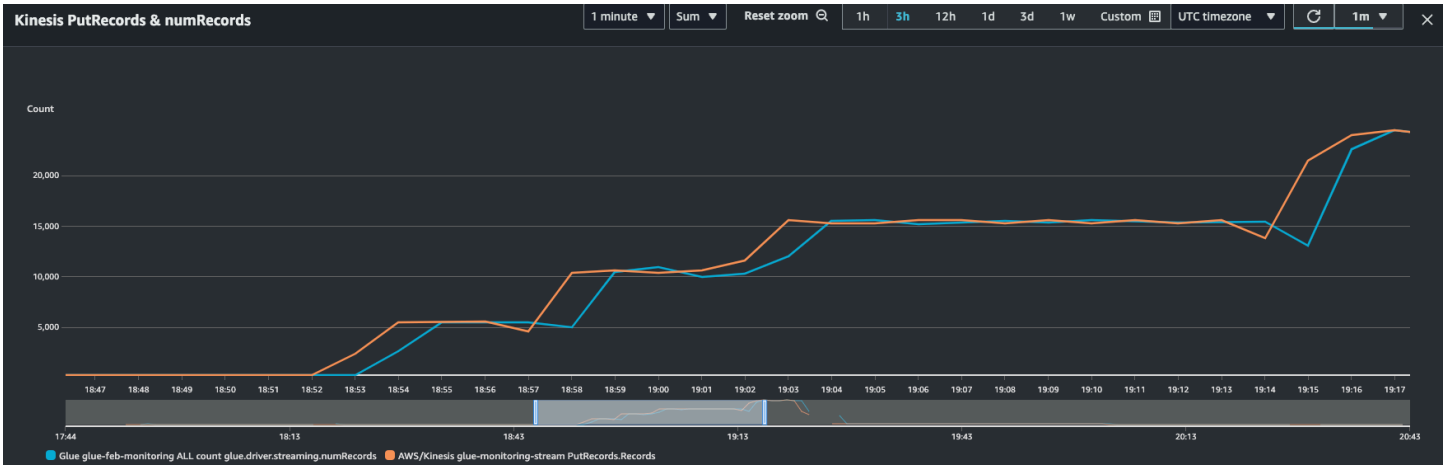

É possível combinar essa métrica com a métrica PutRecords do Kinesis para garantir que o número de eventos que estão sendo ingeridos e o número de registros que estão sendo lidos sejam praticamente semelhantes. Isso é especialmente útil quando você está tentando compreender o atraso. À medida que a taxa de ingestão aumenta, o mesmo acontece com os `numRecords` lidos pelo AWS Glue.

Tempo de processamento em lote (métrica: streaming.batchProcessingTimeInMs)

A métrica de tempo de processamento em lote ajuda a determinar se o cluster está com provisionamento insuficiente ou excessivo.

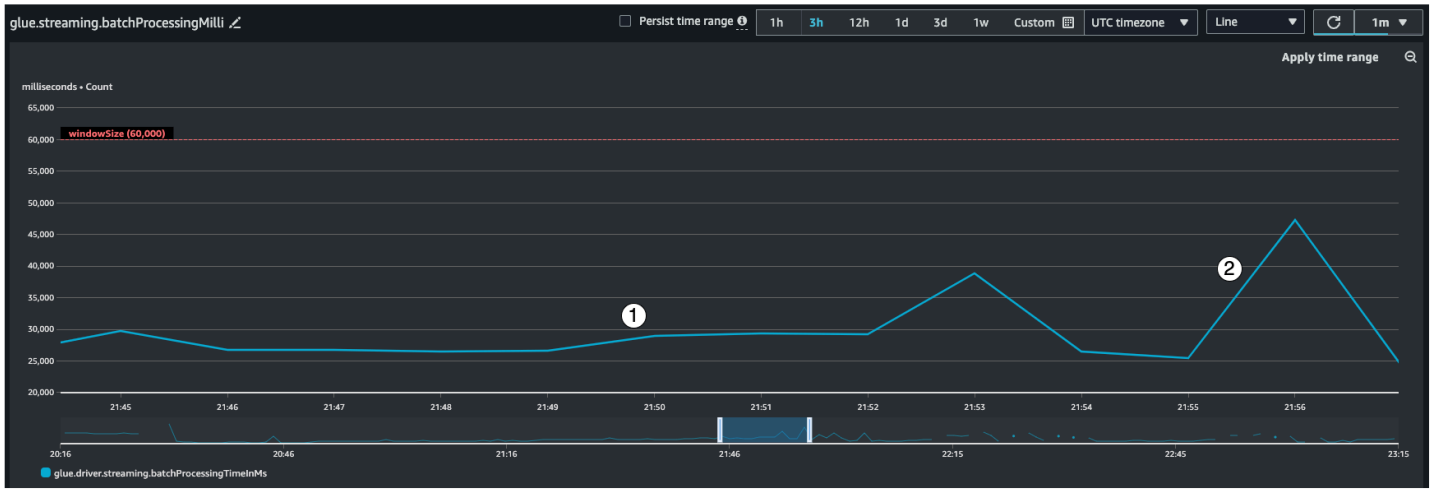

Essa métrica indica o número de milissegundos necessários para processar cada micro lote de registros. Aqui, o principal objetivo é monitorar esse tempo para garantir que seja menor que o intervalo de `windowSize`. Não há problema se `batchProcessingTimeInMs` for temporariamente desativado, desde que se recupere no intervalo de janela seguinte. O indicador n.º 1 mostra um tempo mais ou menos estável necessário para o processamento do trabalho. No entanto, se o

número de registros de entrada estiver aumentando, o tempo necessário para o processamento do trabalho aumentará, conforme mostrado pelo indicador n.º 2. Se o `numRecords` não estiver aumentando, mas o tempo de processamento estiver, você precisará examinar o processamento do trabalho nos executores de forma mais aprofundada. É uma boa prática definir um limite e um alarme para garantir que `batchProcessingTimeInMs` não ultrapasse 120% por mais de dez minutos. Para obter mais informações sobre como configurar alarmes, consulte Usar alarmes do Amazon CloudWatch.

Atraso do consumidor (métrica: streaming.maxConsumerLagInMs)

A métrica de atraso do consumidor ajuda a entender se há um atraso no processamento de eventos. Se o atraso for muito elevado, você poderá perder o SLA de processamento do qual sua empresa depende, mesmo que tenha um windowSize correto. Você deve habilitar explicitamente essas métricas usando a opção de conexão `emitConsumerLagMetrics`. Para obter mais informações, consulte KinesisStreamingSourceOptions.

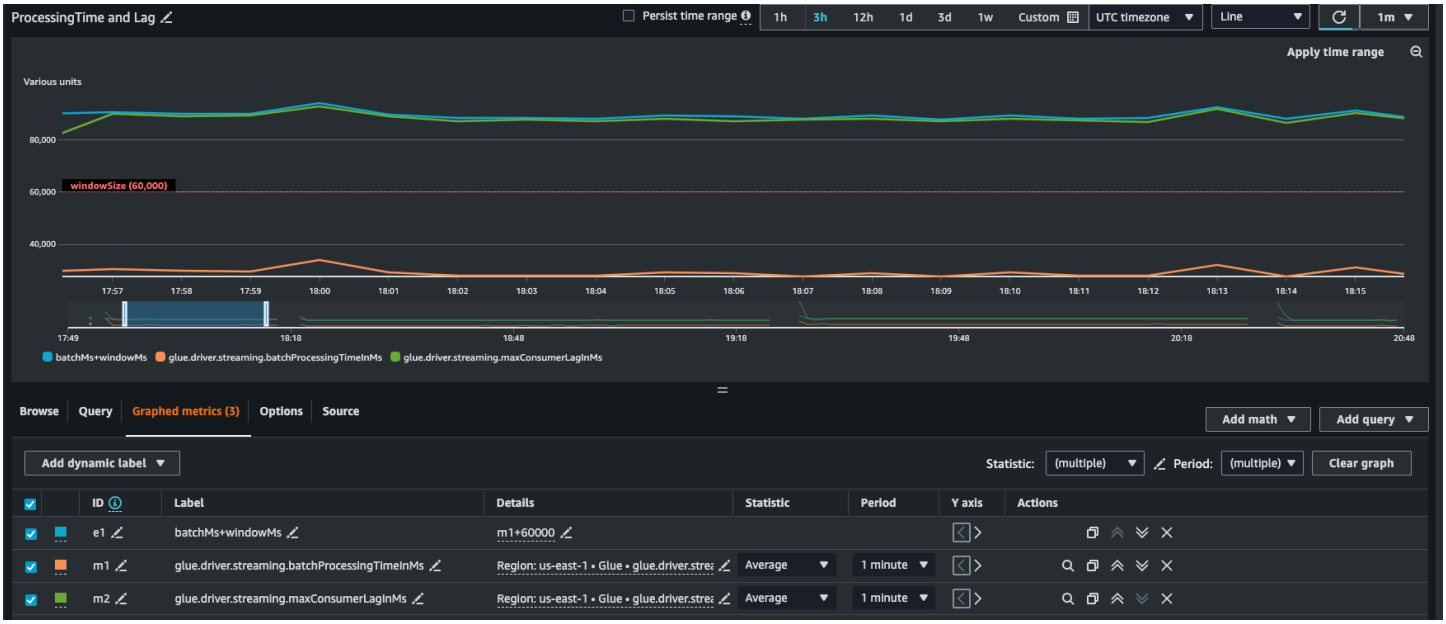

Métricas derivadas

Para obter insights mais aprofundados, é possível criar métricas derivadas para compreender mais sobre os trabalhos de streaming no Amazon CloudWatch.

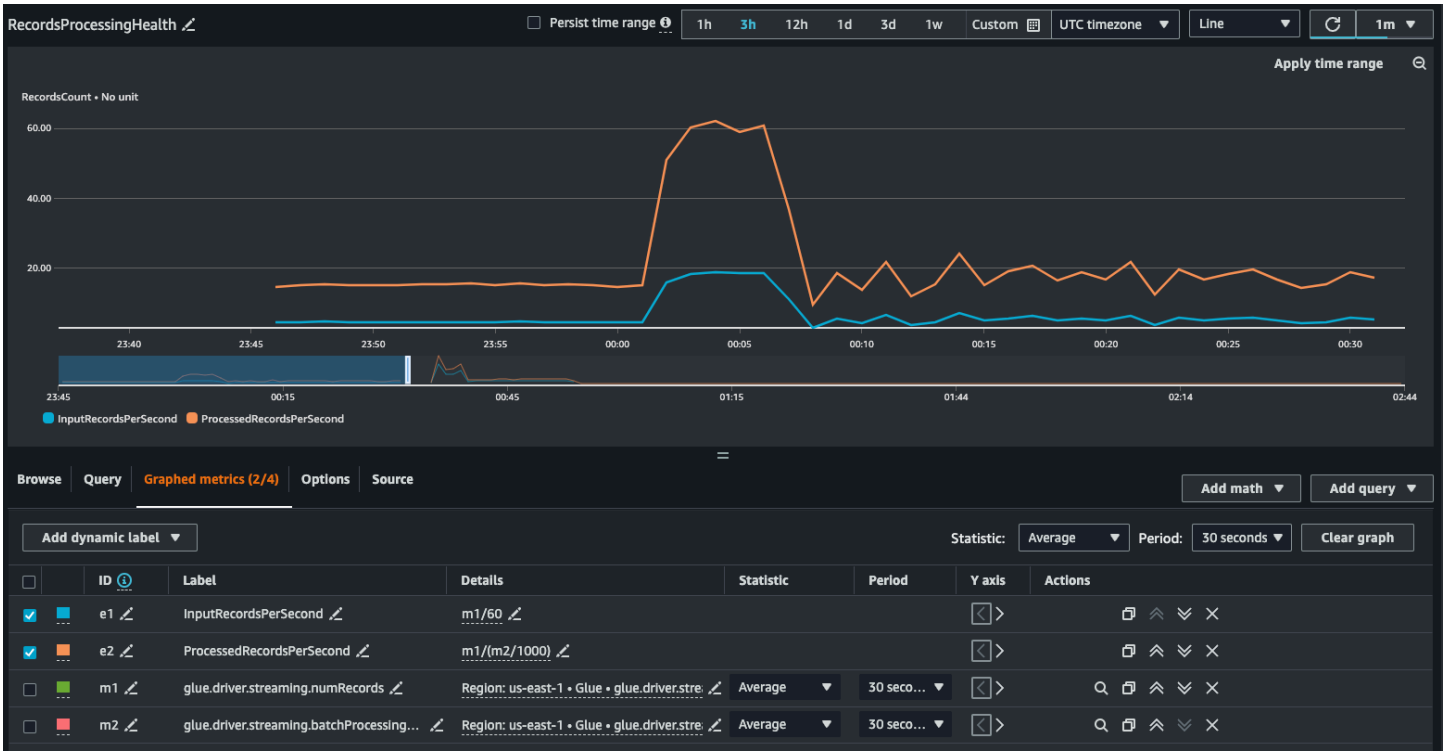

É possível desenvolver uma representação em gráfico com métricas derivadas para decidir se precisa usar mais DPUs. Embora o ajuste de escala automático ajude você a fazer isso automaticamente, é possível usar métricas derivadas para determinar se o ajuste de escala automático está funcionando de maneira eficaz.

- InputRecordsPerSecond indica a taxa na qual você está obtendo registros de entrada. A derivação ocorre da seguinte forma: número de registros de entrada (glue.driver.streaming.numRecords)/ WindowSize.
- ProcessingRecordsPerSecond indica a taxa na qual os registros estão sendo processados. A derivação ocorre da seguinte forma: número de registros de entrada (glue.driver.streaming.numRecords)/batchProcessingTimeInMs.

Se a taxa de entrada for superior à taxa de processamento, talvez seja necessário adicionar mais capacidade para processar os trabalhos ou aumentar o paralelismo.

Métricas do ajuste de escala automático

Quando o tráfego de entrada tiver um amplo aumento, considere habilitar o ajuste de escala automático e especificar o número máximo de trabalhadores. Com isso você obtém duas métricas adicionais, `numberAllExecutors` e `numberMaxNeededExecutors`.

- numberAllExecutors corresponde ao número de executores de trabalhos em execução ativa.
- numberMaxNeededExecutors corresponde ao número máximo de executores de trabalhos (em execução ativa e pendentes) necessários para satisfazer a carga atual.

Essas duas métricas ajudarão você a entender se o ajuste de escala automático está funcionando corretamente.

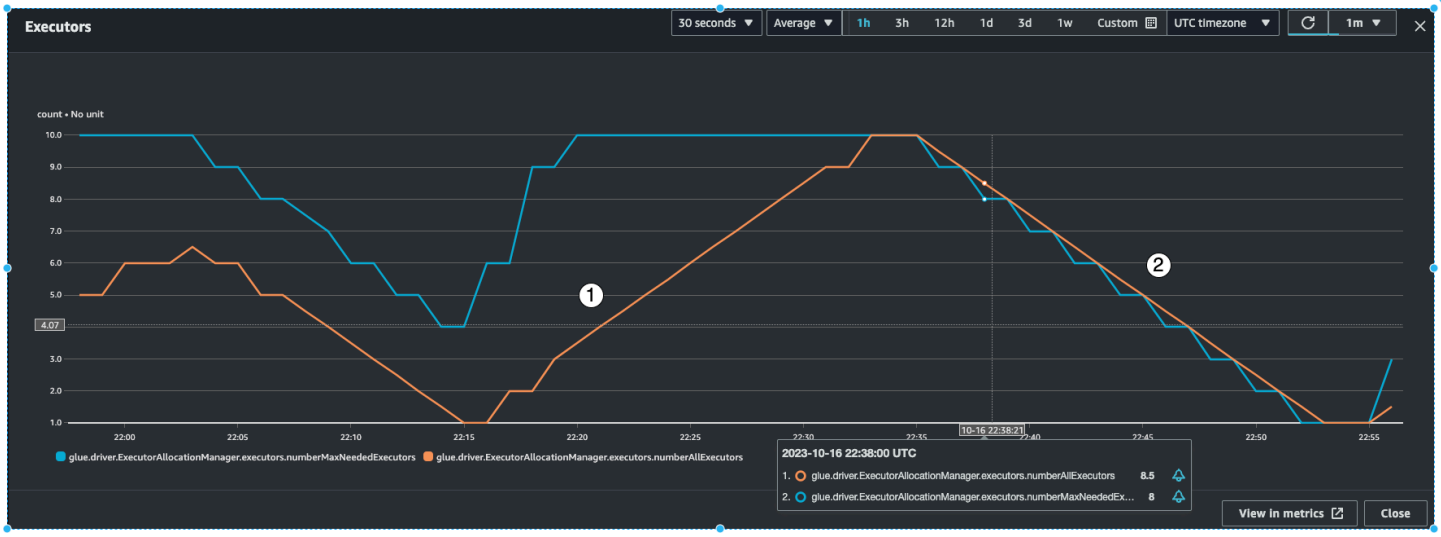

O AWS Glue monitorará a métrica `batchProcessingTimeInMs` em alguns micro lotes e fará uma entre duas coisas. Ele aumentará a escala horizontalmente dos executores, se `batchProcessingTimeInMs` estiver mais próximo de `windowSize`, ou reduzirá a escala horizontalmente dos executores, se `batchProcessingTimeInMs` for comparativamente menor que `windowSize`. Além disso, ele usará um algoritmo para escalar os executores em etapas.

- O indicador n.º 1 mostra como os executores ativos aumentaram a escala verticalmente para alcançar o número máximo de executores necessários para o processamento da carga.
- O indicador n.º 2 mostra como os executores ativos reduziram a escala horizontalmente desde que `batchProcessingTimeInMs` estava baixo.

É possível usar essas métricas para monitorar o paralelismo atual no nível do executor e ajustar, adequadamente, o número máximo de trabalhadores em sua configuração de ajuste de escala automático.

Como obter a melhor performance

O Spark tentará criar uma tarefa por fragmento para leitura no fluxo do Amazon Kinesis. Os dados em cada fragmento se tornam uma partição. Em seguida, ele distribuirá essas tarefas entre os executores e os trabalhadores, dependendo do número de núcleos em cada trabalhador (o número de núcleos por trabalhador depende do tipo de trabalhador que você selecionar, por exemplo, `G.025X`, `G.1X`, entre outros). No entanto, não é determinística a forma como as tarefas são distribuídas. Todas as tarefas são executadas em paralelo em seus respectivos núcleos. As tarefas serão enfileiradas se houver mais fragmentos do que o número de núcleos executores disponíveis.

É possível usar uma combinação das métricas acima e do número de fragmentos para provisionar os executores para uma carga estável com algum espaço para aumentos. É recomendável executar algumas iterações do seu trabalho para determinar o número aproximado de trabalhadores. Para uma workload instável ou com amplo aumento, é possível fazer o mesmo ao configurar o ajuste de escala automático e o número máximo de trabalhadores.

Defina o `windowSize` de acordo com os requisitos de SLA da sua empresa. Por exemplo, se sua empresa exigir que os dados processados não podem ficar obsoletos por mais de 120 segundos, defina `windowSize` para, no mínimo, 60 segundos, de modo que o atraso médio do consumidor seja inferior a 120 segundos (consulte a seção sobre atraso do consumidor acima). A partir desse ponto, dependendo dos `numRecords` e do número de fragmentos, planeje a capacidade em DPUs, certificando-se de que `batchProcessingTimeInMs` seja inferior a 70% do `windowSize` na maioria das vezes.

> **Note**
>
> Os fragmentos ativos podem causar distorção de dados, o que significa que alguns fragmentos e partições são muito maiores do que outros. Isso pode fazer com que algumas tarefas executadas em paralelo demorem mais, causando tarefas retardatárias. Como resultado, o próximo lote só poderá ser iniciado quando todas as tarefas do anterior forem concluídas. Isso afetará o `batchProcessingTimeInMillis` e o atraso máximo.

Integrações ETL zero

ETL zero é um conjunto de integrações totalmente gerenciadas pela AWS que minimiza a necessidade de criar pipelines de dados ETL para casos de uso comuns de ingestão e replicação. Ele disponibiliza dados no Amazon SageMaker Lakehouse e no Amazon Redshift de várias origens operacionais, transacionais e de aplicações. Com a integração ETL zero, você tem dados mais atualizados para análise, IA/ML e relatórios. Você recebe insights mais precisos e oportunos para casos de uso como painéis de negócios, experiência de jogo otimizada, monitoramento da qualidade de dados e análise do comportamento do cliente. É possível fazer previsões baseadas em dados com maior confiança, melhorar as experiências dos clientes e promover insights orientados por dados em toda a empresa.

O Amazon Redshift é um serviço de data warehouse rápido, totalmente gerenciado e em escala de petabytes que torna simples e econômica a análise eficiente de todos os seus dados usando as ferramentas de business intelligence existentes.

O Amazon SageMaker Lakehouse unifica todos os seus dados nos data lakes do Amazon Simple Storage Service (S3) e nos data warehouses do Amazon Redshift, ajudando você a criar aplicações poderosas de análise e IA/ML em uma única cópia dos dados. O SageMaker Lakehouse oferece a flexibilidade de acessar e consultar seus dados localmente com todas as ferramentas e mecanismos compatíveis com o Apache Iceberg. Com o SageMaker Lakehouse, você também tem a flexibilidade de acessar e consultar seus dados localmente com ferramentas e mecanismos compatíveis com o Apache Iceberg. Além disso, você pode proteger seus dados com controles de acesso integrados e refinados que são aplicados em todos os seus dados em todas as ferramentas e mecanismos analíticos. Defina as permissões uma vez e compartilhe dados com confiança em toda a organização.

Recursos de ETL zero no AWS Glue

As integrações ETL zero no AWS Glue simplificam a ingestão e a replicação de dados de serviços de dados da AWS e aplicações de terceiros para destinos na AWS.

Os serviços da AWS compatíveis com origens ETL zero no AWS Glue incluem:

- Amazon DynamoDB

As aplicações terceiros compatíveis com ETL zero incluem:

- Facebook Ads
- Instagram Ads
- Salesforce
- Configuração da conta do Salesforce Marketing Cloud
- SAP OData
- ServiceNow
- Zendesk
- Zoho CRM

Os serviços da AWS compatíveis com destinos ETL zero no AWS Glue incluem:

- Amazon Redshift
- Amazon SageMaker Lakehouse

> **Note**
>
> Ao criar uma integração ETL zero com uma origem Amazon DynamoDB no AWS Glue, o destino é compatível com o Amazon SageMaker Lakehouse.

Pré-requisitos para configurar uma integração ETL zero

Configurar uma integração entre a origem e o destino exige alguns pré-requisitos, como a configuração de perfis do IAM que o AWS Glue usa para acessar dados da origem e gravar no destino, e o uso de chaves do KMS para criptografar os dados no local intermediário ou de destino.

Tópicos

- Configurar recursos de origem
- Configurar recursos de destino
- Criar um data warehouse do Amazon Redshift
- Configurar uma VPC para sua integração ETL zero
- Configurar uma integração entre contas ETL zero

Configurar recursos de origem

Execute as seguintes tarefas de configuração conforme necessário para sua origem.

Configurar o perfil de origem

Esta seção descreve como passar um perfil de origem para permitir que a integração ETL zero acesse sua conexão. Isso também é aplicável somente para origens SaaS.

> **Note**
>
> Para restringir o acesso a apenas algumas conexões, primeiro você pode criar a conexão para obter o ARN da conexão. Consulte Configurar uma origem para uma integração ETL zero.

Crie um perfil que tenha permissões para que a integração acesse a conexão:

```
{
    "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": [
                "*"
            ]
        }
    ]
}
```

Política de confiança:

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

Configurar recursos de destino

Execute as tarefas de configuração a seguir conforme necessário para o destino de integração do data warehouse do Catálogo de Dados do AWS Glue ou do Amazon Redshift.

Para integrações com um destino de banco de dados do AWS Glue:

- Configurar um banco de dados do AWS Glue
- Fornecer uma política de acesso baseado em recursos (RBAC) do catálogo
- Criar um perfil do IAM de destino

Para integrações com um destino de data warehouse do Amazon Redshift:

- https://docs.aws.amazon.com/glue/latest/dg/zero-etl-prerequisites.html#zero-etl-setup-target-redshift-data-warehouse

Configurar um banco de dados do AWS Glue

Para integrações que usam um banco de dados do AWS Glue:

Para configurar um banco de dados de destino no Catálogo de Dados do AWS Glue com uma localização no Amazon S3:

1. Na página inicial do console do AWS Glue, selecione Banco de dados em Catálogo de Dados.
2. Escolha Adicionar dados no canto superior direito. Se você já criou um banco de dados, certifique-se de que o local com o URI do Amazon S3 esteja definido para o banco de dados.
3. Insira um nome e um Local (URI do Amazon S3). Observe que o local é necessário para a integração ETL zero. Clique em Criar banco de dados quando terminar.

> **Note**
>
> O bucket do Amazon S3 deve estar na mesma região que o banco de dados do AWS Glue.

Para obter informações sobre como criar um novo banco de dados no AWS Glue, consulte Introdução ao Catálogo de Dados do AWS Glue.

Você também pode usar a CLI `create-database` para criar o banco de dados no AWS Glue. Observe que o `LocationUri` em `--database-input` é obrigatório.

Otimizar tabelas Iceberg

Depois que uma tabela é criada pelo AWS Glue no banco de dados de destino, é possível habilitar a compactação para acelerar as consultas no Amazon Athena. Para obter informações sobre como configurar os recursos (perfil do IAM) para compactação, consulte Pré-requisitos da otimização de tabelas.

Para obter mais informações sobre como configurar a compactação na tabela do AWS Glue criada pela integração, consulte Otimizar tabelas do Iceberg.

Fornecer uma política de acesso baseado em recursos (RBAC) do catálogo

Para integrações que usam um banco de dados do AWS Glue, adicione as seguintes permissões à política RBAC do catálogo para permitir integrações entre a origem e o destino.

> **Note**
>
> Para integrações entre contas, tanto a política do perfil de Alice (usuária que está criando a integração) quanto a política de recursos do catálogo precisam permitir `glue:CreateInboundIntegration` no recurso. Para a mesma conta, uma política de recursos ou uma política de perfil que permita `glue:CreateInboundIntegration` no recurso é suficiente. Ambos os cenários ainda precisam permitir `glue.amazonaws.com` em `glue:AuthorizeInboundIntegration`.

Você pode acessar as Configurações do catálogo em Catálogo de Dados. Em seguida, forneça as permissões a seguir e preencha as informações que faltam.

```
{
  "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>"
        }
      }
    }
  ]
}
```

Criar um perfil do IAM de destino

Crie um perfil do IAM de destino com as permissões e relação de confiança a seguir.

```
{
    "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"
        }
    ]
```

```
}
```

Adicione seguinte a política de confiança para permitir que o serviço AWS Glue assuma o perfil:

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

Criar um data warehouse do Amazon Redshift

Quando sua meta de integração ETL zero for um data warehouse do Amazon Redshift, crie o data warehouse se você ainda não tiver um. Para criar um grupo de trabalho do Amazon Redshift sem servidor, consulte Criar um grupo de trabalho com um namespace. Para criar um cluster do Amazon Redshift, consulte Criar um cluster.

O grupo de trabalho ou cluster de destino do Amazon Redshift deve ter o parâmetro `enable_case_sensitive_identifier` ativado para que a integração seja bem-sucedida. Para obter mais informações sobre como habilitar a diferenciação de maiúsculas e minúsculas, consulte Ativar diferenciação de maiúsculas e minúsculas para seu data warehouse no guia de gerenciamento do Amazon Redshift.

Depois que a configuração do grupo de trabalho ou cluster do Amazon Redshift estiver concluída, você precisará configurar o data warehouse. Consulte Conceitos básicos das integrações ETL zero no Guia de gerenciamento do Amazon Redshift para obter mais informações.

Configurar uma VPC para sua integração ETL zero

Para configurar uma VPC para sua integração ETL zero:

1. Vá para VPC > Suas VPCs e escolha Criar VPC.
   a. Selecione VPC e mais.

b. Defina o nome da VPC.

c. Configure o CIDR IPv4: 10.0.0.0/16.

d. Defina o número de AZ como 1.

e. Defina o número de sub-redes públicas e privadas como 1.

f. Defina Gateways NAT como Nenhum.

g. Defina Endpoints da VPC como Gateway do S3.

h. Habilitar os nomes de host DNS e a resolução de DNS.

2. Vá para Endpoints e escolha Criar endpoint.
3. Crie endpoints para esses serviços na sub-rede privada da sua VPC (use o grupo de segurança padrão):

   a. com.amazonaws.us-east-1.lambda

   b. com.amazonaws.us-east-1.glue

   c. com.amazonaws.us-east-1.sts

Crie a conexão do AWS Glue:

1. Vá até AWS Glue > Conexões de dados e escolha Criar conexão.
2. Selecione Rede.
3. Selecione a VPC, a sub-rede (privada) e o grupo de segurança padrão que você criou.

Configurar o perfil de destino para a VPC

O perfil de destino deve ter essas permissões (além das outras permissões exigidas pelas integrações ETL zero):

```
{
    "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": [
                "*"
            ]
        }
    ]
}
```

Configurar as propriedades do recurso da perna de destino

Se estiver usando a CLI, defina as propriedades do recurso da perna de destino para o banco de dados do AWS Glue de destino que você criou. Passe o ARN do perfil de destino, bem como o nome da conexão do AWS Glue.

```
aws glue create-integration-resource-property \
--resource-arn arn:aws:glue:us-east-1:<account-id>:database/exampletarget \
--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
```

Possíveis erros de clientes

A seguir estão os possíveis erros do cliente para uma integração configurada com uma VPC.

Mensagem de erro	Ação necessária
O perfil fornecido não está autorizado a executar glue:GetConnection na conexão. Adicione essa permissão à política do perfil e aguarde a recuperação da integração.	Atualizar política de perfil
O perfil fornecido não está autorizado a executar ec2:DescribeSubnets. Adicione essa	Atualizar política de perfil

Mensagem de erro	Ação necessária
permissão à política do perfil e aguarde a recuperação da integração.	
O perfil fornecido não está autorizado a executar ec2:DescribeSecurityGroups. Adicione essa permissão à política do perfil e aguarde a recuperação da integração.	Atualizar política de perfil
O perfil fornecido não está autorizado a executar ec2:DescribeVpcEndpoints. Adicione essa permissão à política do perfil e aguarde a recuperação da integração.	Atualizar política de perfil
O perfil fornecido não está autorizado a executar ec2:DescribeRouteTables. Adicione essa permissão à política do perfil e aguarde a recuperação da integração.	Atualizar política de perfil
O perfil fornecido não está autorizado a executar ec2:CreateTags. Adicione essa permissão à política do perfil e aguarde a recuperação da integração.	Atualizar política de perfil
O perfil fornecido não está autorizado a executar ec2:CreateNetworkInterface. Adicione essa permissão à política do perfil e aguarde a recuperação da integração.	Atualizar política de perfil
A sub-rede de conexão fornecida não contém um endpoint do S3 nem um gateway NAT gateway válido. Atualize a sub-rede e aguarde a recuperação da integração.	Atualizar endpoints da sub-rede da VPC
Sub-rede de conexão não encontrada. Atualize a sub-rede de conexão e aguarde a recuperaç ão da integração.	Atualize a conexão do AWS Glue

Mensagem de erro	Ação necessária
Grupo de segurança da conexão não encontrado. Atualize o grupo de rede da conexão e aguarde a recuperação da integraçã o.	Atualize a conexão do AWS Glue
Não é possível conectar ao S3 via conexão de VPC fornecida. Atualize as configurações da sub-rede e aguarde a recuperação da integraçã o.	Atualizar endpoints da sub-rede da VPC
Não é possível conectar ao Lambda via conexão de VPC fornecida. Atualize as configurações da sub-rede e aguarde a recuperação da integração.	Atualizar endpoints da sub-rede da VPC

Configurar uma integração entre contas ETL zero

Para configurar uma integração entre contas ETL zero:

1. Configure uma política de recursos de destino conforme descrito em Fornecer uma política de acesso baseado em recursos (RBAC) do catálogo. Certifique-se de que o perfil da conta de origem seja explicitamente permitido no recurso de destino.
2. Verifique se o perfil da conta de origem (a função usada para criar a integração) tem o seguinte:

```
{
    "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. Crie a integração conforme descrito em Criar uma integração.

Configurar uma origem para uma integração ETL zero

Suporte para entidades SAP especiais

Para a maioria das entidades SaaS, determinamos os conjuntos de chaves primárias válidos durante o processamento de dados. No entanto, há alguns que exigem uma etapa extra de fornecer o conjunto válido de chaves primárias como entrada, especificamente entidades SAP que começam com `EntityOf`. Quando uma entidade `EntityOf` for selecionada, você será direcionado para fornecer o conjunto de chaves primárias.

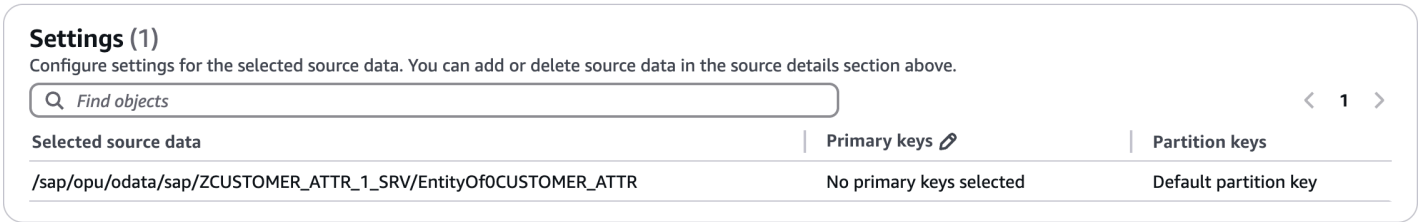

Configurar uma origem do Amazon DynamoDB

Para acessar dados de sua tabela de origem do Amazon DynamoDB, o AWS Glue necessita de acesso para descrever a tabela e exportar dados dela. O Amazon DynamoDB introduziu recentemente um recurso que permite configurar uma política de acesso baseado em recursos (RBAC).

O exemplo a seguir de política de acesso baseado em recursos (RBAC) usa um curinga (*) para integração:

```
{
    "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. Para o DynamoDB que você deseja replicar, cole o modelo de política RBAC acima em Política baseada em recursos para tabela e preencha os campos.
2. Se você quiser tornar a política restritiva, atualize a política depois de criar a integração e especificar o `integrationArn` completo e usar a condição `StringEquals` em vez de `StringLike`.
3. Certifique-se de que a recuperação para um ponto no tempo (PITR) esteja habilitada para a tabela do DynamoDB.
4. Certifique-se de adicionar `Describe Export` à política de acesso baseado em recursos (RBAC).

Você também pode adicionar a política RBAC à tabela usando o seguinte comando:

```
aws dynamodb put-resource-policy \
--resource-arn arn:aws:dynamodb:<region>:<account-id>:table/<ddb-table-name> \
--policy file://resource-policy-with-condition.json \
--region <region>
```

Para verificar se a política foi aplicada corretamente, use o seguinte comando para obter a política de recursos para uma tabela:

```
aws dynamodb get-resource-policy \
--resource-arn arn:aws:dynamodb:<region>:<account-id>:table/<ddb-table-name>
```

```
--region <region>
```

Configurando uma origem do Salesforce

Para criar uma conexão para uma origem no Salesforce, consulte Conectar ao Salesforce.

Após criar a conexão, você poderá especificar os dados de origem para replicar.

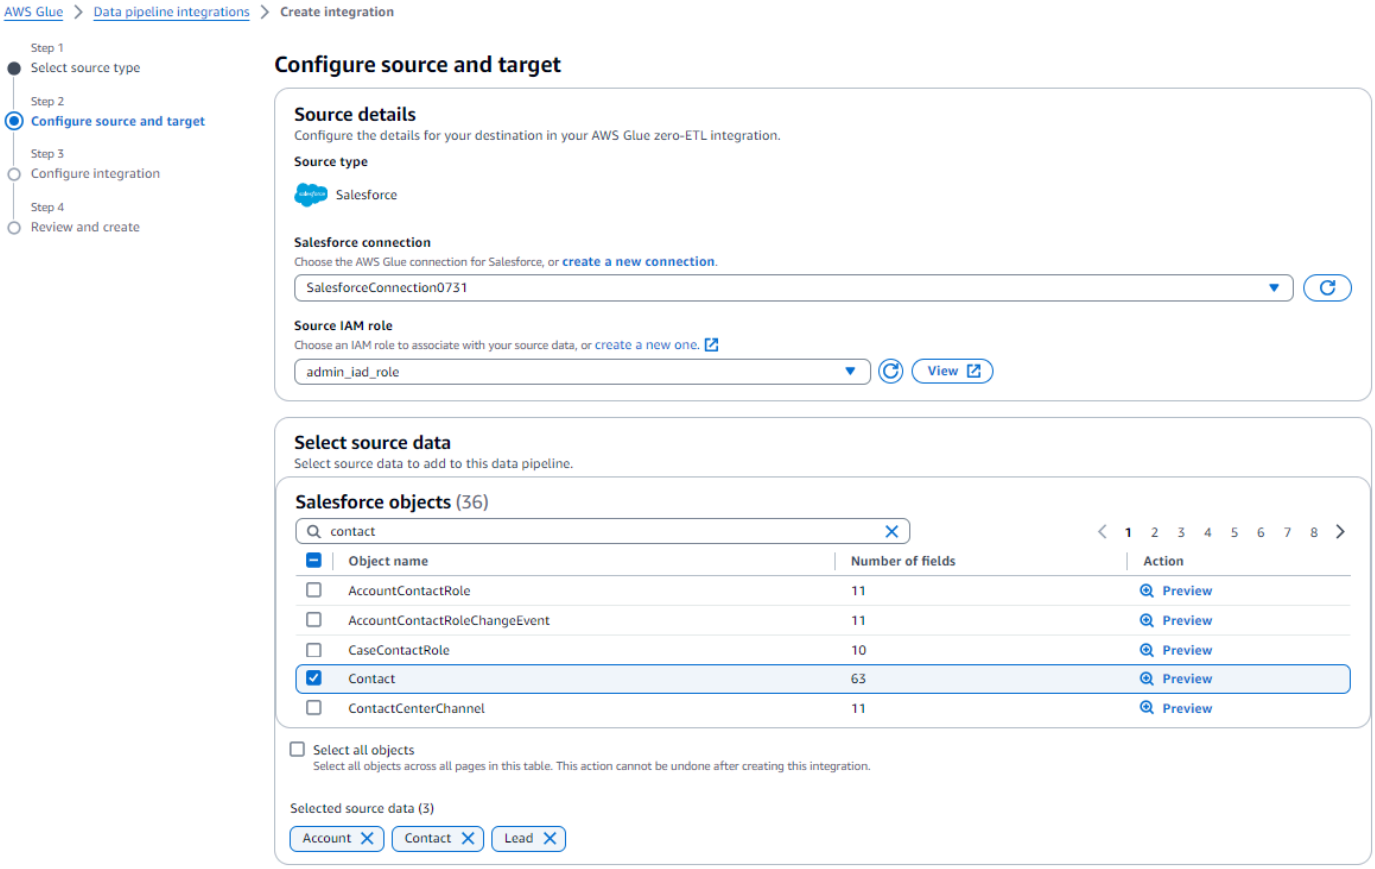

Usando sua integração ETL zero, é possível realizar operações de DDL para entidades compatíveis. Para obter uma lista de entidades sem suporte, consulte Entidades e campos sem suporte no Salesforce.

Configurar uma origem de engajamento de conta do Salesforce Marketing Cloud

Para criar uma conexão para uma origem de engajamento de conta do Salesforce Marketing Cloud, consulte Conexão com o Salesforce Marketing Cloud Account Engagement .

Usando sua integração ETL zero, é possível realizar operações de DDL para as seguintes entidades compatíveis:

Rótulo da entidade	Nome da entidade
Campaign	campaign
Lista	list
Dynamic Content	dynamic-content
Listar associação	list-membership
Cliente potencial	prospect
Usuário	usuário
EmailTemplate	email-template
EngagementStudioProgram	engagement-studio-program
Página de destino	landing-page
Listar e-mail	list-email

Configuração adicional do Salesforce

O ETL zero do Salesforce precisa de permissão do Lake Formation no banco de dados do Glue, caso contrário, obterá `IngestionFailed` do log com o seguinte erro:

```
"errorMessage": "Insufficient lake formation permissions on Target Glue database."
```

Configurar uma origem SAP OData

Para criar uma conexão para uma origem SAP OData, consulte Conexão com o SAP OData .

O conector SAP OData em uma integração ETL zero não oferece suporte a entidades começando com `EntityOf`.

Configurar uma origem ServiceNow

Para criar uma conexão para uma origem ServiceNow, consulte Conectando-se a ServiceNow .

Configurar uma origem Zendesk

Para criar uma conexão para uma origem Zendesk, consulte Conectando-se ao Zendesk .

Usando sua integração ETL zero, é possível realizar as seguintes operações de DDL para as entidades compatíveis:

Rótulo da entidade	Nome da entidade	Suporte a Create	Suporte a Update	Suporte a Delete
Tíquetes	tíquetes	S	S	S
Usuário	usuários	S	S	S
Classificação de satisfação	satisfaction-rating	S	S	N
Artigos	artigos	S	S	N
Organização	organizações	S	S	S
Calls	chamadas	S	S	N
Pernas da chamada	pernas	S	S	N

Configurar uma origem Zoho CRM

Para criar uma conexão para uma origem Zoho CRM, consulte Conexão com o Zoho CRM .

Usando sua integração ETL zero, é possível realizar as seguintes operações de DDL para as entidades compatíveis:

Rótulo da entidade	Nome da entidade	Suporte a DML-Insert	Suporte a DML-Modify	Suporte a DML-Delete	Suporte a DDL-Insert	Suporte a DDL-Modify	Suporte a DDL-Delete
Leads	lead	S	S	S	S	S	S

Rótulo da entidade	Nome da entidade	Suporte a DML-Insert	Suporte a DML-Modify	Suporte a DML-Delete	Suporte a DDL-Insert	Suporte a DDL-Modify	Suporte a DDL-Delete
Contas	conta	S	S	S	S	S	S
Contatos	contact	S	S	S	S	S	S
Campanhas	campaign	S	S	S	S	S	S
Tarefas	task	S	S	S	S	S	S
Eventos	event	S	S	S	S	S	S
Calls	call	S	S	S	S	S	S
Soluções	solução	S	S	S	S	S	S
Produtos	product	S	S	S	S	S	S
Fornecedores	fornecedor	S	S	S	S	S	S
Cotações	cotação	S	S	S	S	S	S
Ordens de venda	sales-order	S	S	S	S	S	S
Ordens de compra	purchase-order	S	S	S	S	S	S
Faturas	fatura	S	S	S	S	S	S
Casos	case	S	S	S	S	S	S
Catálogos de preços	price-book	S	S	S	S	S	S

Configurar uma origem Facebook Ads

Para criar uma conexão para uma origem Facebook Ads, consulte Conexão com o Facebook Ads .

Usando sua integração ETL zero, é possível realizar as seguintes operações de DDL para as entidades compatíveis:

Rótulo da entidade	Nome da entidade	Suporte a Create	Suporte a Update	Suporte a Delete
Adset	*/adsets	S	S	S
Campaign	*/campaigns	S	S	S
Ads	*/ads	S	S	S

Configurando uma origem Instagram Ads

Para criar uma conexão para uma origem Instagram Ads, consulte Conexão com o Instagram Ads .

Usando sua integração ETL zero, é possível realizar as seguintes operações de DDL para as entidades compatíveis:

Nome da entidade	Suporte a Create	Suporte a Update	Suporte a Delete
*/adsets	S	S	S
*/campaigns	S	S	S
*/ads	S	S	S

Entidades e campos sem suporte no Salesforce

Não há suporte aos campos ou entidades do Salesforce a seguir para uso em uma integração ETL zero com uma origem 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,
QueueSobject, 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
```

Entidades e campos não compatíveis com o ServiceNow

As entidades ou campos do ServiceNow, apresentados a seguir, não são compatíveis com uma Integração ETL zero com uma fonte do ServiceNow.

```
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_mapplication, 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,
sysevent_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
```

Configurar um destino de integração ETL zero

Há várias opções oferecidas pela AWS para configurar um destino para uma integração ETL zero. O destino pode ser um data warehouse criptografado do Amazon Redshift ou um catálogo do Amazon SageMaker Lakehouse.

Antes de selecionar o destino para a integração ETL zero, você precisa configurar um dos seguintes recursos de destino.

As opções de configuração para um destino em uma integração ETL zero incluem:

- Um catálogo e banco de dados do Amazon SageMaker Lakehouse configurados com armazenamento normal do Amazon S3. Consulte Configurar um catálogo do Amazon SageMaker Lakehouse com armazenamento normal do S3.
- Um catálogo do Amazon SageMaker Lakehouse configurado com um bucket das Tabelas do Amazon S3. Consulte Configurar Tabelas do Amazon S3 como um destino.
- Um catálogo do Amazon SageMaker Lakehouse configurado com armazenamento gerenciado do Amazon Redshift. Consulte Configurar um catálogo do Amazon SageMaker Lakehouse com armazenamento gerenciado do Amazon Redshift.
- Um data warehouse do Amazon Redshift identificado por um namespace do Redshift. Consulte Configurar um destino de data warehouse do Amazon Redshift.

> **Note**
>
> Não é possível modificar o destino de uma integração ETL zero após a criação.

Configurar um catálogo do Amazon SageMaker Lakehouse com armazenamento normal do S3

Esta seção descreve os pré-requisitos e as etapas de configuração para configurar um bucket normal do Amazon S3 como armazenamento para seu destino de catálogo do Amazon SageMaker Lakehouse em uma integração ETL zero.

Pré-requisitos para configurar uma integração

Antes de criar uma integração ETL zero com um catálogo do Amazon SageMaker Lakehouse usando o armazenamento normal do S3, você precisa concluir as seguintes tarefas de configuração:

1. Configurar um banco de dados do AWS Glue
2. Fornecer uma política RBAC do Catálogo
3. Criar um perfil do IAM de destino

Depois de configurar o catálogo do Amazon SageMaker Lakehouse com armazenamento normal do Amazon S3, você pode prosseguir com Configurar a integração com seu destino para conclusão da configuração da integração.

Configurar Tabelas do Amazon S3 como um destino

Esta seção descreve os pré-requisitos e as etapas de configuração para configurar as Tabelas do Amazon S3 como um destino para sua integração ETL zero.

Pré-requisitos para configurar uma integração

Antes de criar uma integração ETL zero com as Tabelas do Amazon S3 como destino, você precisa concluir as seguintes tarefas de configuração:

1. Configurar o bucket das Tabelas do Amazon S3
2. Fornecer uma política RBAC do Catálogo
3. Criar um perfil do IAM de destino

Configurar o bucket de Tabelas do Amazon S3

1. Crie um bucket de tabelas do S3 em sua conta seguindo as instruções em Introdução às Tabelas do Amazon S3.
2. Habilite as integrações do Analytics com seu bucket das Tabelas do S3 seguindo estas instruções: Integração de serviços da AWS com as Tabelas do Amazon S3.

Fornecer uma política RBAC do Catálogo

As seguintes permissões devem ser adicionadas à política RBAC do Catálogo para permitir integrações entre o destino do catálogo de origem e das Tabelas do Amazon S3.

A política de recursos do destino do Catálogo do AWS Glue precisa incluir permissões do Glue Service para AuthorizeInboundIntegration. Além disso, a permissão CreateInboundIntegration é necessária na fonte principal que cria a integração ou no destino da política de recursos do AWS Glue.

> **Note**
>
> Para um cenário de várias contas, tanto a política de recursos do catálogo da entidade principal de origem quanto a do AWS Glue de destino precisam incluir as permissões glue:CreateInboundIntegration no recurso.

```
{
  "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**
>
> Substitua `<s3tablescatalog>` pelo nome do catálogo de suas tabelas do S3.

Criar um perfil do IAM de destino

Crie um perfil do IAM de destino com as permissões e relação de confiança a seguir.

Exemplo de política do 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"
        }
    ]
}
```

Adicione a seguinte política de confiança no perfil do IAM de destino para permitir que o serviço do AWS Glue assuma:

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

> **Note**
>
> Certifique-se de que não haja uma declaração DENY explícita para esse perfil do IAM de destino na política de recursos do bucket das Tabelas do S3. Uma declaração DENY explícita substituiria todas as permissões ALLOW e impediria que a integração funcionasse corretamente.

Configurar um catálogo do Amazon SageMaker Lakehouse com armazenamento gerenciado do Amazon Redshift

Esta seção descreve os pré-requisitos e as etapas de configuração para configurar um catálogo do Amazon SageMaker Lakehouse com armazenamento gerenciado (RMS) do Amazon Redshift como destino para sua integração ETL zero.

Pré-requisitos para configurar uma integração

Antes de criar uma integração ETL zero com um catálogo do Amazon SageMaker Lakehouse usando o armazenamento normal do Redshift, você precisa concluir as seguintes tarefas de configuração:

1. Configurar um cluster do Amazon Redshift ou grupo de trabalho do Serverless
2. Registrar a integração do Amazon Redshift com o Lake Formation
3. Criar um catálogo gerenciado no Lake Formation
4. Configurar permissões do IAM

Configurar o armazenamento gerenciado do Amazon Redshift

Para configurar um armazenamento gerenciado do Amazon Redshift para sua integração ETL zero:

1. Crie ou use um cluster do Amazon Redshift ou grupo de trabalho do Serverless existente. Confirme se o grupo de trabalho ou cluster de destino do Amazon Redshift tem o parâmetro `enable_case_sensitive_identifier` ativado para que a integração tenha êxito. Para obter mais informações sobre como habilitar a diferenciação de maiúsculas e minúsculas, consulte Ativar diferenciação de maiúsculas e minúsculas para seu data warehouse no guia de gerenciamento do Amazon Redshift.
2. Registre uma integração do Redshift no catálogo no AWS Lake Formation. Consulte Registrar clusters e namespaces do Amazon Redshift no Catálogo de dados do AWS Glue.

3. Crie um catálogo federado ou gerenciado no AWS Lake Formation. Para obter mais informações, consulte:
   - Trazer dados do Amazon Redshift para o catálogo de dados do AWS Glue
   - Criar um catálogo gerenciado do Amazon Redshift no catálogo de dados do AWS Glue
4. Configurar permissões do IAM para o perfil de destino. O perfil precisa de permissões para acessar os recursos do Redshift e do Lake Formation. No mínimo, o perfil deve ter:
   - Permissões para acessar o cluster ou grupo de trabalho do Redshift
   - Permissões para acessar o catálogo do Lake Formation
   - Permissões para criar e gerenciar tabelas no catálogo
   - Permissões do CloudWatch e do CloudWatch Logs para monitoramento

Depois de configurar o catálogo do Amazon SageMaker Lakehouse com o armazenamento gerenciado do Amazon Redshift, você pode prosseguir para Configurar a integração com seu destino para concluir a configuração da integração.

Configurar um destino de data warehouse do Amazon Redshift

Esta seção descreve os pré-requisitos e as etapas de configuração para configurar o data warehouse do Amazon Redshift como um destino para sua integração ETL zero.

Pré-requisitos para configurar uma integração

Antes de criar uma integração ETL zero com um destino de data warehouse do Amazon Redshift, você precisa concluir as seguintes tarefas de configuração:

1. Configurar um cluster do Amazon Redshift ou grupo de trabalho do Serverless
2. Configurar a diferenciação de maiúsculas e minúsculas
3. Configurar permissões do IAM

Configurar o data warehouse do Amazon Redshift

Para configurar um data warehouse do Amazon Redshift para sua integração ETL zero:

1. Navegue até o console do Amazon Redshift e clique em Criar cluster ou use um cluster existente. No Amazon Redshift sem servidor, clique em Criar grupo de trabalho.

2. Ao criar um novo cluster, escolha um tamanho de cluster apropriado e garanta que seu cluster esteja criptografado. Para o Serverless, defina as configurações do grupo de trabalho de acordo com seus requisitos.
3. Confirme se o grupo de trabalho ou cluster de destino do Amazon Redshift tem o parâmetro `enable_case_sensitive_identifier` ativado para que a integração tenha êxito. Para obter mais informações sobre como habilitar a diferenciação de maiúsculas e minúsculas, consulte Ativar diferenciação de maiúsculas e minúsculas para seu data warehouse no guia de gerenciamento do Amazon Redshift.
4. Configure as permissões do IAM para permitir que a integração ETL zero acesse seu data warehouse do Amazon Redshift. Você precisará criar um perfil do IAM com as permissões a seguir:
   - Permissões para acessar o cluster ou grupo de trabalho do Amazon Redshift
   - Permissões para criar e gerenciar bancos de dados e tabelas no Amazon Redshift
   - Permissões do CloudWatch e do Amazon CloudWatch Logs para monitoramento
5. Depois que a configuração do grupo de trabalho ou cluster do Amazon Redshift estiver concluída, você precisará configurar o data warehouse ou as integrações ETL zero. Consulte Introdução a integrações ETL zero no Guia de gerenciamento do Amazon Redshift para obter mais informações.

> **Note**
>
> Ao usar um data warehouse do Amazon Redshift como destino, a integração cria um esquema no banco de dados especificado para armazenar os dados replicados. O nome do esquema é derivado do nome da integração.

Depois de configurar o data warehouse do Amazon Redshift, você pode prosseguir para Configurar a integração com seu destino para concluir a configuração da integração.

Configurar a integração com seu destino

Depois de configurar seus recursos de destino, selecionar sua conexão e especificar um perfil do IAM de origem, siga estas etapas para concluir a configuração da integração:

1. Especifique o destino que você configurou nas etapas anteriores.
2. Selecione a opção Corrigir para mim do AWS Glue. Para o Amazon Redshift de destino, isso fará:

- Aplicar uma entidade principal autorizada no cluster Amazon Redshift ou grupo de trabalho do Serverless.
- Aplicar um ARN de origem autorizado do AWS Glue ao cluster do Amazon Redshift ou ao grupo de trabalho do Serverless.
- Associar um novo grupo de parâmetros a `enable_case_sensitive_identifier = true`.

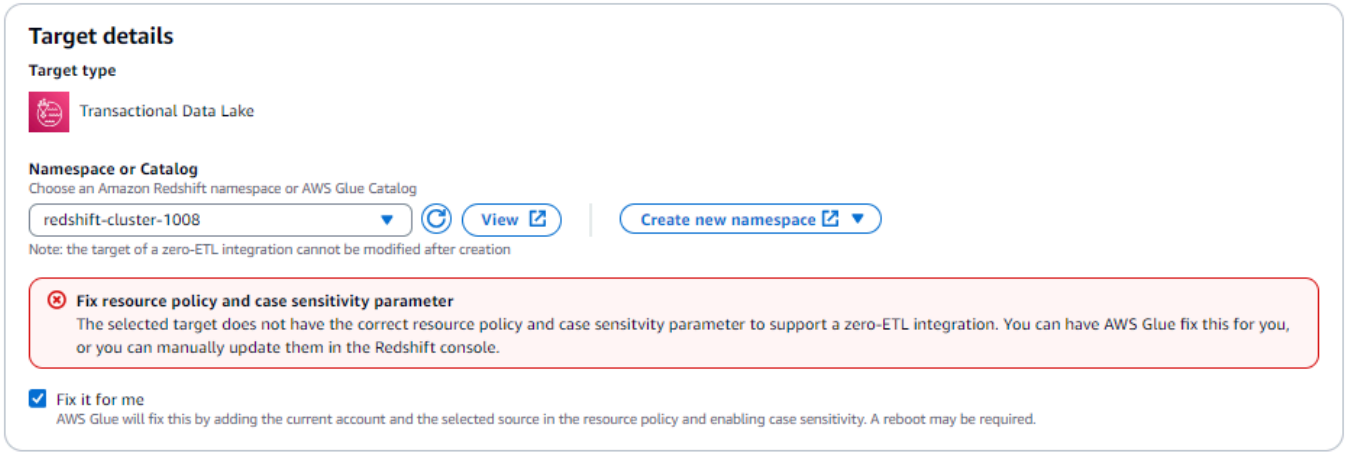

3. Forneça o nome da integração e escolha Criar e iniciar integração.
4. Quando sua integração estiver ativa, navegue até a página de detalhes da integração e escolha Criar um banco de dados com base na integração.
5. Finalmente, você pode navegar até o editor de consultas do Redshift e conectar ao seu banco de dados para validar o snapshot e os dados incrementais.

> **Note**
>
> Você só pode usar caracteres alfanuméricos minúsculos e sublinhados no nome do namespace ou do catálogo. Isso é diferente do que o Catálogo de Dados do AWS Glue permite para criar um banco de dados com qualquer nome (incluindo caracteres especiais).

Guia de desaninhamento de esquema e especificação de partição

Ao trabalhar com fontes de dados NoSQL, como aplicações SaaS e DynamoDB, os dados geralmente apresentam desafios exclusivos do analytics:

1. Os registros na mesma tabela podem ter esquemas diferentes
2. Registros aninhados na mesma tabela podem ser representados de forma diferente

3. Estruturas aninhadas complexas, como mapas e arrays, exigem transformação para consultas eficientes
4. A organização ideal dos dados é necessária para garantir o desempenho das consultas em grande escala

As integrações ETL zero do AWS Glue abordam esses desafios por meio de dois recursos poderosos:

- Desaninhamento de esquema: automaticamente achata estruturas de dados aninhadas complexas em formatos compatíveis com analytics, com níveis configuráveis de desaninhamento para equilibrar a preservação da estrutura de dados e a otimização para simplificar a consulta.
- Particionamento de dados: organiza os dados em partições lógicas com base em colunas especificadas ou dimensões baseadas em tempo, melhorando o desempenho da consulta e reduzindo os custos ao permitir a remoção de partições durante a execução da consulta.

Para consultar essas fontes de dados de forma eficaz, o ETL zero do AWS Glue fornece esquemas de particionamento e manipulação de esquemas prontos para uso para os dados de origem que estão sendo replicados no banco de dados de destino do AWS Glue. Você pode configurar as configurações de desaninhamento e particionamento do esquema para cada tabela por meio da API CreateIntegrationTableProperty, permitindo um controle preciso sobre como os dados são estruturados e organizados para workloads de análise.

Comportamento padrão de desaninhamento e particionamento

1. O ETL zero do AWS Glue assume como padrão o Desaninhamento COMPLETO quando nenhuma opção de desaninhamento é fornecida para a tabela de destino
2. O ETL zero do AWS Glue usa como padrão o particionamento de bucket quando nenhuma PartitionSpec é fornecida para a tabela de destino

Desaninhamento de esquemas

Ao fazer a integração com serviços de analytics por meio do ETL zero, você pode escolher como as estruturas aninhadas são representadas nas tabelas de destino. AWS O ETL zero do Glue fornece opções de desaninhamento de esquemas para nivelar estruturas de dados complexas em formatos mais fáceis de analisar.

Opções de desaninhamento

Ao criar uma integração ETL zero com uma fonte, você pode escolher entre as seguintes opções de desaninhamento. Essas opções correspondem aos valores de enumeração específicos que você usará ao chamar a API CreateIntegrationTableProperty.

Sem desaninhamento (padrão)

Valor da API: **`NO_UNNEST`**

Preserva a estrutura aninhada original dos itens do DynamoDB. Mapas e listas são armazenados como colunas estruturadas no destino.

Ideal para: preservar a estrutura exata dos seus dados do DynamoDB quando suas ferramentas de analytics podem funcionar com dados aninhados.

Desaninhar um nível

Valor da API: **`TOP_LEVEL`**

Achatamento do nível superior dos mapas aninhados em colunas individuais. As estruturas de lista permanecem aninhadas.

Ideal para: equilibrar a preservação da estrutura de dados e a simplicidade da consulta quando seus itens do DynamoDB têm um esquema consistente.

Desaninhar todos os níveis

Valor da API: **`FULL`**

Achatamento recursivo de todas as estruturas aninhadas (mapas e listas) em colunas individuais com notação de pontos para nomeação.

Ideal para: maximizar a simplicidade das consultas ao trabalhar com estruturas profundamente aninhadas e ferramentas de analytics que preferem esquemas simples.

> **Note**
>
> O desaninhamento total pode resultar em tabelas muito amplas com muitas colunas se seus dados do DynamoDB tiverem estruturas variáveis ou profundamente aninhadas.

Example Usar opções de desaninhamento na API

Ao configurar o desaninhamento do esquema por meio da API CreateIntegrationTableProperty, especifique a opção de desaninhamento no parâmetro 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"
  }'
```

Exemplos de desaninhamento

Considere um item do DynamoDB com a seguinte estrutura:

```
{
  "ProductId": "P12345",
  "ProductDetails": {
    "Name": "Smartphone",
    "Brand": "TechCo",
    "Specifications": {
      "Color": "Black",
      "Storage": "128GB"
    }
  },
  "Reviews": [
    {
      "Rating": 5,
      "Comment": "Great product!"
    },
    {
      "Rating": 4,
      "Comment": "Good value."
    }
  ]
}
```

Sem exemplos de desaninhamento

Sem o desaninhamento, a tabela de destino teria colunas:

- ProductId (string)

- ProductDetails (estrutura)
- Avaliações (array de estruturas)

As consultas precisariam usar padrões de acesso de estrutura e array:

```
SELECT
  ProductId,
  ProductDetails.Name,
  ProductDetails.Specifications.Color
FROM product_table;
```

Exemplo de desaninhamento de um nível

Sem o desaninhamento de um nível, a tabela de destino teria colunas:

- ProductId (string)
- ProductDetails_Name (string)
- ProductDetails_Brand (string)
- ProductDetails_Specifications (struct)
- Avaliações (array de estruturas)

As consultas seriam simplificadas para o primeiro nível:

```
SELECT
  ProductId,
  ProductDetails_Name,
  ProductDetails_Specifications.Color
FROM product_table;
```

Exemplo de desaninhamento em todos os níveis

Com o desaninhamento de todos os níveis, a tabela de destino teria colunas e valores:

Nome da coluna (Tipo)	Valor
ProductId (string)	P12345
ProductDetails_Name (string)	Smartphone

Nome da coluna (Tipo)	Valor
ProductDetails_Brand (string)	TechCo
ProductDetails_Specifications_Color (string)	Preto
ProductDetails_Specifications_Storage (string)	128 GB
Reviews_0_Rating (number)	5
Reviews_0_Comment (string)	Ótimo produto!
Reviews_1_Rating (number)	4
Reviews_1_Comment (string)	Bom valor.

As consultas seriam totalmente achatadas:

```
SELECT
  ProductId,
  ProductDetails_Name,
  ProductDetails_Specifications_Color
FROM product_table;
```

Particionamento de dados para integrações ETL zero

O que é particionamento de dados?

O particionamento de dados é uma técnica que divide grandes conjuntos de dados em segmentos menores e mais gerenciáveis, chamados de partições. No contexto das integrações ETL zero do AWS Glue, o particionamento organiza seus dados no local de destino com base em valores específicos de coluna ou transformações desses valores.

Benefícios do particionamento de dados

O particionamento de dados eficaz fornece vários benefícios importantes para workloads de analytics:

- Melhor desempenho de consultas: as consultas podem ignorar partições irrelevantes (poda de partições), reduzindo a quantidade de dados que precisam ser verificados.

- Custos reduzidos: ao verificar menos dados, você pode reduzir os custos de computação e E/S para suas consultas de analytics.
- Melhor escalabilidade: o particionamento permite o processamento paralelo de segmentos de dados, possibilitando um escalonamento mais eficiente de workloads de analytics.
- Gerenciamento simplificado do ciclo de vida dos dados: você pode gerenciar políticas de retenção no nível da partição, facilitando o arquivamento ou a exclusão de dados antigos.

Principais conceitos de particionamento

Colunas da partição

: Colunas em seus dados que são usadas para determinar como os registros são organizados em partições. As colunas de partição efetivas devem se alinhar com os padrões de consulta comuns e ter a cardinalidade apropriada.

Funções da partição

: Transformações aplicadas aos valores da coluna de partição para criar os limites reais da partição. Os exemplos incluem identidade (usando o valor bruto), funções baseadas em tempo (ano, mês, dia, hora) e armazenamento em bucket.

Limpeza da partição

: O processo em que o mecanismo de consulta identifica e ignora partições que não contêm dados relevantes para uma consulta, melhorando significativamente o desempenho.

Granularidade de partição

: O nível de detalhe no qual os dados são particionados. Uma granularidade mais fina (mais partições) pode melhorar o desempenho da consulta, mas pode aumentar a sobrecarga de metadados. Uma granularidade mais grossa (menos partições) reduz a sobrecarga de metadados, mas pode resultar na digitalização de mais dados do que o necessário.

Particionamento em integrações ETL zero do AWS Glue

As integrações do ETL zero do AWS Glue usam o formato de tabela Apache Iceberg, que fornece recursos avançados de particionamento. Ao criar uma integração ETL zero, você pode:

- Use estratégias de particionamento padrão otimizadas para sua fonte de dados
- Defina especificações personalizadas de particionamento adaptadas aos seus padrões de consulta

- Aplique transformações às colunas de particionamento (especialmente útil para particionamento baseado em carimbo de data/hora)
- Combine várias estratégias de particionamento para particionamento em vários níveis

As configurações de particionamento são especificadas por meio da API `CreateIntegrationTableProperty` ao configurar sua integração ETL zero. Depois de configurado, o AWS Glue aplica automaticamente essas estratégias de particionamento para organizar seus dados no local de destino.

Referência da API de especificação de partição

Use os seguintes parâmetros na API CreateIntegrationTableProperties para configurar particionamento:

PartitionSpec

Uma matriz de especificações de partição que define como os dados são particionados no local de destino.

```
{
  "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

Uma string UTF-8 (de 1 a 128 bytes) especificando o nome da coluna a ser usada para particionamento.

FunctionSpec

Especifica a função de particionamento. Valores válidos:

- `identity`: usa valores de origem diretamente sem transformação
- `year`: extrai o ano dos valores do carimbo de data/hora (por exemplo, 2023)
- `month`: extrai o mês dos valores do carimbo de data/hora (por exemplo, 2023-01)
- `day`: extrai o dia dos valores do carimbo de data/hora (por exemplo, 2023-01-15)
- `hour`: extrai a hora dos valores do carimbo de data/hora (por exemplo, 2023-01-15-14)
- `bucket`: distribui valores em um número específico de buckets usando particionamento baseado em hash. Necessário um parâmetro `bucketCount`.
- `truncate`: trunca os valores da string para uma largura especificada. Necessário um parâmetro `width`.

> **Note**
>
> As funções baseadas em tempo (`year`, `month`, `day`, `hour`) exigem que o parâmetro `ConversionSpec` especifique o formato do carimbo de data/hora de origem. As funções `bucket` e `truncate` exigem parâmetros adicionais, conforme especificado em suas descrições.

ConversionSpec

Uma string UTF-8 que especifica o formato de timestamp dos dados da fonte. Os valores válidos são:

- `epoch_sec`: timestamp da era Unix em segundos
- `epoch_milli`: timetstamp da era Unix em milissegundos
- `iso`: timestamp no formato ISO 8601

BucketCount

Um número inteiro que especifica o número de buckets a serem criados ao usar a função `bucket`. Esse parâmetro é necessário quando `functionSpec` está definido como `bucket`. O valor deve ser um inteiro positivo. O armazenamento em bucket baseado em hash distribui os valores uniformemente pelo número especificado de buckets.

Example Exemplo de particionamento de bucket

```
{
  "partitionSpec": [
    {
      "fieldName": "user_id",
      "functionSpec": "bucket",
      "bucketCount": 16
    }
  ]
}
```

Largura

Um inteiro que especifica a largura do truncamento ao usar a função `truncate`. Esse parâmetro é necessário quando `functionSpec` está definido como `truncate`. O valor deve ser um inteiro positivo representando o número de caracteres que devem ser retidos do início dos valores da string.

Example Exemplo de particionamento truncado

```
{
  "partitionSpec": [
    {
      "fieldName": "product_code",
      "functionSpec": "truncate",
      "width": 4
    }
  ]
}
```

Estratégias de particionamento

Particionamento padrão

Quando nenhuma coluna de partição é especificada, o ETL zero do AWS Glue aplica estratégias de particionamento padrão otimizadas para sua fonte de dados:

- Particionamento baseado em chave primária: para fontes com chaves primárias (como tabelas do DynamoDB), o ETL zerp dp AWS Glue particiona automaticamente os dados usando a chave primária com o armazenamento em bucket para evitar a explosão de partições.

O particionamento padrão foi projetado para funcionar bem para padrões de consulta comuns sem exigir configuração manual. No entanto, para padrões de consulta específicos ou requisitos de desempenho, você pode querer definir estratégias personalizadas de particionamento.

Estratégias de particionamento definidas pelo usuário

O ETL zero do AWS Glue permite que você defina estratégias de particionamento personalizadas usando o parâmetro `PartitionSpec`. Você pode especificar uma ou mais colunas de partição e aplicar diferentes funções de particionamento a cada coluna.

O particionamento de identidade usa os valores brutos de uma coluna para criar partições. Essa estratégia é útil para colunas com cardinalidade baixa a média, como campos de categoria, região ou status.

Example Exemplo de particionamento de identidade

```
{
  "partitionSpec": [
    {
      "fieldName": "category",
      "functionSpec": "identity"
    }
  ]
}
```

Isso cria partições separadas para cada valor exclusivo na coluna "categoria".

> **Warning**
>
> Evite usar o particionamento de identidade com colunas de alta cardinalidade (como chaves primárias ou carimbos de data/hora), pois isso pode causar uma explosão de partições, o que prejudica o desempenho e aumenta a sobrecarga de metadados.

O particionamento com base em tempo organiza os dados com base em valores do carimbo de data/hora em diferentes granularidades (ano, mês, dia ou hora). Essa estratégia é ideal para dados de séries temporais e permite consultas eficientes em intervalos de tempo.

Ao usar o particionamento baseado em tempo, o ETL zero do AWS Glue pode converter automaticamente vários formatos do carimbo de data/hora em um formato padronizado antes de aplicar a função de partição. Essa conversão é especificada usando o parâmetro `ConversionSpec`.

Example Exemplo de particionamento com base em tempo

```
{
  "partitionSpec": [
    {
      "fieldName": "created_at",
      "functionSpec": "month",
      "conversionSpec": "epoch_milli"
    }
  ]
}
```

Isso particiona os dados por mês com base na coluna “created_at”, que contém carimbos de data/hora da época Unix em milissegundos.

O ETL zero do AWS Glue suporta as seguintes funções de partição baseadas em tempo:

- ano: particiona dados por ano (por exemplo, 2023, 2024)
- mês: particiona dados por mês (por exemplo, 2023-01, 2023-02)
- dia: particiona dados por dia (por exemplo, 2023-01-01, 2023-01-02)
- hora: particiona dados por hora (por exemplo, 2023-01-01-01, 2023-01-01-02)

O ETL zero do AWS Glue suporta os seguintes formatos de carimbo de data/hora por meio do parâmetro `ConversionSpec`:

- epoch_sec: carimbos de data/hora da época Unix em segundos
- epoch_milli: carimbos de data/hora da época Unix em milissegundos
- iso: carimbos de data/hora formatado em ISO 8601

> **Note**
>
> Os valores originais da coluna permanecem inalterados nos dados da fonte. AWS O Glue transformará apenas os valores das colunas de partição no tipo de carimbo de data/hora na tabela do banco de dados de destino. As transformações se aplicam apenas ao processo de particionamento baseado em carimbo de data/hora.

O particionamento de buckets usa distribuição baseada em hash para espalhar uniformemente os dados em um número fixo de buckets. Essa estratégia é útil para colunas de alta cardinalidade nas quais você deseja controlar o número de partições e garantir uma distribuição uniforme dos dados.

Example Exemplo de particionamento de bucket

```
{
  "partitionSpec": [
    {
      "fieldName": "user_id",
      "functionSpec": "bucket",
      "bucketCount": 16
    }
  ]
}
```

Isso cria 16 buckets com base nos valores de hash da coluna "user_id", garantindo uma distribuição uniforme, independentemente dos valores reais do ID do usuário.

O particionamento de buckets é particularmente eficaz para:

- Colunas de alta cardinalidade, como IDs de usuário, IDs de sessão ou chaves primárias
- Cenários em que você precisa do número de partições previsíveis
- Workloads que se beneficiam do processamento paralelo entre limites de partição fixos

O particionamento truncado cria partições com base em valores de cadeia de caracteres truncados, mantendo somente os primeiros N caracteres. Essa estratégia é útil para colunas de string nas quais você deseja agrupar valores semelhantes.

Example Exemplo de particionamento truncado

```
{
  "partitionSpec": [
    {
      "fieldName": "product_code",
      "functionSpec": "truncate",
      "width": 4
    }
  ]
}
```

Isso cria partições com base nos primeiros 4 caracteres da coluna "product_code". Por exemplo, "ELEC12345" e "ELEC67890" seriam agrupados na mesma partição "ELEC".

O particionamento é particularmente eficaz para:

- Códigos de produto, SKUs ou outros identificadores estruturados com prefixos significativos
- Códigos geográficos ou postais em que o agrupamento regional é benéfico
- Qualquer coluna de string em que o agrupamento baseado em prefixo se alinha aos padrões de consulta

O particionamento de vários níveis combina várias estratégias de partição para criar um esquema de particionamento hierárquico. Isso é útil para otimizar diferentes tipos de consultas no mesmo conjunto de dados.

Example Exemplo de particionamento de vários níveis

```
{
  "partitionSpec": [
    {
      "fieldName": "created_at",
      "functionSpec": "month",
      "conversionSpec": "iso"
    },
    {
```

```
      "fieldName": "region",
      "functionSpec": "identity"
    },
    {
      "fieldName": "user_id",
      "functionSpec": "bucket",
      "bucketCount": 8
    }
  ]
}
```

Isso cria um esquema de particionamento de três níveis: primeiro por mês (da coluna "created_at"), depois por região e, finalmente, por bucket de ID de usuário. Isso permite consultas eficientes que filtram por intervalos de datas, regiões específicas, segmentos de usuários ou qualquer combinação dessas dimensões.

Ao projetar esquemas de particionamento de vários níveis, considere:

- Colocar colunas de maior seletividade em primeiro lugar na hierarquia de partições
- Equilibrar a granularidade da partição com o número de partições
- Alinhar o esquema de particionamento com seus padrões de consulta mais comuns

Práticas recomendadas

Seleção da coluna de partição

- Não use colunas de alta cardinalidade com a função de partição `identity`. O uso de colunas de alta cardinalidade com particionamento baseado em identidade cria muitas pequenas partições, o que pode degradar significativamente o desempenho de ingestão. Colunas de alta cardinalidade podem incluir:
  - Chaves primárias
  - Campos de timestamp (como `LastModifiedTimestamp`, `CreatedDate`)
  - Timestamps gerados pelo sistema
- Não selecione várias partições de timestamp na mesma coluna. Por exemplo:

```
"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"}
]
```

Seleção de FunctionSpec/ConversionSpec da partição

- Especifique o ConversionSpec correto (epoch_sec | epoch_milli | iso) que representa o formato dos valores de coluna escolhidos para particionamento baseado em carimbo de data/hora ao usar funções de partição baseadas em carimbo de data/hora. AWS O Glue Zero-ETL usa esse parâmetro para transformar corretamente os dados da fonte no formato de timestamp antes do particionamento.
- Use a granularidade apropriada (ano/mês/dia/hora) com base no volume de dados.
- Considere as implicações de fuso horário ao usar timestamps ISO. AWS O Glue Zero-ETL preenche todos os valores de registros da coluna de timestamp escolhida com o fuso horário UTC.
- Ao usar o particionamento `bucket`, escolha o número de buckets que se alinham aos seus requisitos de paralelismo de consulta. O número comum de buckets são potências de 2 (8, 16, 32) para uma distribuição de hash ideal.
- Para o particionamento `truncate`, selecione valores de largura que criem agrupamentos significativos com base em seus padrões de dados. Certifique-se de que a largura do truncamento capture a parte significativa do prefixo dos valores da string.
- Evite usar as funções `bucket` ou `truncate` como a única estratégia de partição para conjuntos de dados muito pequenos, pois isso pode criar uma sobrecarga de partição desnecessária.

Tratamento de erros

Estado NEEDS_ATTENTION

Uma integração entra no estado NEEDS_ATTENTION quando:

- As colunas de partição especificadas não existem na fonte
- Ocorre falha na conversão de timestamp das colunas de partição

Limitações

Limitações de particionamento

- As especificações da partição não podem ser alteradas após a criação de uma integração. Para usar uma estratégia de particionamento diferente, você deve criar uma nova integração.
- O número máximo de colunas de partição é limitado a dez.

Limitações de integração entre contas

- Ao criar integrações entre contas, o console do AWS Glue tem uma limitação em que não invoca a API CreateIntegrationTableProperty para configurar UnnestSpec e PartitionSpec para tabelas de destino do AWS Glue hospedadas na conta em que a integração não existe.

  Solução alternativa: a API CreateIntegrationTableProperty deve ser invocada pelo CX a partir da conta a qual existe o banco de dados de destino.

Limitações de várias integrações

- Se você precisar replicar a mesma fonte com diferentes configurações de desaninhamento/partição de esquema, será necessário criar um novo banco de dados do AWS Glue para cada integração separadamente. Posteriormente, invoque CreateIntegrationTableProperty para cada tabela do banco de dados individual do AWS Glue com as configurações desejadas de desaninhamento e particionamento do esquema.

Tarefas comuns de integração

Criar uma integração

Esta seção descreve as etapas gerais necessárias para criar uma integração. Este exemplo usa o Amazon DynamoDB como fonte.

1. Na página inicial do console do AWS Glue, selecione Integrações ETL zero.
2. É possível visualizar todas as suas integrações na página inicial da integração ETL zero. Para criar uma nova integração, selecione Criar integração ETL zero.

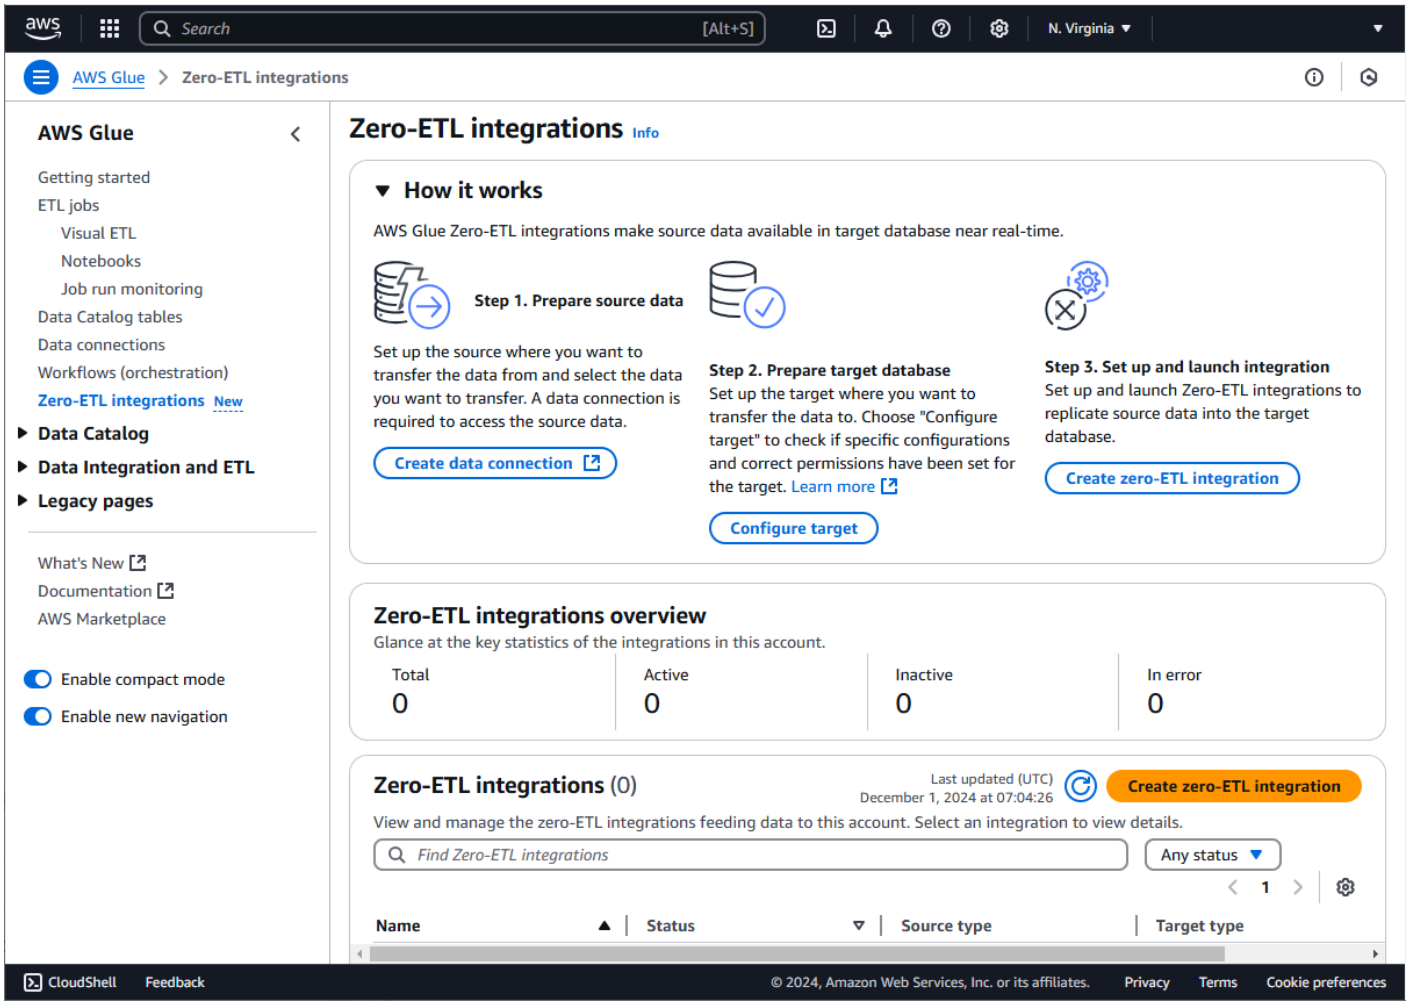

3. Você será avisado para selecionar um Tipo de origem. Selecione sua fonte e clique em Avançar. Consulte as seções de configuração da origem para obter as fontes de integração de SaaS.
4. Na página Configurar origem e destino, selecione as tabelas ou entidades a serem replicadas. Para o Amazon DynamoDB, certifique-se de que a política PITR e RBAC esteja configurada.
5. Especifique o destino da integração:
   - Para um destino de Catálogo de Dados do AWS Glue, selecione o banco de dados do AWS Glue para o qual você deseja replicar os dados.
   - Para um data warehouse de dados do Amazon Redshift, selecione o namespace do cluster do Redshift ou o namespace do grupo de trabalho do Redshift sem servidor.

   Para obter mais informações, consulte Configurar a integração com seu destino.
6. Forneça o Perfil do IAM de destino que você criou nos pré-requisitos.

7. Se você quiser configurar uma Chave do KMS de destino opcional para seus dados que estão sendo armazenados no destino, forneça uma chave do KMS habilitada. Da mesma forma, se você quiser configurar uma conexão de rede de destino, selecione uma conexão do AWS Glue.
8. O botão Corrigir destino configura algumas das etapas na seção Pré-requisitos desta documentação. Ou seja, ele 1) fornecerá uma política de catálogo RBAC e 2) se nenhum URI do Amazon S3 for fornecido, ele gerará um para você. Caso contrário, ele usará o URI fornecido.
9. Para integrações com um destino de data warehouse do Redshift:
10. Na seção Configuração de saída da página Configurar origem e destino, selecione a opção de desaninhamento do esquema que você deseja para seus dados no destino. Se você quiser usar chaves de partição do cliente para seus dados, selecione Especificar chaves de partição personalizadas e forneça até 10 chaves. Caso contrário, você poderá simplesmente usar as chaves de partição atribuídas à tabela do DynamoDB que está sendo replicada.
11. Na seção Segurança e criptografia de dados, você pode fornecer uma chave do KMS que será usada no processo intermediário de replicação dos dados para o destino. Caso contrário, uma chave do KMS gerenciada pela AWS será usada. No momento, oferecemos suporte apenas a uma configuração de replicação de 15 minutos. Insira um nome para a integração ETL zero em Detalhes da integração.
12. Revise e verifique se todos os detalhes fornecidos estão corretos. Clique em Criar e iniciar a integração quando tudo for confirmado.
13. Na página inicial do ETL zero, é possível selecionar a integração que você criou, e os detalhes de suas integrações aparecerão. O "Status" indica o estado da sua integração.

Modificar uma integração

É possível modificar uma integração existente.

1. Selecione Editar no canto superior direito da página de detalhes da integração.
2. Na página Editar origem e destino, é possível alterar o perfil do IAM de destino e a conexão de rede do Target. Os outros campos não são editáveis após a criação da integração. Clique em Next.
3. Você também pode editar o nome e a descrição da integração na página Editar integração e configuração. Clique em Next.
4. Revise suas edições e, uma vez confirmadas, clique em Atualizar integração.

Excluir uma integração

A exclusão é um estado terminal para uma integração. Após a exclusão, não é possível recuperar a integração. A exclusão de uma integração limpa todos os metadados internos e quaisquer dados intermediários armazenados.

Durante esse processo, todas as tarefas em execução que estejam gravando dados em uma tabela de destino são encerradas. O AWS Glue não excluirá nem limpará o banco de dados do AWS Glue de destino (no Catálogo de Dados) e os dados associados no bucket do Amazon S3 em sua conta. Se necessário, você terá que limpá-los de forma explícita.

Para excluir uma integração:

1. Na página de detalhes da integração, clique em Excluir.
2. Digite "Excluir" e clique em Excluir. Observação: essa ação é irreversível.
3. Na página de detalhes da integração, o status mostra "Excluindo". Depois que a integração for realmente excluída, ela não aparecerá mais na página inicial da integração ETL zero.

Criar integrações usando as APIs

Você pode usar as seguintes APIs para criar e gerenciar integrações ETL zero no AWS Glue:

- CreateIntegration
- CreateIntegrationTableProperties
- CreateIntegrationResourceProperty
- UpdateIntegrationTableProperties
- UpdateIntegrationResourceProperty
- ModifyingIntegration
- DeleteIntegration
- DeleteIntegrationTableProperties
- DescribeIntegrations
- DescribeInboundIntegrations
- GetIntegrationTableProperties
- GetIntegrationResourceProperty

Para obter mais informações, consulte APIs de integração no AWS Glue.

Monitorar uma integração

Estados de integração

Os seguintes estados de integração descrevem a integração:

- `Creating`: a integração está sendo criada.
- `Active`: a integração está enviando dados transacionais para o destino.
- `Modifying`: a integração está sendo modificada.
- `Syncing`: a integração encontrou um erro recuperável e está realimentando os dados.
- `Needs attention`: a integração encontrou um evento ou erro que requer intervenção manual para resolvê-lo. Para corrigir o problema, siga as instruções na mensagem de erro na página de detalhes da integração.
- `Failed`: a integração encontrou um evento ou erro irrecuperável. Você precisa excluir e recriar a integração.
- `Deleting`: a integração está sendo excluída.

Visualização de logs do Amazon CloudWatch para uma integração

As integrações ETL zero do AWS Glue geram logs do Amazon CloudWatch para visibilidade da movimentação dos seus dados. Eventos de logs relacionados a cada ingestão com êxito ou a quaisquer falhas ocorridas devido a registros de dados problemáticos na fonte, ou erros de gravação de dados devido a alterações no esquema ou permissões insuficientes são emitidos para um grupo de logs padrão criado em uma conta de cliente.

Para cada integração criada, os eventos de logs dessa integração serão coletados em `/aws-glue/zeroETL-integrations/logs/` no Amazon CloudWatch. No grupo de logs, as mensagens de log serão divididas em fluxos de logs. Cada integração criada tem um fluxo de logs dedicado no qual todos os logs dessa integração são gravados. Por exemplo, os logs de uma integração com IntegrationArn `arn:aws:glue:us-east-1:123456789012:integration:03cabe77-79e7-4b7a-b3da-8c160bea6bbf` podem ser encontrados em /aws-glue/zeroETL-integrations/logs/03cabe77-79e7-4b7a-b3da-8c160bea6bbf. {IntegrationId} pode ser referenciado com base no {integrationArn} gerado quando uma integração é criada.

> **Note**
>
> Em um cenário entre contas, os logs de processamento de origem são emitidos na conta de origem, onde a integração existe, e os logs de processamento de destino são emitidos na conta de destino, onde o banco de dados de destino existe.

Permissões do IAM necessárias para habilitar registros em log

Ao criar sua integração, as seguintes permissões do IAM são necessárias para os perfis de origem e destino a fim de habilitar o registro em log do CloudWatch para uma integração. As integrações ETL zero do AWS Glue usam essas permissões fornecidas nos perfis de origem e destino para emitir logs do CloudWatch para contas de clientes.

```
{
"Version": "2012-10-17",
    "Statement": [
        {
"Effect": "Allow",
            "Action": [
                "logs:CreateLogGroup",
                "logs:CreateLogStream",
                "logs:PutLogEvents",
             ],
            "Resource": [
                "*"
            ]
        }
    ]
}
```

Mensagens de log

Formato de log: as integrações ETL zero emitem quatro tipos de mensagens de log.

```
// 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"
    }
}
```

Visualizar métricas do Amazon CloudWatch para uma integração

Depois que a integração for concluída, você poderá ver essas métricas do Amazon Cloudwatch geradas em sua conta para cada execução de trabalho do AWS Glue:

Namespace de métricas do CloudWatch: "AWS/Glue/zeroETL"

Dimensões de métricas:

- `integrationArn`
- `loadType`
- `tableName`

Nomes de métricas:

- `InsertCount`: número de registros inseridos na tabela do Iceberg de destino.
- `UpdateCount`: número de registros atualizados na tabela do Iceberg de destino.
- `DeleteCount`: número de registros excluídos da tabela do Iceberg de destino.
- `IngestionSucceeded`: conte 1, se a ingestão foi bem-sucedida para a integração.
- `IngestionFailed`: conte 1, se a ingestão falhou para a integração.
- `LastSyncTimestamp`: timestamp até o qual a origem foi sincronizada com o destino.

Gerenciamento de notificações de eventos com o Amazon EventBridge

As integrações ETL zero usam o Amazon EventBridge para gerenciar notificações de eventos a fim de manter você por dentro das alterações feitas nas integrações. O Amazon EventBridge é uma tecnologia sem servidor de barramento de eventos que você pode usar para facilitar a conexão de aplicações a dados de diversas origens. Nesse caso, a origem do evento é o AWS Glue. Os eventos, que são alterações monitoradas em um ambiente, são enviados automaticamente para o EventBridge pelo AWS Glue. Os eventos são entregues quase em tempo real.

O EventBridge oferece um ambiente para você gravar regras de evento, capazes de especificar medidas a serem tomadas para eventos específicos. Você também pode configurar destinos, que são recursos para os quais o EventBridge pode enviar um evento. Um destino pode incluir um destino de API, um grupo de logs do Amazon CloudWatch, entre outros. Para obter mais informações sobre regras, consulte Regras do Amazon EventBridge. Para obter mais informações sobre destinos, consulte Destinos do Amazon EventBridge.

Para capturar todas as notificações de ETL zero, crie uma regra do EventBridge que corresponda ao seguinte:

```
{
```

```
  "source": [{
    "prefix": "aws.glue-zero-etl“
  }],
  "detail-type": [{
    "prefix": "Glue Zero ETL“
  }]
}
```

Esta tabela inclui eventos de integração ETL zero, com metadados adicionais:

Tipo de detalhe para o cliente	Explicação
Ingestão do Glue ETL zero concluída	A execução individual de uma entidade foi concluída com êxito.
Ingestão do Glue ETL zero com falha	A execução individual de uma entidade foi concluída sem êxito (com um erro do cliente ou do sistema).
Integração ETL zero do Glue ressincronizada	A integração foi RESYNCED.
Integração ETL zero do Glue com falha	O status da integração foi alterado para FAILED devido a um erro.
A integração ETL zero do Glue precisa de atenção	O status da integração foi alterado para NEEDS_ATTENTION devido a um erro.

Limitações

São limitações gerais ou considerações sobre as integrações ETL zero:

- As propriedades do recurso têm um relacionamento de um para um com o recurso correspondente. Consequentemente, todas as integrações criadas usando esse recurso devem aderir à propriedade única do recurso. Portanto, a modificação de uma propriedade do recurso afetará todas as integrações associadas a esse recurso.
- As propriedades da tabela têm um relacionamento de um para um com o objeto ou a tabela correspondente no recurso. Como resultado, todas as integrações que processam a mesma tabela de ou para o mesmo recurso devem aderir à propriedade da tabela única.

- Não é possível renomear uma coluna na origem. Se uma coluna for renomeada, não há garantia de que a detecção do esquema será feita com precisão pelo AWS Glue e que as repercussões na integração serão indefinidas.
- A consideração a seguir se aplica à forma como a integração funciona com tabelas gerenciadas do AWS Lake Formation: por padrão, você usa a política do IAM/AWS Glue para gerenciar sua tabela e bancos de dados.
- Se você quiser usar o AWS Lake Formation para gerenciar a criação de tabelas nesse banco de dados, deverá garantir que o perfil tenha permissões suficientes do Lake Formation para criar, modificar e excluir a tabela e o banco de dados.
- A página de resumo de ETL zero não contém nenhuma métrica no momento.

São limitações específicas da origem de integrações ETL zero:

- Integrações ETL zero com uma fonte SAPOData agora são compatíveis com entidades que começam com `Entity0f`. Atualmente, a capacidade de substituir a chave primária é compatível somente para objetos SAPOData `Entity0f`. Depois que essa propriedade tiver sido definida, ela não poderá ser modificada.
- Integrações ETL zero do Amazon DynamoDB com o Amazon SageMaker Lakehouse (via S3) oferecem suporte a um tamanho máximo de tabela do DynamoDB de 50 TB.
- A tabela de origem do DynamoDB deve ser criptografada com uma chave do AWS KMS pertencente à Amazon ou gerenciada pelo cliente. A criptografia gerenciada pela Amazon não se aplica à tabela de origem do DynamoDB.
- O SAP OData funciona usando um token delta, em que a combinação de um cliente OAuth mais uma entidade, ou autenticação básica mais uma entidade, pode ter apenas um único token delta. Evite usar a mesma entidade em duas integrações diferentes com o mesmo cliente.
- Não há suporte aos campos ou entidades do Salesforce a seguir para uso em uma integração ETL zero com uma origem 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, QueueSobject, 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
```

- As entidades ou campos do ServiceNow, apresentados a seguir, não são compatíveis com uma Integração ETL zero com uma fonte do ServiceNow.

```
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_mapplication, 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,
sysevent_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 Data Quality

O AWS Glue Data Quality permite que você meça e monitore a qualidade dos dados para que você possa tomar decisões de negócios acertadas. Baseado na estrutura de código aberto do DeeQu, o AWS Glue Data Quality fornece uma experiência de tecnologia sem servidor gerenciada para ajudar você a avaliar e monitorar a qualidade dos dados. O AWS Glue Data Quality trabalha com Data Quality Definition Language (DQDL), que é uma linguagem específica de domínio que você usa para definir regras para o de qualidade de dados. Para saber mais sobre a DQDL e os tipos de regras compatíveis, consulte Referência de Data Quality Definition Language (DQDL).

Para detalhes adicionais sobre o produto e os preços, consulte a página de serviços do AWS Glue Data Quality.

Benefícios e principais atributos

Os benefícios e os principais atributos do AWS Glue Data Quality incluem:

- Tecnologia sem servidor: não requer instalação, aplicação de patches nem manutenção.
- Comece rapidamente: o AWS Glue Data Quality analisa rapidamente os dados e cria regras de qualidade de dados para você. Você pode começar com dois cliques: “Criar regras de qualidade de dados → Recomendar regras”.
- Detectar problemas de qualidade de dados: use o machine learning (ML) para detectar anomalias e problemas de qualidade de dados difíceis de detectar.
- Improvise as regras: começando com mais de 25 regras de DQ prontas para usar, você pode criar regras que atendam às suas necessidades específicas.
- Avalie a qualidade e tome decisões comerciais confiáveis: depois de avaliar as regras, você obtém uma pontuação de qualidade de dados que fornece uma visão geral da integridade dos dados. Use a pontuação de qualidade de dados para tomar decisões de negócios confiáveis.
- Concentre-se nos dados insatisfatórios: o AWS Glue Data Quality ajuda você a identificar os registros exatos que causaram a queda de suas pontuações de qualidade. Identifique-os facilmente, coloque-os em quarentena e corrija-os.
- Pagamento conforme o uso: não há necessidade de licenças anuais para usar o AWS Glue Data Quality.
- Sem exigência de fidelidade: o AWS Glue Data Quality é baseado no DeeQu de código aberto, permitindo que você mantenha as regras que estiver criando em uma linguagem aberta.

- Verificações de qualidade de dados: é possível forçar verificações de qualidade de dados em pipelines de ETL do Data Catalog e do AWS Glue, o que permite gerenciar a qualidade dos dados em repouso e em trânsito.
- Detecção de qualidade de dados baseada em ML: use o machine learning (ML) para detectar anomalias e problemas de qualidade de dados difíceis de detectar.
- Linguagem aberta para expressar regras: garante que as regras de qualidade de dados sejam criadas de maneira consistente e simples. Os usuários corporativos podem expressar facilmente as regras de qualidade de dados em uma linguagem simples e compreensível. Para engenheiros, essa linguagem proporciona a flexibilidade de gerar código, implementar controle consistente de versão e automatizar implantações.

Como funciona

Há dois pontos de entrada para o AWS Glue Data Quality: os trabalhos de ETL do AWS Glue Data Catalog e do AWS Glue. Esta seção fornece uma visão geral dos casos de uso e dos atributos do AWS Glue compatíveis com cada ponto de entrada.

Qualidade de dados para o AWS Glue Data Catalog

O AWS Glue Data Quality avalia objetos armazenados no AWS Glue Data Catalog. Ele oferece a quem não é programador uma maneira fácil de configurar regras de qualidade de dados. Essas pessoas incluem administradores de dados e analistas de negócios.

Você pode escolher essa opção para os seguintes casos de uso:

- Você deseja realizar tarefas de qualidade de dados em conjuntos de dados que já catalogou no AWS Glue Data Catalog.
- Você trabalha com governança de dados e precisa identificar ou avaliar problemas de qualidade de dados no data lake de forma constante.

Você pode gerenciar a qualidade dos dados do catálogo de dados usando as seguintes interfaces:

- O console de gerenciamento do AWS Glue
- APIs do AWS Glue

Para começar a usar o AWS Glue Data Quality para o AWS Glue Data Catalog, consulte Introdução ao AWS Glue Data Quality para o Data Catalog.

Qualidade de dados para trabalhos de ETL do AWS Glue

O AWS Glue Data Quality para trabalhos de ETL do AWS Glue permite que você realize tarefas de qualidade de dados proativas. As tarefas proativas ajudam você a identificar e filtrar dados insatisfatórios antes de carregar um conjunto de dados no data lake.

Vídeo: introdução do AWS Glue Data Quality para pipelines de ETL

Você pode escolher a qualidade dos dados para trabalhos de ETL para os seguintes casos de uso:

- Você deseja incorporar tarefas de qualidade de dados nos trabalhos de ETL
- Você deseja escrever um código que defina tarefas de qualidade de dados em scripts de ETL
- Você quer gerenciar a qualidade dos dados que fluem pelos pipelines de dados visuais

Você pode gerenciar a qualidade dos dados para trabalhos de ETL usando as seguintes interfaces:

- AWS Glue Studio, cadernos do AWS Glue Studio e sessões interativas do AWS Glue
- Bibliotecas do AWS Glue para scripts ETL
- APIs do AWS Glue

Para começar com a qualidade de dados para trabalhos de ETL, consulte Tutorial: Getting started with Data Quality no AWS Glue Studio User Guide.

Comparar a qualidade dos dados do catálogo de dados com a qualidade dos dados dos trabalhos de ETL

Esta tabela fornece uma visão geral dos atributos que cada ponto de entrada compatível com o AWS Glue Data Quality.

Recurso	Qualidade dos dados para o catálogo de dados	Qualidade de dados para trabalhos de ETL
Fontes de dados	Amazon S3, Amazon Redshift, fontes JDBC compatíveis	Todas as fontes de dados compatíveis com o AWS

Recurso	Qualidade dos dados para o catálogo de dados	Qualidade de dados para trabalhos de ETL
	com o catálogo de dados e formatos de data lakes transacionais, como Apache Iceberg, Apache Hudi e Delta Lake. Observe que, se as tabelas forem gerenciadas pelo AWS Lake Formation, as tabelas Iceberg, Delta e HUDI não serão compatíveis. As visualizações do Amazon Athena que estão catalogadas no AWS Glue Data Catalog também não serão compatíveis.	Glue, incluindo conectores personalizados e conectores de terceiros.
Recomendações de regras de qualidade de dados	Compatível	Não compatível
Criar e executar regras DQDL	Compatível	Compatível
Ajuste de escala automático	Não compatível	Compatível
Compatibilidade com o AWS Glue Flex	Não compatível	Compatível
Programação	Compatível ao avaliar regras de qualidade de dados e por meio do Step Functions.	Compatível com o uso do Step Functions e fluxos de trabalho.
Identificação de registros que falharam nas verificações de qualidade de dados	Não compatível	Compatível
Integração com o Amazon EventBridge	Compatível	Compatível

Recurso	Qualidade dos dados para o catálogo de dados	Qualidade de dados para trabalhos de ETL
Integração com o AWS Cloudwatch	Compatível	Compatível
Gravar resultados de qualidade de dados no Amazon S3	Compatível	Compatível
Qualidade incremental dos dados	Compatível por meio dos predicados de pushdown	Compatível por meio dos marcadores do AWS Glue
Compatibilidade com o AWS CloudFormation	Compatível	Compatível
Detecção de anomalias baseada em ML	Não compatível	Compatível
Regras dinâmicas	Não compatível	Compatível

Considerações

Considere os seguintes itens antes de usar o AWS Glue Data Quality:

- As regras de qualidade de dados não podem avaliar fontes de dados aninhadas ou do tipo lista. Consulte Nivelar structs aninhados.

Terminologia

A tabela a seguir define os termos relacionados ao AWS Glue Data Quality.

Data Quality Definition Language (DQDL)

Uma linguagem específica de domínio que você pode usar para escrever regras do AWS Glue Data Quality.

Para saber mais sobre DQDL, consulte o guia de Referência de Data Quality Definition Language (DQDL).

qualidade de dados

Descreve em que medida um conjunto de dados atende à sua finalidade específica. AWS Glue O Data Quality avalia as regras em relação a um conjunto de dados para medir a qualidade dos dados. Cada regra verifica características específicas, como atualidade ou integridade dos dados. Para quantificar a qualidade dos dados, você pode usar uma pontuação de qualidade de dados.

pontuação de qualidade e dados

A porcentagem de regras de qualidade de dados aprovadas (resultam em verdadeiras) quando você avalia um conjunto de regras com o AWS Glue Data Quality.

regra

Uma expressão DQDL que verifica os dados em busca de uma característica específica e retorna um valor booliano. Para obter mais informações, consulte Estrutura da regra.

analisador

Uma expressão de DQDL que reúne estatísticas de dados. Um analisador reúne estatísticas de dados que podem ser usadas por algoritmos de ML para detectar anomalias e problemas de qualidade de dados difíceis de detectar ao longo do tempo.

conjunto de regras

Um recurso do AWS Glue que compreende um conjunto de regras de qualidade de dados. Um conjunto de regras deve estar associado a uma tabela no AWS Glue Data Catalog. Ao salvar um conjunto de regras, o AWS Glue atribui nome do recurso da Amazon (ARN) ao conjunto de regras.

pontuação de qualidade e dados

A porcentagem de regras de qualidade de dados aprovadas (resultam em verdadeiras) quando você avalia um conjunto de regras com o AWS Glue Data Quality.

observação

Um insight não confirmado gerado pelo AWS Glue pela análise de estatísticas de dados coletadas de regras e analisadores ao longo do tempo.

Limites

Limites de serviço do AWS Glue Data Quality:

- Você pode ter 2.000 regras em um conjunto de regras. Se seus conjuntos de regras forem maiores, recomendamos dividi-los em vários conjuntos de regras.
- O tamanho do conjunto de regras é 65 KB. Se seus conjuntos de regras forem maiores, recomendamos dividi-los em vários conjuntos de regras.
- O AWS Glue Data Quality coleta estatísticas quando você cria uma regra ou um analisador. Não há custo associado ao armazenamento dessas estatísticas. No entanto, há um limite de 100.000 estatísticas por conta, e essas estatísticas serão mantidas por no máximo 2 anos.

Notas de versão do AWS Glue Data Quality

Este tópico descreve os atributos introduzidos no AWS Glue Data Quality.

Disponibilidade geral: novos atributos

Os seguintes atributos novos estão disponíveis com a disponibilidade geral do AWS Glue Data Quality:

- A capacidade de identificar quais registros não foram aprovados nas verificações de qualidade de dados agora é compatível com o AWS Glue Studio
- Novos tipos de regras de qualidade de dados, como validação da integridade referencial de dados entre dois conjuntos de dados, comparação de dados entre dois conjuntos de dados e verificações de tipos de dados
- Experiência de usuário aprimorada no AWS Glue Data Catalog
- Compatibilidade com o Apache Iceberg, o Apache Hudi e o Delta Lake
- Compatibilidade com o Amazon Redshift
- Notificação simplificada com o Amazon EventBridge
- Compatibilidade com o AWS CloudFormation para criação de conjuntos de regras
- Melhorias no performance: opção de armazenamento em cache em ETL e no AWS Glue Studio para uma performance mais rápida ao avaliar a qualidade dos dados

27 de novembro de 2023 (pré-visualização)

- Os recursos de detecção de anomalias com tecnologia ML agora estão disponíveis no AWS Glue ETL e AWS Glue Studio. Com isso, agora é possível detectar anomalias e problemas de qualidade de dados difíceis de detectar
- As regras dinâmicas permitem que você forneça limites dinâmicos (p. ex.: `RowCount > avg(last(10))`)

12 de março de 2024

- Melhorias em DQDL
  - Suporte a palavras-chave como NULL, BLANKS, WHITESPACES_ONLY
  - Opções para especificar como a qualidade de dados do AWS Glue deve lidar com regras compostas
  - O tipo de regra ColumnValues não permitirá que valores NULL sejam passados durante comparações
  - Suporte ao operador NOT em DQDL

26 de junho de 2024

- Melhorias em DQDL
  - Agora, O DQDL agora é compatível com a cláusula where para que você possa filtrar dados antes de aplicar as regras do DQ

7 de agosto de 2024

- A detecção de anomalias e as regras dinâmicas já estão disponíveis ao público

22 de novembro de 2024

- Regras compostas complexas permitem que você crie regras de negócios mais complexas com suporte aninhado
- Novos tipos de regras para gerenciar a qualidade dos dados de seus arquivos
  - FileFreshness

  - FileSize
  - FileUniqueness
  - FileMatch
- Verificações de qualidade de dados padrão em trabalhos de Visual ETL

6 de dezembro de 2024

- O AWS Glue Data Quality agora oferece suporte a tabelas do Amazon SageMaker AI LakeHouse e tabelas do Iceberg, Delta e HUDI gerenciadas pelo AWS Lake Formation no AWS Glue ETL 5.0.

30 de junho de 2025

- Métricas agregadas: agora você pode obter métricas agregadas, como número de registros processados e falhas no nível da API para trabalhos de DQ baseados em ETL do AWS Glue.

Detecção de anomalias no AWS Glue Data Quality

Caso de machine learning no Data Quality

Os engenheiros gerenciam centenas de pipelines de dados ao mesmo tempo. Cada pipeline pode extrair dados de diferentes fontes e carregá-los no data lake ou em outros repositórios de dados. Para garantir a entrega de dados de alta qualidade para a tomada de decisões, eles estabelecem regras de qualidade de dados. Essas regras avaliam os dados com base em critérios fixos que refletem o estado atual dos negócios. No entanto, quando o ambiente de negócios muda, as propriedades dos dados também mudam, tornando esses critérios fixos desatualizados e resultando em baixa qualidade dos dados.

Por exemplo, um engenheiro de dados de uma empresa de varejo estabeleceu uma regra que valida que as vendas diárias devem exceder o limite de um milhão de dólares. Após alguns meses, as vendas diárias ultrapassaram dois milhões de dólares, tornando o limite obsoleto. Devido à ausência de notificação e ao esforço necessário para analisar e atualizar manualmente a regra, o engenheiro de dados não conseguiu atualizar as regras para refletir os limites mais recentes. No final do mês, os usuários corporativos observaram uma queda de 25% em suas vendas. Após muitas horas de investigação, os engenheiros de dados descobriram que um pipeline de ETL responsável por extrair dados de algumas lojas havia falhado sem gerar erros. A regra com limites desatualizados continuou operando com sucesso e sem detectar esse problema.

Como alternativa, alertas proativos capazes de detectar essas anomalias poderiam ter permitido que os usuários detectassem esse problema. Além disso, o monitoramento da sazonalidade nos negócios pode destacar problemas significativos de qualidade de dados. Por exemplo, as vendas no varejo podem ser maiores nos finais de semana e durante as festas de fim de ano, enquanto relativamente baixas nos dias de semana. A divergência desse padrão pode indicar problemas de qualidade de dados ou mudanças nas condições comerciais. As regras de qualidade de dados não são capazes de detectar padrões sazonais, pois isso requer algoritmos avançados que possam aprender com padrões anteriores que capturam a sazonalidade para detectar desvios.

Por fim, os usuários acham difícil criar e manter regras devido à natureza técnica do processo de criação de regras e ao tempo necessário para criá-las. Como resultado, eles preferem explorar os insights de dados antes de definir as regras. Os clientes precisam ter a capacidade de detectar anomalias facilmente, viabilizando a detecção proativa de problemas de qualidade de dados e a tomada de decisão com confiança.

Como funciona

> **Note**
>
> A detecção de anomalias só é compatível com o processo de ETL do AWS Glue. Esse recurso não é compatível com qualidade de dados baseada no Catálogo de Dados.

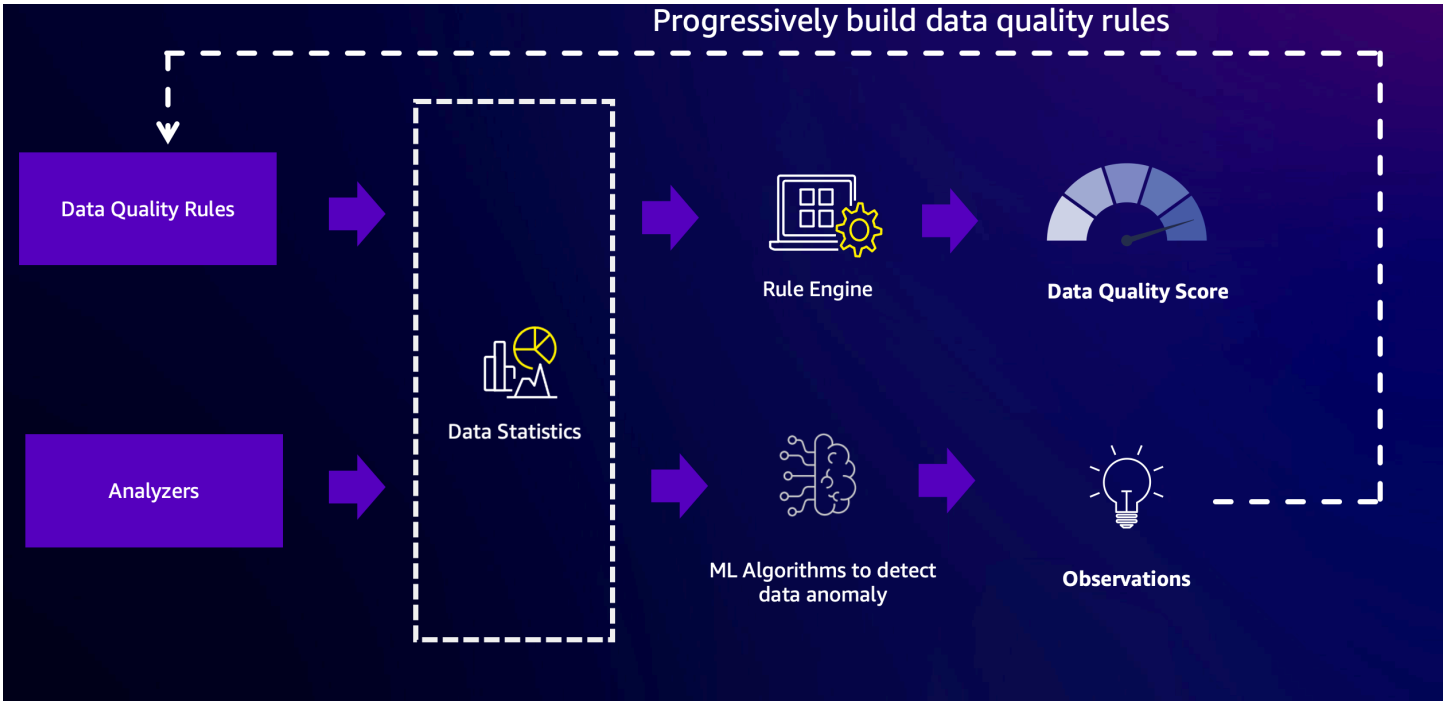

O AWS Glue Data Quality combina o poder da qualidade de dados baseada em regras e das capacidades de detecção de anomalias para fornecer dados de alta qualidade. Para começar, é necessário configurar regras e analisadores, e então habilitar a detecção de anomalias.

Regras

Regras: as regras expressam as expectativas para seus dados em uma linguagem aberta chamada de Data Quality Definition Language (DQDL). Veja um exemplo de regra abaixo. Essa regra será bem-sucedida quando não houver valores vazios ou NULL na coluna `passenger_count`:

```
Rules = [
    IsComplete "passenger_count"
]
```

Analisadores

Em situações nas quais você conheça as colunas críticas, mas talvez não saiba o suficiente sobre os dados para criar regras específicas, será possível monitorar essas colunas usando analisadores. Os analisadores são uma maneira de coletar estatísticas de dados sem definir regras explícitas. Veja um exemplo de configuração de analizadores abaixo:

```
Analyzers = [
AllStatistics "fare_amount",
DistinctValuesCount "pulocationid",
RowCount
]
```

Neste exemplo, há três analisadores configurados:

1. O primeiro analisador, `AllStatistics “fare_amount"`, capturará todas as estatísticas disponíveis para o campo `fare_amount`.
2. O segundo Analisador, `DistinctValuesCount “pulocationid"`, capturará a contagem de valores distintos na coluna `pulocationid`.
3. O terceiro analisador, `RowCount`, capturará o número total de registros no conjunto de dados.

Os analisadores são uma maneira simples de coletar estatísticas de dados relevantes sem especificar regras complexas. Ao monitorar essas estatísticas, você pode obter insights sobre a qualidade dos dados e identificar possíveis problemas ou anomalias que possam exigir uma investigação mais aprofundada ou a criação de regras específicas.

Estatísticas de tabela

Tanto os analisadores quanto as regras no AWS Glue Data Quality coletam estatísticas de dados, também conhecidas como perfis de dados. Essas estatísticas fornecem insights sobre as características e a qualidade dos seus dados. As estatísticas coletadas são armazenadas ao longo do tempo no serviço AWS Glue, permitindo que você acompanhe e analise as alterações em seus perfis de dados.

Invocando as APIs adequadas, é possível recuperar facilmente essas estatísticas e gravá-las no Amazon S3 para análise adicional ou armazenamento de longo prazo. Essa funcionalidade permite integrar a criação de perfis de dados aos seus fluxos de trabalho de processamento de dados e aproveitar as estatísticas coletadas para vários fins, como monitoramento da qualidade dos dados e detecção de anomalias.

Ao armazenar os perfis de dados no Amazon S3, você pode aproveitar a escalabilidade, durabilidade e economia do serviço de armazenamento de objetos da Amazon. Além disso, você pode aproveitar outros serviços da AWS ou ferramentas de terceiros para analisar e visualizar os perfis de dados, permitindo que você obtenha insights mais profundos sobre a qualidade dos dados e tome decisões informadas sobre gerenciamento e governança de dados.

Veja um exemplo das estatísticas de dados armazenadas ao longo do tempo.

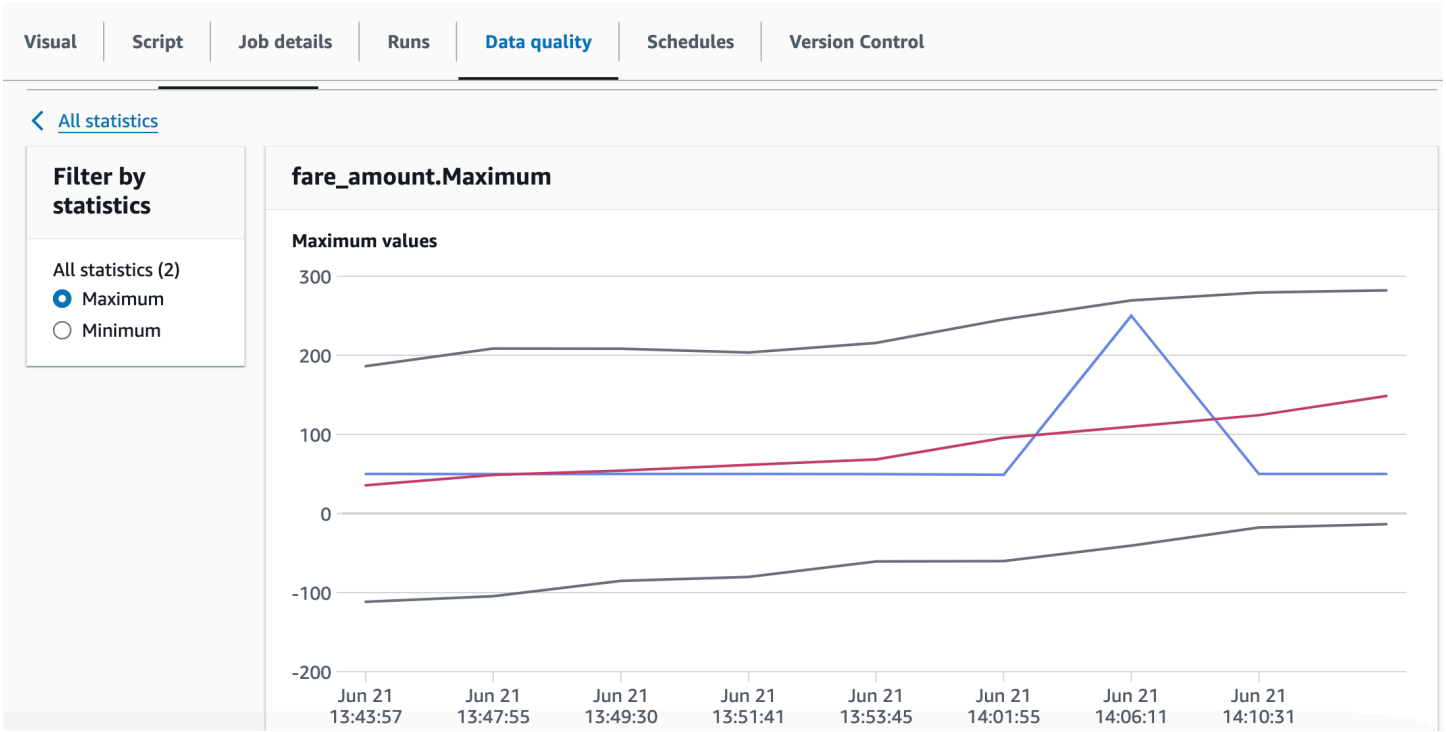

> **Note**
>
> O AWS Glue Data Quality coletará estatísticas apenas uma vez, mesmo que você tenha a regra e o analisador para as mesmas colunas, tornando eficiente o processo de geração de estatísticas.

Detecção de anomalias

Para detectar anomalias, o AWS Glue Data Quality requer um mínimo de três pontos de dados. Ele utiliza um algoritmo de machine learning para aprender com as tendências passadas e, em seguida, prever valores futuros. Quando o valor efetivo não estiver dentro da faixa prevista, o AWS Glue Data Quality criará uma observação de anomalias. Isso disponibilizará uma representação visual do valor efetivo e das tendências. Há quatro valores exibidos no gráfico abaixo.

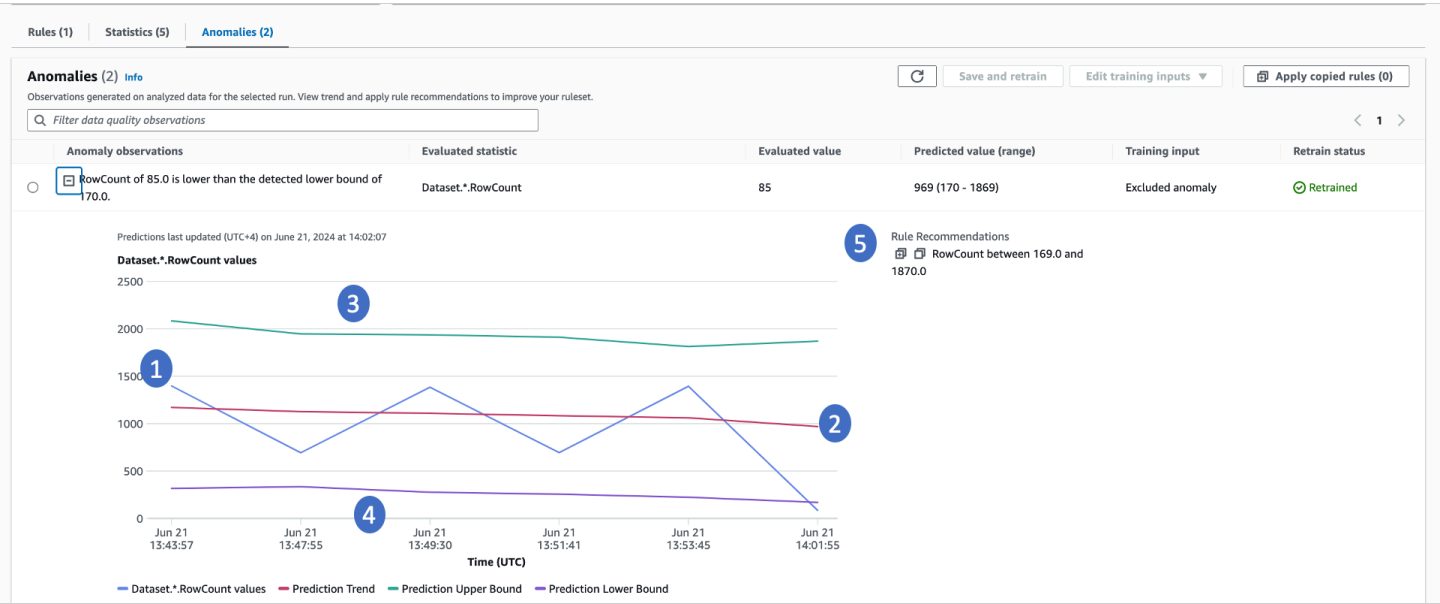

1. A estatística efetiva e sua tendência ao longo do tempo.
2. Uma tendência derivada do aprendizado com a tendência efetiva. Isso é útil para entender a direção da tendência.
3. O possível limite superior para a estatística.
4. O possível limite inferior para a estatística.
5. Regras de qualidade de dados recomendadas capazes de detectar esses problemas no futuro.

Há algumas coisas importantes a serem observadas em relação às anomalias:

- Quando há a geração de anomalias, as pontuações de qualidade dos dados não são afetadas.
- Quando há a detecção de uma anomalia, ela é considerada normal para execuções subsequentes. A menos que esse valor anômalo seja explicitamente excluído, o algoritmo de machine learning o considerará como uma entrada.

Retreinamento

É fundamental retreinar o modelo de detecção de anomalias para detectar as anomalias corretas. Quando há a detecção de anomalias, o AWS Glue Data Quality inclui a anomalia no modelo como um valor normal. Para garantir que a detecção de anomalias funcione com precisão, é importante fornecer feedback reconhecendo ou rejeitando a anomalia. AWS O Glue Data Quality fornece mecanismos no AWS Glue Studio e nas APIs para fornecer feedback ao modelo. Para saber mais, consulte a documentação sobre como configurar a Anomaly Detection in AWS Glue ETL pipelines.

Detalhes do algoritmo de detecção de anomalias

- O algoritmo de detecção de anomalias examina as estatísticas dos dados ao longo do tempo. O algoritmo considera todos os pontos de dados disponíveis e ignora todas as estatísticas que tenham sido explicitamente excluídas.
- Essas estatísticas de dados são armazenadas no serviço AWS Glue e você pode fornecer chaves do AWS KMS para criptografá-las. Consulte o Guia de segurança para saber como fornecer chaves do AWS KMS para criptografar as estatísticas do AWS Glue Data Quality.
- O componente de tempo é crucial para o algoritmo de detecção de anomalias. O AWS Glue Data Quality determina os limites superior e inferior com base nos valores anteriores. Durante essa determinação, ele considera o componente de tempo. Os limites serão diferentes para os mesmos valores em um intervalo de 1 minuto, um intervalo de 1 hora ou um intervalo diário.

Captura da sazonalidade

O algoritmo de detecção de anomalias do AWS Glue Data Quality pode capturar padrões sazonais. Por exemplo, ele pode entender que os padrões dos dias da semana são diferentes dos padrões dos finais de semana. É possível ver isso no exemplo abaixo, no qual o AWS Glue Data Quality detecta uma tendência sazonal nos valores dos dados. Você não precisa fazer nada específico para habilitar essa capacidade. Com o tempo, o AWS Glue Data Quality aprende tendências sazonais e detecta anomalias quando esses padrões deixam de existir.

Custo

Você receberá cobranças com base no tempo necessário para detectar anomalias. Cada estatística recebe a cobrança de 1 DPU para o tempo necessário para a detecção de anomalias. Consulte Definição de preço do AWS Glue para ver exemplos detalhados.

Considerações importantes

Não há custo para armazenar as estatísticas. No entanto, há um limite de 100.000 estatísticas por conta. Essas estatísticas serão armazenadas por no máximo 2 anos.

Permissões do IAM para o AWS Glue Data Quality

Este tópico fornece informações para ajudar você a entender as ações e os recursos que podem ser usados em uma política do AWS Identity and Access Management (IAM) para o AWS Glue Data Quality. Inclui também exemplos de políticas do IAM com as permissões mínimas necessárias para usar o AWS Glue Data Quality com o AWS Glue Data Catalog.

Para obter mais informações sobre grupos de segurança no AWS Glue, consulte Segurança no AWS Glue.

Permissões do IAM para o AWS Glue Data Quality

A tabela a seguir lista as permissões de que um usuário precisa para realizar operações específicas do AWS Glue Data Quality. Para definir uma autorização refinada para o AWS Glue Data Quality, você pode especificar essas ações no elemento `Action` de uma instrução de política do IAM.

Ações do AWS Glue Data Quality

Ação	Descrição	Tipos de recursos
`glue:CreateDataQualityRuleset`	Concede permissão para criar um conjunto de regras de qualidade de dados.	`::dataQualityRuleset/<name>`
`glue:DeleteDataQualityRuleset`	Concede permissão para excluir um conjunto de regras de qualidade de dados.	`::dataQualityRuleset/<name>`
`glue:GetDataQualityRuleset`	Concede permissão para recuperar um conjunto de regras de qualidade de dados.	`::dataQualityRuleset/<name>`
`glue:ListDataQualityRulesets`	Concede permissão para recuperar todos os conjunto de regras de qualidade de dados.	`::dataQualityRuleset/*`
`glue:UpdateDataQualityRuleset`	Concede permissão para atualizar um conjunto de regras de qualidade de dados.	`::dataQualityRuleset/<name>`
`glue:GetDataQualityResult`	Concede permissão para recuperar um resultado de execução de tarefa de qualidade de dados. Essa ação do IAM também fornece permissões para as seguintes APIs:	`::dataQualityRuleset/<name>`

Ação	Descrição	Tipos de recursos
	• BatchGetDataQualityQualityResult • ListDataQualityStatistics • ListDataQualityStatisticAnnotations	
glue:ListDataQualityResults	Concede permissão para recuperar todos os resultados de execução de tarefas de qualidade de dados.	::dataQualityRuleset/*
glue:CancelDataQualityRuleRecommendationRun	Concede permissão para interromper uma execução de tarefa de recomendação de qualidade de dados em andamento.	::dataQualityRuleset/*
glue:GetDataQualityRuleRecommendationRun	Concede permissão para recuperar uma execução de tarefa de recomendação de qualidade de dados.	::dataQualityRuleset/*
glue:ListDataQualityRuleRecommendationRuns	Concede permissão para recuperar todas as execuções de tarefas de recomendação de qualidade de dados.	::dataQualityRuleset/*
glue:StartDataQualityRuleRecommendationRun	Concede permissão para iniciar uma execução de tarefa de recomendação de qualidade de dados.	::dataQualityRuleset/*

Ação	Descrição	Tipos de recursos
glue:CancelDataQualityRulesetEvaluationRun	Concede permissão para interromper uma execução de recomendação de tarefa de qualidade de dados em andamento.	::dataQualityRuleset/*
glue:GetDataQualityRulesetEvaluationRun	Concede permissão para recuperar uma execução de uma tarefa de qualidade de dados.	::dataQualityRuleset/*
glue:ListDataQualityRulesetEvaluationRuns	Concede permissão para recuperar todas as execuções de tarefas de qualidade de dados.	::dataQualityRuleset/*
glue:StartDataQualityRulesetEvaluationRun	Concede permissão para iniciar uma execução de tarefa de qualidade de dados.	::dataQualityRuleset/<name>
glue:PublishDataQuality	Concede permissão para publicar resultados de qualidade de dados.	::dataQualityRuleset/<name>
glue:GetDataQualityModel	Concede permissão para recuperar um modelo de qualidade de dados.	::dataQualityRuleset/<name>, ::job/<name>
glue:GetDataQualityModelResult	Concede permissão para recuperar resultados de um modelo de qualidade de dados.	::dataQualityRuleset/<name>, ::job/<name>

Ação	Descrição	Tipos de recursos
`glue:PutDataQualityStatisticAnnotation`	Concede permissão para adicionar anotações às Estatísticas. Essa ação do IAM também fornece permissões para as seguintes APIs: • `BatchPutDataQualityStatisticAnnotation`	`::dataQualityRuleset/<name>, ::job/<name>`
`glue:PutDataQualityProfileAnnotation`	Concede permissão para colocar anotações em todas as estatísticas em um perfil.	`::dataQualityRuleset/<name>, ::job/<name>`

A configuração do IAM é requerida para agendar execuções de avaliação

Permissões do IAM

Para que as execuções de avaliação da qualidade de dados agendadas sejam realizadas, você deve adicionar a ação `IAM:PassRole` à política de permissões.

Permissões do Agendador do AWS EventBridge requeridas

Ação	Descrição	Tipos de recursos
`iam:PassRole`	Concede permissão para o IAM a fim de permitir que o usuário passe os perfis aprovados.	ARN do perfil usado para chamar `StartDataQualityRulesetEvaluationRun`

Sem essas permissões, ocorre o seguinte erro:

```
"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"
```

Entidades confiáveis do IAM

Os serviços AWS Glue e Agendados do AWS EventBridge precisam estar listados nas entidades confiáveis para criar e executar uma `StartDataQualityEvaluationRun` agendada.

```
{
    "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"
        }
    ]
}
```

Políticas de exemplo do IAM

Um perfil do IAM para o AWS Glue Data Quality precisa dos seguintes tipos de permissões:

- Permissões para operações do AWS Glue Data Quality para que você possa obter as regras de qualidade de dados recomendadas e executar uma tarefa de qualidade de dados em uma tabela do AWS Glue Data Catalog. Os exemplos de políticas do IAM desta seção incluem as permissões mínimas necessárias para as operações do AWS Glue Data Quality.
- Permissões que concedem acesso à tabela do Data Catalog aos dados subjacentes. Essas permissões variam dependendo do caso de uso. Por exemplo, para dados que você cataloga no Amazon S3, as permissões devem incluir acesso ao Amazon S3.

> **Note**
>
> Você deve configurar as permissões do Amazon S3 além das descritas nesta seção.

Permissões mínimas para obter as regras de qualidade de dados recomendadas

Esse exemplo de política inclui as permissões necessárias para gerar as regras de qualidade de dados recomendadas.

```
{
  "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": "*"
    },
  ]
}
```

Permissões mínimas para executar uma tarefa de qualidade de dados

Esse exemplo de política inclui as permissões necessárias para executar a tarefa de avaliação de qualidade de dados.

As seguintes instruções da política são opcionais dependendo do caso de uso:

- `AllowCloudWatchPutMetricDataToPublishTaskMetrics`: obrigatório se você quiser publicar métricas de execução de qualidade de dados no Amazon CloudWatch.
- `AllowS3PutObjectToWriteTaskResults`: obrigatório se você quiser gravar resultados de execução de qualidade de dados no 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>/*"
```

```
    }
  ]
}
```

Permissões mínimas para executar um trabalho de qualidade de dados

Esse exemplo de política inclui as permissões necessárias para executar um trabalho de ETL de qualidade de dados.

```
{
  "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}"
      ]
    }
}
```

Introdução ao AWS Glue Data Quality para o Data Catalog

Esta seção de introdução fornece instruções para ajudar você a começar a usar o AWS Glue Data Quality no console da AWS Glue. Você aprenderá a realizar as tarefas essenciais, como gerar recomendações de regras de qualidade de dados e avaliar um conjunto de regras em relação aos seus dados.

Tópicos

- Pré-requisitos
- Exemplo passo a passo
- Gerar recomendações de regras
- Monitorar recomendações de regras
- Editar conjuntos de regras recomendadas
- Criar um conjunto de regras
- Como executar um conjunto de regras para avaliar a qualidade de dados
- Como visualizar o índice de qualidade de dados e os resultados
- Tópicos relacionados

Pré-requisitos

Antes de usar o AWS Glue Data Quality, você deve estar familiarizado com o uso do Data Catalog e de crawlers no AWS Glue. Com o AWS Glue Data Quality, você pode avaliar a qualidade das tabelas em um banco de dados do Data Catalog. Você precisará dos seguintes itens:

- Uma tabela do Data Catalog para avaliar segundo o conjunto de regras de qualidade de dados.
- Um perfil do IAM para o AWS Glue Glue, que você fornece quando gera recomendações de regras ou executa uma tarefa de qualidade de dados. Esse perfil deve ter permissão para acessar os recursos que vários processos do AWS Glue Data Quality exigem para realizar a execução em seu nome. Esses recursos incluem o AWS Glue, o Amazon S3 e o CloudWatch. Para ver exemplos de políticas que incluem as permissões mínimas para o AWS Glue Data Quality, consulte Políticas de exemplo do IAM.

  Para saber mais sobre perfis do IAM para o AWS Glue, consulte Create an IAM policy for the AWS Glue service eCreate an IAM role for the AWS Glue service. Você também pode ver uma lista de todas as permissões do AWS Glue que são específicas para qualidade de dados em Authorization for AWS Glue Data Quality actions.
- Um banco de dados com pelo menos uma tabela que contém uma variedade de dados. A tabela usada neste tutorial é denominada `yyz-tickets`, com a tabela `tickets`. Esses dados são uma coleção de informações publicamente disponíveis da cidade de Toronto para multas de estacionamento. Se você criar sua própria tabela, certifique-se de que ela esteja preenchida com uma variedade de dados válidos para obter o melhor conjunto de regras recomendadas.

Exemplo passo a passo

Para ver um exemplo passo a passo com conjuntos de dados de amostra, consulte a postagem do blog sobre o AWS Glue Data Quality.

Gerar recomendações de regras

As recomendações de regras tornam mais fácil começar a trabalhar com qualidade de dados sem precisar escrever código. O AWS Glue Data Quality analisa os dados, identifica as regras e cria um conjunto de regras que você pode avaliar em uma tarefa de qualidade de dados. As execuções de recomendação são excluídas automaticamente após 90 dias.

Para gerar recomendações de regras de qualidade de dados

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, selecione Tables (Tabelas). Em seguida, selecione a tabela para a qual deseja gerar recomendações de regras de qualidade de dados.
3. Na página de detalhes da tabela, selecione a guia Qualidade dos dados para acessar as regras e as configurações do AWS Glue Data Quality para a tabela.

4. Na guia Qualidade dos dados, escolha Adicionar regras e monitorar a qualidade dos dados.
5. Na página Criador de conjuntos de regras, um alerta na parte superior da página solicitará que você inicie uma tarefa de recomendação se não houver nenhuma execução de recomendação de regra.
6. Escolha Recomendar regras para abrir o modal e inserir os parâmetros para a tarefa de recomendação.
7. Escolha um perfil do IAM com acesso ao AWS Glue. Esse perfil deve ter permissão para acessar os recursos que vários processos do AWS Glue Data Quality exigem para realizar a execução em seu nome.
8. Depois que os campos forem preenchidos de acordo com suas preferências, escolha Recomendar regras para iniciar a execução da tarefa de recomendação. Se as execuções de recomendação estiverem em andamento ou tiverem sido concluídas, você poderá gerenciar as execuções neste alerta. Talvez seja necessário atualizar o alerta para ver a alteração de status. As execuções de tarefas de recomendação concluídas e em andamento aparecem na página Histórico de execução, que lista todas as execuções de recomendação dos últimos 90 dias.

O que significam as regras recomendadas

O AWS Glue Data Quality gera regras com base nos dados de cada coluna da tabela de entrada. Ele usa as regras para identificar possíveis limites nos quais os dados podem ser filtrados para manter os requisitos de qualidade. A lista de regras geradas a seguir inclui exemplos que são úteis para entender o que as regras significam e o que elas podem fazer quando aplicadas aos dados.

Para obter uma lista completa dos tipos de regras em Data Quality Definition Language (DQDL) gerados, consulte a referência de tipos de regras de DQDL.

- `IsComplete "SET_FINE_AMOUNT"`: a regra `IsComplete` verifica se a coluna está preenchida para qualquer linha dada. Use essa regra para marcar colunas como não opcionais nos dados.
- `Uniqueness "TICKET_NUMBER" > 0.95`: a `Uniqueness` regra verifica se os dados dentro da coluna atendem a algum limite de exclusividade. Neste exemplo, foi determinado que os dados que preenchem qualquer linha dada para `"TICKET_NUMBER"` têm, no máximo, 95% de conteúdo idêntico a todas as outras linhas, o que sugere essa regra.
- `ColumnValues "PROVINCE" in ["ON", "QC", "AB", "NY",...]`: a regra `ColumnValues` define valores válidos para a coluna, com base no conteúdo existente da coluna. Neste exemplo, os dados de cada linha são uma placa de código de licença de 2 letras para um estado ou província.

- `ColumnLength "INFRACTION_DESCRIPTION" between 15 and 31`: a regra `ColumnLength` impõe uma restrição de tamanho aos dados de uma coluna. Essa regra é gerada a partir dos dados de amostra com base nos comprimentos mínimo e máximo registrados para uma coluna de strings.

Monitorar recomendações de regras

Quando as recomendações de regras de qualidade de dados estão em execução, a página Adicionar regras e monitorar a qualidade de dados exibe informações e ações adicionais que você pode realizar na barra superior.

Quando as recomendações de regras estão em andamento, você pode escolher Parar a execução antes que a tarefa de recomendação seja concluída. Enquanto a tarefa estiver em andamento, você verá o status, em andamento e a data e a hora em que a execução começou.

Quando as recomendações de regras forem concluídas, a barra de recomendação de regras exibirá o número de regras recomendadas, o status da última execução da recomendação e a data e o timestamp em que ela foi concluída.

Você pode adicionar as regras recomendadas escolhendo Inserir recomendação de regra. Para ver as regras recomendadas anteriormente, selecione uma data específica. Para executar uma nova recomendação, escolha Mais ações e depois Regras recomendadas.

Defina as configurações padrão escolhendo Gerenciar configurações do usuário. Você pode definir o caminho padrão para o Amazon S3 armazenar conjuntos de regras ou configurar uma função padrão para executar o catálogo de dados.

Editar conjuntos de regras recomendadas

Como o AWS Glue Data Quality gera regras com base nos dados existentes que você tem disponíveis, é possível ver algumas regras inesperadas ou indesejáveis nas sugestões automatizadas. Para tirar o máximo proveito dos conjuntos de regras recomendadas, você precisa avaliá-los e modificá-los. Nesta etapa do tutorial, você toma as regras geradas na etapa anterior e as ajusta para impor qualidades mais restritivas a alguns dados. Você também relaxa outras regras para garantir que dados corretos e exclusivos possam ser adicionados posteriormente.

Editar um conjunto de regras sugeridas

1. No console do AWS Glue, escolha Catálogo de dados no painel de navegação e depois Adicionar banco de dados. Selecione a tabela `tickets`.
2. Na página de detalhes da tabela, escolha a guia Qualidade dos dados para acessar as regras e as configurações do AWS Glue Data Quality para a tabela.
3. Na seção Conjuntos de regras, selecione o conjunto de regras gerado em Gerar recomendações de regras.
4. Escolha Ações e depois escolha Editar na janela do console. O editor do conjunto de regras é carregado no console. Ele inclui um painel de edição para as regras e uma referência rápida de DQDL.
5. Remova a linha 2 do script. Isso relaxa a exigência de que o tamanho do banco de dados seja restrito a um determinado número de linhas. Após a edição, o arquivo deve conter o seguinte nas linhas de 1 a 3:

```
Rules = [
    IsComplete "TAG_NUMBER_MASKED",
    ColumnLength "TAG_NUMBER_MASKED" between 6 and 9,
```

6. Remova a linha 25 do script. Isso relaxa a exigência de que 96% das províncias registradas sejam ON. Após a edição, o arquivo deve conter o seguinte, da linha 24 até o final do conjunto de regras:

```
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
]
```

7. Altere a linha 14 para o seguinte:

```
IsComplete "TIME_OF_INFRACTION",
```

Isso reforça a exigência na coluna, limitando o banco de dados apenas a multas que contenham a hora da infração registrada. Você deve sempre considerar as multas cuja hora da infração não

está registrada como dados inválidos nesse conjunto de dados. Isso é diferente de situações em que o particionamento ou a transformação podem ser mais apropriados para uso ou inspeção adicional de dados para determinar uma regra de qualidade.

8. Escolha Atualizar conjunto de regras na parte inferior da página do console.

Criar um conjunto de regras

Um conjunto de regras é um grupo de regras de qualidade de dados que você avalia em relação aos seus dados. No console do AWS Glue, você pode criar conjuntos de regras personalizados usando Data Quality Definition Language (DQDL).

Para criar um conjunto de regras de qualidade de dados

1. No console do AWS Glue, escolha Catálogo de dados, Bancos de dados e depois Tabelas no painel de navegação. Selecione a tabela `tickets`.
2. Abra a guia Data quality (Qualidade de dados).
3. Na seção Regras, escolha Criar regra). O editor DQDL é iniciado no console. Ele tem uma área de texto para edição direta e uma referência rápida para as regras do DQDL e o esquema da tabela.
4. Comece a adicionar regras à área de texto do editor DQDL. Você pode escrever as regras diretamente deste tutorial ou usar o atributo de criação de regras Criador de regras DQDL do editor de regras de qualidade de dados.

> **Note**
>
> Como usar o criador de regras DQDL
>
> 1. Selecione um tipo de regra na lista e o sinal de adição para inserir um exemplo de sintaxe no painel do editor.
> 2. Troque os nomes das colunas do espaço reservado por seus próprios nomes de coluna. Os nomes das colunas da tabela estão disponíveis na guia Esquema.
> 3. Atualize o parâmetro de expressão conforme desejar. Para obter uma lista completa de expressões compatíveis com DQDL, consulte Expressões.

Como exemplo, as regras a seguir são restrições para a validação de dados da coluna `ticket_number` na tabela `tickets`. Para adicionar as seguintes regras, use o criador de regras DQDL ou edite diretamente o conjunto de regras:

```
IsComplete "ticket_number",
IsUnique "ticket_number",
ColumnValues "ticket_number" > 9000000000
```

5. Forneça um nome para o novo conjunto de regras no campo Nome do conjunto de regras.
6. Escolha Salvar conjunto de regras.

Avaliar a qualidade dos dados em vários conjuntos de dados

Você pode configurar regras de qualidade de dados em vários conjuntos de dados usando os conjuntos de regras ReferentialIntegrity e DatasetMatch. ReferentialIntegrity verifica se os dados no conjunto de dados primário estão presentes em outros conjuntos de dados.

Para adicionar um conjunto de dados de referência, escolha a guia Esquema e depois Atualizar tabelas de referência. Será solicitado que você selecione um banco de dados e uma tabela. Você pode adicionar a tabela e depois configurar as regras de qualidade dos dados. Tipos de regras como AggregateMatch, RowCountMatch, ReferentialIntegrity, SchemaMatch, and DatasetMatch ofesão compatíveis com a capacidade de executar verificações de qualidade de dados em vários conjuntos de dados.

Como executar um conjunto de regras para avaliar a qualidade de dados

Quando você executa uma tarefa de qualidade de dados, o AWS Glue Data Quality avalia um conjunto de regras em relação aos seus dados e calcula uma pontuação de qualidade de dados. A pontuação representa a porcentagem de regras de qualidade de dados aprovadas para os dados fornecidos.

Para executar uma tarefa de qualidade de dados

1. No console do AWS Glue, escolha Catálogo de dados, Bancos de dados e depois Tabelas no painel de navegação. Selecione a tabela `tickets`.
2. Escolha a guia Qualidade de dados.

3. Na lista Conjuntos de regras, escolha o conjunto de regras segundo as quais você deseja avaliar a tabela. Para esta etapa, recomendamos usar um conjunto de regras que você já tenha escrito ou modificado, em vez de regras geradas. Escolha Executar.
4. No modal, escolha seu perfil do IAM. Esse perfil deve ter permissão para acessar os recursos que vários processos do AWS Glue Data Quality exigem para realizar a execução em seu nome. Você pode salvar o perfil do IAM como padrão ou modificá-lo acessando a página Configuração padrão.
5. Em Data quality actions (Ações de qualidade de dados), escolha se você deseja Publish metrics to Amazon CloudWatch. (Publicar métricas no Amazon CloudWatch). Quando essa opção está selecionada, o AWS Glue Data Quality publica métricas que indicam o número de regras aprovadas e o número de regras reprovadas. Para atuar sobre as métricas armazenadas dessa forma, você pode usar os alarmes do CloudWatch. As principais métricas também são publicadas no Amazon EventBridge para você configurar alertas. Para obter mais informações, consulte Configurar alertas, implantações e agendamentos.
6. Em Frequência de execução, escolha executar sob demanda ou agende o conjunto de regras. Ao agendar um conjunto de regras, é solicitado a você um nome de tarefa. A agenda será criada no Amazon EventBridge. Você pode editar sua agenda no Amazon EventBridge.
7. Para salvar os resultados de qualidade dos dados no Amazon S3, escolha um Local para os resultados de qualidade de dados. O perfil do IAM que você selecionou anteriormente para essa tarefa deve ter acesso de gravação ao local escolhido.
8. Em Configurações adicionais, insira o Número necessário de operadores que você deseja que o AWS Glue aloque para a tarefa de qualidade de dados.
9. Opcionalmente, você pode configurar um filtro na fonte de dados. Isso ajuda a reduzir os dados que você está lendo. Você também pode usar um filtro para executar validações incrementais selecionando as informações da partição e passando-as como parâmetros por meio de chamadas de API. Para melhorar a performance, você pode fornecer um predicado de partição.
10. Escolha Executar. Você deve ver a nova tarefa na lista Data quality task runs (Execuções de tarefas de qualidade de dados). Quando a coluna Status da execução da tarefa for exibida como Concluída, você poderá visualizar os resultados da pontuação de qualidade. Pode ser necessário atualizar a janela do console para que o status seja atualizado corretamente.
11. Para visualizar a coluna dos detalhes do resultado da qualidade dos dados, escolha o ícone “+” para expandir o conjunto de regras. Os resultados mostram as regras em que as regras foram aprovadas e reprovadas na avaliação e o que causou a reprovação da regra.

Como visualizar o índice de qualidade de dados e os resultados

Para ver a última execução em todos os conjuntos de regras criados

1. No console do AWS Glue, escolha Tables (Tabelas) no painel de navegação. Em seguida, selecione a tabela para a qual deseja executar uma tarefa de qualidade de dados.
2. Escolha a guia Qualidade de dados.
3. O resumo da qualidade de dados mostra uma tendência geral das execuções ao longo do tempo. As últimas 10 execuções em todos os conjuntos de regras são exibidas por padrão. Para filtrar por conjunto de regras, selecione o conjunto desejado na lista suspensa. Se houver menos de 10 execuções, todas as execuções concluídas disponíveis serão exibidas.
4. Na tabela Qualidade de dados, cada conjunto de regras com sua última execução (se houver) é mostrado, junto com a pontuação. A expansão do conjunto de regras exibe as regras que estão nesse conjunto de regras, junto com os resultados da regra na execução.

Para ver a última execução de um conjunto de regras específico

1. No console do AWS Glue, escolha Tables (Tabelas) no painel de navegação. Em seguida, selecione a tabela para a qual deseja executar uma tarefa de qualidade de dados.
2. Escolha a guia Qualidade de dados.
3. Na tabela Qualidade de dados, escolha um conjunto de regras específico.
4. Na página de Detalhes do conjunto de regras, escolha a guia Histórico de execuções.

   Todas as execuções de avaliação desse conjunto de regras específico estão listadas na tabela dessa guia. Você pode ver o histórico das pontuações e o status das execuções.
5. Para ver mais informações sobre uma execução específica, escolha a ID da execução para acessar a página Detalhes da execução de avaliação. Nessa página, você pode ver detalhes específicos sobre a execução e mais detalhes sobre o status dos resultados de regras individuais.

Tópicos relacionados

- Referência de tipos de regra DQDL
- Referência de Data Quality Definition Language (DQDL)

Avaliar qualidade de dados com o AWS

O AWS Glue Data Quality avalia e monitora a qualidade dos dados com base em regras que você define. Isso facilita a identificação dos dados que precisam de ação. No AWS Glue Studio, você pode adicionar nós de qualidade de dados ao trabalho visual para criar regras de qualidade de dados em tabelas no catálogo de dados. Você poderá, então, monitorar e avaliar as alterações nos conjuntos de dados à medida que eles evoluírem ao longo do tempo. Para obter uma visão geral de como trabalhar com a qualidade de dados do AWS Glue no AWS Glue Studio, veja o vídeo a seguir.

A seguir estão as etapas de alto nível de como você trabalha com o AWS Glue Data Quality:

1. Criar regras de qualidade de dados: compile um conjunto de regras de qualidade de dados usando o compilador DQDL escolhendo conjuntos de regras integrados que você configura.
2. Configurar um trabalho de qualidade de dados: defina ações com base nos resultados de qualidade de dados e nas opções de saída.
3. Salvar e executar um trabalho com qualidade de dados: criar e executar um trabalho. Salvar o trabalho salvará os conjuntos de regras que você criou para o trabalho.
4. Monitorar e analisar os resultados de qualidade dos dados: analise os resultados da qualidade dos dados após a conclusão da execução do trabalho. Opcionalmente, agende o trabalho para uma data futura.

Benefícios

Analistas de dados, engenheiros de dados e cientistas de dados podem usar o nó Evaluate Data Quality no AWS Glue Studio para analisar, configurar, monitorar e melhorar a qualidade dos dados do editor de trabalho visual. Os benefícios de usar o nó de qualidade de dados incluem:

- Você pode detectar problemas de qualidade de dados: você pode verificar problemas criando regras que verificam as características dos seus conjuntos de dados.
- É fácil começar: você pode começar com regras e ações pré-construídas.
- Integração perfeita: você pode usar nós de qualidade de dados no AWS Glue Studio porque o AWS Glue Data Quality é executado em cima do catálogo de dados do AWS Glue.

Avaliar a qualidade dos dados para trabalhos de ETL no AWS Glue Studio

Neste tutorial, você começa a usar o AWS Glue Data Quality no AWS Glue Studio. Você aprenderá a fazer o seguinte:

- Criar regras usando o compilador de regras da Data Quality Definition Language (DQDL).
- Especificar ações de qualidade de dados, dados a serem produzidos e o local de saída dos resultados de qualidade de dados.
- Analisar os resultados de qualidade dos dados.

Para praticar com um exemplo, revise a postagem do blog Getting started with AWS Glue Data Quality for ETL pipelines.

Etapa 1: adicionar o nó de transformação Evaluate Data Quality à tarefa visual

Nesta etapa, você adiciona o nó Evaluate Data Quality à tarefa visual

Para adicionar o nó de qualidade de dados

1. No console Glue Studio do AWS, escolha Visual com origem e destino na seção Criar tarefa e, em seguida, escolha Criar.
2. Escolha um nó ao qual você deseja aplicar a transformação de qualidade de dados. Normalmente, isso será um nó de transformação ou uma fonte de dados.
3. Abra o painel de recursos à esquerda escolhendo o ícone “+”. Em seguida, procure Evaluate Data Quality na barra de pesquisa e escolha Evaluate Data Quality nos resultados da pesquisa.
4. O editor visual de tarefas mostrará a ramificação do nó de transformação Evaluate Data Quality a partir do nó selecionado. No lado direito do console, a guia Transform (Transformar) é aberta automaticamente. Se você precisar alterar o nó principal, escolha a guia Propriedades do nó e, em seguida, escolha o nó principal no menu suspenso.

   Quando você escolhe um novo nó principal, uma nova conexão é feita entre o nó superior e o nó Evaluate Data Quality (Avaliar qualidade dos dados). Remova todos os nós principais indesejados. Somente um nó principal pode ser conectado a um nó Evaluate Data Quality.
5. A transformação Evaluate Data Quality oferece suporte a vários pais para que você possa validar as regras de qualidade de dados em vários conjuntos de dados. As regras que oferecem suporte a vários conjuntos de dados incluem ReferentialIntegrity, DatasetMatch, SchemaMatch, RowCountMatch e AggregateMatch.

Ao adicionar várias entradas à transformação Evaluate Data Quality, você precisa selecionar sua entrada “primária”. Sua entrada principal é o conjunto de dados para o qual você deseja validar a qualidade dos dados. Todos os outros nós ou entradas são tratados como referências.

Você pode usar a transformação Evaluate Data Quality para identificar registros específicos que falharam nas verificações de qualidade dos dados. Recomendamos que você escolha seu conjunto de dados principal porque novas colunas que sinalizam registros incorretos são adicionadas ao conjunto de dados primário.

6. Você pode especificar aliases para fontes de dados de entrada. Os aliases fornecem outra forma de referenciar a fonte da entrada quando você está usando a regra ReferentialIntegrity. Como somente uma fonte de dados pode ser designada como fonte primária, cada fonte de dados adicional adicionada exigirá um alias.

   No exemplo a seguir, a regra ReferentialIntegrity especifica a fonte de dados de entrada pelo nome do alias e realiza uma comparação individual com a fonte de dados primária.

   ```
   Rules = [
    ReferentialIntegrity “Aliasname.name” = 1
   ]
   ```

Etapa 2: criar uma regra usando DQDL

Nesta etapa, você cria uma regra usando DQDL. Para este tutorial, você criará uma única regra usando o tipo de regra Completeness. Esse tipo de regra verifica a porcentagem de valores completos (não nulos) em uma coluna em relação a uma determinada expressão. Para obter mais informações sobre o uso de DQDL, consulte DQDL.

1. Na guia Transformar, adicione um tipo de regra clicando no botão Inserir. Isso adiciona o tipo de regra ao editor de regras, onde você pode inserir os parâmetros da regra.

   > **Note**
   >
   > Ao editar regras, verifique se as regras estão entre colchetes e certifique-se de que as regras estejam separadas por vírgulas. Por exemplo, uma expressão de regra completa terá a seguinte aparência:

```
Rules= [
    Completeness "year">0.8, Completeness "month">0.8
]
```

Este exemplo especifica o parâmetro de completude para as colunas denominadas 'ano' e 'mês'. Para que a regra seja aprovada, essas colunas devem estar mais de 80% 'completas' ou ter dados em mais de 80% das instâncias para cada coluna respectiva.

Neste exemplo, pesquise e insira o tipo de regra Completeness (Completude). Isso adiciona o tipo de regra ao editor de regras. Esse tipo de regra tem a seguinte sintaxe: `Completeness <COL_NAME> <EXPRESSION>`.

A maioria dos tipos de regras exige que você forneça uma expressão como parâmetro para criar uma resposta booleana. Para obter mais informações sobre expressões DQDL compatíveis, consulte Expressões DQDL. Em seguida, você adicionará o nome da coluna.

2. No compilador de regras DQDL, clique na guia Esquema. Use a barra de pesquisa para localizar o nome da coluna no esquema de entrada. O esquema de entrada exibe o nome da coluna e o tipo de dados.
3. No editor de regras, clique à direita do tipo de regra para inserir o cursor onde a coluna será inserida. Como alternativa, você pode digitar o nome da coluna na regra.

   Por exemplo, na lista de colunas na lista de esquemas de entrada, clique no botão Inserir ao lado da coluna (neste exemplo, ano). Isso adicionará a coluna à regra.
4. Em seguida, no editor de regras, adicione uma expressão para avaliar a regra. Como o tipo de regra Completeness verifica a porcentagem de valores completos (não nulos) em uma coluna em relação a uma determinada expressão, insira uma expressão como `> 0.8`. Essa regra verificará se a coluna tem mais de 80% de valores completos (não nulos).

Etapa 3: configurar saídas de qualidade de dados

Depois de criar regras de qualidade de dados, você pode selecionar opções adicionais para especificar a saída do nó de qualidade de dados.

1. Em Data quality transform output (Saída de transformação de qualidade de dados), escolha uma das seguintes opções:

   - Original data: escolha para saída dos dados de entrada originais. Quando você escolhe essa opção, um novo nó filho “rowLevelOutcomes” é adicionado ao trabalho. O esquema corresponde ao esquema do conjunto de dados primário que foi passado como entrada para a transformação. Essa opção é útil se você quiser apenas transmitir os dados e rejeitar o trabalho quando ocorrerem problemas de qualidade.

     Outro caso de uso é quando você deseja detectar registros incorretos que falharam nas verificações de qualidade dos dados. Para detectar registros incorretos, escolha a opção Adicionar novas colunas para indicar erros na qualidade dos dados. Essa ação adiciona quatro novas colunas ao esquema da transformação “rowLevelOutcomes”.

     - DataQualityRulesPass (matriz de strings): Fornece uma matriz de regras que passaram pelas verificações de qualidade dos dados.
     - DataQualityRulesFail (matriz de strings): Fornece uma matriz de regras que foram reprovadas pelas verificações de qualidade dos dados.
     - DataQualityRulesSkip (matriz de strings): Fornece uma matriz de regras que foram ignoradas. As regras a seguir não podem identificar registros de erro porque são aplicadas no nível do conjunto de dados.
       - AggregateMatch
       - ColumnCount
       - ColumnExists
       - ColumnNamesMatchPattern
       - CustomSql
       - RowCount
       - RowCountMatch
       - StandardDeviation
       - Média
       - ColumnCorrelation
     - DataQualityEvaluationResult: fornece o status “Aprovado” ou “Falha” no nível da linha. Observe que seu resultado geral pode ser FALHA, mas um determinado registro pode ser aprovado. Por exemplo, a regra RowCount pode ter falhado, mas todas as outras regras podem ter sido bem-sucedidas. Nesses casos, o status desse campo é “Aprovado”.

2. Resultados de qualidade dos dados: opte pela saída das regras configuradas e seu status de aprovação ou reprovação. Essa opção é útil se você quiser gravar seus resultados no Amazon S3 ou em outros bancos de dados.
3. Configurações de saída de qualidade de dados (Opcional): escolha Configurações de saída de qualidade de dados para revelar o campo Local do resultado da qualidade de dados. Em seguida, clique em Procurar para procurar um local do Amazon S3 para definir como objetivo de saída de qualidade de dados.

Etapa 4. Configurar ações de qualidade de dados

Você pode usar ações para publicar métricas do CloudWatch ou para interromper trabalhos com base em critérios específicos. As ações só estarão disponíveis depois que você criar uma regra. Quando você escolhe essa opção, as mesmas métricas também são publicadas no Amazon EventBridge. Você pode usar essas opções para criar alertas para notificação.

- Em caso de falha no conjunto de regras: você pode escolher o que fazer se um conjunto de regras falhar durante a execução do trabalho. Se você quiser que o trabalho falhe se a qualidade dos dados falhar, escolha quando o trabalho deve falhar selecionando uma das opções a seguir. Por padrão, essa ação não é selecionada e a tarefa concluirá sua execução mesmo se as regras de qualidade de dados falharem.
  - Nenhum: se você escolher Nenhum (padrão), o trabalho não falhará e continuará sendo executado apesar das falhas no conjunto de regras.
  - Falha na tarefa após carregar os dados no destino: a tarefa falha e nenhum dado é salvo. Para salvar os resultados, escolha um local do Amazon S3 onde os resultados de qualidade dos dados serão salvos.
  - Falha na tarefa sem carregar os dados de destino: essa opção causa falha na tarefa imediatamente quando ocorre um erro de qualidade de dados. Ela não carrega nenhum destino de dados, incluindo os resultados da transformação da qualidade dos dados.

Etapa 5: visualizar os resultados de qualidade dos dados

Depois de executar o trabalho, visualize os resultados de qualidade dos dados clicando na guia Qualidade dos dados.

1. Para cada trabalho executado, veja os resultados de qualidade dos dados. Cada nó exibe um status de qualidade de dados e detalhes de status. Clique em um nó para ver todas as regras e o status de cada regra.
2. Escolha Baixar resultados para baixar um arquivo CSV que contém informações sobre a execução do trabalho e os resultados da qualidade dos dados.
3. Se você tiver mais de uma execução de trabalho com resultados de qualidade de dados, poderá filtrar os resultados por intervalo de data e hora. Clique em Filtrar por um intervalo de data e hora para expandir a janela do filtro.
4. É possível escolher entre intervalo relativo e intervalo absoluto. Para intervalos absolutos, use o calendário para selecionar uma data e insira valores para hora de início e hora de término. Após terminar, escolha Aplicar.

Qualidade de dados automática

Quando você cria um trabalho de ETL do AWS Glue com o Amazon S3 como destino, o ETL do AWS Glue habilita automaticamente uma regra de qualidade de dados que verifica se os dados que estão sendo carregados têm pelo menos uma coluna. Essa regra foi desenvolvida para garantir que os dados que estão sendo carregados não estejam vazios ou corrompidos. No entanto, se essa regra falhar, o trabalho não falhará; em vez disso, você notará uma redução no seu índice de qualidade de dados. Além disso, a detecção de anomalias é ativada por padrão e monitora o número de colunas nos dados. Se houver alguma variação ou anormalidade na contagem de colunas, o ETL do AWS Glue informará você sobre essas anomalias. Esse recurso ajuda você a identificar possíveis problemas com os dados e a tomar as medidas apropriadas. Para visualizar a regra de qualidade de dados e sua configuração, é possível clicar no destino do Amazon S3 em seu trabalho de ETL do AWS Glue. A configuração da regra será exibida, conforme mostrado na captura de tela fornecida.

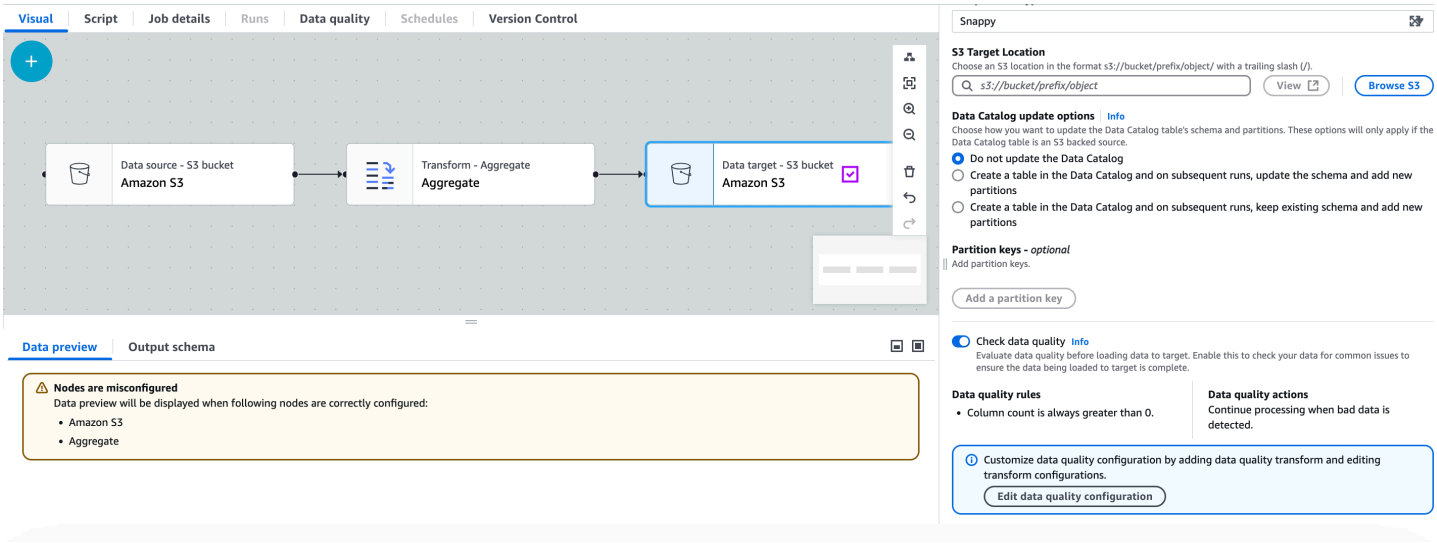

Você pode adicionar outras regras de qualidade de dados selecionando Editar configuração de qualidade de dados.

Métricas agregadas

Você pode exigir métricas agregadas, como o número de registros aprovados, reprovados ou ignorados no nível da regra ou no nível do conjunto de regras para criar painéis. Para obter as métricas agregadas e as métricas de regras para cada regra, primeiro habilite as métricas agregadas adicionando a opção `publishAggregatedMetrics` à sua função `EvaluateDataQuality`.

As opções possíveis para `additional_options` `publishAggregatedMetrics` são `ENABLED` e `DISABLED`. Exemplo:

```
EvaluateDataQualityMultiframe = EvaluateDataQuality().process_rows(
    frame=medicare_dyf,
    ruleset=EvaluateDataQuality_ruleset,
    publishing_options={
        "dataQualityEvaluationContext": "EvaluateDataQualityMultiframe",
        "enableDataQualityCloudWatchMetrics": False,
        "enableDataQualityResultsPublishing": False,
    },
    additional_options={"publishAggregatedMetrics.status": "ENABLED"},
)
```

Se não for especificado, o `publishAggregatedMetrics.status` é `DISABLED` por padrão, e as ruleMetrics e as métricas agregadas agora serão computadas. Esse atributo é atualmente suportado

nas sessões interativas do AWS Glue e nas tarefas de ETL do Glue. Isso não é suportado nas APIs do Glue Catalog Data Quality.

Recuperar resultados de métricas agregadas

Quando `additionalOptions` for `"publishAggregatedMetrics.status": "ENABLED"`, você poderá obter os resultados em dois lugares:

1. `AggregatedMetrics` e `RuleMetrics` são retornados por meio do `GetDataQualityResult()` ao fornecer o `resultId` onde `AggregatedMetrics` e `RuleMetrics` incluem:

   Métricas agregadas:

   - Total de linhas processadas
   - Total de linhas processadas
   - Total de linhas com falha
   - Total de regras processadas
   - Total de regras aprovadas
   - Total de regras com falha

```
[redacted] % aws --region us-east-1 glue get-data-quality-result --result-id "dqresult-09655f0234b3e3d129381bd162d0347ed25d1c05"
{
    "ResultId": "dqresult-09655f0234b3e3d129381bd162d0347ed25d1c05",
    "ProfileId": "dqprofile-[redacted]",
    "Score": 0.6666666666666666,
    "RulesetName": "EvaluateDataQuality_node1741974822533",
    "EvaluationContext": "EvaluateDataQuality_node1741974822533",
    "StartedOn": 1750687515.374,
    "CompletedOn": 1750687537.485,
    "JobName": "[redacted]_aggregatedmetrics_test",
    "JobRunId": "jr_[redacted]",
    "RuleResults": [
        {
            "Name": "Rule_1",
            "Description": "IsUnique \"customer_identifier\"",
            "Result": "PASS",
            "EvaluatedMetrics": {
                "Column.customer_identifier.Uniqueness": 1.0
            },
            "EvaluatedRule": "IsUnique \"customer_identifier\"",
            "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_identifier\" > 0.5",
            "Result": "PASS",
            "EvaluatedMetrics": {
                "Column.customer_identifier.Completeness": 1.0
            },
            "EvaluatedRule": "Completeness \"customer_identifier\" > 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
    }
}
```

Além disso, no nível da regra, as seguintes métricas são fornecidas:

Métricas de regra:

- Linhas aprovadas
- Linhas com falha
- Linha ignorada
- Total de linhas processadas

2. `AggregatedMetrics` é retornado como um quadro de dados adicional e o quadro de dados `RuleOutcomes` é aumentado para incluir `RuleMetrics`.

Exemplos de implementação

O exemplo a seguir mostra como implementar métricas agregadas no 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_identifier",
      RowCount > 10,
      Completeness "customer_identifier" > 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()
```

Exemplos de resultados

Os resultados são retornados da seguinte forma:

```
{
    "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
}
```

As métricas agregadas são as seguintes:

```
{ "TotalRowsProcessed": 10, "PassedRows": 10, "FailedRows": 0, "TotalRulesProcessed":
 3, "RulesPassed": 2, "RulesFailed": 1 }
```

Compilador de regras de qualidade de dados

Com o criador de regras da Data Quality Definition Language (DQDL), você pode criar regras de qualidade de dados para avaliar seus dados. Comece selecionando um tipo de regra e depois especifique os parâmetros no editor de regras. O editor de regras também mostra erros e avisos à medida que você criar regras.

O guia do DQDL fornece documentação abrangente sobre como estruturar regras usando a sintaxe, os tipos e os exemplos de regras integradas do DQDL.

Nó Evaluate Data Quality

Ao trabalhar com o nó de transformação Evaluate Data Quality e o compilador de regras DQDL, você pode expandir o espaço de trabalho.

- Para expandir a guia Transformar para preencher a tela inteira, escolha o ícone de expansão no canto superior direito do painel de detalhes do nó.
- Para expandir o editor de regras DQDL, escolha o ícone << para expandir o editor de regras e fechar as guias Tipos de regras e Esquema.

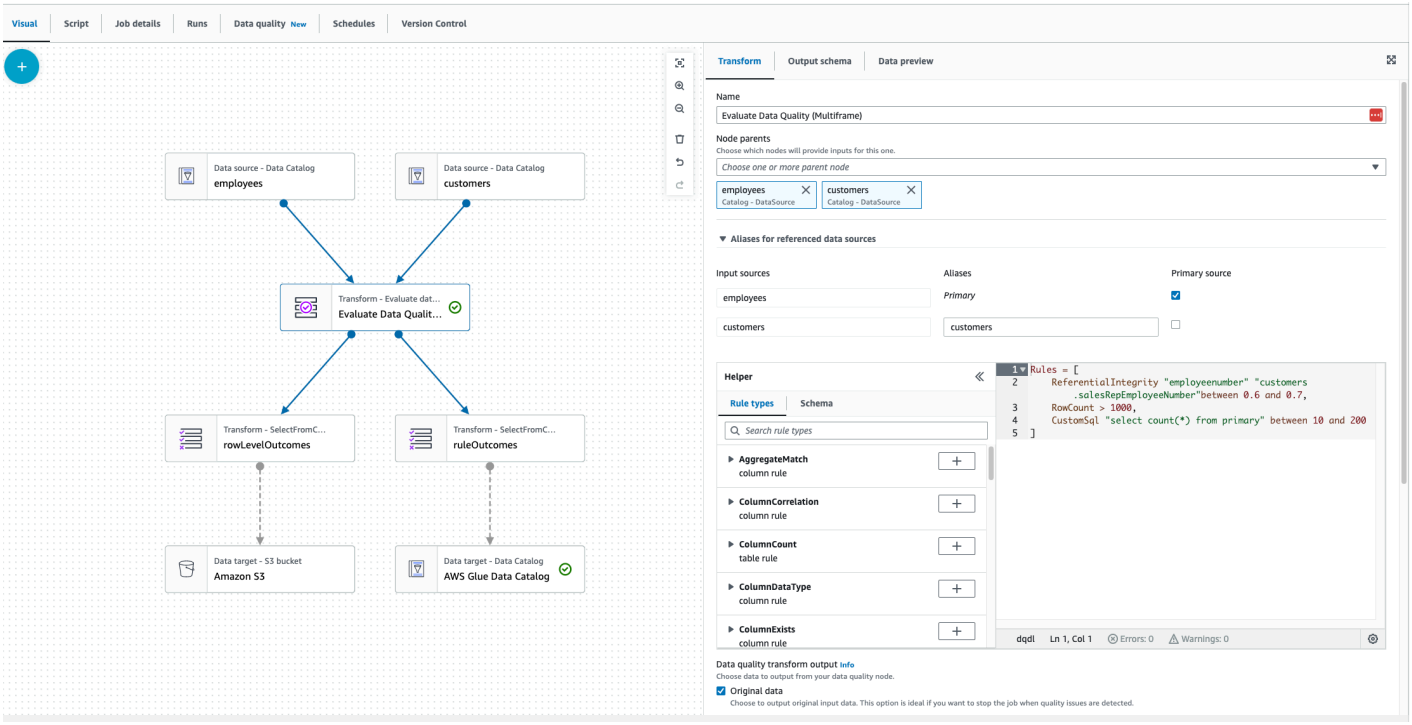

Componentes

Existem 26 tipos de regras que são incorporados ao AWS Glue Studio. Cada tipo de regra tem uma descrição e exemplos de como elas podem ser usadas.

Tipos de regras de qualidade de dados

O AWS Glue Studio fornece tipos de regras integrados para facilitar a criação de uma regra. Para obter mais informações sobre tipos de regras, consulte Referência de tipos de regras DQDL.

Schema

A guia Schema (Esquema) exibe os nomes das colunas e o tipo de dados do nó principal. Esquemas de vários nós são exibidos. Você pode visualizar o esquema de entrada, pesquisar pelo nome da coluna e inserir a coluna no editor de regras.

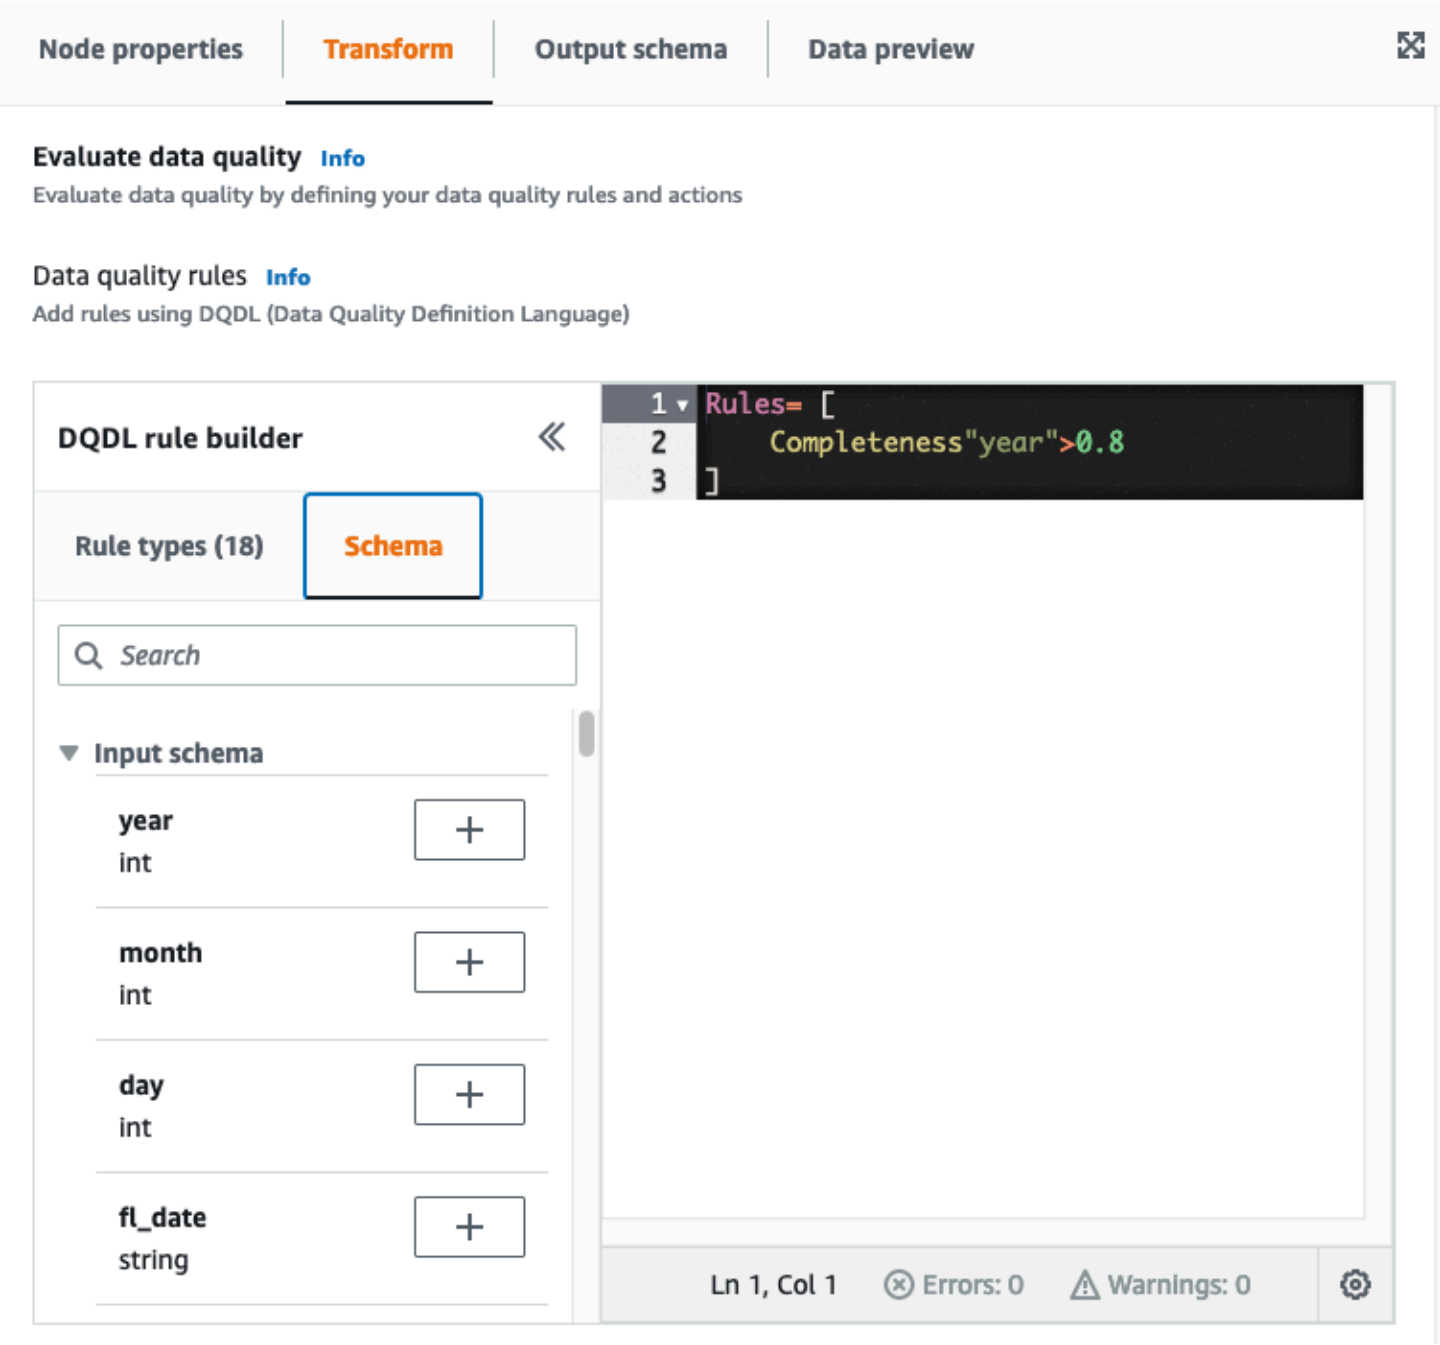

Editor de regras

O editor de regras é um editor de texto em que você pode escrever e editar regras. Se você selecionar um tipo de regra no compilador de regras DQDL, o tipo de regra será adicionado ao editor de regras. Em seguida, você pode especificar parâmetros, adicionar regras e editar regras conforme necessário, modificando o texto. O AWS Glue Studio valida as regras no editor de regras e exibe erros e avisos, se houver.

Erros e advertências

Se uma regra não seguir a sintaxe da regra DQDL, o editor de regras mostra vários indicadores visuais de que há um erro:

- O editor de regras exibe um ícone de erro e a linha com o erro em vermelho.
- O editor de regras exibe o número de erros ao lado do ícone vermelho de erro.
- Quando você escolhe a linha com o erro, uma descrição e o local (linha e coluna) do erro são exibidos na parte inferior do editor de regras.

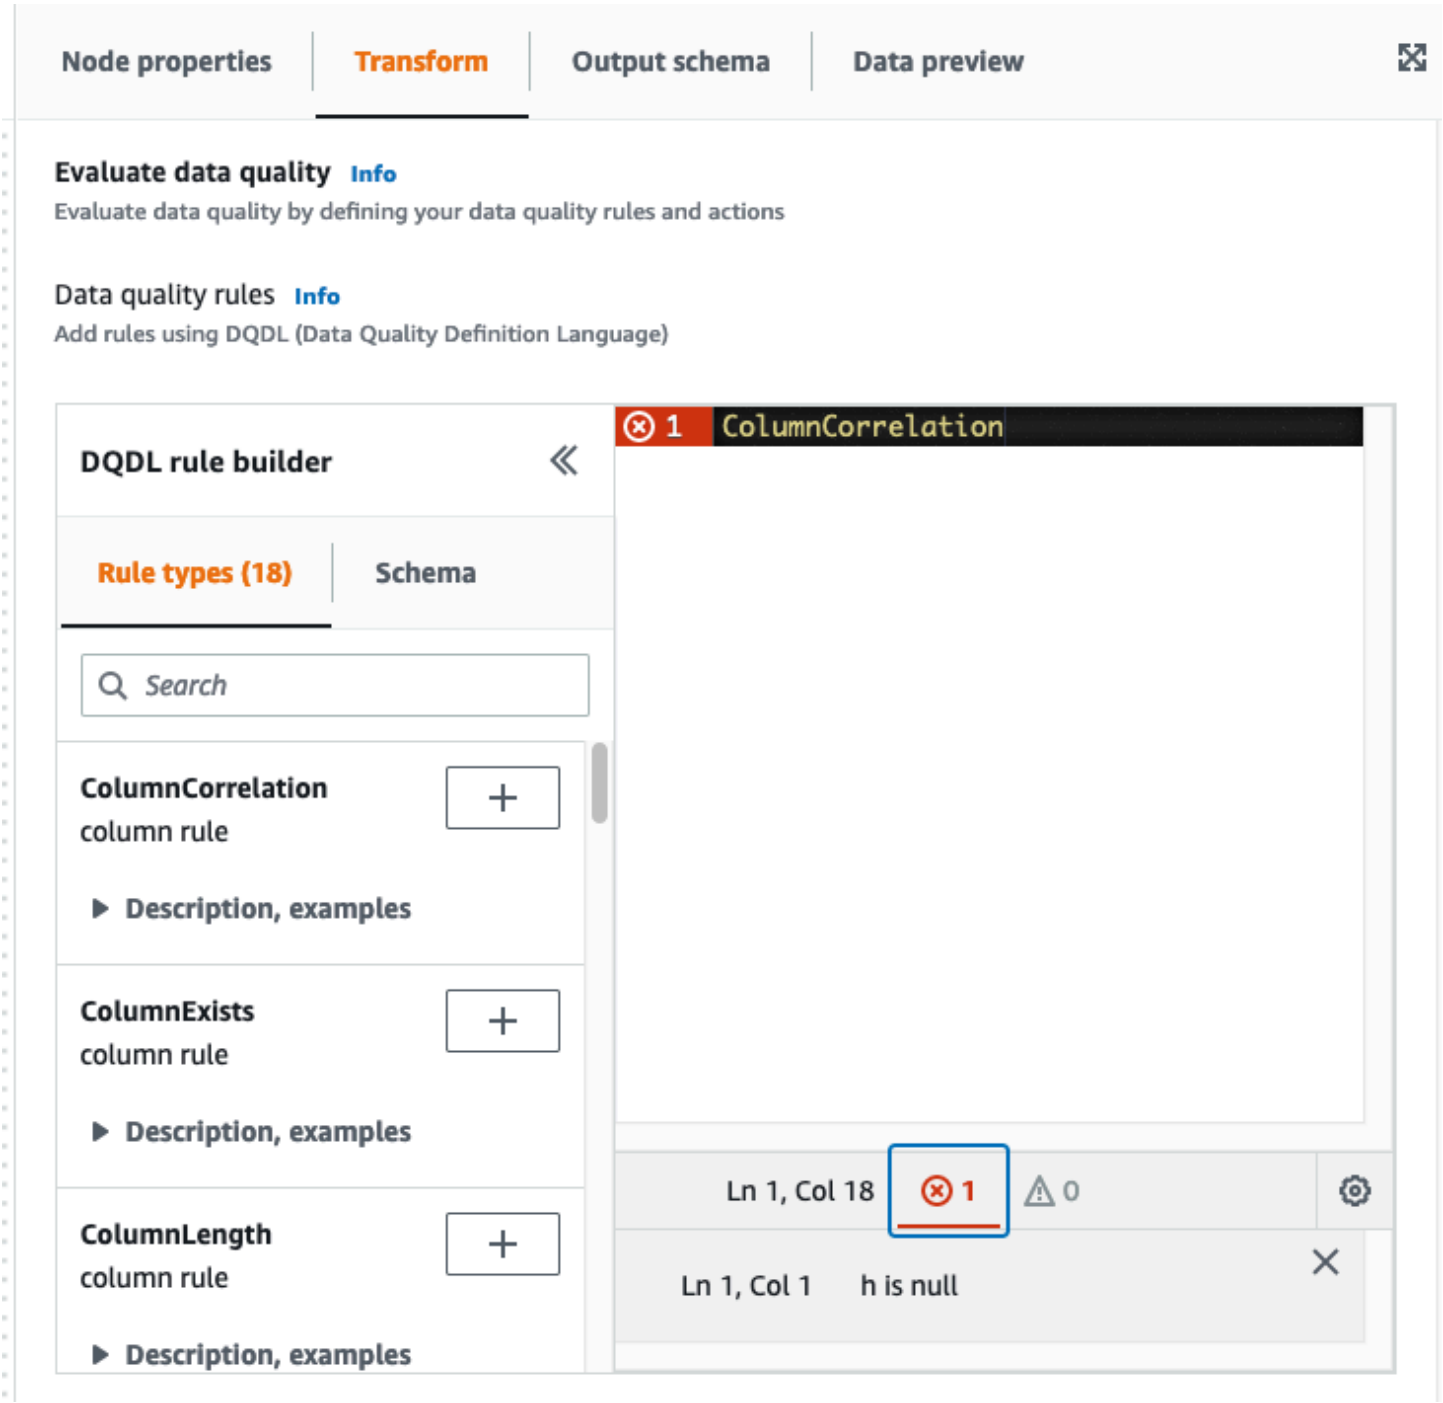

Ações de qualidade de dados

Por padrão, essa ação não é selecionada e o trabalho concluirá sua execução mesmo se as regras de qualidade de dados falharem.

Escolha entre as ações a seguir. Você pode usar ações para publicar resultados no CloudWatch ou interromper trabalhos com base em critérios específicos. As ações só estarão disponíveis depois que você criar uma regra.

- Publicar resultados no CloudWatch: ao executar um trabalho, adicione os resultados ao CloudWatch.
- Reprovar o trabalho quando a qualidade dos dados for reprovada: se as regras de qualidade de dados forem reprovadas, o trabalho também será reprovado como resultado.

Saída da transformação Data quality

- Dados originais: escolha a saída dos dados de entrada originais. Essa opção é ideal se você quiser interromper o trabalho quando problemas de qualidade forem detectados.
- Métricas de qualidade de dados: opte pela saída das regras configuradas e o status de aprovação ou reprovação correspondente. Essa opção é útil se você quiser fazer uma ação personalizada.

Configurações de saída de qualidade de dados

Defina a localização do resultado de qualidade de dados especificando o local do Amazon S3 como o destino de saída de qualidade de dados.

Configuração da detecção de anomalias em tarefas de ETL do AWS Glue

Para começar com a detecção de anomalias no AWS Glue Studio, abra uma tarefa do AWS Glue Studio e clique em Avaliar transformação do Data Quality.

Ao habilitar esse recurso, o AWS Glue Data Quality analisará seus dados ao longo do tempo para detectar anomalias. Isso fornecerá estatísticas de dados e observações valiosas sobre seus dados, permitindo que você adote medidas sobre quaisquer anomalias identificadas.

Consulte a documentação de detecção de anomalias para entender o funcionamento interno desse recurso.

Como habilitar a detecção de anomalias

Para habilitar a detecção de anomalias no AWS Glue Studio:

1. Escolha o nó do Data Quality em seu trabalho e, em seguida, escolha a guia Detecção de anomalias. Alterne o seletor para ativar a opção Habilitar detecção de anomalias.

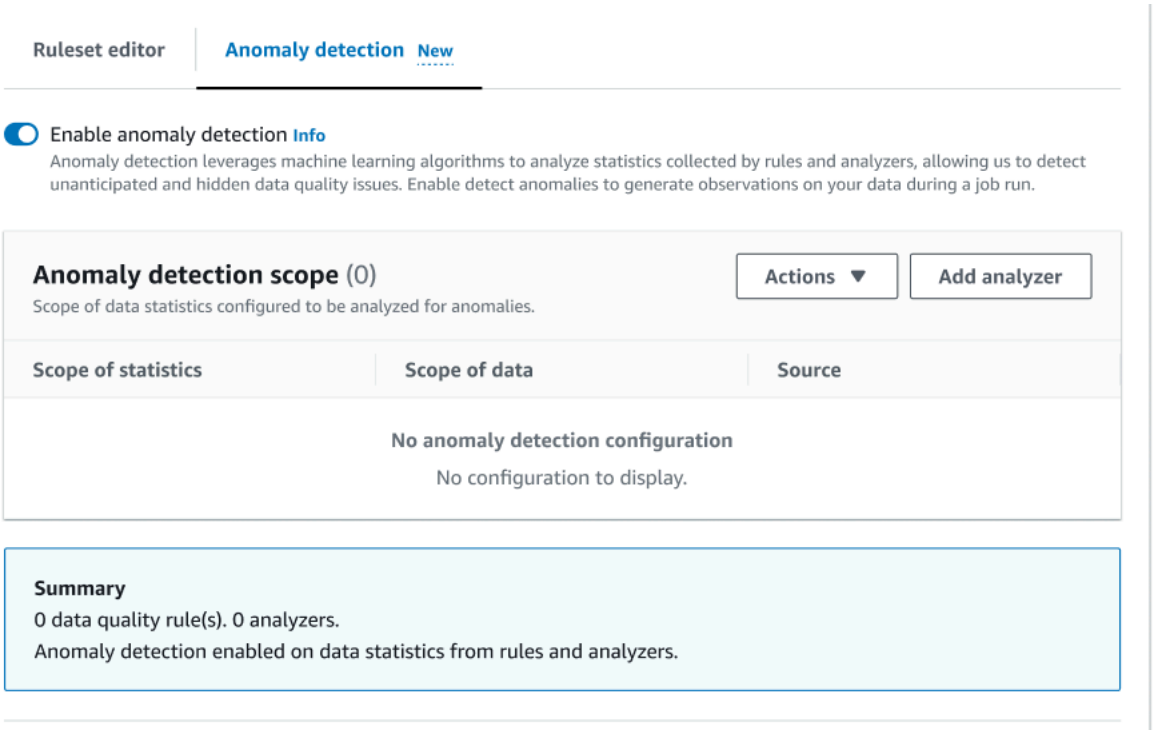

2. Defina os dados para monitorar anomalias ao escolher Adicionar analisador. Há dois campos que você pode preencher: Estatísticas e Dados.

   - As Estatísticas são informações sobre a forma e outras propriedades dos dados. É possível escolher uma ou mais estatísticas por vez ou escolher Todas as estatísticas. As estatísticas incluem: completude, exclusividade, média, soma, desvio padrão, entropia, DistinctValuesCount e UniqueValueRatio. Consulte a documentação Analisadores para obter mais detalhes.
   - Os Dados são as colunas no seu conjunto de dados. Você pode escolher todas as colunas ou colunas individuais.

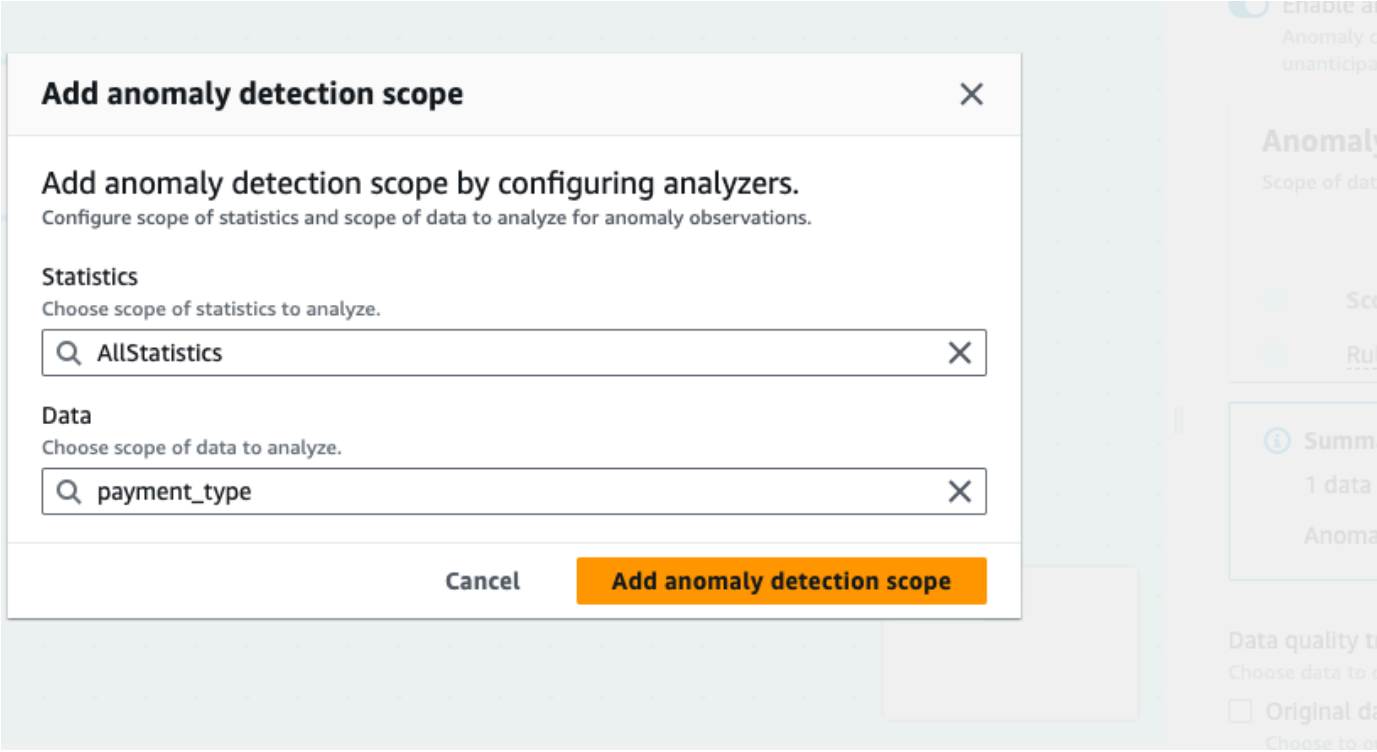

3. Escolha Adicionar escopo de detecção de anomalias para salvar as alterações. Depois de adicionar analisadores, você poderá visualizá-los na seção Escopo de detecção de anomalias.

   Você também pode usar o menu Ações para editar seus analisadores ou escolher a guia Editor de conjunto de regras e editar o analisador diretamente no bloco de notas do editor de conjunto de regras. Você verá os analisadores que salvou abaixo de todas as regras que criou.

```
Rules = [

]

Analyzers = [
    Completeness “id”
]
```

Após a configuração do conjunto de regras e dos analisadores atualizados, o AWS Glue Data Quality vai monitorar continuamente os fluxos de dados recebidos. Dependendo de suas configurações, ele poderá sinalizar possíveis anomalias por meio de alertas ou interrupções de tarefa. Esse

monitoramento proativo ajuda a garantir a qualidade e a integridade dos dados em todos os seus pipelines de dados.

Na próxima seção, você aprenderá a monitorar com eficácia as anomalias identificadas pelo sistema. Você também aprenderá a visualizar e analisar as estatísticas de dados coletadas pelo AWS Glue Data Quality. Além disso, você entenderá como fornecer feedback ao modelo de machine learning que alimenta o recurso de detecção de anomalias. Esse ciclo de feedback é crucial para melhorar a precisão do modelo e garantir que ele possa detectar com eficácia anomalias que se alinhem aos requisitos comerciais e aos padrões de dados específicos.

Visualização de pontuações de qualidade de dados e anomalias

Nesta seção, exploraremos o painel de qualidade de dados e as diferentes funcionalidades que ele disponibiliza.

Visualizar e compreender métricas e tendências de alto nível sobre qualidade de dados

Quando sua tarefa for bem-sucedida, escolha a guia Qualidade de dados para ver as pontuações e anomalias da qualidade de dados.

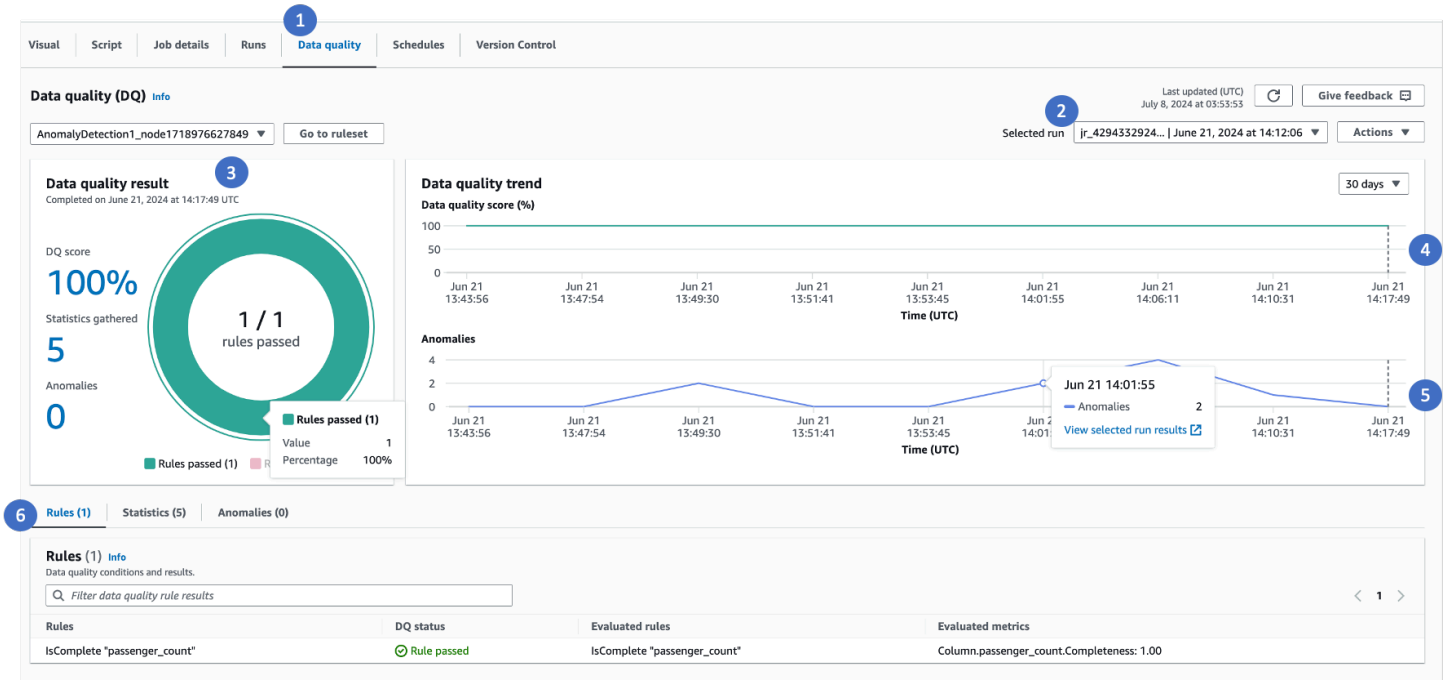

Os componentes a seguir na guia Qualidade de dados disponibilizam informações úteis.

1. Escolha a guia Qualidade de dados para visualizar as métricas de qualidade dos dados.

2. Selecione um ID específico de execução de tarefa para ver a pontuação de qualidade de dados.
3. Esse painel mostra três informações importantes. Você pode escolher cada um deles para acessar as tabelas específicas a fim de visualizar anomalias, estatísticas de dados ou regras.
   - Pontuação de qualidade de dados quando as regras são configuradas.
   - Número de estatísticas coletadas por regras e analisadores.
   - O número total de anomalias detectadas.
4. Esse gráfico de tendências mostra como a qualidade dos dados está evoluindo ao longo do tempo. Você pode passar o mouse sobre a tendência e acessar um horário específico no qual as pontuações de qualidade dos dados se deterioraram.
5. As tendências de anomalias ao longo do tempo mostrarão o número de anomalias detectadas ao longo do tempo.
6. Guias:
   - A guia Regras é a guia padrão que mostra a lista de todas as regras e status. No caso de regras dinâmicas, as regras avaliadas são úteis para visualizar o valor efetivo com base no qual a regra foi avaliada.
   - A guia Estatísticas lista todas as estatísticas, permitindo que você visualize as métricas e as tendências ao longo do tempo.
   - A guia Anomalias mostra a lista das anomalias que foram detectadas.

Visualização de anomalias e treino do algoritmo de detecção de anomalias

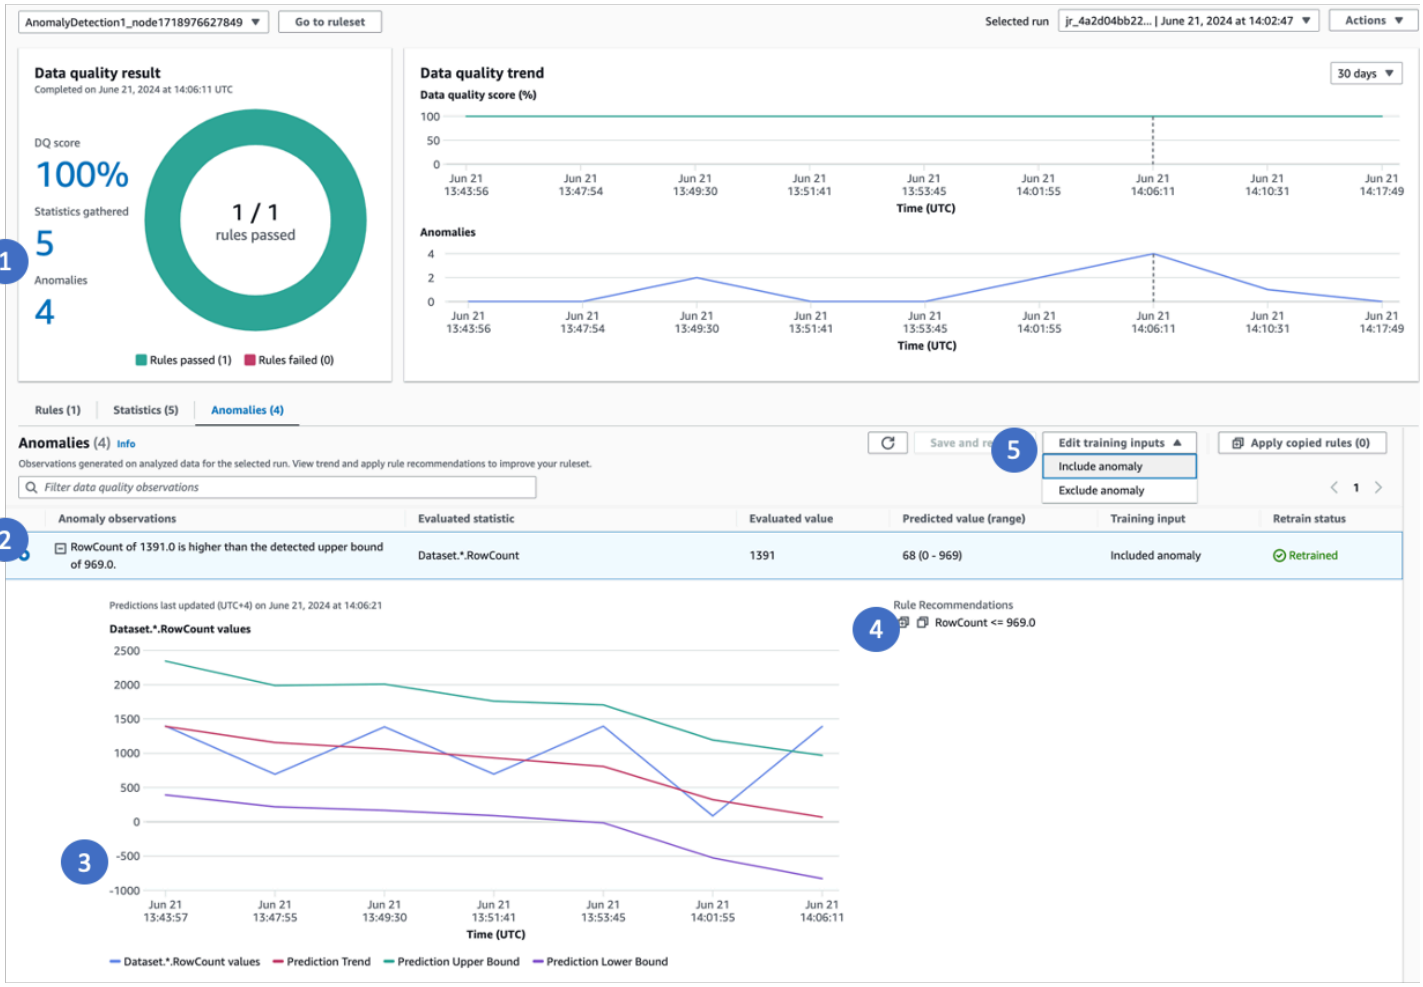

Explicações para a imagem acima:

1. Quando houver a detecção de anomalias, clique na anomalia ou selecione a guia Anomalias.
2. O AWS Glue Data Quality apresenta uma explicação detalhada da anomalia, o valor efetivo e a faixa prevista.
3. O AWS Glue Data Quality mostra uma linha de tendência. Ela tem o valor efetivo, uma tendência derivada com base nos valores efetivos (linha vermelha), o limite superior e o limite inferior
4. OAWS Glue Data Quality recomenda regras de qualidade de dados que podem ser usadas para capturar os padrões para o futuro. Você pode copiar todas as regras recomendadas e aplicá-las ao seu nó de qualidade de dados para capturar esses padrões de modo eficaz.
5. É possível fornecer entradas para o modelo de machine learning (ML) para excluir valores anômalos, garantindo que execuções futuras detectem anomalias com precisão. Se você não excluir as anomalias explicitamente, o AWS Glue Data Quality as considerará automaticamente

como parte do modelo para previsões futuras. É importante observar que somente a execução mais recente refletirá as entradas do modelo que você fornece. Por exemplo, se você retornar e excluir pontos anômalos de algumas execuções anteriores, o modelo não refletirá essas alterações, a menos que você visualize e atualize as entradas do modelo na última execução. O modelo continuará usando as entradas fornecidas anteriormente até que você faça os ajustes necessários na execução mais recente. Ao gerenciar ativamente a exclusão de valores anômalos, você pode refinar a compreensão do modelo de ML sobre o que constitui uma anomalia em seus padrões e requisitos de dados específicos, levando a uma detecção mais precisa de anomalias ao longo do tempo.

Visualização de estatísticas de dados ao longo do tempo e oferta de informações de treinamento

Às vezes, talvez você queira visualizar estatísticas de dados ou perfis de dados e ver como eles estão progredindo ao longo do tempo. Para fazer isso, escolha Estatísticas ou abra a guia Estatísticas. Em seguida, você poderá ver as estatísticas de dados mais recentes coletadas pelo AWS Glue Data Quality.

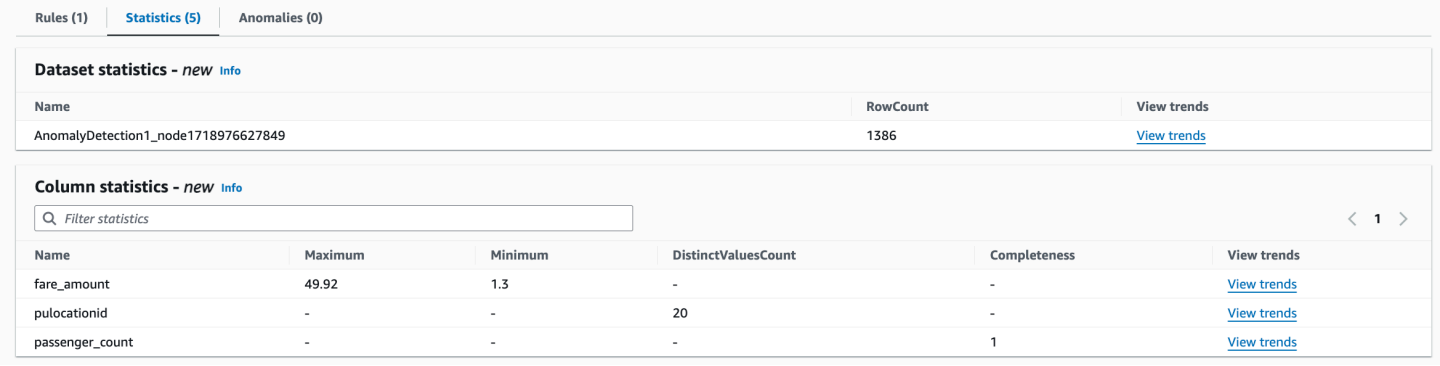

Clicar em Exibir tendências mostra como cada uma das estatísticas está progredindo ao longo do tempo.

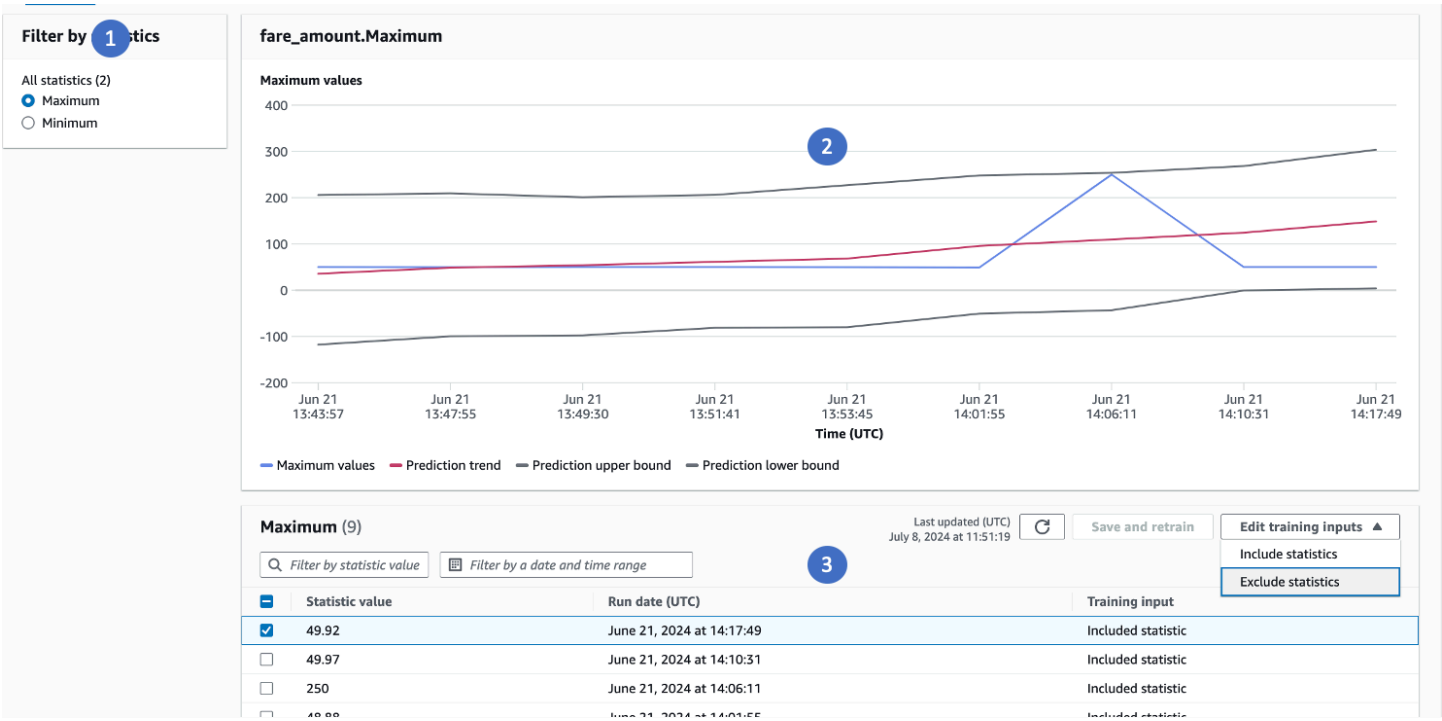

1. Você pode selecionar a estatística para uma coluna especificada.
2. Você pode ver como as tendências estão progredindo.
3. Você pode selecionar valores anômalos e optar por excluí-los ou incluí-los. Ao fornecer esse feedback, o algoritmo excluirá ou incluirá os pontos de dados anômalos identificados e retreinará o modelo. Esse processo de reciclagem garante a detecção precisa de anomalias no futuro, conforme o modelo aprende com o feedback que você forneceu sobre quais valores devem ser considerados anômalos ou não.

   Por meio desse ciclo de feedback, você tem a capacidade de refinar a compreensão do algoritmo sobre o que constitui uma anomalia para seus padrões de dados e requisitos comerciais específicos. Ao excluir valores que não devem ser sinalizados como anomalias ou incluir valores que não foram devidamente capturados, o modelo retreinado se tornará melhor na diferenciação entre pontos de dados esperados e verdadeiramente anômalos.

Qualidade de dados para trabalhos de ETL em cadernos do AWS Glue Studio

Neste tutorial, você aprende a usar o AWS Glue Data Quality para extração, transformação e carregamento (ETL) em cadernos do AWS Glue Studio.

Você pode usar cadernos no AWS Glue Studio para editar scripts de trabalhos e visualizar a saída sem precisar executar um trabalho inteiro. Você também pode adicionar markdown e salvar cadernos como arquivos do `.ipynb` e scripts de trabalho. Observe que é possível iniciar um caderno sem instalar software localmente nem gerenciar servidores. Quando estiver satisfeito com seu código, você pode usar o AWS Glue Studio para converter facilmente seu caderno em um trabalho do AWS Glue.

O conjunto de dados que você usa neste exemplo consiste nos dados de pagamento de um provedor da Medicare obtidos baixando dois conjuntos de dados do Data.CMS.gov: "Inpatient Prospective Payment System Provider Summary for the Top 100 Diagnosis-Related Groups - FY2011" e "Inpatient Charge Data FY 2011".

Depois de fazer download dos dados, nós os modificamos para apresentar alguns registros errados ao final do arquivo. Esse arquivo modificado está localizado em um bucket público do Amazon S3 em `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv`.

Pré-requisitos

- Função do AWS Glue com a permissão do Amazon S3 para gravar no seu bucket Amazon S3 de destino
- Um novo caderno (consulte Getting started with notebooks in AWS Glue Studio)

Criar um trabalho de ETL no AWS Glue Studio

Para criar um trabalho de ETL

1. Altere a versão da sessão para AWS Glue 3.0.

   Para fazer isso, remova todas as células de código padronizado com a seguinte mágica e execute a célula. Observe que esse código padronizado é fornecido automaticamente na primeira célula quando um novo caderno é criado.

   ```
   %glue_version 3.0
   ```

2. Copie código a seguir no e execute na célula.

   ```
   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. Na próxima célula, importe a classe `EvaluateDataQuality` que avalia AWS Glue Data Quality.

```
from awsgluedq.transforms import EvaluateDataQuality
```

4. Na próxima célula, leia os dados de origem usando o arquivo .csv que está armazenado no bucket público do 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. Converta os dados em um AWS Glue DynamicFrame.

```
from awsglue.dynamicframe import DynamicFrame
medicare_dyf = DynamicFrame.fromDF(medicare,glueContext,"medicare_dyf")
```

6. Crie o conjunto de regras usando a Data Quality Definition Language (DQDL).

```
EvaluateDataQuality_ruleset = """
    Rules = [
        ColumnExists "Provider Id",
        IsComplete "Provider Id",
        ColumnValues  " Total Discharges " > 15
]
    ]
"""
```

7. Valide o conjunto de dados em relação ao conjunto de regras.

```
EvaluateDataQualityMultiframe = EvaluateDataQuality().process_rows(
    frame=medicare_dyf,
    ruleset=EvaluateDataQuality_ruleset,
    publishing_options={
        "dataQualityEvaluationContext": "EvaluateDataQualityMultiframe",
        "enableDataQualityCloudWatchMetrics": False,
        "enableDataQualityResultsPublishing": False,
    },
    additional_options={"performanceTuning.caching": "CACHE_NOTHING"},
)
```

8. Reveja os resultados.

```
ruleOutcomes = SelectFromCollection.apply(
    dfc=EvaluateDataQualityMultiframe,
    key="ruleOutcomes",
    transformation_ctx="ruleOutcomes",
)

ruleOutcomes.toDF().show(truncate=False)
```

Saída:

```
-------------------------------------+-------
+-----------------------------------------------------
+-----------------------------------------+
|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. Filtre as linhas aprovadas e revise as linhas com falha nos resultados em nível de linha do Data Quality.

```
owLevelOutcomes = 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
```

Saída:

```
+-----------------------------------------+-----------
+-------------------------------------+-------------------------+-------------
+--------------+-----------------+-----------------------------------
+------------------+-------------------------+-----------------------
+--------------------------+-------------------------
+-----------------------------------------+---------------------------
+---------------------------+
|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
```

Observe que o AWS Glue Data Quality adicionou quatro novas colunas (DataQualityRulesPass, DataQualityRulesFail, DataQualityRulesSkip e DataQualityEvaluationResult). Isso indica os registros aprovados, os registros que falharam, as regras ignoradas para a avaliação em nível de linha e os resultados gerais em nível de linha.

10. Grave a saída em um bucket do Amazon S3 para analisar os dados e visualizar os resultados.

```
#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")
```

Referência de Data Quality Definition Language (DQDL)

Data Quality Definition Language (DQDL) é uma linguagem específica de domínio que você usa para definir regras para o AWS Glue Data Quality.

Este guia apresenta os principais conceitos de DQDL para ajudar você a entender a linguagem. Ele também fornece uma referência para tipos de regras DQDL com sintaxe e exemplos. Antes de usar este guia, recomendamos que você se familiarize com o AWS Glue Data Quality. Para ter mais informações, consulte AWS Glue Data Quality.

> **Note**
>
> As regras dinâmicas são aceitas somente em ETL do AWS Glue.

Sumário

- Sintaxe DQDL
  - Estrutura da regra
  - Regras compostas
    - Como as regras compostas funcionam

- Expressões
  - Palavras-chave para NULL, EMPTY e WHITESPACES_ONLY
  - Filtragem com a cláusula Where
- Regras dinâmicas
- Analisadores
- Comentários

- Referência de tipos de regra DQDL
  - AggregateMatch
  - ColumnCorrelation
  - ColumnCount
  - ColumnDataType
  - ColumnExists
  - ColumnLength
  - ColumnNamesMatchPattern
  - ColumnValues
  - Completeness
  - CustomSQL
  - DataFreshness
  - DatasetMatch
  - DistinctValuesCount
  - Entropia
  - IsComplete
  - IsPrimaryKey
  - IsUnique
  - Média
  - ReferentialIntegrity
  - RowCount
  - RowCountMatch
  - StandardDeviation
  - Sum

- SchemaMatch
- Exclusividade
- UniqueValueRatio
- DetectAnomalies
- FileFreshness
- FileMatch
- FileUniqueness
- FileSize

Sintaxe DQDL

Um documento DQDL diferencia maiúsculas de minúsculas e contém um conjunto de regras que agrupa regras individuais de qualidade de dados. Para estruturar um conjunto de regras, você deve criar uma lista denominada `Rules` (em maiúsculas), delimitada por colchetes. A lista deve conter uma ou mais regras DQDL separadas por vírgula, como no exemplo a seguir.

```
Rules = [
   IsComplete "order-id",
   IsUnique "order-id"
]
```

Estrutura da regra

A estrutura de uma regra DQDL depende do tipo de regra. No entanto, as regras DQDL geralmente se encaixam no formato a seguir.

```
<RuleType> <Parameter> <Parameter> <Expression>
```

`RuleType` é o nome com distinção entre maiúsculas e minúsculas do tipo de regra que você quer configurar. Por exemplo, `IsComplete`, `IsUnique` ou `CustomSql`. Os parâmetros da regra diferem para cada tipo de regra. Para obter uma referência completa dos tipos de regras DQDL e seus parâmetros, consulte Referência de tipos de regra DQDL.

Regras compostas

A DQDL é compatível com os seguintes operadores lógicos que você pode usar para combinar regras. Essas regras são chamadas de regras compostas.

e

O operador lógico `and` resultará em `true` se, e somente se, as regras que ele conecta forem `true`. Caso contrário, a regra combinada resultará em `false`. Cada regra que você conecta com o operador `and` deve estar entre parênteses.

O exemplo a seguir usa o operador `and` para combinar duas regras DQDL.

```
(IsComplete "id") and (IsUnique "id")
```

or

O operador lógico `or` resultará em `true` se, e somente se, uma ou mais regras que ele conecta forem `true`. Cada regra que você conecta com o operador `or` deve estar entre parênteses.

O exemplo a seguir usa o operador `or` para combinar duas regras DQDL.

```
(RowCount "id" > 100) or (IsPrimaryKey "id")
```

Você pode usar o mesmo operador para conectar várias regras, portanto, a combinação de regras a seguir é permitida.

```
(Mean "Star_Rating" > 3) and (Mean "Order_Total" > 500) and (IsComplete "Order_Id")
```

Você pode combinar os operadores lógicos em uma única expressão. Por exemplo:

```
(Mean "Star_Rating" > 3) and ((Mean "Order_Total" > 500) or (IsComplete "Order_Id"))
```

Você também pode criar regras mais complexas e aninhadas.

```
(RowCount > 0) or ((IsComplete "colA") and (IsUnique "colA"))
```

Como as regras compostas funcionam

Por padrão, as regras compostas são avaliadas como regras individuais em todo o conjunto de dados ou tabela e, em seguida, os resultados são combinados. Em outras palavras, a coluna inteira é avaliada primeiro e, em seguida, o operador é aplicado. Esse comportamento padrão é explicado abaixo com um exemplo:

```
# Dataset

+------+------+
|myCol1|myCol2|
+------+------+
|     2|     1|
|     0|     3|
+------+------+

# Overall outcome

+-------------------------------------------------------------+-------+
|Rule                                                         |Outcome|
+-------------------------------------------------------------+-------+
|(ColumnValues "myCol1" > 1) OR (ColumnValues "myCol2" > 2)|Failed |
+-------------------------------------------------------------+-------+
```

No exemplo acima, o AWS Glue Data Quality avalia primeiro `(ColumnValues "myCol1" > 1)`, o que resultará em uma falha. Em seguida, ele avaliará `(ColumnValues "myCol2" > 2)`, que também falhará. A combinação de ambos os resultados será anotada como FALHA.

No entanto, se você preferir um comportamento semelhante ao SQL, em que a linha inteira deve ser avaliada, é necessário definir explicitamente o parâmetro `ruleEvaluation.scope` conforme mostrado em `additionalOptions` no trecho de código abaixo.

```
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"
        }
      """
    )
  )
}
```

No Catálogo de Dados do AWS Glue, é possível configurar facilmente essa opção na interface do usuário, conforme demonstrado abaixo.

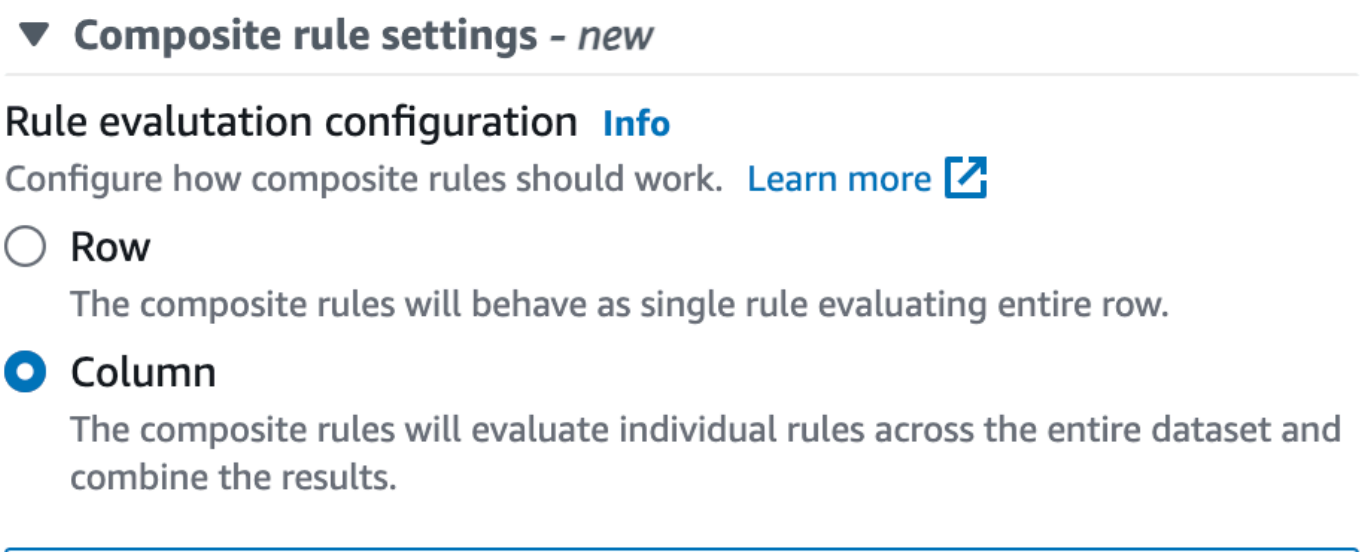

Depois de definidas, as regras compostas se comportarão como uma única regra avaliando a linha inteira. O exemplo a seguir ilustra esse comportamento.

```
# 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
                |
+------+------+-----------------------------------------------------------------
+--------------------------+
```

Algumas regras não podem ser aceitas nesse recurso porque seu resultado geral depende de limites ou proporções. Elas estão listadas abaixo.

Regras baseadas em índices:

- Completeness
- DatasetMatch
- ReferentialIntegrity
- Exclusividade

Regras dependentes de limites:

Quando as regras a seguir incluem limites, elas não são aceitas. No entanto, as regras que não envolvem `with threshold` permanecem válidas.

- ColumnDataType
- ColumnValues
- CustomSQL

Expressões

Se um tipo de regra não produzir uma resposta booliana, você deverá fornecer uma expressão como parâmetro para criar uma resposta booliana. Por exemplo, a regra a seguir verifica a média de todos os valores em uma coluna em relação a uma expressão para retornar um resultado verdadeiro ou falso.

```
Mean "colA" between 80 and 100
```

Alguns tipos de regras, como `IsUnique` e `IsComplete` já retornam uma resposta booleana.

A tabela a seguir lista as expressões que você pode usar nas regras DQDL.

Expressões DQDL compatíveis

Expressão	Descrição	Exemplo
= *x*	Será resolvido como `true` se a resposta do tipo de regra for igual a *x*.	`Completeness "colA" = "1.0", ColumnValues "colA" = "2022-06-30"`
!=*x*	x será resolvido como verdadeiro se a resposta do tipo de regra for diferente de *x*.	`ColumnValues "colA" != "a", ColumnValues "colA" != "2022-06-30"`
> *x*	Será resolvido como `true` se a resposta do tipo de regra for maior que *x*.	`ColumnValues "colA" > 10`
< *x*	Será resolvido como `true` se a resposta do tipo de regra for menor que *x*.	`ColumnValues "colA" < 1000, ColumnValues "colA" < "2022-06-30"`
>= *x*	Será resolvido como `true` se a resposta do tipo de regra for maior que ou igual a *x*.	`ColumnValues "colA" >= 10`
<= *x*	Será resolvido como `true` se a resposta do tipo de regra for menor que ou igual a *x*.	`ColumnValues "colA" <= 1000`
between *x* and *y*	Será resolvido como `true` se a resposta do tipo de regra estiver em um intervalo especificado (exclusivo). Use esse tipo de expressão apenas para tipos numéricos e de data.	`Mean "colA" between 8 and 100, ColumnValues "colA" between "2022-05-31" and "2022-06-30"`

Expressão	Descrição	Exemplo
not between *x* and *y*	Será resolvido como verdadeiro se a resposta do tipo de regra não estiver em um intervalo especificado (inclusive). Você só deve usar esse tipo de expressão para tipos numéricos e dados.	`ColumnValues "colA" not between "2022-05-31" and "2022-06-30"`
in [*a, b, c,...*]	Será resolvido para `true` se a resposta do tipo de regra está no conjunto especific ado.	`ColumnValues "colA" in [ 1, 2, 3 ], ColumnValues "colA" in [ "a", "b", "c" ]`
not in [*a, b, c, ...*]	Será resolvido para `true` se a resposta do tipo de regra não estiver no conjunto especificado.	`ColumnValues "colA" not in [ 1, 2, 3 ], ColumnValues "colA" not in [ "a", "b", "c" ]`
matches */ab+c/i*	Será resolvido como `true` se a resposta do tipo de regra corresponder a uma expressão regular.	`ColumnValues "colA" matches "[a-zA-Z]*"`
not matches */ab+c/i*	Será resolvido como `true` se a resposta do tipo de regra não corresponder a uma expressão regular.	`ColumnValues "colA" not matches "[a-zA-Z]*"`
`now( )`	Só funciona com o tipo de regra `ColumnValues` para criar uma expressão de data.	`ColumnValues "load_date" > (now() - 3 days)`

Expressão	Descrição	Exemplo
matches/in […]/not matches/not in [...] `with threshold`	Especifica a porcentagem de valores que correspondem às condições da regra. Funciona somente com os tipos de regras `ColumnValues` , `ColumnDataType` e `CustomSQL` .	`ColumnValues "colA" in ["A", "B"] with threshold > 0.8, ColumnValues "colA" matches "[a-zA-Z]*" with threshold between 0.2 and 0.9 ColumnDataType "colA" = "Timestamp" with threshold > 0.9`

Palavras-chave para NULL, EMPTY e WHITESPACES_ONLY

Se desejar validar se uma coluna de string tem uma string nula, vazia ou apenas com espaços em branco, você pode usar as seguintes palavras-chave:

- NULL/null: Essa palavra-chave é resolvida como verdadeira para um valor `null` em uma coluna de string.

  `ColumnValues "colA" != NULL with threshold > 0.5` retornaria verdadeiro se mais de 50% dos seus dados não tivessem valores nulos.

  `(ColumnValues "colA" = NULL) or (ColumnLength "colA" > 5)` retornaria verdadeiro para todas as linhas que têm um valor nulo ou comprimento > 5. Observe que isso exigirá o uso da opção "compositeRuleEvaluation.method" = "ROW".
- EMPTY/empty: essa palavra-chave é resolvida como verdadeira para um valor de string vazio ("") em uma coluna de string. Alguns formatos de dados transformam nulos em uma coluna de string para strings vazias. Essa palavra-chave ajuda a filtrar strings vazias em seus dados.

  `(ColumnValues "colA" = EMPTY) or (ColumnValues "colA" in ["a", "b"])` retornaria verdadeiro se uma linha estivesse vazia, "a" ou "b". Observe que isso exige o uso da opção "compositeRuleEvaluation.method" = "ROW".
- WHITESPACES_ONLY/whitespaces_only: essa palavra-chave é resolvida como verdadeira para uma string somente com espaços em branco (" ") em uma coluna de string.

  `ColumnValues "colA" not in ["a", "b", WHITESPACES_ONLY]` retornaria verdadeiro se uma linha não fosse "a" ou "b" nem apenas espaços em branco.

Regras compatíveis:

- ColumnValues

Para uma expressão numérica ou baseada em data, se você quiser validar se uma coluna tem um valor nulo, poderá usar as palavras-chave a seguir.

- NULL/null: Essa palavra-chave é resolvida como verdadeira para um valor nulo em uma coluna de string.

  `ColumnValues "colA" in [NULL, "2023-01-01"]` retornaria verdadeiro se as datas em sua coluna fossem iguais a `2023-01-01` ou nulas.

  `(ColumnValues "colA" = NULL) or (ColumnValues "colA" between 1 and 9)` retornaria verdadeiro para todas as linhas que têm um valor nulo ou valores entre 1 e 9. Observe que isso exigirá o uso da opção "compositeRuleEvaluation.method" = "ROW".

  Regras compatíveis:

  - ColumnValues

Filtragem com a cláusula Where

> **Note**
>
> A cláusula Where só é compatível com o AWS Glue 4.0.

Você pode filtrar seus dados ao criar regras. Isso é útil quando você quiser aplicar regras condicionais.

```
<DQDL Rule> where "<valid SparkSQL where clause> "
```

É necessário especificar o filtro com a palavra-chave `where`, seguida por uma instrução válida do SparkSQL entre aspas (`""`).

Se você quiser adicionar a cláusula where a uma regra com um limite, será necessário especificar a cláusula where antes da condição de limite.

```
<DQDL Rule> where "valid SparkSQL statement>" with threshold <threshold condition>
```

Com essa sintaxe, você pode escrever regras como as seguintes.

```
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)"
```

Vamos validar se a instrução do SparkSQL fornecida é válida. Se for inválida, a avaliação da regra falhará e lançaremos o `IllegalArgumentException` com o seguinte formato:

```
Rule <DQDL Rule> where "<invalid SparkSQL>" has provided an invalid where clause :
<SparkSQL Error>
```

Comportamento da cláusula where quando a identificação do registro de erro no nível de linha estiver ativada

Com o AWS Glue Data Quality, você pode identificar registros específicos que falharam. Ao aplicar uma cláusula where às regras compatíveis com resultados no nível de linha, rotularemos como `Passed` as linhas que forem filtradas pela cláusula where.

Se você preferir rotular separadamente as linhas filtradas como `SKIPPED`, defina o seguinte `additionalOptions` para a tarefa de 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"
        }
      """
    )
  )
}
```

Como exemplo, consulte a regra e o quadro de dados a seguir:

```
IsComplete att2 where "att1 = 'a'"
```

id	att1	att2	Resultados no nível de linha (padrão)	Resultados no nível de linha (opção ignorada)	Comentários
1	a	f	PASSED	PASSED	
2	b	d	PASSED	SKIPPED	A linha é filtrada, pois `att1` não é `"a"`
3	a	nulo	COM FALHA	COM FALHA	
4	a	f	PASSED	PASSED	
5	b	nulo	PASSED	SKIPPED	A linha é filtrada, pois `att1` não é `"a"`
6	a	f	PASSED	PASSED	

Regras dinâmicas

> **Note**
>
> As regras dinâmicas são compatíveis somente no ETL do AWS Glue e não são compatíveis no Catálogo de Dados do AWS Glue.

Agora é possível criar regras dinâmicas para comparar as métricas atuais produzidas por suas regras com seus valores históricos. Essas comparações históricas são habilitadas ao usar o operador `last()` em expressões. Por exemplo, a regra `RowCount > last()` terá êxito quando o número de linhas na execução atual for maior do que a contagem de linhas anterior mais recente para o mesmo conjunto de dados. `last()` usa um argumento opcional de número natural que descreve quantas métricas anteriores devem ser consideradas; `last(k)` em que `k >= 1` fará referência às últimas k métricas.

- Se nenhum ponto de dados estiver disponível, `last(k)` retornará o valor padrão 0,0.
- Se menos de k métricas estiverem disponíveis, `last(k)` retornará todas as métricas anteriores.

Para formar expressões válidas, use `last(k)`, em que `k > 1` requer uma função de agregação para reduzir vários resultados históricos a um único número. Por exemplo, `RowCount > avg(last(5))` verificará se a contagem de linhas do conjunto de dados atual é estritamente maior do que a média das últimas cinco contagens de linhas do mesmo conjunto de dados. `RowCount > last(5)` produzirá um erro porque a contagem de linhas do conjunto de dados atual não pode ser comparada de forma significativa a uma lista.

Funções de agregação compatíveis:

- `avg`
- `median`
- `max`
- `min`
- `sum`
- `std` (desvio padrão)
- `abs` (valor absoluto)

- `index(last(k), i)` permitirá selecionar o `i` valor mais recente entre os últimos `k`. `i` é indexado em zero, então `index(last(3), 0)` retornará o ponto de dados mais recente e `index(last(3), 3)` resultará em um erro, pois há apenas três pontos de dados e tentamos indexar o 4.º mais recente.

Exemplos de expressões

ColumnCorrelation

- `ColumnCorrelation "colA" "colB" < avg(last(10))`

DistinctValuesCount

- `DistinctValuesCount "colA" between min(last(10))-1 and max(last(10))+1`

A maioria dos tipos de regras com condições ou limites numéricos é compatível com as regras dinâmicas. Consulte a tabela fornecida, Analisadores e regras, para determinar se as regras dinâmicas são compatíveis com seu tipo de regra.

Exclusão de estatísticas das regras dinâmicas

Às vezes, você precisará excluir estatísticas de dados dos cálculos das regras dinâmicas. Digamos que você tenha feito um carregamento de dados históricos e não queira que isso afete as médias. Para fazer isso, abra o trabalho no ETL do AWS Glue e escolha a guia Qualidade de dados, em seguida escolha Estatísticas e selecione as estatísticas que você deseja excluir. Você poderá ver um gráfico de tendências com uma tabela de estatísticas. Selecione os valores que você deseja excluir e escolha Excluir estatísticas. Agora, as estatísticas excluídas não serão consideradas nos cálculos dinâmicos das regras.

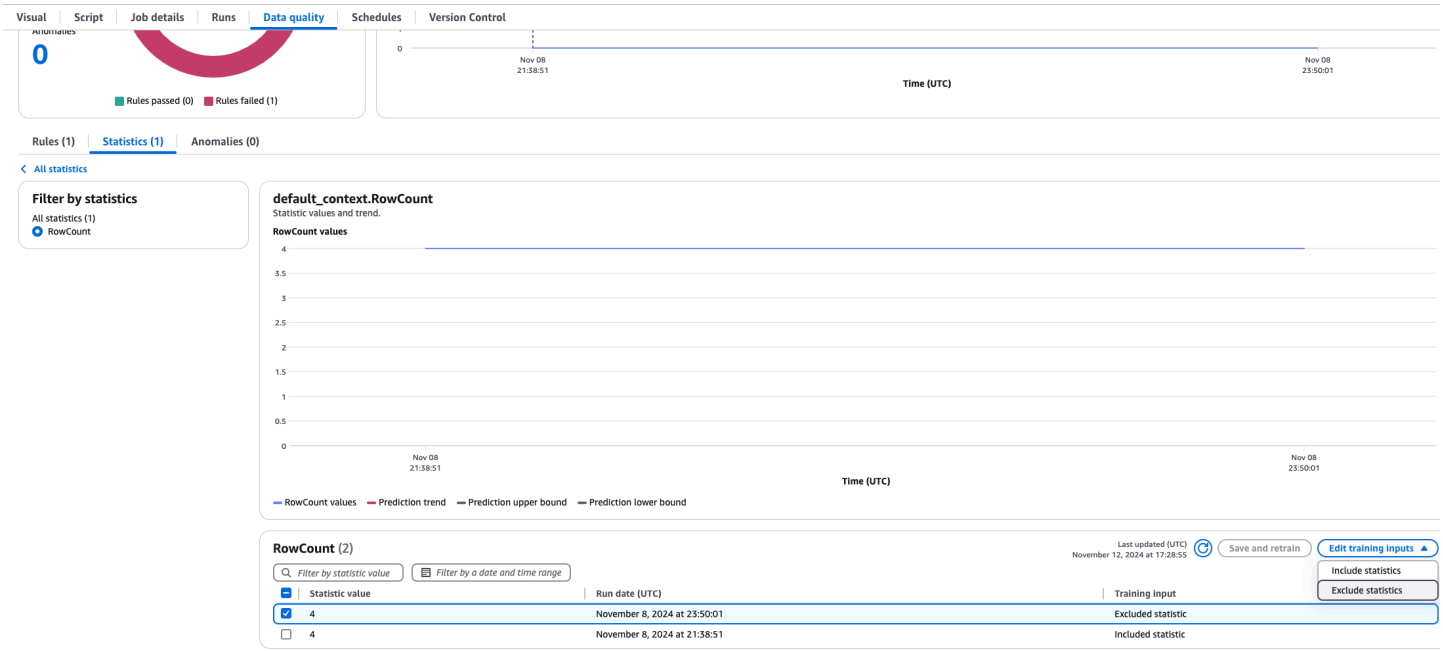

Analisadores

> **Note**
>
> Não há suporte a analisadores no Catálogo de Dados do AWS Glue.

As regras de DQDL usam funções chamadas analisadores para coletar informações sobre seus dados. Essas informações são empregadas por uma expressão booleana da regra para determinar se a regra terá êxito ou não. Por exemplo, a regra RowCount `RowCount > 5` usará um analisador de contagem de linhas para descobrir o número de linhas em seu conjunto de dados e comparar essa contagem com a expressão `> 5` para verificar se existem mais de cinco linhas no conjunto de dados atual.

Às vezes, em vez de criar regras, recomendamos criar analisadores e depois fazer com que eles gerem estatísticas que possam ser usadas para detectar anomalias. Para esses casos, será necessário criar analisadores. Os analisadores diferem das regras nas seguintes maneiras:

Característica	Analisadores	Regras
Parte do conjunto de regras	Sim	Sim

Característica	Analisadores	Regras
Gera estatísticas	Sim	Sim
Gera observações	Sim	Sim
Pode avaliar e afirmar uma condição	Não	Sim
É possível configurar ações, como interromper os trabalhos em caso de falha ou continuar o processamento do trabalho	Não	Sim

Os analisadores podem existir de forma independente, sem a necessidade de regras, permitindo a configuração rápida e a construção progressiva de regras de qualidade de dados.

Alguns tipos de regras podem ser inseridos no bloco de `Analyzers` do seu conjunto de regras para executar as regras necessárias para os analisadores e coletar informações sem aplicar verificações para nenhuma condição. Alguns analisadores não estão associados a regras e só podem ser inseridos no bloco de `Analyzers`. A tabela a seguir indica se cada item é compatível como uma regra ou como um analisador independente, junto com detalhes adicionais para cada tipo de regra.

Exemplo de conjunto de regras com o analisador

O seguinte conjunto de regras usa:

- uma regra dinâmica para verificar se um conjunto de dados está crescendo acima da média final nas últimas três execuções de trabalho;
- um analisador de `DistinctValuesCount` para registrar o número de valores distintos na coluna `Name` do conjunto de dados;
- um analisador de `ColumnLength` para rastrear o tamanho mínimo e máximo de `Name` ao longo do tempo.

Os resultados das métricas do analisador podem ser visualizados na guia Data Quality da execução do trabalho.

```
Rules = [
```

```
   RowCount > avg(last(3))
]
Analyzers = [
   DistinctValuesCount "Name",
   ColumnLength "Name"
]
```

O AWS Glue Data Quality é compatível com os seguintes analisadores.

Nome do analisador	Funcionalidade
`RowCount`	Calcula as quantidades de linhas para um conjunto de dados
`Completeness`	Calcula a porcentagem de completude de uma coluna
`Uniqueness`	Calcula a porcentagem de exclusividade de uma coluna
`Mean`	Calcula a média de uma coluna numérica
`Sum`	Calcula a soma de uma coluna numérica
`StandardDeviation`	Calcula o desvio padrão de uma coluna numérica
`Entropy`	Calcula a entropia de uma coluna numérica
`DistinctValuesCount`	Calcular o número de valores distintos em uma coluna
`UniqueValueRatio`	Calcula a proporção de valores exclusivos em uma coluna
`ColumnCount`	Calcula o número de colunas em um conjunto de dados
`ColumnLength`	Calcula o comprimento de uma coluna

Nome do analisador	Funcionalidade
`ColumnValues`	Calcula o mínimo e o máximo para colunas numéricas Calcula o mínimo e o máximo de ColumnLength para colunas não numéricas
`ColumnCorrelation`	Calcula as correlações de colunas para colunas específicas
`CustomSql`	Calcula as estatísticas retornadas pelo CustomSQL
`AllStatistics`	Calcula as seguintes estatísticas: • RowCount, ColumnCount • Cada coluna: completude, exclusividade • Numérico: mínimo, máximo, entropia, média, desvio padrão, soma • Cadeia de caracteres: MinLength, MaxLength

Comentários

É possível usar o caractere "#" para adicionar um comentário ao seu documento DQDL. Qualquer coisa após o caractere "#" e até o final da linha é ignorada pelo DQDL.

```
Rules = [
    # More items should generally mean a higher price, so correlation should be
 positive
    ColumnCorrelation "price" "num_items" > 0
]
```

Referência de tipos de regra DQDL

Esta seção fornece uma referência para cada tipo de regra compatível com o AWS Glue Data Quality.

> **Note**
>
> - Atualmente, o DQDL não é compatível com dados de colunas aninhadas ou do tipo lista.
> - Os valores entre colchetes na tabela abaixo serão substituídos pelas informações fornecidas nos argumentos da regra.
> - As regras normalmente exigem um argumento adicional para expressão.

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatí l como regra?	Compatí l como analisad r?	Retorna resultad s em nível de linha?	Compatí l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
Aggregat Match	Verifica se há correspo dência entre dois conjunto de dados compara o as métricas resumid , como o valor total das vendas. Útil para	Uma ou mais agregaçõ s	Quando os nomes da primeira e da segunda coluna de agregaçã coincider : `Column [C olumn] gregate tch` Quando os	Sim	Não	Não	Não	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
	instituiç ões financeir as compara m se todos os dados são ingerido dos sistema de origem.		nomes da primeira e da segunda coluna de agregaçã divergem `Column [C olumn1, lumn2]. gregate tch`						

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?

AllStatis tics	Analisad r indepenc nte para coletar diversas métricas para a coluna fornecid em um conjunto de dados.	Um único nome de coluna	Para as colunas de todos os tipos:
			
			`Dataset .RowCou`
			
			`Column. [C olumn]. mpleter s`
			
			`Column. [C olumn]. iquenes`
			
			Métricas adicionai s para colunas com valor de string:
				Não	Sim	Não	Não	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?

			`ColumnL gth metrics`
			
			Métricas adicionai s para colunas com valor numéricc
			
			`Column\ ues metrics`						

ColumnC relation	Verifica em que medida duas colunas estão correlaci onadas.	Exatame e dois nomes de coluna	`Multicc mn. [Colum n1,Colu 2].Colu Correla on`	Sim	Sim	Não	Sim	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
ColumnC nt	Verifica se alguma coluna foi descarta a.	Nenhum	`Dataset .Columr unt`	Sim	Sim	Não	Sim	Sim	Não
ColumnD aType	Verifica se uma coluna é compatív l com um tipo de dados.	Exatame e um nome de coluna	`Column. [C olumn]. lumnDat ype.Cor iance`	Sim	Não	Não	Sim, na expressã de limite em nível de linha	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatí l como regra?	Compatí l como analisad r?	Retorna resultad s em nível de linha?	Compatí l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
ColumnE sts	Verifica se existem colunas em um conjunto de dados. Isso permite que os clientes criem plataform as de dados de autoaten imento para garantir que determin das colunas sejam disponibi lizadas.	Exatame e um nome de coluna	N/D	Sim	Não	Não	Não	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?

ColumnL gth	Verifica se o comprim to dos dados é consister te.	Exatame e um nome de coluna	`Column [C olumn]. ximumLe th`
			
			`Column [C olumn]. nimumLe th`
			
			Métrica adicional quando o limite de nível de linha é fornecid :
			
			`Column [C olumn]. lumnVal s.Compl nce`
				Sim	Sim	Sim, quando o limite de nível de linha é fornecid	Não	Sim. Gera apenas observaç es ao analisar o comprim to mínimo e máximo	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
ColumnN esMatch ttern	Verifica se os nomes das colunas correspo dem a padrões definidos . Útil para equipes de governar a imporem consistên cia nos nomes das colunas.	Um regex para nomes de colunas	`Dataset .Columr mesPatt nMatchF io`	Sim	Não	Não	Não	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?

ColumnV ues	Verifica se os dados são consister tes de acordo com os valores definidos . Essa regra é compatív l com expressõ s regulares .	Exatame e um nome de coluna	`Column. [C olumn]. ximum`
			
			`Column. [C olumn]. nimum`
			
			Métrica adicional quando o limite de nível de linha é fornecid :
			
			`Column. [C olumn]. lumnVa] s.Comp] nce`
				Sim	Sim	Sim, quando o limite de nível de linha é fornecid	Não	Sim. Gera apenas observaç es ao analisar valores mínimos e máximos	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatí l como regra?	Compatí l como analisad r?	Retorna resultado s em nível de linha?	Compatí l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
Complet ess	Verifica se há espaços em branco ou nulos nos dados.	Exatame e um nome de coluna	`Column [C olumn]. mpleter s`	Sim	Sim	Sim	Sim	Sim	Sim

Custom	Os clientes podem implemer ar praticam nte qualquer tipo de verificaç ão de qualidad de dados em SQL.	Uma instruçã SQL
		
		(Opciona) Um limite em nível de linha
			`Dataset .Custor L`
			
			Métrica adicional quando o limite de nível de linha é fornecid :
			
			`Dataset .Custor L.Compl nce`
				Sim	Não	Sim, quando o limite de nível de linha é fornecid	Sim	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
DataFres ness	Verifica se os dados estão atualizad os.	Exatame e um nome de coluna	`Column [C olumn]. taFresh ss.Comp ance`	Sim	Não	Sim	Não	Não	Sim
DatasetM tch	Compara dois conjunto de dados e identific a se eles estão sincroniz ados.	Nome de um conjunto de dados de referênci a Um mapeam o de colunas (Opciona) Colunas para verificar as correspo dências	`Dataset [ Referer Dataset ias].Da setMatc`	Sim	Não	Sim	Sim	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
DistinctV aluesCou t	Verifica a existênci a de valores duplicad s.	Exatame e um nome de coluna	`Column [C olumn]. stinct\ uesCour`	Sim	Sim	Sim	Sim	Sim	Sim
DetectAr malies	Verifica anomalia nas métricas relatadas de outro tipo de regra.	Um tipo de regra	Métricas relatadas pelo argumen do tipo de regra	Sim	Não	Não	Não	Não	Não
Entropia	Verifica a entropia dos dados.	Exatame e um nome de coluna	`Column [C olumn]. tropy`	Sim	Sim	Não	Sim	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
IsComple e	Verifica se 100% dos dados estão completo .	Exatame e um nome de coluna	`Column. [C olumn]. mpleter s`	Sim	Não	Sim	Não	Não	Sim
IsPrimary Key	Verifica se uma coluna é uma chave primária (não NULA e exclusiva).	Exatame e um nome de coluna	Para colunas únicas: `Column. [C olumn]. iquenes` Para várias colunas: `Multico mn. [Comma Delimit Columns Uniquer s`	Sim	Não	Sim	Não	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
IsUnique	Verifica se 100% dos dados estão exclusivo s.	Exatame e um nome de coluna	`Column [C olumn]. iquenes`	Sim	Não	Sim	Não	Não	Sim
Média	Verifica se a média atende ao limite definido.	Exatame e um nome de coluna	`Column [C olumn]. an`	Sim	Sim	Sim	Sim	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisado r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
Referent alIntegri ty	Verifica se dois conjunto de dados têm integrida de referenci al.	Um ou mais nomes de coluna do conjunto de dados Um ou mais nomes de coluna do conjunto de dados de referênci a	`Column [R eferenc ataset/ as].Re ential egrity`	Sim	Não	Sim	Sim	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
RowCou	Verifica se a contager de registros atende a um limite.	Nenhum	`Dataset .RowCou`	Sim	Sim	Não	Sim	Sim	Sim
RowCou atch	Verifica se há correspo dência nas contager de registros entre dois conjunto de dados.	Alias do conjunto de dados de referênci a	`Dataset [ Referer Dataset ias].Ro ountMat`	Sim	Não	Não	Sim	Não	Não
Standarc eviation	Verifica se o desvio padrão atende ao limite.	Exatame e um nome de coluna	`Column. [C olumn]. andardD iation`	Sim	Sim	Sim	Sim	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatí l como regra?	Compatí l como analisad r?	Retorna resultado s em nível de linha?	Compatí l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
Schemal ch	Verifica se há correspo dência de esquem entre dois conjunto de dados.	Alias do conjunto de dados de referênci a	`Dataset [ Referer Dataset ias].Sc maMatch`	Sim	Não	Não	Sim	Não	Não
Soma	Verifica se a soma atende ao limite definido.	Exatame e um nome de coluna	`Column [C olumn]. m`	Sim	Sim	Não	Sim	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
Exclusivi dade	Verifica se a exclusivi dade do conjunto de dados atende ao limite.	Exatame e um nome de coluna	`Column [C olumn]. iquenes`	Sim	Sim	Sim	Sim	Não	Sim
UniqueV ueRatio	Verifica se a razão de valores exclusivo s atende ao limite.	Exatame e um nome de coluna	`Column [C olumn]. iqueVa Ratio`	Sim	Sim	Sim	Sim	Não	Sim

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?

FileFresh ness	Verifica se arquivos no Amazon S3 estão atualizad os.	Caminho e um limite de arquivo ou pasta.	`Dataset .FileFr hness.C pliance`
			
			`Dataset .FileCo t`
				Sim	Não	Não	Não	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatí l como regra?	Compatí l como analisad r?	Retorna resultad s em nível de linha?	Compatí l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?
FileMatc	Verifica se o conteúdc do arquivo corresp de a uma soma de verificaç ão ou a outro arquivo. Essa regra usa somas de verificaç ão para validar se dois arquivos são iguais.	Caminh do arquivo ou pasta de origem e caminho do arquivo ou pasta de destino.	Nenhum estatísti ca é gerada.	Sim	Não	Não	Não	Não	Não

Ruletype	Descriçã	Argumer s	Métricas reportada s	Compatív l como regra?	Compatív l como analisad r?	Retorna resultado s em nível de linha?	Compatív l com regras dinâmica ?	Gera observaç es	Compatíve l com sintaxe da cláusula Where?

FileSize	Verifica se o tamanho de um arquivo corresponde a uma condição especificada.	Caminho e limite de arquivo ou pasta.	`Dataset .FileSi .Compli ce`
			`Dataset .FileCo t`
			`Dataset .Maximu ileSize`
			`Dataset .Minimu ileSize`
				Sim	Não	Não	Não	Não	Não

FileUniqu eness	Verifica se os arquivos são exclusivos usando somas de verificação.	Caminho e limite de arquivo ou pasta.	`Dataset .FileUn uenessR io` `Dataset .FileCo t`	Sim	Não	Não	Não	Não	Não

Tópicos

- AggregateMatch
- ColumnCorrelation
- ColumnCount
- ColumnDataType
- ColumnExists
- ColumnLength
- ColumnNamesMatchPattern
- ColumnValues
- Completeness
- CustomSQL
- DataFreshness
- DatasetMatch
- DistinctValuesCount
- Entropia
- IsComplete
- IsPrimaryKey
- IsUnique
- Média
- ReferentialIntegrity
- RowCount
- RowCountMatch
- StandardDeviation
- Sum
- SchemaMatch
- Exclusividade
- UniqueValueRatio
- DetectAnomalies
- FileFreshness
- FileMatch
- FileUniqueness

- FileSize

AggregateMatch

Verifica a razão de agregações de duas colunas em relação a uma dada expressão. Esse tipo de regra funciona em vários conjuntos de dados. As agregações de duas colunas são avaliadas e uma razão é produzida dividindo o resultado da agregação da primeira coluna pelo resultado da agregação da segunda coluna. A razão é verificada em relação à expressão fornecida para produzir uma resposta booleana.

Sintaxe

Agregação de colunas

```
AggregateMatch <AGG_OPERATION> (<OPTIONAL_REFERENCE_ALIAS>.<COL_NAME>)
```

- AGG_OPERATION: a operação a ser usada para a agregação. No momento, `sum` e `avg` são compatíveis.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- OPTIONAL_REFERENCE_ALIAS: esse parâmetro precisa ser fornecido se a coluna for de um conjunto de dados de referência e não do conjunto de dados primário. Se você estiver usando essa regra no catálogo de dados do AWS Glue, o alias de referência deverá seguir o formato "<nome_banco de dados>.<nome_tabela>.<nome_coluna>

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- COL_NAME: o nome da coluna a ser agregada.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

Exemplo: média

```
"avg(rating)"
```

Exemplo: soma

```
"sum(amount)"
```

Exemplo: média da coluna no conjunto de dados de referência

```
"avg(reference.rating)"
```

Regra

```
AggregateMatch <AGG_EXP_1> <AGG_EXP_2> <EXPRESSION>
```

- AGG_EXP_1: a agregação da primeira coluna.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- AGG_EXP_2: a agregação da segunda coluna.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: Aggregate Match usando soma

O exemplo de regra a seguir verifica se a soma dos valores na coluna `amount` é exatamente igual à soma dos valores na coluna `total_amount`.

```
AggregateMatch "sum(amount)" "sum(total_amount)" = 1.0
```

Exemplo: Aggregate Match usando média

O exemplo de regra a seguir verifica se a média dos valores na coluna `ratings` é igual a pelo menos 90% da média dos valores na coluna `ratings` no conjunto de dados `reference`. O conjunto de dados de referência é fornecido como uma fonte de dados adicional na experiência de ETL ou do catálogo de dados.

No AWS Glue ETL, você pode usar:

```
AggregateMatch "avg(ratings)" "avg(reference.ratings)" >= 0.9
```

No catálogo de dados do AWS Glue, você pode usar:

```
AggregateMatch "avg(ratings)" "avg(database_name.tablename.ratings)" >= 0.9
```

Comportamento nulo

A `AggregateMatch` regra ignorará as linhas com valores NULL no cálculo dos métodos de agregação (soma/média). Por exemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
|104|40         |
+---+-----------+
```

A média da coluna `units` será (0 + 20 + 40)/3 = 20. As linhas 101 e 103 não são consideradas nesse cálculo.

ColumnCorrelation

Verifica a correlação entre duas colunas em relação a uma determinada expressão. AWS O Glue Data Quality usa o coeficiente de correlação de Pearson para medir a correlação linear entre duas colunas. O resultado é um número entre -1 e 1 que mede a força e a direção da relacão.

Sintaxe

```
ColumnCorrelation <COL_1_NAME> <COL_2_NAME> <EXPRESSION>
```

- COL_1_NAME: o nome da primeira coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- COL_2_NAME: o nome da segunda coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: correlação de colunas

O exemplo de regra a seguir verifica se o coeficiente de correlação entre as colunas `height` e `weight` tem uma correlação positiva forte (um valor de coeficiente maior que 0,8).

```
ColumnCorrelation "height" "weight" > 0.8
```

```
ColumnCorrelation "weightinkgs" "Salary" > 0.8 where "weightinkgs > 40"
```

Exemplos de regras dinâmicas

- `ColumnCorrelation "colA" "colB" between min(last(10)) and max(last(10))`
- `ColumnCorrelation "colA" "colB" < avg(last(5)) + std(last(5))`

Comportamento nulo

A `ColumnCorrelation` regra ignorará linhas com valores `NULL` no cálculo da correlação. Por exemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
|104|40         |
+---+-----------+
```

As linhas 101 e 103 serão ignoradas e `ColumnCorrelation` será 1.0.

ColumnCount

Verifica a contagem de colunas de um conjunto de dados primário em relação a uma expressão dada. Na expressão, você pode especificar o número de colunas ou um intervalo de colunas usando operadores como > e <.

Sintaxe

```
ColumnCount <EXPRESSION>
```

- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: verificação numérica da contagem de colunas

O exemplo de regra a seguir verifica se a contagem de colunas está dentro de um dado intervalo.

```
ColumnCount between 10 and 20
```

Exemplos de regras dinâmicas

- `ColumnCount >= avg(last(10))`
- `ColumnCount between min(last(10))-1 and max(last(10))+1`

ColumnDataType

Verifica se os valores em uma determinada coluna podem ser convertidos no Apache Spark para o tipo fornecido. Aceita uma expressão `with threshold` para verificar um subconjunto dos valores da coluna.

Sintaxe

```
ColumnDataType <COL_NAME> = <EXPECTED_TYPE>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: string

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- EXPECTED_TYPE: o tipo esperado dos valores da coluna.

  Valores compatíveis: booleano, data, timestamp, inteiro, duplo, flutuante, longo

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

- EXPRESSION: uma expressão opcional para especificar a porcentagem de valores que devem ser do tipo esperado.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

Exemplo: números inteiros do tipo de dados da coluna como strings

O exemplo de regra a seguir verifica se os valores na coluna indicada, que é do tipo string, podem ser números inteiros.

```
ColumnDataType "colA" = "INTEGER"
```

Exemplo: números inteiros do tipo de dados da coluna como strings verificam um subconjunto dos valores

O exemplo de regra a seguir verifica se mais de 90% dos valores na coluna indicada, que é do tipo string, podem ser números inteiros.

```
ColumnDataType "colA" = "INTEGER" with threshold > 0.9
```

ColumnExists

Verifica se uma coluna existe.

Sintaxe

```
ColumnExists <COL_NAME>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna

Exemplo: A coluna existe

O exemplo de regra a seguir verifica se a coluna nomeada `Middle_Name` existe.

```
ColumnExists "Middle_Name"
```

ColumnLength

Verifica se o tamanho de cada linha de uma coluna está de acordo com uma determinada expressão.

Sintaxe

```
ColumnLength <COL_NAME><EXPRESSION>
```

- COL_ NAME — O nome da coluna com a qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: string
- EXPRESSION— Uma expressão a ser executada em relação à resposta do tipo de regra para produzir um valor booleano. Para obter mais informações, consulte Expressões.

Exemplo: tamanho da linha da coluna

O exemplo de regra a seguir verifica se o valor em cada linha na coluna nomeada `Postal_Code` contém 5 caracteres.

```
ColumnLength "Postal_Code" = 5
ColumnLength "weightinkgs" = 2 where "weightinkgs > 10"
```

Comportamento nulo

A `ColumnLength` regra trata `NULL`s como strings de comprimento 0. Para uma linha `NULL`:

```
ColumnLength "Postal_Code" > 4 # this will fail
```

```
ColumnLength "Postal_Code" < 6 # this will succeed
```

O exemplo de regra composta a seguir fornece uma maneira de falhar explicitamente valores `NULL`:

```
(ColumnLength "Postal_Code" > 4) AND (ColumnValues "Postal_Code" != NULL)
```

ColumnNamesMatchPattern

Verifica se os nomes de todas as colunas no conjunto de dados primário correspondem à expressão regular dada.

Sintaxe

```
ColumnNamesMatchPattern <PATTERN>
```

- PATTERN: o padrão em relação ao qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

Exemplo: os nomes das colunas correspondem ao padrão

O exemplo de regra a seguir verifica se todas as colunas começam com o prefixo "aws_"

```
ColumnNamesMatchPattern "aws_.*"
ColumnNamesMatchPattern "aws_.*" where "weightinkgs > 10"
```

ColumnValues

Executa uma expressão em relação aos valores em uma coluna.

Sintaxe

```
ColumnValues <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: valores permitidos

O exemplo de regra a seguir verifica se cada valor na coluna especificada está em um conjunto de valores permitidos (inclusive nulo, vazio e strings somente com espaços em branco).

```
ColumnValues "Country" in [ "US", "CA", "UK", NULL, EMPTY, WHITESPACES_ONLY ]
ColumnValues "gender" in ["F", "M"] where "weightinkgs < 10"
```

Exemplo: expressão regular

O exemplo de regra a seguir verifica os valores em uma coluna em relação a uma expressão regular.

```
ColumnValues "First_Name" matches "[a-zA-Z]*"
```

Exemple: valores de data

O exemplo de regra a seguir verifica os valores em uma coluna de datas em relação a uma expressão regular.

```
ColumnValues "Load_Date" > (now() - 3 days)
```

Exemplo: valores numéricos

O exemplo de regra a seguir verifica se os valores da coluna correspondem a uma determinada restrição numérica.

```
ColumnValues "Customer_ID" between 1 and 2000
```

Comportamento nulo

Para todas as regras `ColumnValues` (exceto `!=` e`NOT IN`), as linhas `NULL` falharão na regra. Se a regra falhar devido a um valor nulo, o motivo da falha exibirá o seguinte:

```
Value: NULL does not meet the constraint requirement!
```

O exemplo de regra composta a seguir fornece uma maneira de permitir explicitamente valores `NULL`:

```
(ColumnValues "Age" > 21) OR (ColumnValues "Age" = NULL)
```

As regras de ColumnValues negadas usando a sintaxe `!=` e `not in` serão transmitidas para as linhas `NULL`. Por exemplo:

```
ColumnValues "Age" != 21
```

```
ColumnValues "Age" not in [21, 22, 23]
```

Os exemplos a seguir fornecem uma maneira de falhar explicitamente valores `NULL`

```
(ColumnValues "Age" != 21) AND (ColumnValues "Age" != NULL)
```

```
ColumnValues "Age" not in [21, 22, 23, NULL]
```

Completeness

Verifica a porcentagem de valores completos (não nulos) em uma coluna em relação a uma determinada expressão.

Sintaxe

```
Completeness <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: porcentagem de valor nulo

O exemplo de regras a seguir verifica se mais de 95 por cento dos valores em uma coluna são completos .

```
Completeness "First_Name" > 0.95
Completeness "First_Name" > 0.95 where "weightinkgs > 10"
```

Exemplos de regras dinâmicas

- `Completeness "colA" between min(last(5)) - 1 and max(last(5)) + 1`
- `Completeness "colA" <= avg(last(10))`

Comportamento nulo

Observação sobre formatos de dados CSV: linhas em branco em colunas CSV podem apresentar vários comportamentos.

- Se uma coluna for do tipo `String`, a linha em branco será reconhecida como uma string vazia e não falhará na regra `Completeness`.
- Se uma coluna for de outro tipo de dados, por exemplo, `Int`, a linha em branco será reconhecida como `NULL` e falhará na regra `Completeness`.

CustomSQL

Esse tipo de regra foi estendido para ser compatível a dois casos de uso:

- Executar uma instrução SQL personalizada em um conjunto de dados e verificar o valor de retorno em relação a uma dada expressão.
- Executar uma instrução SQL personalizada na qual você especifica um nome de coluna na instrução SELECT a qual você compara com alguma condição para obter resultados no nível de linha.

Sintaxe

```
CustomSql <SQL_STATEMENT> <EXPRESSION>
```

- SQL_STATEMENT: uma instrução SQL que retorna um único valor numérico entre aspas duplas.
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: SQL personalizado para recuperar o resultado de uma regra geral

Esse exemplo de regra usa uma instrução SQL para recuperar a contagem de registros de um conjunto de dados. A regra então verifica se a contagem de registros está entre 10 e 20.

```
CustomSql "select count(*) from primary" between 10 and 20
```

Exemplo: SQL personalizado para recuperar resultados no nível de linha

Esse exemplo de regra usa uma instrução SQL personalizada na qual você especifica um nome de coluna na instrução SELECT que você compara com alguma condição para obter resultados no nível de linha. Uma expressão de condição limite define um limite de quantos registros devem ser reprovados para que toda a regra seja reprovada. Observe que uma regra pode não conter uma condição e uma palavra-chave juntas.

```
CustomSql "select Name from primary where Age  > 18"
```

or

```
CustomSql "select Name from primary where Age > 18" with threshold  > 3
```

> **Important**
>
> O alias `primary` representa o nome do conjunto de dados que você deseja avaliar. Quando você lida com trabalhos visuais do ETL no console, `primary` sempre representa o `DynamicFrame` que está sendo passado para a transformação `EvaluateDataQuality.apply()`. Quando você usa o AWS Glue Data Catalog para executar tarefas de qualidade de dados em uma tabela, `primary` representa a tabela.

Se você estiver no catálogo de dados do AWS Glue, também poderá usar os nomes reais das tabelas:

```
CustomSql "select count(*) from database.table" between 10 and 20
```

Você também pode unir várias tabelas para comparar diferentes elementos de dados:

```
CustomSql "select count(*) from database.table inner join database.table2 on id1 = id2"
 between 10 and 20
```

No AWS Glue ETL, o CustomSQL pode identificar registros que foram reprovados nas verificações de qualidade dos dados. Para que isso funcione, você precisará retornar registros que sejam parte da tabela primária para cuja qualidade de dados você está avaliando. Os registros retornados como parte da consulta são considerados bem-sucedidos e os registros que não são retornados são considerados reprovados. Isso funciona unindo o resultado da sua consulta em CustomSQL com o conjunto de dados original. Pode haver implicações para a performance dependendo da complexidade da consulta em SQL.

Para fazer isso:

- Você precisa selecionar pelo menos uma coluna na tabela primária.
  - `select count(*) from primary` é uma consulta válida para a regra de DQ em CustomSQL OVERALL, mas não para CustomSQL no nível de linha.

  - Essa regra gerará um erro durante a avaliação: `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.`
- Em sua consulta em SQL, selecione uma "chave primária" na tabela ou selecione um conjunto de colunas que formam uma chave composta. Não fazer isso pode gerar resultados inconsistentes devido à correspondência de linhas duplicadas e degradação do performance.
- Selecione chaves SOMENTE na tabela primária e não nas tabelas de referência.

A regra a seguir garantirá que registros com idade < 100 sejam identificados como bem-sucedidos e que os registros acima sejam marcados como reprovados.

```
CustomSql "select id from primary where age < 100"
```

Essa regra CustomSQL será aprovada quando 50% dos registros tiverem mais de 10 anos e também identificará os registros que foram reprovados. Os registros retornados por esse CustomSQL serão considerados aprovados, enquanto os não retornados serão considerados reprovados.

```
CustomSQL "select ID, CustomerID from primary where age > 10" with threshold > 0.5
```

Observação: a regra CustomSQL falhará se você retornar registros que não estão disponíveis no conjunto de dados.

DataFreshness

Verifica a atualidade dos dados em uma coluna avaliando a diferença entre a hora atual e os valores de uma coluna de data. Você pode especificar uma expressão baseada em tempo para esse tipo de regra para garantir que os valores das colunas estejam atualizados.

Sintaxe

```
DataFreshness <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

Tipos de coluna compatíveis: data

- EXPRESSION: uma expressão numérica em horas ou dias. Você deve especificar a unidade de tempo na expressão.

Exemplo: atualidade dos dados

O exemplo de regras a seguir verifica a atualidade dos dados.

```
DataFreshness "Order_Date" <= 24 hours
DataFreshness "Order_Date" between 2 days and 5 days
```

Comportamento nulo

As regras `DataFreshness` falharão para linhas com valores `NULL`. Se a regra falhar devido a um valor nulo, o motivo da falha exibirá o seguinte:

```
80.00 % of rows passed the threshold
```

onde 20% das linhas que falharam incluem as linhas com `NULL`.

O exemplo de regra composta a seguir fornece uma maneira de permitir explicitamente valores `NULL`:

```
(DataFreshness "Order_Date" <= 24 hours) OR (ColumnValues "Order_Date" = NULL)
```

Atualidade dos dados para objetos do Amazon S3

Às vezes, você precisará validar a atualidade dos dados com base na hora de criação do arquivo Amazon S3. Para fazer isso, é possível usar o código a seguir para obter o carimbo de data/hora e adicioná-lo ao seu quadro de dados e, em seguida, aplicar as verificações de atualidade dos dados.

```
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

Verifica se os dados do conjunto de dados primário correspondem aos dados de um conjunto de dados de referência. Os dois conjuntos de dados são unidos usando os mapeamentos de colunas de chaves fornecidos. Mapeamentos de colunas adicionais podem ser fornecidos caso você deseje verificar a igualdade dos dados somente nessas colunas. Para que DataSetMatch funcione, suas chaves de união deverão ser exclusivas e não deverão ser NULL (deverão ser uma chave primária). Se você não atender a essas condições, receberá a mensagem de erro “O mapa de teclas fornecido não é adequado para determinados quadros de dados”. Nos casos em que você não puder ter chaves de união exclusivas, considere usar outros tipos de regras, como AggregateMatch, para comparar com base nos dados resumidos.

Sintaxe

```
DatasetMatch <REFERENCE_DATASET_ALIAS> <JOIN CONDITION WITH
 MAPPING> <OPTIONAL_MATCH_COLUMN_MAPPINGS> <EXPRESSION>
```

- REFERENCE_DATASET_ALIAS: o alias do conjunto de dados de referência com o qual você compara os dados do conjunto de dados primário.
- KEY_COLUMN_MAPPINGS: uma lista separada por vírgulas dos nomes das colunas que formam uma chave nos conjuntos de dados. Se os nomes das colunas não forem iguais nos dois conjuntos de dados, você deverá separá-los com um `->`
- OPTIONAL_MATCH_COLUMN_MAPPINGS: você pode fornecer esse parâmetro se quiser verificar se existe correspondência de dados somente em determinadas colunas. É usada a mesma sintaxe dos mapeamentos de colunas de chaves. Se esse parâmetro não for fornecido, compararmos os todas as colunas restantes. As colunas sem chave restantes, devem ter os mesmos nomes nos dois conjuntos de dados.
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: comparar os conjuntos de dados usando a coluna ID

O exemplo de regra a seguir verifica se mais de 90% do conjunto de dados primário corresponde ao conjunto de dados de referência, usando a coluna "ID" para unir os dois conjuntos de dados. Ele compara todas as colunas nesse caso.

```
DatasetMatch "reference" "ID" >= 0.9
```

Exemplo: comparar os conjuntos de dados usando várias colunas de chaves

No exemplo a seguir, o conjunto de dados primário e o conjunto de dados de referência têm nomes diferentes para as colunas-chave. `ID_1` e `ID_2` juntos formam uma chave composta no conjunto de dados primário. `ID_ref1` e `ID_ref2` juntos formam uma chave composta no conjunto de dados de referência. Nesse cenário, você pode usar a sintaxe especial para fornecer os nomes das colunas.

```
DatasetMatch "reference" "ID_1->ID_ref1,ID_ref2->ID_ref2" >= 0.9
```

Exemplo: comparar conjuntos de dados usando várias colunas de chaves e verifique se a coluna específica corresponde

Este exemplo se baseia no exemplo anterior. Queremos verificar se apenas a coluna que contém os valores corresponde. Essa coluna é denominada `Amount1` no conjunto de dados primário e `Amount2` no conjunto de dados de referência. Você quer uma correspondência exata.

```
DatasetMatch "reference" "ID_1->ID_ref1,ID_2->ID_ref2" "Amount1->Amount2" >= 0.9
```

DistinctValuesCount

Verifica o número de valores distintos em uma coluna em relação a uma determinada expressão.

Sintaxe

```
DistinctValuesCount <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: contagem distinta de valores de colunas

O exemplo de regra a seguir verifica se a coluna denominada `State` contém mais de 3 valores distintos.

```
DistinctValuesCount "State" > 3
```

```
DistinctValuesCount "Customer_ID" < 6  where "Customer_ID < 10"
```

Exemplos de regras dinâmicas

- `DistinctValuesCount "colA" between avg(last(10))-1 and avg(last(10))+1`
- `DistinctValuesCount "colA" <= index(last(10),2) + std(last(5))`

Entropia

Verifica se o valor de entropia de uma coluna corresponde a uma determinada expressão. A entropia mede o nível de informação que está contida em uma mensagem. Dada a distribuição de probabilidade pelos valores em uma coluna, a entropia descreve quantos bits são necessários para identificar um valor.

Sintaxe

```
Entropy <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: entropia de coluna

O exemplo de regra a seguir verifica se a coluna determinada `Feedback` tem um valor de entropia maior que um.

```
Entropy "Star_Rating" > 1
Entropy "First_Name" > 1  where "Customer_ID < 10"
```

Exemplos de regras dinâmicas

- `Entropy "colA" < max(last(10))`
- `Entropy "colA" between min(last(10)) and max(last(10))`

IsComplete

Verifica se todos os valores em uma coluna estão completos (não nulos).

Sintaxe

```
IsComplete <COL_NAME>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna

Exemplo: valores nulos

O exemplo a seguir verifica se todos os valores em uma coluna denominada `email` não são nulos.

```
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"
```

Comportamento nulo

Observação sobre formatos de dados CSV: linhas em branco em colunas CSV podem apresentar vários comportamentos.

- Se uma coluna for do tipo `String`, a linha em branco será reconhecida como uma string vazia e não falhará na regra `Completeness`.
- Se uma coluna for de outro tipo de dados, por exemplo, `Int`, a linha em branco será reconhecida como `NULL` e falhará na regra `Completeness`.

IsPrimaryKey

Verifica se uma coluna contém uma chave primária. Uma coluna contém uma chave primária se todos os valores na coluna forem exclusivos e completos (não nulos). Também é possível verificar as chaves primárias com várias colunas.

Sintaxe

```
IsPrimaryKey <COL_NAME>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna

Exemplo: chave primária

O exemplo de regra a seguir verifica se a coluna denominada `Customer_ID` contém uma chave primária.

```
IsPrimaryKey "Customer_ID"
IsPrimaryKey "Customer_ID" where "Customer_ID < 10"
```

Exemplo: chave primária com várias colunas. Qualquer um dos exemplos a seguir é válido.

```
IsPrimaryKey "colA" "colB"
IsPrimaryKey "colA" "colB" "colC"
IsPrimaryKey colA "colB" "colC"
```

IsUnique

Verifica se todos os valores em uma coluna são exclusivos e retorna um valor booliano.

Sintaxe

```
IsUnique <COL_NAME>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna

Exemplos

O exemplo de regra a seguir verifica se todos os valores em uma coluna denominada `email` são exclusivos.

```
IsUnique "email"
IsUnique "Customer_ID" where "Customer_ID < 10"]
```

O exemplo de regra a seguir verifica várias colunas.

```
IsUnique "vendorid" "tpep_pickup_datetime"
```

Média

Verifica se o valor mediano (média) de uma coluna corresponde a uma determinada expressão.

Sintaxe

```
Mean <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: valor médio

O exemplo de regra a seguir verifica se a média de todos os valores em uma coluna excede um limite.

```
Mean "Star_Rating" > 3
Mean "Salary" < 6200 where "Customer_ID < 10"
```

Exemplos de regras dinâmicas

- `Mean "colA" > avg(last(10)) + std(last(2))`
- `Mean "colA" between min(last(5)) - 1 and max(last(5)) + 1`

Comportamento nulo

A regra `Mean` ignorará linhas com valores `NULL` no cálculo da média. Por exemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
|104|40         |
+---+-----------+
```

A média da coluna `units` será (0 + 20 + 40)/3 = 20. As linhas 101 e 103 não são consideradas nesse cálculo.

ReferentialIntegrity

Verifica até que ponto os valores de um conjunto de colunas no conjunto de dados primário são um subconjunto dos valores de um conjunto de colunas em um conjunto de dados de referência.

Sintaxe

```
ReferentialIntegrity <PRIMARY_COLS> <REFERENCE_DATASET_COLS> <EXPRESSION>
```

- PRIMARY_COLS: uma lista de nomes de coluna separados por vírgulas no conjunto de dados primário.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- REFERENCE_DATASET_COLS: esse parâmetro contém duas partes separadas por um ponto. A primeira parte é o alias do conjunto de dados de referência. A segunda parte é a lista separada por vírgulas dos nomes das colunas do conjunto de dados de referência entre colchetes.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: verificar a integridade referencial de uma coluna de códigos postais

O exemplo de regra a seguir verifica se mais de 90% dos valores da coluna `zipcode` do conjunto de dados primário estão presentes na coluna `zipcode` do conjunto de dados `reference`.

```
ReferentialIntegrity "zipcode" "reference.zipcode" >= 0.9
```

Exemplo: verificar a integridade referencial das colunas de cidades e estados

No exemplo a seguir, existem colunas contendo informações sobre cidades e estados no conjunto de dados primário e no conjunto de dados de referência. Os nomes das colunas são diferentes nos dois conjuntos de dados. A regra verifica se o conjunto de valores das colunas do conjunto de dados primário é exatamente igual ao conjunto de valores das colunas do conjunto de dados de referência.

```
ReferentialIntegrity "city,state" "reference.{ref_city,ref_state}" = 1.0
```

Exemplos de regras dinâmicas

- `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

Verifica a contagem de linhas de um conjunto de dados em relação a uma determinada expressão. Na expressão, você pode especificar o número de linhas ou um intervalo de linhas usando operadores como > e <.

Sintaxe

```
RowCount <EXPRESSION>
```

- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: verificação numérica da contagem de linhas

O exemplo de regra a seguir verifica se a contagem de linhas está dentro de um determinado intervalo.

```
RowCount between 10 and 100
RowCount between 1 and 50 where "Customer_ID < 10"
```

Exemplos de regras dinâmicas

```
RowCount > avg(last(10)) *0.8
```

RowCountMatch

Verifica a razão entre a contagem de linhas do conjunto de dados primário e a contagem de linhas de um conjunto de dados de referência em relação à expressão dada.

Sintaxe

```
RowCountMatch <REFERENCE_DATASET_ALIAS> <EXPRESSION>
```

- REFERENCE_DATASET_ALIAS O alias do conjunto de dados de referência com o qual comparar as contagens de linhas.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: verificação da contagem de linhas em relação a um conjunto de dados de referência

O exemplo de regra a seguir verifica se a contagem de linhas do conjunto de dados primário é pelo menos 90% da contagem de linhas do conjunto de dados de referência.

```
RowCountMatch "reference" >= 0.9
```

StandardDeviation

Verifica o desvio padrão de todos os valores em uma coluna em relação a uma determinada expressão.

Sintaxe

```
StandardDeviation <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto

- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: desvio padrão

O exemplo de regra a seguir verifica se o desvio padrão dos valores em uma coluna denominada `colA` é menor que um valor especificado.

```
StandardDeviation "Star_Rating" < 1.5
StandardDeviation "Salary" < 3500 where "Customer_ID < 10"
```

Exemplos de regras dinâmicas

- `StandardDeviation "colA" > avg(last(10) + 0.1`
- `StandardDeviation "colA" between min(last(10)) - 1 and max(last(10)) + 1`

Comportamento nulo

A regra `StandardDeviation` ignorará linhas com valores `NULL` no cálculo do desvio padrão. Por exemplo:

```
+---+-----------+-----------+
|id |units1     |units2     |
+---+-----------+-----------+
|100|0          |0          |
|101|null       |0          |
|102|20         |20         |
|103|null       |0          |
|104|40         |40         |
+---+-----------+-----------+
```

O desvio padrão da coluna `units1` não considerará as linhas 101 e 103 e resultará em 16,33. O desvio padrão da coluna `units2` resultará em 16.

Sum

Verifica a soma de todos os valores em uma coluna em relação a uma determinada expressão.

Sintaxe

```
Sum <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: soma

O exemplo de regra a seguir verifica se a soma de todos os valores em uma coluna excede um limite.

```
Sum "transaction_total" > 500000
Sum "Salary" < 55600 where "Customer_ID < 10"
```

Exemplos de regras dinâmicas

- `Sum "ColA" > avg(last(10))`
- `Sum "colA" between min(last(10)) - 1 and max(last(10)) + 1`

Comportamento nulo

A regra `Sum` ignorará linhas com valores `NULL` no cálculo da soma. Por exemplo:

```
+---+-----------+
|id |units      |
+---+-----------+
|100|0          |
|101|null       |
|102|20         |
|103|null       |
|104|40         |
+---+-----------+
```

A soma da coluna `units` não considerará as linhas 101 e 103 e resultará em (0 + 20 + 40) = 60.

SchemaMatch

Verifica se o esquema do conjunto de dados primário corresponde ao esquema de um conjunto de dados de referência. A verificação de esquema é feita coluna por coluna. O esquema de duas colunas corresponde se os nomes forem idênticos e os tipos forem idênticos. A ordem das colunas não importa.

Sintaxe

```
SchemaMatch <REFERENCE_DATASET_ALIAS> <EXPRESSION>
```

- REFERENCE_DATASET_ALIAS: o alias do conjunto de dados de referência com o qual comparar os esquemas.

  Tipos de coluna compatíveis: byte, decimal, duplo, flutuante, inteiro, longo, curto
- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: SchemaMatch

A regra de exemplo a seguir verifica se o esquema do conjunto de dados primário corresponde exatamente ao esquema de um conjunto de dados de referência.

```
SchemaMatch "reference" = 1.0
```

Exclusividade

Verifica a porcentagem de valores exclusivos em uma coluna em relação a uma determinada expressão. Valores exclusivos ocorrem exatamente uma vez.

Sintaxe

```
Uniqueness <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna

- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para obter mais informações, consulte Expressões.

Exemplo

O exemplo de regra a seguir verifica se a porcentagem de valores exclusivos em uma coluna corresponde a determinados critérios numéricos.

```
Uniqueness "email" = 1.0
Uniqueness "Customer_ID" != 1.0 where "Customer_ID < 10"
```

O exemplo de regra a seguir verifica várias colunas.

```
Uniqueness "vendorid" "tpep_pickup_datetime" = 1
```

Exemplos de regras dinâmicas

- `Uniqueness "colA" between min(last(10)) and max(last(10))`
- `Uniqueness "colA" >= avg(last(10))`

UniqueValueRatio

Verifica a razão de valores exclusivos em uma coluna em relação a uma determinada expressão. Uma razão de valor exclusivo é a fração de valores exclusivos dividida pelo número de todos os valores distintos em uma coluna. Valores exclusivos ocorrem exatamente uma vez, enquanto valores distintos ocorrem pelo menos uma vez.

Por exemplo, o conjunto `[a, a, b]` contém um valor exclusivo (b) e dois valores distintos (a e b). Portanto, a proporção de valores exclusivos do conjunto é ½ = 0,5.

Sintaxe

```
UniqueValueRatio <COL_NAME> <EXPRESSION>
```

- COL_NAME: o nome da coluna em relação à qual você deseja avaliar a regra de qualidade de dados.

  Tipos de coluna compatíveis: qualquer tipo de coluna

- EXPRESSION: uma expressão a ser executada na resposta do tipo de regra para produzir um valor booliano. Para ter mais informações, consulte Expressões.

Exemplo: razão de valores exclusivos

Esse exemplo verifica a proporção de valores exclusivos de uma coluna em relação a um intervalo de valores.

```
UniqueValueRatio "test_score" between 0 and 0.5
UniqueValueRatio "Customer_ID" between 0 and 0.9 where "Customer_ID < 10"
```

Exemplos de regras dinâmicas

- `UniqueValueRatio "colA" > avg(last(10))`
- `UniqueValueRatio "colA" <= index(last(10),2) + std(last(5))`

DetectAnomalies

Detecta anomalias em uma determinada regra de qualidade de dados. Cada execução da regra DetectAnomalies resulta em salvar o valor avaliado para a regra fornecida. Quando há dados suficientes coletados, o algoritmo de detecção de anomalias pega todos os dados históricos dessa regra e executa a detecção de anomalias. A regra DetectAnomalies falha quando uma anomalia é detectada. Para obter mais informações sobre qual anomalia foi detectada, consulte Observações.

Sintaxe

```
DetectAnomalies <RULE_NAME> <RULE_PARAMETERS>
```

`RULE_NAME`: o nome da regra para a qual você quer avaliar e detectar anomalias. Regras compatíveis:

- "RowCount"
- "Completeness"
- "Uniqueness"
- "Mean"

- "Sum"
- "StandardDeviation"
- "Entropy"
- "DistinctValuesCount"
- "UniqueValueRatio"
- "ColumnLength"
- "ColumnValues"
- "ColumnCorrelation"
- "CustomSQL"
- "ColumnCount"

`RULE_PARAMETERS`: algumas regras exigem parâmetros adicionais para serem executadas. Consulte a documentação da regra fornecida para ver os parâmetros necessários.

Exemplo: anomalias para RowCount

Por exemplo, se quisermos detectar anomalias de RowCount, fornecemos RowCount como nome de regra.

```
DetectAnomalies "RowCount"
```

Exemplo: anomalias para ColumnLength

Por exemplo, se quisermos detectar anomalias de ColumnLength, fornecemos ColumnLength como nome de regra e nome de coluna.

```
DetectAnomalies "ColumnLength" "id"
```

FileFreshness

O FileFreshness garante que os arquivos de dados estejam atualizados com base nas condições que você fornece. Ele usa a hora da última modificação dos arquivos para garantir que os arquivos de dados ou a pasta inteira esteja atualizada.

Essa regra reúne duas métricas:

- Conformidade com o FileFreshness com base na regra que você configurou
- O número de arquivos que foram verificados pela regra

```
{"Dataset.*.FileFreshness.Compliance":1,"Dataset.*.FileCount":1}
```

A detecção de anomalias não considera essas métricas.

Verificação da atualização do arquivo

A regra a seguir garante que o tickets.parquet tenha sido criado nas últimas 24 horas.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/tickets.parquet" >
 (now() - 24 hours)
```

Verificação da atualização da pasta

A regra a seguir será válida se todos os arquivos da pasta tiverem sido criados ou modificados nas últimas 24 horas.

```
FileFreshness "s3://bucket/" >= (now() -1 days)
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" >= (now() - 24 hours)
```

Verificação da atualização da pasta ou do arquivo com limite

A regra a seguir é válida se 10% dos arquivos da pasta “tiquetes” tiverem sido criados ou modificados nos últimos 10 dias.

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" < (now() - 10 days)
 with threshold > 0.1
```

Verificação de arquivos ou pastas com datas específicas

Você pode verificar a atualização de arquivos em dias específicos.

```
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"
```

Verificação de arquivos ou pastas com hora

É possível usar FileFreshness para garantir que os arquivos chegaram com base em determinadas horas.

```
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"
```

Considerações importantes:

- O FileFreshness pode avaliar arquivos usando unidades de dias, horas e minutos
- Para horários, ele oferece suporte aos formatos AM/PM e de 24 horas
- Os horários são calculados em UTC, a menos que algo diferente seja especificado
- As datas são calculadas em UTC no horário 00:00

O FileFreshness baseado em hora funciona da seguinte forma:

```
FileFreshness "s3://amzn-s3-demo-bucket/artifacts/file/tickets/" > "21:45"
```

- Primeiro, o horário "21h45" é combinado com a data de hoje no formato UTC para criar um campo de data e hora
- Em seguida, a data e hora são convertidas para um fuso horário que você especificou
- Finalmente, a regra é avaliada

Tags de regras opcionais baseadas em arquivos:

As tags permitem controlar o comportamento da regra.

recentFiles

Essa tag limita o número de arquivos processados ao manter primeiro o arquivo mais recente.

```
FileFreshness "s3://amzn-s3-demo-bucket/" between (now() - 100 minutes) and (now() + 10
 minutes) with recentFiles = 1
```

timeZone

Substituições de fuso horário aceitas, consulte Fusos horários permitidos para ver os fusos horários compatíveis.

```
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"
```

Dedução de nomes de arquivos diretamente de quadros de dados

Você nem sempre precisa fornecer um caminho de arquivo. Por exemplo, quando você está criando a regra no Catálogo de Dados do AWS Glue, pode ser difícil descobrir quais pastas as tabelas do catálogo estão usando. O AWS Glue Data Quality pode encontrar as pastas ou arquivos específicos usados para o preenchimento do quadro de dados e detectar se eles estão atualizados.

> **Note**
>
> Esse recurso só funcionará quando os arquivos forem lidos com sucesso no DynamicFrame ou no DataFrame.

```
FileFreshness > (now() - 24 hours)
```

Essa regra descobrirá o caminho da pasta ou os arquivos usados para preencher o quadro dinâmico ou o quadro de dados. Isso funciona para caminhos do Amazon S3 ou para tabelas do Catálogo de Dados do AWS Glue baseadas no Amazon S3. Existem algumas considerações:

1. No ETL do AWS Glue, você deve ter a transformação EvaluateDataQuality imediatamente após uma transformação do Amazon S3 ou do Catálogo de Dados do AWS Glue.

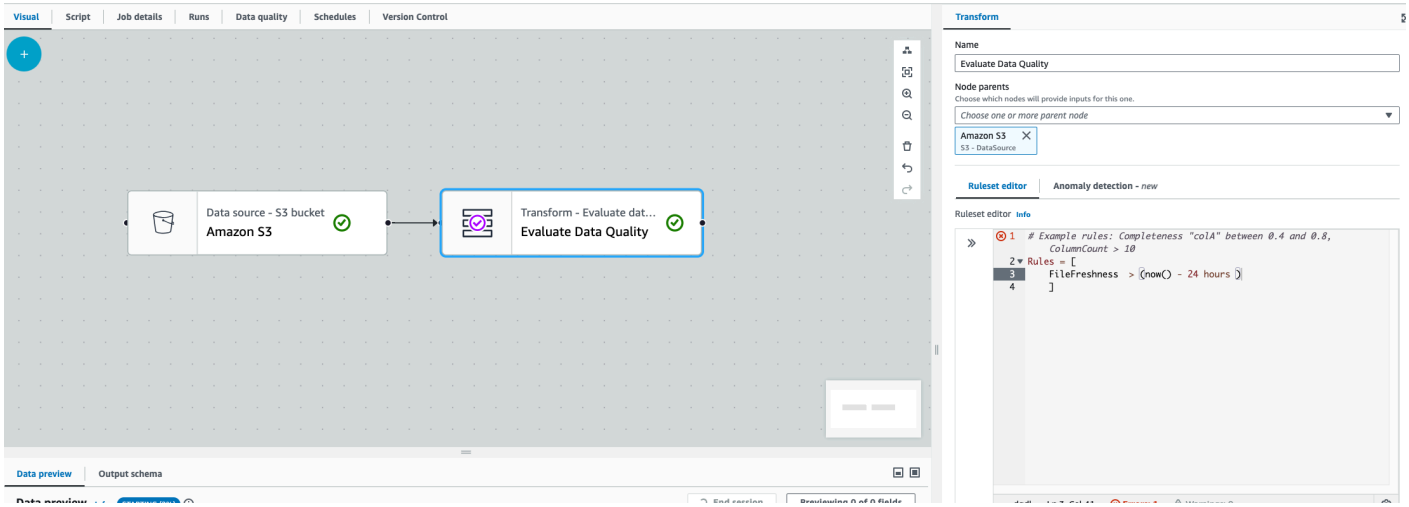

2. Essa regra não funcionará nas sessões interativas do AWS Glue.

Se você tentar isso em ambos os casos, ou quando o AWS Glue não conseguir encontrar os arquivos, o AWS Glue irá gerar o seguinte erro: “`Unable to parse file path from DataFrame`”

FileMatch

A regra FileMatch permite que você compare arquivos com outros arquivos ou somas de verificação. Isso pode ser útil em algumas situações:

1. Validação de arquivos recebidos de fontes externas: você pode usar o FileMatch para garantir que recebeu os arquivos corretos de fontes externas ao compará-los com somas de verificação. Isso ajuda a validar a integridade dos dados que você está ingerindo.
2. Comparação de dados em duas pastas diferentes: o FileMatch pode ser usado para comparar arquivos entre duas pastas.

Essa regra reúne uma métrica: o número de arquivos que foram examinados pela regra.

```
{"Dataset.*.FileCount":1}
```

Validar arquivos com uma soma de verificação:

O FileMatch aceita um arquivo e um conjunto de somas de verificação para garantir que pelo menos uma delas corresponda ao arquivo.

```
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"]
```

Os seguintes algoritmos padrão são compatíveis:

- MD5
- SHA-1
- SHA-256

Se você não fornecer um algoritmo, o padrão será SHA-256.

Validar todos os arquivos de uma pasta com um conjunto de somas de verificação:

```
FileMatch "s3://amzn-s3-demo-bucket /" in ["3ee0d8617ac041793154713e5ef8f319",
 "7e8617ac041793154713e5ef8f319"] with hashAlgorithm = "MD5"
FileMatch "s3://amzn-s3-demo-bucket /internal-folder/" in
 ["3ee0d8617ac041793154713e5ef8f319", "7e8617ac041793154713e5ef8f319"]
```

Comparar arquivos em pastas diferentes

```
FileMatch "s3://original_bucket/" "s3://archive_bucket/"
FileMatch "s3://original_bucket/internal-folder/" "s3://original_bucket/other-folder/"
```

O FileMatch verificará o conteúdo dos arquivos do `original_bucket` e garantirá que eles correspondam ao conteúdo do `archive_bucket`. A regra falhará se eles não corresponderem exatamente. Ele também pode verificar o conteúdo de pastas internas ou arquivos individuais.

O FileMatch também pode comparar arquivos individuais uns com os outros.

```
FileMatch "s3://amzn-s3-demo-bucket /file_old.json" "s3://amzn-s3-demo-bucket /
file_new.json"
```

Dedução de nomes de arquivos diretamente de quadros de dados

Você nem sempre precisa fornecer um caminho de arquivo. Por exemplo, quando você está criando a regra no Catálogo de Dados do AWS Glue (com o suporte do Amazon S3), pode ser difícil descobrir quais pastas as tabelas do catálogo estão usando. O AWS Glue Data Quality pode encontrar as pastas ou arquivos específicos usados para o preenchimento do quadro de dados.

> **Note**
>
> Esse recurso só funcionará quando os arquivos forem lidos com sucesso no DynamicFrame ou no DataFrame.

```
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "MD5"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "SHA-1"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"] with hashAlgorithm = "SHA-256"
FileMatch in ["3ee0d8617ac041793154713e5ef8f319"]
```

Se a soma de verificação fornecida for diferente da calculada, o FileMatch alertará você sobre a diferença.

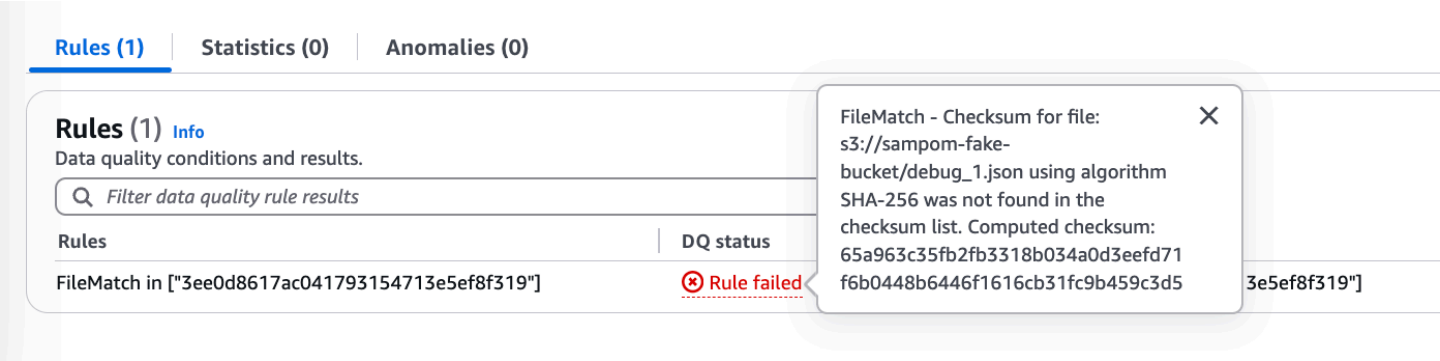

Tags de regras opcionais baseadas em arquivos:

As tags permitem controlar o comportamento da regra.

recentFiles

Essa tag limita o número de arquivos processados ao manter primeiro o arquivo mais recente.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac04179sam4713e5ef8f319"]
 with recentFiles = 1
```

matchFileName

Essa tag garante que os arquivos não tenham nomes duplicados. O comportamento padrão é falso.

```
FileMatch "s3://amzn-s3-demo-bucket/file.json" in ["3ee0d8617ac04179sam4713e5ef8f319"]
 with matchFileName = "true"
```

Existem algumas considerações:

1. No ETL do AWS Glue, você deve ter a transformação EvaluateDataQuality imediatamente após uma transformação do Amazon S3 ou do Catálogo de Dados do AWS Glue.

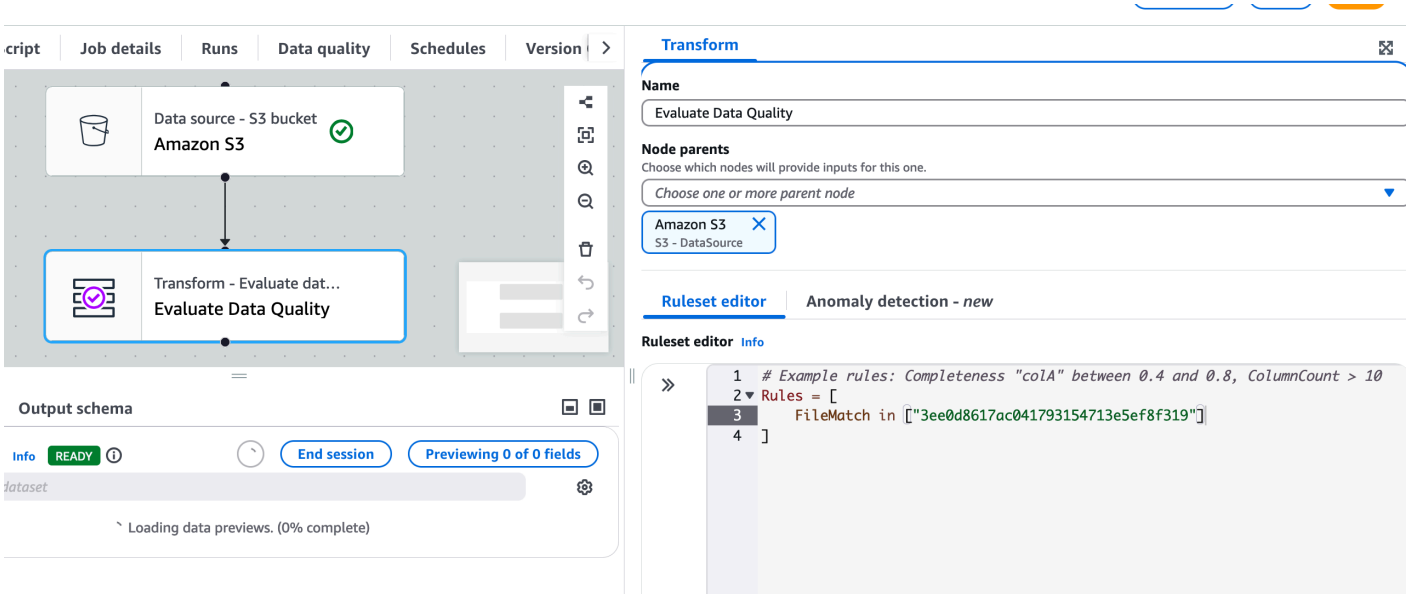

2. Essa regra não funcionará nas sessões interativas do AWS Glue.

FileUniqueness

O FileUniqueness permite que você garanta que não haja arquivos duplicados nos dados que você recebeu dos produtores de dados.

A regra reúne as seguintes estatísticas de dados:

1. O número de arquivos que foram verificados pela regra

2. A taxa de exclusividade dos arquivos

```
Dataset.*.FileUniquenessRatio: 1.00, Dataset.*.FileCount: 8.00
```

Encontrar arquivos duplicados em uma pasta:

```
FileUniqueness "s3://bucket/" > 0.5
FileUniqueness "s3://bucket/folder/" = 1
```

Inferir nomes de pastas diretamente dos quadros de dados para detectar duplicatas:

Você nem sempre precisa fornecer um caminho de arquivo. Por exemplo, quando você está criando a regra no Catálogo de Dados do AWS Glue, pode ser difícil descobrir quais pastas as tabelas do catálogo estão usando. O AWS Glue Data Quality pode encontrar as pastas ou arquivos específicos usados para o preenchimento do quadro de dados.

> **Note**
>
> Quando a inferência é usada, as regras baseadas em arquivos só podem detectar arquivos lidos com sucesso no DynamicFrame ou no DataFrame.

```
FileUniqueness > 0.5
```

Tags de regras opcionais baseadas em arquivos:

As tags permitem controlar o comportamento da regra.

recentFiles

Essa tag limita o número de arquivos processados ao manter primeiro o arquivo mais recente.

```
FileUniqueness "s3://amzn-s3-demo-bucket/" > 0.5 with recentFiles = 1
```

matchFileName

Essa tag garante que os arquivos não tenham nomes duplicados. O comportamento padrão é falso.

```
FileUniqueness "s3://amzn-s3-demo-bucket/" > 0.5 with matchFileName = "true"
```

Existem algumas considerações:

1. No ETL do AWS Glue, você deve ter a transformação EvaluateDataQuality imediatamente após uma transformação do Amazon S3 ou do Catálogo de Dados do AWS Glue.
2. Essa regra não funcionará nas sessões interativas do AWS Glue.

FileSize

A regra FileSize permite que você garanta que os arquivos atendam a determinados critérios de tamanho. Isso é útil para os seguintes casos de uso:

1. Certificar-se de que os produtores não estejam enviando arquivos vazios ou substancialmente menores para processamento.
2. Certificar-se de que os buckets de destino não tenham arquivos menores, o que pode causar problemas de desempenho.

O FileSize reúne as seguintes métricas:

1. Conformidade: retorna a porcentagem de arquivos que atendem ao limite da regra que você estabeleceu
2. Contagem de arquivos: o número de arquivos que foram verificados pela regra
3. Tamanho mínimo do arquivo em bytes
4. Tamanho máximo do arquivo em bytes

```
Dataset.*.FileSize.Compliance: 1.00,
Dataset.*.FileCount: 8.00,
Dataset.*.MaximumFileSize: 327413121.00,
Dataset.*.MinimumFileSize: 204558920.00
```

A detecção de anomalias não é compatível com essas métricas.

Validar o tamanho dos arquivos

Essa regra será válida quando file.dat for maior do que 2 MB.

```
FileSize "s3://amzn-s3-demo-bucket/file.dat" > 2 MB
```

As unidades compatíveis incluem B (bytes), MB (megabytes), GB (gigabytes) e TB (terabytes).

Validar o tamanho dos arquivos nas pastas

```
FileSize "s3://bucket/" > 5 B
FileSize "s3://bucket/" < 2 GB
```

Essa regra será válida se 70% dos arquivos em s3://amzn-s3-demo-bucket tiverem entre 2 GB e 1 TB.

```
FileSize "s3://amzn-s3-demo-bucket/" between 2 GB and 1 TB  with threshold > 0.7
```

Dedução de nomes de arquivos diretamente de quadros de dados

Você nem sempre precisa fornecer um caminho de arquivo. Por exemplo, quando você está criando a regra no Catálogo de Dados, pode ser difícil descobrir quais pastas as tabelas do catálogo estão usando. O AWS Glue Data Quality pode encontrar as pastas ou arquivos específicos usados para o preenchimento do quadro de dados.

> **Note**
>
> Esse recurso só funcionará quando os arquivos forem lidos com sucesso no DynamicFrame ou no DataFrame.

```
FileSize < 10 MB with threshold > 0.7
```

Tags de regras opcionais baseadas em arquivos:

As tags permitem controlar o comportamento da regra.

recentFiles

Essa tag limita o número de arquivos processados ao manter primeiro o arquivo mais recente.

```
FileSize "s3://amzn-s3-demo-bucket/" > 5 B with recentFiles = 1
```

matchFileName

Essa tag garante que os arquivos não tenham nomes duplicados. O comportamento padrão é falso.

```
FileSize "s3://amzn-s3-demo-bucket/" > 5 B with matchFileName = "true"
```

Existem algumas considerações:

1. No ETL do AWS Glue, você deve ter a transformação EvaluateDataQuality imediatamente após uma transformação do Amazon S3 ou do Catálogo de Dados.
2. Essa regra não funcionará nas sessões interativas do AWS Glue.

Usar APIs para medir e gerenciar a qualidade dos dados

Este tópico descreve como usar as APIs para medir e gerenciar a qualidade dos dados.

Sumário

- Pré-requisitos
- Trabalhar com as recomendações do AWS Glue Data Quality
- Trabalhar com conjuntos de regras do AWS Glue Data Quality
- Trabalhar com execuções do AWS Glue Data Quality
- Trabalhar com resultados do AWS Glue Data Quality

Pré-requisitos

- Certifique-se de que sua versão do boto3 esteja atualizada para incluir a API do AWS Glue Data Quality mais recente.
- Certifique-se de que sua versão da AWS CLI esteja atualizada, para incluir a CLI mais recente.

Se você estiver usando um trabalho do AWS Glue para executar essas APIs, poderá usar a opção a seguir para atualizar a biblioteca do boto3 para a versão mais recente:

```
—additional-python-modules boto3==<version>
```

Trabalhar com as recomendações do AWS Glue Data Quality

Para iniciar uma recomendação do AWS Glue Data Quality, execute:

```
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']
```

Para uma execução de recomendação, você pode usar `pushDownPredicates` ou `catalogPartitionPredicates` para melhorar a performance e executar recomendações somente em partições específicas das fontes do catálogo.

```
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>'
  )
```

Para obter os resultados de uma recomendação do AWS Glue Data Quality, execute:

```
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
```

Do objeto de resposta acima, você pode extrair o conjunto de regras recomendado pela execução, para usar em outras etapas:

```
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"
]
```

Para obter uma lista de todas as suas execuções de recomendação que podem ser filtradas e listadas:

```
response = client.list_data_quality_rule_recommendation_runs(
    Filter={
        'DataSource': {
            'GlueTable': {
                'DatabaseName': '<database_name>',
                'TableName': '<table_name>'
            }
        }
)
```

Para cancelar as tarefas existentes de recomendação do AWS Glue Data Quality:

```
response = client.cancel_data_quality_rule_recommendation_run(
    RunId='dqrun-d4b6b01957fdd79e59866365bf9cb0e40fxxxxxxx'
)
```

Trabalhar com conjuntos de regras do AWS Glue Data Quality

Para criar um conjunto de regras do AWS Glue Data Quality:

```
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>'
    }
)
```

Para criar um conjunto de regras de qualidade de dados:

```
response = client.get_data_quality_ruleset(
    Name='<ruleset_name>'
)
print(response)
```

Você pode usar essa API para extrair o conjunto de regras:

```
print(response['Ruleset'])
```

Para listar todos os conjuntos de regras de qualidade de dados para uma tabela:

```
response = client.list_data_quality_rulesets()
```

Você pode usar a condição de filtro na API para filtrar todos os conjuntos de regras anexados a um banco de dados ou a uma tabela específica:

```
response = client.list_data_quality_rulesets(
    Filter={
        'TargetTable': {
            'TableName': '<table_name>',
```

```
            'DatabaseName': '<database_name>'
        }
    },
)
```

Para atualizar um conjunto de regras de qualidade de dados:

```
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
```

Para excluir um conjunto de regras de qualidade de dados:

```
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
```

Trabalhar com execuções do AWS Glue Data Quality

Para iniciar uma execução do AWS Glue Data Quality:

```
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']
```

Lembre-se de que você pode passar um parâmetro `pushDownPredicate` ou `catalogPartitionPredicate` para garantir que sua execução de qualidade de dados só tenha como objetivo um conjunto específico de partições na tabela do catálogo. Por exemplo:

```
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>',
    ]
)
```

Você também pode configurar como as regras compostas em seu conjunto de regras são avaliadas, no nível ROW ou COLUMN. Para obter mais informações sobre o funcionamento das regras compostas, consulte How composite rules work na documentação.

Exemplo de como definir o método de avaliação de regra composta em sua solicitação:

```
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>',
    ]
)
```

Para obter informações sobre uma execução do AWS Glue Data Quality:

```
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
```

Para obter os resultados de uma execução do AWS Glue Data Quality:

Para uma determinada execução do AWS Glue Data Quality, você pode extrair os resultados da avaliação da execução usando o seguinte método:

```
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'])
```

Para listar todas as suas execuções do AWS Glue Data Quality:

```
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
```

Você pode modificar a cláusula de filtro para só mostrar os resultados entre determinadas horas ou os resultados de execuções em tabelas específicas.

Para interromper uma execução contínua do AWS Glue Data Quality:

```
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
```

Trabalhar com resultados do AWS Glue Data Quality

Para obter os resultados de uma execução do AWS Glue Data Quality:

```
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
```

Para ver as estatísticas coletadas para um determinado resultado de qualidade de dados:

```
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
```

Para visualizar a série temporal de uma estatística coletada em várias execuções de qualidade de dados:

```
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
```

Para visualizar o modelo de detecção de anomalias para uma estatística específica:

```
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
```

Para excluir um ponto de dados da linha de base de detecção de anomalias de seu modelo estatístico:

```
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
```

Para visualizar o status do treinamento do modelo de detecção de anomalias para uma estatística específica:

```
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
```

Para excluir todos os resultados de uma rodada específica de qualidade de dados das linhas de base de detecção de anomalias:

```
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
```

Para obter os resultados de uma determinada rodada qualidade de dados e exibir os resultados:

Com um `runID` do AWS Glue Data Quality, você pode extrair o `resultID` para obter os resultados reais, conforme apresentado abaixo:

```
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'])
```

Configurar alertas, implantações e agendamentos

Este tópico descreve como configurar alertas, implantações e agendamentos para o AWS Glue Data Quality.

Sumário

- Configurar alertas e notificações na integração com o Amazon EventBridge
  - Opções de configuração adicionais para o padrão de eventos
  - Formatar notificações como e-mails
- Configurar alertas e notificações na integração com o CloudWatch
- Consultar resultados de qualidade de dados para criar painéis
- Implantar regras de qualidade de dados usando o AWS CloudFormation
- Agendar regras de qualidade de dados

Configurar alertas e notificações na integração com o Amazon EventBridge

O AWS Glue Data Quality é compatível com a publicação de eventos do EventBridge, que são emitidos após a conclusão de uma execução de avaliação do conjunto de regras de qualidade de

dados. Com isso, você pode facilmente configurar alertas quando as regras de qualidade de dados não forem atendidas.

Aqui está um exemplo de evento quando você avalia os conjuntos de regras de qualidade de dados no catálogo de dados. Com essas informações, você pode revisar os dados disponibilizados com o Amazon EventBridge. Você pode emitir chamadas de API adicionais para obter mais detalhes. Por exemplo, chame a API `get_data_quality_result` com o ID do resultado para obter os detalhes de uma execução específica.

```
{
    "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":"dqrun-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
    }
}
```

Este é um exemplo de evento que é publicado quando você avalia conjuntos de regras de qualidade de dados nos cadernos do AWS Glue ETL ou do 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
    }
}
```

Para execuções de avaliação de qualidade de dados no catálogo de dados e em trabalhos de ETL, a opção Publicar métricas no Amazon CloudWatch, selecionada por padrão, deve permanecer selecionada para que a publicação do EventBridge funcione.

Configurar eventos e notificações

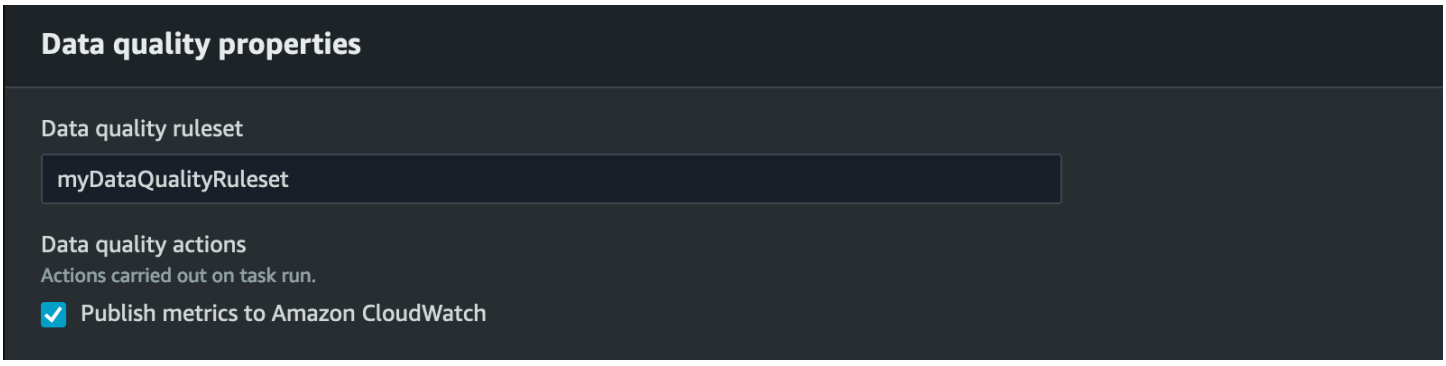

Para receber os eventos emitidos e definir destinos, você deve configurar as regras do Amazon EventBridge. Para criar regras:

1. Abra o console do Amazon EventBridge.

2. Escolha Regras na seção Barramentos da barra de navegação.
3. Selecione Create Rule.
4. Em Definir detalhes da regra:
   a. Em Nome, insira `myDQRule`.
   b. Insira uma descrição (opcional).
   c. Para barramento de eventos, selecione seu barramento de eventos. Se você não tiver um, deixe o padrão.
   d. Em Tipo de regra, escolha Regra com um padrão de eventos.
5. Em Criar padrão de eventos:
   a. Como a origem dos eventos, selecione Eventos da AWS ou eventos de parceiros do EventBridge.
   b. Pule a seção de exemplo de evento.
   c. Como método de criação, selecione Usar formulário de padrão.
   d. Para padrão de eventos:
      i. Selecione Serviços da AWS para Fonte do evento.
      ii. Selecione Glue Data Quality para serviço da AWS.
      iii. Selecione Resultados da avaliação de qualidade de dados disponíveis para Tipo de evento.
      iv. Selecione FALHA para Estados específicos. Em seguida, você verá um padrão de evento como este:

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "state": ["FAILED"]
  }
}
```

      v. Para obter mais opções de conexão, consulte Opções de configuração adicionais para o padrão de eventos.
6. Em Selecionar alvos:
   a. Em Tipos de destino, selecione Serviço da AWS.
   b. Use o menu suspenso Selecionar um destino para escolher o AWS serviço ao qual você deseja se conectar (SNS, Lambda, SQS etc.) e escolha Avançar.

7. Em Configurar tag(s), clique em Adicionar novas tags para adicionar tags opcionais e escolha Avançar.
8. Você verá uma página de resumo de todas as seleções. Escolha Criar regra na parte inferior.

Opções de configuração adicionais para o padrão de eventos

Além de filtrar o evento baseado em sucesso ou fracasso, talvez você queira filtrar ainda mais os eventos com base em outros parâmetros.

Para fazer isso, vá para a seção Padrão de eventos e selecione Editar padrão para especificar parâmetros adicionais. Observe que os campos no padrão de eventos diferenciam maiúsculas de minúsculas. Estes são exemplos de configuração do padrão de eventos.

Para capturar eventos de uma tabela específica avaliando conjuntos de regras específicos, use esse tipo de padrão:

```
{
  "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"]
  }
}
```

Para capturar eventos de trabalhos específicos na experiência de ETL, use esse tipo de padrão:

```
{
  "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"]
  }
}
```

Para capturar eventos com uma pontuação abaixo de um limite específico (por exemplo, 70%):

```
{
  "source": ["aws.glue-dataquality"],
  "detail-type": ["Data Quality Evaluation Results Available"],
  "detail": {
    "score": [{
      "numeric": ["<=", 0.7]
    }]
  }
}
```

Formatar notificações como e-mails

Às vezes, você precisa enviar uma notificação por e-mail bem formatada para as equipes da sua empresa. Você pode usar o Amazon EventBridge e o AWS Lambda para fazer isso.

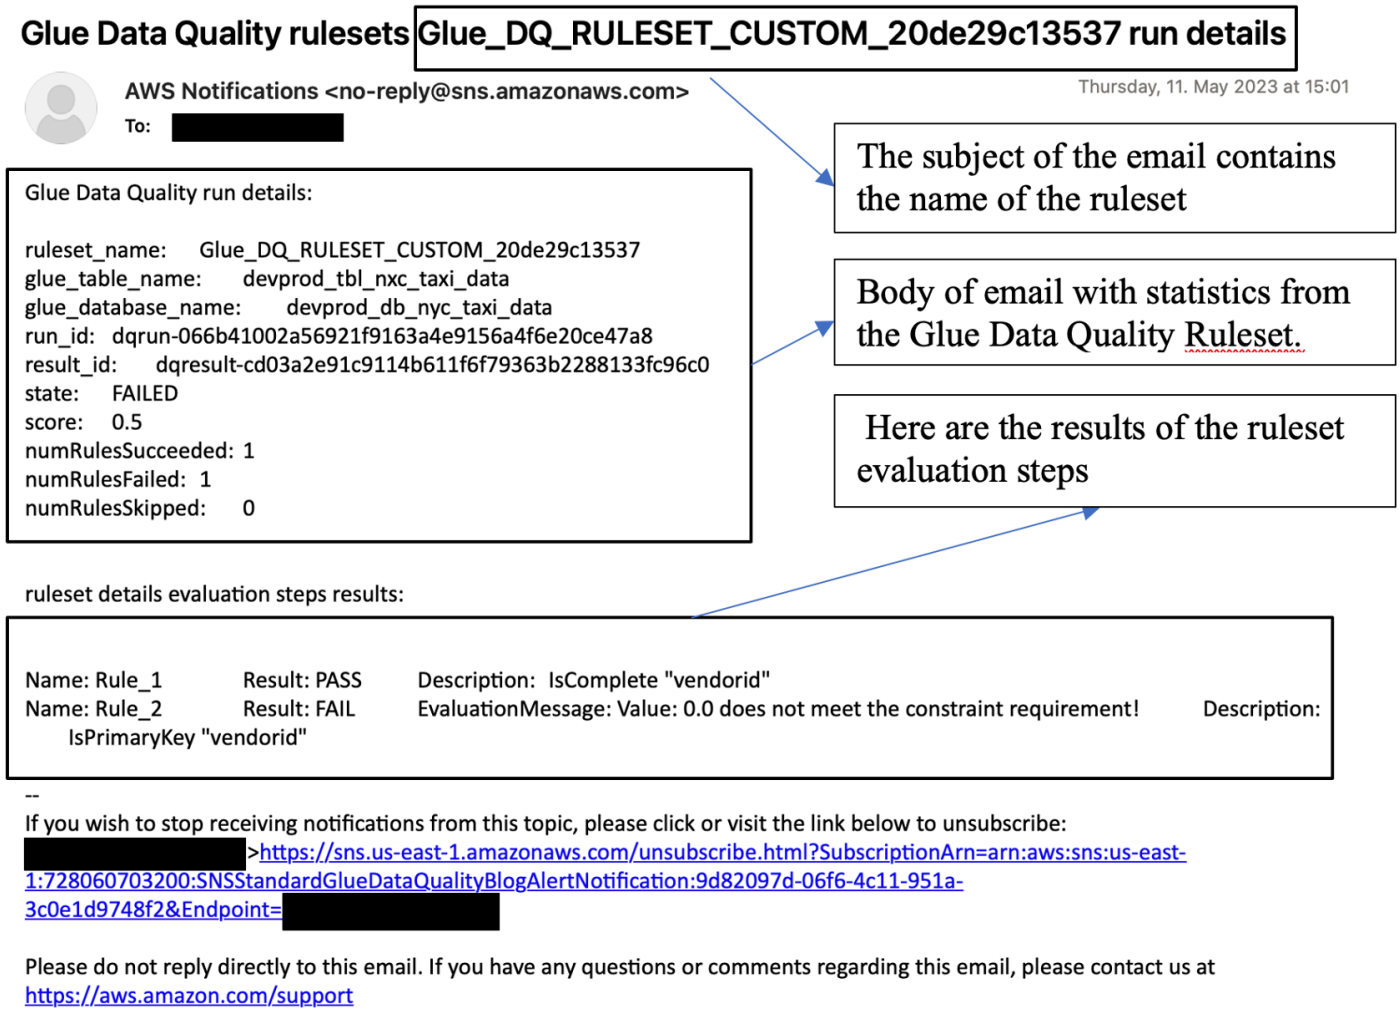

O exemplo de código a seguir pode ser usado para formatar as notificações de qualidade de dados para gerar e-mails.

```
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: {}\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: {}\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'])

    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')
    }
```

Configurar alertas e notificações na integração com o CloudWatch

Nossa abordagem recomendada é configurar alertas de qualidade de dados usando o Amazon EventBridge, porque o Amazon EventBridge só precisa ser configurado uma única vez para alertar os clientes. Porém, alguns clientes preferem o Amazon CloudWatch por sua familiaridade. Para esses clientes, oferecemos a integração com o Amazon CloudWatch.

Cada avaliação do AWS Glue Data Quality emite um par de métricas denominadas `glue.data.quality.rules.passed` (indicando o número de regras aprovadas) e `glue.data.quality.rules.failed` (indicando o número de regras que falharam) por execução de qualidade de dados. Você pode usar essa métrica emitida para criar alarmes para avisar os usuários se uma determinada execução de qualidade de dados ficar abaixo de um limite. Para começar a configurar um alarme que enviaria um e-mail por meio de uma notificação do Amazon SNS, siga as etapas abaixo:

Para começar a configurar um alarme que enviaria um e-mail por meio de uma notificação do Amazon SNS, siga as etapas abaixo:

1. Abra o console do Amazon CloudWatch.
2. Escolha Todas as métricas em Métricas. Você verá um namespace adicional em Namespaces personalizados intitulado Glue Data Quality.

> **Note**
>
> Ao iniciar uma execução do AWS Glue Data Quality, certifique-se de que a caixa de seleção Publicar métricas no Amazon CloudWatch esteja marcada. Caso contrário, as métricas dessa execução específica não serão publicadas no Amazon CloudWatch.

No namespace `Glue Data Quality`, você pode ver as métricas que estão sendo emitidas por tabela, por conjunto de regras. Para a finalidade deste tópico, usaremos a regra `glue.data.quality.rules.failed` e o alarme se esse valor ultrapassar 1 (indicando que, se observarmos um número de avaliações de regras com falha maior do que 1, queremos ser notificados).

3. Para criar o alarme, escolha Todos os alarmes em Alarmes.
4. Selecione Criar alarme.
5. Escolha Selecionar métrica.
6. Selecione a métrica `glue.data.quality.rules.failed` correspondente à tabela que você criou e depois escolha Selecionar métrica.
7. Na guia Especificar métricas e condições, na seção Métricas:
   a. Em Estatística, selecione Soma.
   b. Em Período, escolha 1 minuto.
8. Na seção Condições:
   a. Em Tipo de limite, escolha Estático.
   b. para Sempre que glue.data.quality.rules.failed for..., selecione Maior/Igual.
   c. Por do que... , insira 1 como o valor limite.

   Essas seleções implicam que, se a métrica `glue.data.quality.rules.failed` emitir um valor maior ou igual a 1, acionaremos um alarme. Porém, se não houver dados, nós a trataremos como aceitável.
9. Escolha Próximo.
10. Em Configurar ações:
    a. Em Gatilho de estado do alarme, escolha Em alarme.
    b. Em Enviar uma notificação para o seguinte tópico do SNS, escolha Criar um novo tópico para enviar uma notificação por um novo tópico do SNS.
    c. Em Endpoints de e-mail que receberão a notificação, insira o endereço de e-mail. Depois clique em Criar tópico.
    d. Escolha Avançar.
11. Em Nome secreto, insira `myFirstDQAlarm` e escolha Avançar.
12. Você verá uma página de resumo de todas as seleções. Escolha Criar alarme na parte inferior.

Agora você pode ver o alarme sendo criado no painel de alarmes do Amazon CloudWatch.

Consultar resultados de qualidade de dados para criar painéis

Talvez você queira criar um painel para exibir seus resultados de qualidade de dados. Há duas maneiras de fazer isso:

Configure o Amazon EventBridge com o seguinte códigopara gravar os dados no 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: {}\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'])

    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

    write_logs(log_metadata)


    return {
        'statusCode': 200,
        'body': json.dumps('Message published to SNS topic')
    }
```

Depois de gravar no Amazon S3, você pode usar os crawlers do AWS Glue para se registrar no Athena e consultar as tabelas.

Configure um local no Amazon S3 durante uma avaliação de qualidade de dados:

Ao executar tarefas de qualidade de dados no catálogo de dados do AWS Glue ou no AWS Glue ETL, você pode fornecer um local no Amazon S3 para gravar os resultados de qualidade de dados. Você pode usar a sintaxe abaixo para criar uma tabela referenciando o destino para o qual ler os resultados de qualidade dos dados.

Observe que você deve executar as consultas `CREATE EXTERNAL TABLE` e `MSCK REPAIR TABLE` separadamente.

```
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>;
```

Depois de criar a tabela acima, você poderá executar consultas analíticas usando o Amazon Athena.

Implantar regras de qualidade de dados usando o AWS CloudFormation

Você pode usar o AWS CloudFormation para criar regras de qualidade de dados. Para obter mais informações, consulte AWS CloudFormation para o AWS Glue.

Agendar regras de qualidade de dados

Você pode agendar as regras de qualidade de dados usando os seguintes métodos:

- Agende as regras de qualidade no dados do catálogo de dados: nenhum usuário de código pode usar essa opção para agendar facilmente suas verificações de qualidade de dados. O AWS O Glue Data Quality criará a agenda no Amazon EventBridge. Para agendar regras de qualidade de dados:
  - Navegue até o conjunto de regras e clique em Executar.
  - Na Frequência de execução, selecione a agenda desejada e forneça um Nome de tarefa. Esse nome de tarefa será o nome da sua agenda no EventBridge.
- Use o Amazon EventBridge e o AWS Step Functions para orquestrar avaliações e recomendações para regras de qualidade de dados.

Criptografia de dados em repouso no AWS Glue Data Quality

O AWS Glue Data Quality fornece criptografia por padrão para proteger dados sensíveis do cliente em repouso usando chaves de criptografia de propriedade da AWS.

chaves de propriedade da AWS

O AWS Glue Data Quality usa essas chaves para criptografar automaticamente os ativos do Data Quality dos clientes. Você não pode visualizar, gerenciar nem usar chaves de propriedade da AWS, tampouco auditar o uso delas. No entanto, você não precisa realizar nenhuma ação nem alterar nenhum programa para proteger as chaves que criptografam seus dados. Para obter mais informações, consulte AWS owned keys no Guia do desenvolvedor do AWS KMS.

A criptografia de dados em repouso por padrão reduz a sobrecarga operacional e a complexidade envolvidas na proteção de dados confidenciais. Ao mesmo tempo, ela permite que você crie aplicações seguras que atendam aos rigorosos requisitos regulatórios e de conformidade de criptografia.

Embora você não possa desabilitar essa camada de criptografia nem selecionar um tipo alternativo de criptografia, é possível adicionar uma segunda camada de criptografia sobre as chaves de criptografia existentes pertencentes à AWS mediante a escolha de uma chave gerenciada pelo cliente ao criar seus recursos do Data Quality.

Chaves gerenciadas pelo cliente

Chaves gerenciadas pelo cliente: o AWS Glue Data Quality é compatível com o uso de uma chave simétrica gerenciada pelo cliente que você cria, assume e gerencia. Isso adiciona uma segunda

camada de criptografia sobre a criptografia existente pertencente à AWS. Como você tem controle total dessa camada de criptografia, é possível realizar tarefas como:

- Estabelecer e manter as políticas de chave
- Estabelecer e manter políticas do IAM
- Ativar e desativar políticas de chaves
- Alternar os materiais de criptografia de chave
- Adicionar etiquetas
- Criar réplicas de chaves
- Chaves de agendamento para exclusão

Para obter mais informações, consulte Chaves gerenciadas pelo cliente no Guia do desenvolvedor do AWS KMS.

A tabela a seguir resume como o AWS Glue Data Quality criptografa diferentes ativos do Data Quality.

Tipo de dados	Criptografia de chave de propriedade da AWS	Criptografia de chave gerenciada pelo cliente
Conjunto de regras do Data Quality Cadeia de caracteres do conjunto de regras da DQDL que é indicada pelo conjunto persistente de regras do DQ. Por enquanto, esses conjuntos persistentes de regras são usados apenas na experiência do Catálogo de Dados do AWS Glue.	Habilitada	Habilitado
Resultados de regra/analisador do Data Quality	Habilitada	Habilitado

Tipo de dados	Criptografia de chave de propriedade da AWS	Criptografia de chave gerenciada pelo cliente
Artefatos de resultado que contêm o status de aprovação /reprovação de cada regra em um conjunto de regras, bem como as métricas coletadas pelas regras e pelos analisadores.		
Observações As observações são geradas quando há a detecção de uma anomalia nos dados. Elas contêm informações sobre os limites superior e inferior esperados, além de uma regra sugerida com base nesses limites. Se geradas, elas serão exibidas com os resultados do Data Quality.	Habilitada	Habilitado
Estatísticas Essa opção contém informações sobre métricas coletadas após avaliar os dados fornecidos por um conjunto de regras específico, como o valor da métrica (p. ex., RowCount, completude), nomes de colunas e outros metadados.	Habilitada	Habilitado

Tipo de dados	Criptografia de chave de propriedade da AWS	Criptografia de chave gerenciada pelo cliente
Modelos estatísticos de detecção de anomalias Os modelos estatísticos contêm a série temporal dos limites superior e inferior de uma determinada métrica gerada com base em avaliações anteriores dos dados do cliente.	Habilitada	Habilitado

> **Note**
>
> O AWS Data Quality habilita automaticamente a criptografia em repouso usando chaves pertencentes à AWS para proteger dados de identificação pessoal sem nenhum custo. No entanto, AWS KMS há cobrança aplicável pelo uso de uma chave gerenciada pelo cliente. Para obter mais informações sobre precificação, consulte Precificação do AWS KMS. Para obter mais informações sobre AWS KMS, consulte AWS KMS.

Criar uma chave gerenciada pelo cliente

Você pode criar uma chave simétrica gerenciada pelo cliente usando o AWS Management Console ou as APIs do AWS KMS.

Para criar uma chave gerenciada pelo cliente:

- Siga as etapas em Creating symmetric encryption AWS KMS keys no Guia do desenvolvedor do AWS Key Management Service.

Política de chave

As políticas de chaves controlam o acesso à chave gerenciada pelo cliente. Cada chave gerenciada pelo cliente deve ter exatamente uma política de chaves, que contém declarações que determinam

quem pode usar a chave e como pode usá-la. Ao criar a chave gerenciada pelo cliente, é possível especificar uma política de chave. Para obter mais informações, consulte Key policies in AWS KMS keys no Guia do desenvolvedor do AWS Key Management Service.

Para usar sua chave gerenciada pelo cliente com seus recursos do Data Quality, é necessário permitir as seguintes operações de API na política de chave:

- `kms:Decrypt`: descriptografa o texto cifrado que foi criptografado por uma chave do AWS KMS usando `GenerateDataKeyWithoutPlaintext`.
- `kms:DescribeKey`: Fornecer os principais detalhes gerenciados pelo cliente para permitir que o Amazon Location valide a chave.
- `kms:GenerateDataKeyWithoutPlaintext`: retorna uma chave de dados simétrica exclusiva para uso fora do AWS KMS. Essa operação retorna uma chave de dados criptografada com a chave do KMS de criptografia simétrica que você especifica. Os bytes na chave são aleatórios e não estão relacionados ao chamador ou à chave do KMS. Isso é usado para reduzir as chamadas do KMS que o cliente precisa fazer.
- `kms:ReEncrypt*`: descriptografa o texto cifrado e, em seguida, o recriptografa inteiramente no AWS KMS. Você pode usar essa operação para alterar a chave do KMS sob a qual os dados são criptografados, como quando você alterna manualmente uma chave do KMS ou altera a chave do KMS que protege um texto cifrado. Você também pode usá-la para recriptografar o texto cifrado com a mesma chave do KMS, assim como para alterar o contexto de criptografia de um texto cifrado.

A seguir estão exemplos de declarações de política que você pode adicionar ao 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" : "*"
    }
]
```

Observações sobre o uso de chaves do KMS no AWS Glue Data Quality

O AWS Glue Data Quality não é compatível com transições de chave. Isso significa que se você criptografar seus ativos do Data Quality com a chave A e decidir mudar para a chave B, não vamos criptografar novamente os dados que foram criptografados com a chave A para usar a chave B. Você ainda poderá mudar para a chave B, mas precisará manter o acesso à chave A para acessar dados previamente criptografados com a chave A.

Para obter mais informações sobre como especificar permissões em uma política, consulte Permissions for AWS services in key policies no Guia do desenvolvedor do AWS Key Management Service.

Para obter mais informações sobre solução de problemas de acesso a chaves, consulte Troubleshooting key access no Guia do desenvolvedor do AWS Key Management Service.

Criar uma configuração de segurança

No AWS Glue, o recurso configurações de segurança contém as propriedades que são necessárias quando você grava dados criptografados.

Para criptografar seus ativos de qualidade de dados:

1. Em Configurações de criptografia, em Configurações avançadas, escolha Habilitar criptografia do Data Quality.
2. Selecione sua chave do KMS ou escolha Criar uma chave do AWS KMS.

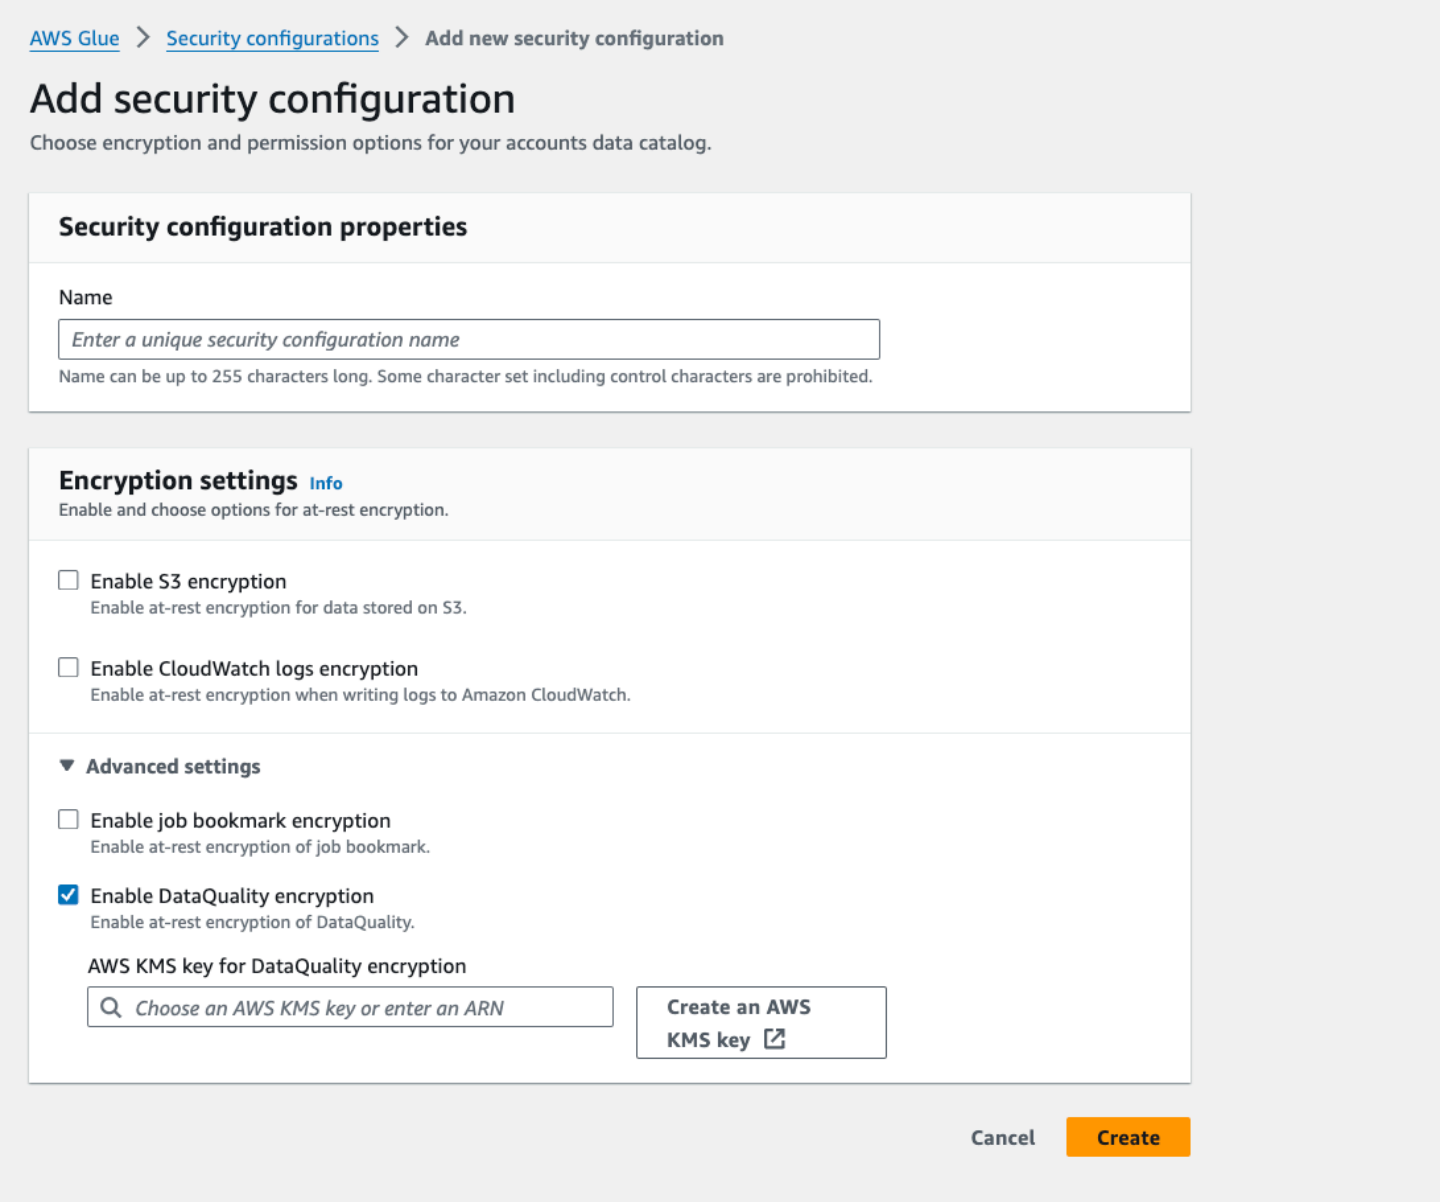

Contexto de criptografia do AWS Glue Data Quality

Um contexto de criptografia é um conjunto opcional de pares de chave/valor que pode conter informações contextuais adicionais sobre os dados.

O AWS KMS usa o contexto de criptografia como dados autenticados adicionais para viabilizar a criptografia autenticada. Quando você inclui um contexto de criptografia em uma solicitação para criptografar dados, o AWS KMS vincula de forma criptográfica o contexto da criptografia aos dados criptografados. Para descriptografar os dados, você inclui o mesmo contexto de criptografia na solicitação.

Exemplo de contexto de criptografia do AWS 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"
}
```

Uso do contexto de criptografia para monitoramento

Ao usar uma chave simétrica gerenciada pelo cliente para criptografar seu rastreador ou sua coleção de geocercas, você também pode usar o contexto de criptografia nos registros e logs de auditoria para identificar como a chave gerenciada pelo cliente está sendo usada. O contexto de criptografia também aparece nos logs gerados pelo AWS CloudTrail ou Amazon CloudWatch Logs.

Monitoramento das suas chaves de criptografia para o AWS Glue Data Quality

Ao usar uma chave do AWS KMS gerenciada pelo cliente com seus recursos do AWS Glue Data Quality, você pode usar o AWS CloudTrail ou o Amazon CloudWatch Logs para rastrear as solicitações que o AWS Glue Data Quality envia para o AWS KMS.

Os exemplos a seguir são eventos do AWS CloudTrail para `GenerateDataKeyWithoutPlainText` e `Decrypt` para monitorar as operações do KMS chamadas pelo AWS Glue Data Quality para acessar dados criptografados por sua chave gerenciada pelo cliente.

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"
}
```

ReEncyrpt

```
{
    "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": "AwsGlueMlEncryptionKeyStore",
            "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"
}
```

Saiba mais

Os recursos a seguir fornecem mais informações sobre a criptografia de dados em repouso.

- Para obter mais informações sobre AWS Key Management Service basic concepts, consulte o Guia do desenvolvedor do AWS Key Management Service.
- Para obter mais informações sobre Security best practices for AWS Key Management Service consulte o Guia do desenvolvedor do AWS Key Management Service.

Solução de problemas de erros do AWS Glue Data Quality

Se você encontrar erros no AWS Glue Data Quality, use as seguintes soluções para ajudar você a encontrar a fonte dos problemas e corrigi-los.

Sumário

- Erro: módulo AWS Glue Data Quality ausente
- Erro: permissões insuficientes do AWS Lake Formation
- Erro: os conjuntos de regras não têm nomes exclusivos
- Erro: tabelas com caracteres especiais
- Erro: erro de estouro com um conjunto de regras grande
- Erro: o status geral da regras é com falha
- AnalysisException: não é possível verificar a existência de banco de dados padrão
- Mensagem de erro: o mapa de chaves fornecido não é adequado para os quadros de dados fornecidos
- Exceção na classe de usuário: java.lang.RuntimeException: falha ao buscar dados. Verificar os logs do CloudWatch para obter mais detalhes
- ERRO DE INICIALIZAÇÃO: erro ao baixar o S3 para o bucket
- InvalidInputException (status: 400): as regras DataQuality não podem ser analisadas
- Erro: o Eventbridge não está acionando trabalhos do Glue DQ com base na agenda que eu configurei
- Erros de CustomSQL
- Regras dinâmicas

- Exceção na classe de usuário: org.apache.spark.sql.AnalysisException: org.apache.hadoop.hive.ql.metadata.HiveException
- UNCLASSIFIED_ERROR; IllegalArgumentException: erro de análise: nenhuma regra ou analisador fornecido, nenhuma alternativa viável na entrada

Erro: módulo AWS Glue Data Quality ausente

Mensagem de erro: nenhum módulo denominado 'awsgluedq'.

Resolução: esse erro ocorre quando você executa o AWS Glue Data Quality em uma versão não compatível. O AWS Glue Data Quality é compatível com o Glue versão 3.0 ou posterior.

Erro: permissões insuficientes do AWS Lake Formation

Mensagem de erro: exceção na classe de usuário `com.amazonaws.services.glue.model.AccessDeniedException`: Permissões insuficientes do Lake Formation em impact_sdg_involvement (Serviço: AWS Glue; Código de status: 400; Código de erro: AccessDeniedException; ID da solicitação: 465ae693-b7ba-4df0-a4e4-6b17xxxxxxxx; Proxy: nulo).

Resolução: você precisa fornecer permissões suficientes no AWS Lake Formation.

Erro: os conjuntos de regras não têm nomes exclusivos

Mensagem de erro: exceção na classe de usuário:... services.glue.model.AlreadyExistsException: já existe outro conjunto de regras com o mesmo nome.

Resolução: os conjuntos de regras precisam ser exclusivos.

Erro: tabelas com caracteres especiais

Mensagem de erro: exceção na classe de usuário: org.apache.spark.sql.AnalysisException: não é possível resolver colunas de entrada dadas de "C": [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]; Linha 1 posição 44;.

Resolução: existe uma limitação atual de que o AWS Glue Data Quality não pode ser executado em tabelas com caracteres especiais, como ".".

Erro: erro de estouro com um conjunto de regras grande

Mensagem de erro: exceção na classe de usuário: java.lang.StackOverflowError.

Resolução: se você tiver um conjunto de regras grande com mais de 2 mil regras, poderá encontrar esse problema. Divida as regras em vários conjuntos de regras.

Erro: o status geral da regras é com falha

Condição de erro: meu conjunto de regras teve sucesso, mas o status geral de regras é com falha.

Resolução: esse erro provavelmente ocorreu porque você escolheu a opção de publicar métricas no Amazon CloudWatch durante a publicação. Se o conjunto de dados estiver em uma VPC, ela talvez não permita que o AWS Glue publique métricas no Amazon CloudWatch. Nesse caso, você >precisa configurar um endpoint para a VPC acessar o Amazon CloudWatch.

AnalysisException: não é possível verificar a existência de banco de dados padrão

Condição de erro: AnalysisException: não foi possível verificar a existência de um banco de dados padrão: com.amazonaws.services.glue.model.AccessDeniedException: permissões insuficientes do Lake Formation no padrão (Serviço: AWS Glue; Código de status: 400; Código de erro: AccessDeniedException; ID da solicitação: XXXXXXXX-XXXX-XXXXXXXXXXXX; Proxy: nulo)

Resolução: na integração do catálogo do trabalho do AWS Glue, o AWS Glue sempre tenta verificar se o banco de dados padrão existe ou não está usando a `GetDatabase API` do AWS Glue. Quando a permissão do `DESCRIBE` Lake Formation não é concedida, ou a permissão `GetDatabase IAM` é concedida e depois o trabalho falha ao verificar a existência do banco de dados padrão.

Para resolver:

1. Adicione a permissão `DESCRIBE` no Lake Formation para o banco de dados padrão.
2. Configure o perfil do IAM anexado ao trabalho do AWS Glue como criador de banco de dados no Lake Formation. Isso criará automaticamente um banco de dados padrão e concederá ao perfil as permissões necessárias do Lake Formation.
3. Desabilite a opção `--enable-data-catalog`. (É mostrado como Usar o Data Catalog como metastore do Hive no AWS Glue Studio).

   Se você não precisar da integração do Data Catalog com o Spark SQL no trabalho, poderá desabilitá-la.

Mensagem de erro: o mapa de chaves fornecido não é adequado para os quadros de dados fornecidos

Condição de erro: o mapa de chaves fornecido não é adequado para os quadros de dados fornecidos.

Resolução: você está usando o tipo de regra DatasetMatch e o tipo de regra e as chaves de união têm duplicatas. Suas chaves de união devem ser exclusivas e não devem ser NULL. Nos casos em que você não puder ter chaves de união exclusivas, considere usar outros tipos de regras, como AggregateMatch, para fazer a correspondência com os dados resumidos.

Exceção na classe de usuário: java.lang.RuntimeException: falha ao buscar dados. Verificar os logs do CloudWatch para obter mais detalhes

Condição de erro: exceção na classe de usuário: java.lang.RuntimeException: falha ao buscar dados. Verifique os logs do CloudWatch para obter mais detalhes.

Resolução: isso acontece quando você cria regras de DQ em uma tabela baseada no Amazon S3 que é comparada com o Amazon RDS ou o Amazon Redshift. Nesses casos, o AWS Glue não consegue carregar a conexão. Em vez disso, tente configurar a regra do DQ no Amazon Redshift ou no conjunto de dados do Amazon RDS. Esse é um erro conhecido.

ERRO DE INICIALIZAÇÃO: erro ao baixar o S3 para o bucket

Condição de erro: ERRO DE INICIALIZAÇÃO: erro ao baixar o S3 para o bucket: `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)` .

Resolução: as permissões no perfil passadas para o AWS Glue Data Quality precisam permitir a leitura do local anterior do Amazon S3. Essa política do IAM deve ser anexada ao perfil:

```
{
  "Sid": "allowS3",
  "Effect": "Allow",
  "Action": "s3:GetObject",
  "Resource": "arn:aws:s3:::aws-glue-ml-data-quality-assets-<region>/*"
}
```

Consulte a Autorização de qualidade de dados para ver as permissões detalhadas. Essas bibliotecas são necessárias para avaliar a qualidade dos dados de seus conjuntos de dados.

InvalidInputException (status: 400): as regras DataQuality não podem ser analisadas

Condição de erro: InvalidInputException (status: 400): as regras DataQuality não podem ser analisadas.

Resolução: existem muitas possibilidades para esse erro. Uma possibilidade é que suas regras tenham aspas simples. Verifique se elas estão entre aspas duplas. Por exemplo:

```
Rules = [
ColumnValues "tipo_vinculo" in ["CODO", "DOCO", "COCO", "DODO"] AND "categoria" = 'ES'
    AND "cod_bandera" = 'CEP'
```

Altere isso para:

```
Rules = [
(ColumnValues "tipovinculo" in [ "CODO", "DOCO", "COCO", "DODO"]) AND (ColumnValues
 "categoria" = "ES")
    AND (ColumnValues "codbandera" = "CEP")
]
```

Erro: o Eventbridge não está acionando trabalhos do Glue DQ com base na agenda que eu configurei

Condição de erro: o Eventbridge não está acionando trabalhos do AWS Glue Data Quality com base na agenda que eu configurei.

Resolução: o perfil que aciona o trabalho pode não ter as permissões certas. Verifique se o perfil que você está usando para iniciar os trabalhos tem as permissões mencionadas em Configuração do IAM requerida para programar execuções de avaliação.

Erros de CustomSQL

Condição de erro: `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.`

Resolução: a consulta SQL é válida, mas verifique se as colunas selecionadas pertencem apenas à tabela primária. Selecionar funções agregadas como sum, count on the columns from the primary pode resultar nesse erro.

Condição de erro: `There was a problem when executing your SQL statement: cannot resolve "Col"`.

Resolução: essa coluna não está presente na tabela primária.

Condição de erro: `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"`.

Resolução: em consultas SQL, ao unir a tabela primária com outras tabelas de referência, verifique se a instrução de selecionar tem apenas nomes de colunas da tabela primária para gerar resultados em nível de linha para a tabela primária.

Regras dinâmicas

Condição de erro: `Dynamic rules require job context, and cannot be evaluated in interactive session or data preview.`.

Causa: essa mensagem de erro pode aparecer nos resultados da visualização de dados ou em outras sessões interativas quando as regras dinâmicas do DQ estiverem presentes no conjunto de regras. As regras dinâmicas fazem referência a métricas históricas associadas a um determinado nome de trabalho e contexto de avaliação. Portanto, não podem ser avaliadas em sessões interativas.

Resolução: a execução de trabalho do AWS Glue produzirá métricas históricas, que podem ser referenciadas em execuções posteriores do mesmo trabalho.

Condição de erro:

- `[RuleType] rule only supports simple atomic operands in thresholds.`.
- `Function last not yet implemented for [RuleType] rule.`

Resolução: as regras dinâmicas geralmente são compatíveis com todos os tipos de regras de DQDL em expressões numéricas (consulte Referência de DQDL). No entanto, algumas regras que produzem várias métricas, ColumnValues e ColumnLength, ainda não são compatíveis.

Condição de erro: `Binary expression operands must resolve to a single number.`.

Causa: as regras dinâmicas são compatíveis com expressões binárias, como `RowCount > avg(last(5)) * 0.9`. Nesse caso, a expressão binária é `avg(last(5)) * 0.9`. Essa regra é válida porque os dois operandos `avg(last(5))` e `0.9` se resolvem para um único número. `RowCount > last(5) * 0.9` é um exemplo incorreto, pois `last(5)` produzirá uma lista que não poderá ser comparada de forma significativa com a contagem de linhas atual.

Resolução: use funções de agregação para reduzir um operando com valores de lista para um único número.

Condição de erro:

- `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.`

Causa: as regras dinâmicas podem ser usadas para comparar alguns atributos do conjunto de dados com os valores históricos. A última função permite a recuperação de vários valores históricos, se um argumento inteiro positivo for fornecido. Por exemplo, `last(5)` recuperará os últimos cinco valores mais recentes observados nas execuções de trabalho da sua regra.

Resolução: uma função de agregação precisa ser usada para reduzir esses valores a um único número para fazer uma comparação significativa com o valor observado na execução do trabalho atual.

Exemplos válidos:

- `RowCount >= avg(last(5))`
- `RowCount > last(1)`
- `RowCount < last()`

Exemplo inválido: `RowCount > last(5)`.

Condição de erro:

- `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.`

Resolução: ao criar regras dinâmicas, você poderá usar a função de agregação `index` para selecionar um valor histórico em uma lista. Por exemplo, `RowCount > index(last(5), 1)` verificará se a contagem de linhas observada no trabalho atual é estritamente maior do que a segunda contagem de linhas mais recente observada no trabalho. `index` é indexado em zero.

Condição de erro: `IllegalArgumentException: Parsing Error: Rule Type: DetectAnomalies is not valid`.

Resolução: a detecção de anomalias só está disponível na versão 4.0 do AWS Glue.

Condição de erro: `IllegalArgumentException: Parsing Error: Unexpected condition for rule of type ... no viable alternative at input ...`.

Observação: `...` é dinâmico. Exemplo: `IllegalArgumentException: Parsing Error: Unexpected condition for rule of type RowCount with number return type, line 4:19 no viable alternative at input '>last'`.

Resolução: a detecção de anomalias só está disponível na versão 4.0 do AWS Glue.

Exceção na classe de usuário: org.apache.spark.sql.AnalysisException: org.apache.hadoop.hive.ql.metadata.HiveException

Condição de erro: `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)`

Causa: você está usando o Apache Iceberg no Catálogo de Dados do AWS Glue e o atributo Input Format no Catálogo de Dados do AWS Glue está vazio.

Resolução: esse problema ocorre quando o tipo de regra CustomSQL é usado em sua regra de DQ. Uma maneira de corrigir isso é usar "primary" ou adicionar o nome do catálogo `glue_catalog.` a `<database>.<table> in Custom ruletype`.

UNCLASSIFIED_ERROR; IllegalArgumentException: erro de análise: nenhuma regra ou analisador fornecido, nenhuma alternativa viável na entrada

Condição de erro: `UNCLASSIFIED_ERROR; IllegalArgumentException: Parsing Error: No rules or analyzers provided., no viable alternative at input`

Resolução: o DQDL não é analisável. Existem alguns casos em que isso pode ocorrer. Se você estiver usando regras compostas, verifique se elas têm parênteses corretos.

```
(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
```

Integração de dados do Amazon Q no AWS Glue

A integração de dados do Amazon Q no AWS Glue é um novo recurso de IA generativa do AWS Glue que permite que engenheiros de dados e desenvolvedores de ETL criem trabalhos de integração de dados usando linguagem natural. Engenheiros e desenvolvedores podem pedir ao Amazon Q para criar trabalhos, solucionar problemas e responder perguntas sobre o AWS Glue e a integração de dados.

O que é o Amazon Q?

> **Note**
>
> Tecnologia da Amazon Bedrock: a AWS implementa a detecção automática de abusos. Como a integração de dados do Amazon Q é baseada no Amazon Bedrock, os usuários podem aproveitar ao máximo os controles implementados no Amazon Bedrock para reforçar a segurança, a proteção e o uso responsável de inteligência artificial.

O Amazon Q é um assistente conversacional baseado em inteligência artificial (IA) generativa que pode ajudar você a entender, criar, estender e operar aplicações da AWS. O modelo que impulsiona o Amazon Q foi aprimorado com conteúdo de alta qualidade da AWS para fornecer respostas mais completas, acionáveis e referenciadas para acelerar seu desenvolvimento na AWS. Para obter mais informações, consulte What is Amazon Q?

O que é a integração de dados do Amazon Q no AWS Glue?

A integração de dados do Amazon Q no AWS Glue inclui os seguintes recursos:

- Chat: a integração de dados do Amazon Q no AWS Glue pode responder a perguntas de linguagem natural em inglês sobre o AWS Glue e domínios de integração de dados, como conectores de origem e destino do AWS Glue, trabalhos de ETL do AWS Glue, catálogo de dados, crawlers e AWS Lake Formation e outras documentações de recurcos e práticas recomendadas. A integração de dados do Amazon Q no AWS Glue responde com instruções passo a passo e inclui referências às suas fontes de informação.

- Geração de código de integração de dados: a integração de dados do Amazon Q no AWS Glue pode responder a perguntas sobre scripts de ETL do AWS Glue e gerar novos códigos com base em uma pergunta de linguagem natural em inglês.
- Solução de problemas: a integração de dados do Amazon Q no AWS Glue foi criada especificamente para ajudar você a entender erros em trabalhos do AWS Glue e fornece instruções passo a passo para identificar a causa e resolver os problemas.

> **Note**
>
> A integração de dados do Amazon Q no AWS Glue não usa o contexto da sua conversa para informar respostas futuras durante a conversa. Cada conversa com a integração de dados do Amazon Q no AWS Glue é independente de conversas anteriores ou futuras.

Como trabalhar com a integração de dados do Amazon Q no AWS Glue?

No painel do Amazon Q, é possível solicitar que o Amazon Q gere código para um script de ETL do AWS Glue, responda a uma pergunta sobre recursos do AWS Glue ou solucione um erro. A resposta é um script de ETL no PySpark com instruções passo a passo para personalizar o script, revisá-lo e executá-lo. Para perguntas, a resposta é gerada de acordo com a base de conhecimento de integração de dados com um resumo e um URL de origem para referências.

Por exemplo, é possível pedir ao Amazon Q para "Fornecer um script Glue que leia do Snowflake, renomeie os campos e grave no Redshift", e, em resposta, a integração de dados do Amazon Q no AWS Glue retornará um script de trabalho do AWS Glue que possa realizar a ação solicitada. Você pode revisar o código gerado para garantir que ele atenda à intenção solicitada. Quando estiver satisfeito, você pode implantá-lo como um trabalho do AWS Glue na produção. Você pode solucionar problemas solicitando que a integração explique erros e falhas e proponha soluções. O Amazon Q pode responder a perguntas sobre o AWS Glue ou sobre as práticas recomendadas de integração.

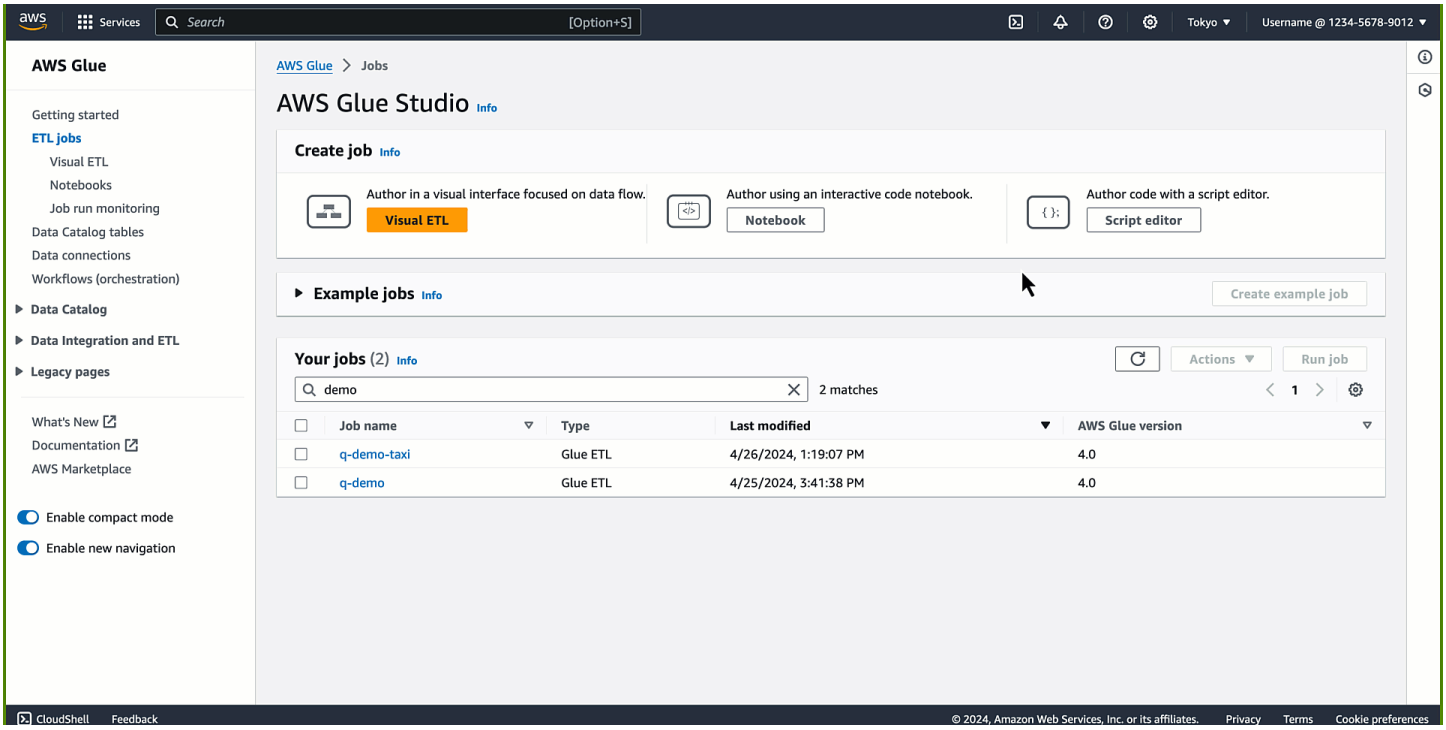

Veja a seguir exemplos de perguntas que demonstram como a integração de dados do Amazon Q no AWS Glue pode ajudar você a criar no AWS Glue:

Geração de códigos de ETL no AWS Glue:

- Grave um script do AWS Glue que leia o JSON do S3, transforme campos usando o mapeamento de aplicação e grave no Amazon Redshift
- Como gravar um script do AWS Glue para ler do DynamoDB aplicando a transformação DropNullFields e gravando no S3 como Parquet?
- Forneça-me um script do AWS Glue que leia o MySQL, descarte alguns campos com base na minha lógica de negócios e grave no Snowflake
- Grave um trabalho do AWS Glue para ler do DynamoDB e gravar no S3 como JSON
- Ajude-me a desenvolver um script do AWS Glue para o catálogo de dados do AWS Glue para o S3
- Grave um trabalho do AWS Glue para ler JSON do S3, descartar nulos e gravar no Redshift

Explicações de recursos do AWS Glue:

- Como usar o AWS Glue Data Quality?
- Como usar marcadores de trabalho do AWS Glue?
- Como habilitar o ajuste de dimensionamento automático do AWS Glue?

- Qual é a diferença entre quadros dinâmicos do AWS Glue e quadros de dados do Spark?
- Quais são os diferentes tipos de conexões compatíveis com o AWS Glue?

Solução de problemas do AWS Glue:

- Como solucionar erros de falta de memória (OOM) em trabalhos do AWS Glue?
- Que mensagens de erro você pode ver ao configurar o AWS Glue Data Quality e como corrigi-las?
- Como faço para corrigir um trabalho do AWS Glue com o erro de acesso negado ao Amazon S3?
- Como resolver problemas com o shuffle de dados em trabalhos do AWS Glue?

Práticas recomendadas para interagir com a integração de dados do Amazon Q

Estas são as práticas recomendadas para interagir com a integração de dados do Amazon Q:

- Ao interagir com o SQL generativo do Amazon Q, faça perguntas específicas, itere quando tiver solicitações complexas e verifique se as respostas estão corretas.
- Ao fornecer prompts de análise em linguagem natural, tente usar o máximo de especificidade para ajudar o assistente de codificação a compreender exatamente aquilo de que você precisa. Em vez de pedir "extraia dados do S3", forneça mais detalhes, como "escreva um script do AWS Glue que extraia arquivos JSON do S3".
- Revise o SQL gerado antes de executá-lo para garantir a precisão. Se a consulta SQL gerada tiver erros ou não corresponder à intenção, dê instruções ao assistente sobre como corrigi-la, em vez de reformular a solicitação inteira.
- A tecnologia de IA generativa é nova e pode haver erros, às vezes chamados de alucinações, nas respostas. Teste e analise todo o código em busca de erros e vulnerabilidades antes de usá-lo no ambiente ou no workload.

Integração de dados do Amazon Q na melhoria de serviços do AWS Glue

Para ajudar a integração de dados do Amazon Q no AWS Glue a fornecer as informações mais relevantes sobre os serviços da AWS, podemos usar determinados conteúdos do Amazon Q, como perguntas que você faz ao Amazon Q e suas respostas, para melhorar o serviço.

Para obter informações sobre o conteúdo que usamos e como optar por não participar, consulte Melhoria do serviço do Amazon Q Developer no Manual do Usuário do Amazon Q Developer.

Considerações

Considere os seguintes itens antes de usar a integração de dados do Amazon Q no AWS Glue:

- No momento, a geração de código só funciona com o kernel PySpark. O código gerado é para trabalhos do AWS Glue baseados no Python Spark.
- Para obter informações sobre a compatibilidade das combinações de capacidades de geração de código da integração de dados do Amazon Q noAWS Glue, consulte Capacidades de geração de código suportadas.

Configurar a integração de dados do Amazon Q no AWS Glue

As seções a seguir fornecem informações sobre como configurar a integração de dados do Amazon Q no AWS Glue.

Tópicos

- Configurar permissões do IAM

Configurar permissões do IAM

Este tópico descreve as permissões do IAM que você configura para a experiência de chat do Amazon Q e a experiência do caderno do AWS Glue Studio.

Tópicos

- Configurar permissões do IAM para o chat do Amazon Q
- Permissões do IAM para cadernos do AWS Glue Studio

Configurar permissões do IAM para o chat do Amazon Q

A concessão de permissões às APIs usadas pela integração de dados do Amazon Q no AWS Glue exige permissões apropriadas do AWS Identity and Access Management (IAM). Você pode obter permissões anexando a seguinte política da AWS personalizada à sua identidade do IAM (como usuário, perfil ou grupo):

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "glue:StartCompletion",
                "glue:GetCompletion"
            ],
            "Resource": [
                "arn:aws:glue:*:*:completion/*"
            ]
        }
    ]
}
```

Permissões do IAM para cadernos do AWS Glue Studio

Para habilitar a integração de dados do Amazon Q em cadernos do AWS Glue Studio, certifique-se de que a seguinte permissão esteja anexada ao perfil do IAM do caderno:

> **Note**
>
> O prefixo `codewhisperer` é um nome antigo de um serviço que foi fundido com o Amazon Q Developer. Para obter mais informações, consulte Renomeação do Amazon Q Developer: resumo das alterações.

```
{
    "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**
>
> A integração de dados do Amazon Q no AWS Glue não tem APIs disponíveis por meio do AWS SDK que você possa usar programaticamente. As duas APIs a seguir são usadas na política do IAM para permitir essa experiência por meio do painel de chat do Amazon Q ou dos cadernos do AWS Glue Studio: `StartCompletion` e `GetCompletion`.

Atribuindo permissões

Para conceder acesso, adicione as permissões aos seus usuários, grupos ou perfis:

- Usuários e grupos no Centro de Identidade do AWS IAM: criem um conjunto de permissões. Siga as instruções em Criar um conjunto de permissões no Guia do usuário do Centro de Identidade do AWS IAM.
- Usuários gerenciados no IAM por meio de um provedor de identidades: criem um perfil para federação de identidades. Siga as instruções em Criando um perfil para um provedor de identidades de terceiros (federação) no Guia do Usuário do IAM.
- Usuários do IAM:
  - Crie um perfil que seu usuário possa assumir. Siga as instruções em Criação de um perfil para um usuário do IAM no Guia do usuário do IAM.
  - (Não recomendado) Vincule uma política diretamente a um usuário ou adicione um usuário a um grupo de usuários. Siga as instruções em Adição de permissões a um usuário (console) no Guia do usuário do IAM.

Capacidades de geração de código suportadas

A seguir estão as combinações das capacidades de geração de código da integração de dados do Amazon Q.

Origens e destinos	Transformação
S3 com os seguintes tipos de formato: json, csv, parquet, hudi, delta	Drop
AWS Glue Data Catalog	Agregar
Redlake	DropDuplicates
Amazon DynamoDB	Ingressar
MySQL	Filtro
Oracle	RenameColumns
PostgresSQL	FillNull
Microsoft SQL Server	DropNull
Amazon DocumentDB/MongoDB	WithColumns
Snowflake	Consulta SQL
Google BigQuery	Union
Teradata	Selecionar
Amazon OpenSearch Service	
Vertica	
SAP HANA	
Amazon Redshift	

Interações de exemplo

A integração de dados do Amazon Q no AWS Glue permite inserir a consulta/solicitação no painel do Amazon Q. Você pode inserir uma pergunta sobre a funcionalidade de integração de dados fornecida pelo AWS Glue. Uma resposta detalhada, junto com documentos de referência, será retornada.

Outro caso de uso é gerar scripts de trabalhos de ETL do AWS Glue. Você pode fazer uma pergunta sobre como realizar um trabalho de extração, transformação e carregamento de dados. Um script PySpark gerado será devolvido.

Tópicos

- Interações de chat do Amazon Q
- Interações do AWS Glue com um caderno do Studio

Interações de chat do Amazon Q

No console do AWS Glue, comece a criar um novo trabalho e peça ao Amazon Q: "Crie um fluxo de ETL do Glue, conecte-se a dois locais e eventos de tabelas do catálogo do Glue no meu banco de dados glue_db, junte os resultados no venueid do local e no e_venueid do evento e, em seguida, filtre por estado do local com a condição VenuEstate=='DC' e escreva em s3://amzn-s3-demo-bucket/codegen/BDB-9999/output/ no formato CSV".

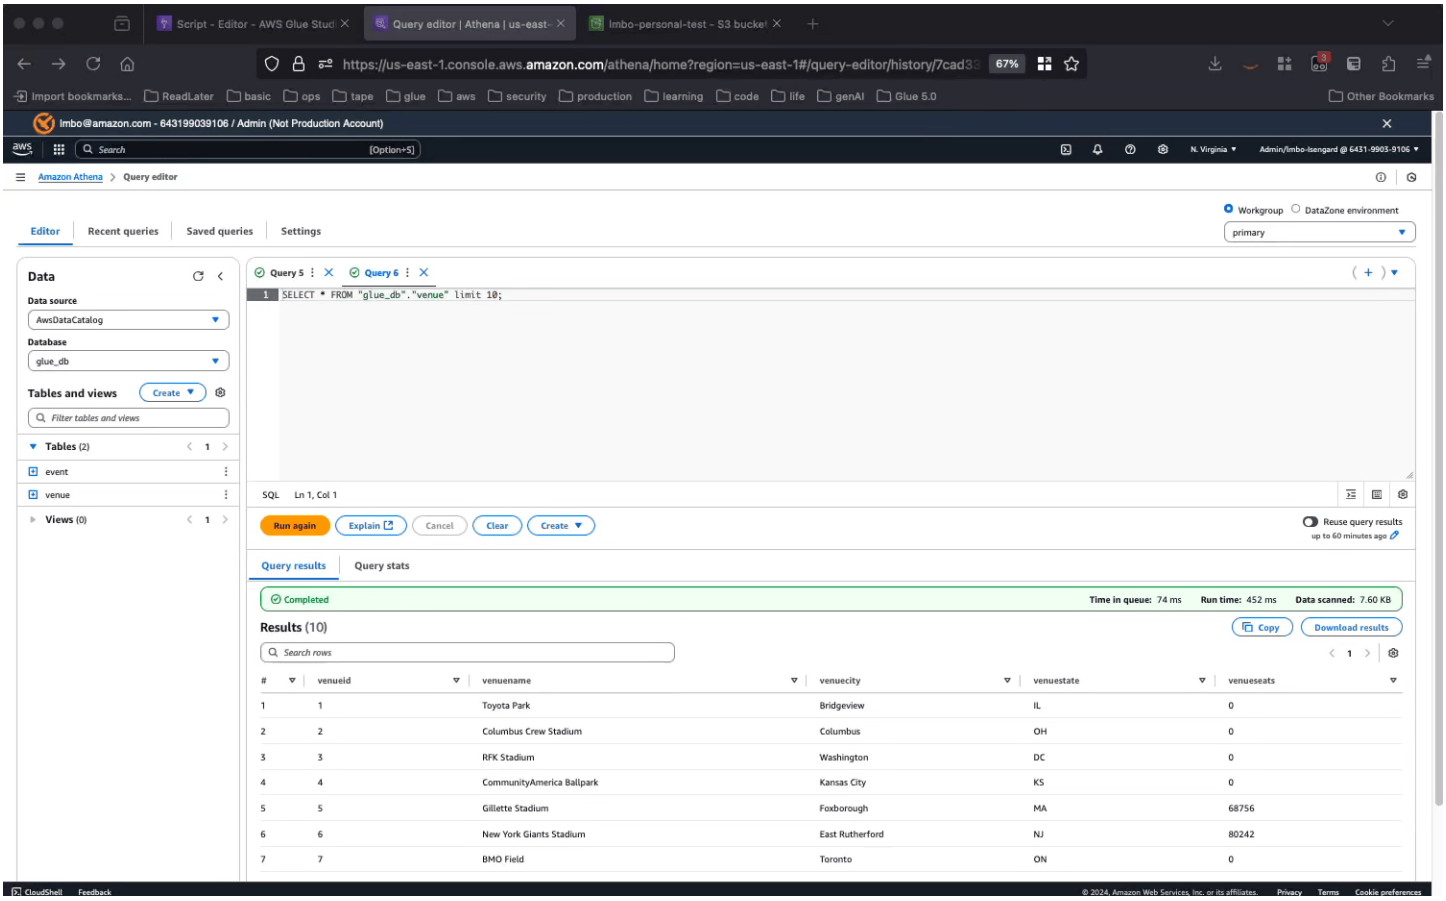

Você notará que o código foi gerado. Com essa resposta, você pode aprender e entender como criar o código do AWS Glue para sua finalidade. Você pode copiar/colar o código gerado no editor de scripts e configurar espaços reservados. Depois de configurar um perfil do IAM e conexões do AWS Glue no trabalho, salve e execute o trabalho. Quando o trabalho estiver concluído, você poderá verificar se os dados resumidos permanecem no Amazon S3 conforme o esperado e podem ser usados por workloads downstream.

Interações do AWS Glue com um caderno do Studio

> **Note**
>
> A experiência de integração de dados do Amazon Q em cadernos do AWS Glue Studio ainda se concentra no fluxo de integração de dados baseado em DynamicFrame.

Adicione uma nova célula e insira seu comentário para descrever o que deseja alcançar. Depois de pressionar Tab e Enter, o código recomendado é exibido.

A primeira intenção é extrair os dados: "Forneça um código que leia uma tabela do Glue Data Catalog", seguido por "Forneça um código para aplicar uma transformação de filtro com star_rating>3" e "Forneça o código que grava o quadro no S3 como Parquet".

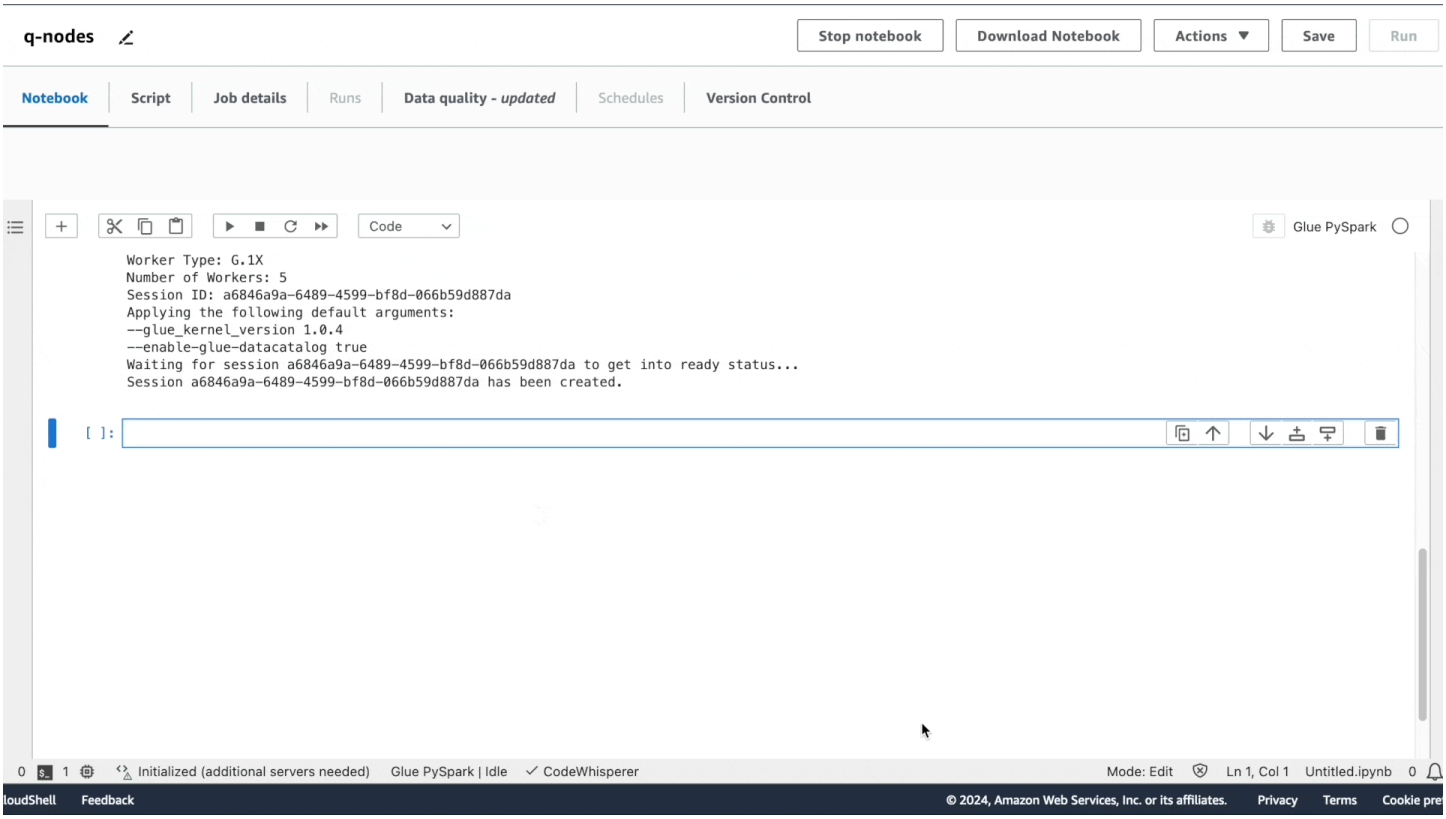

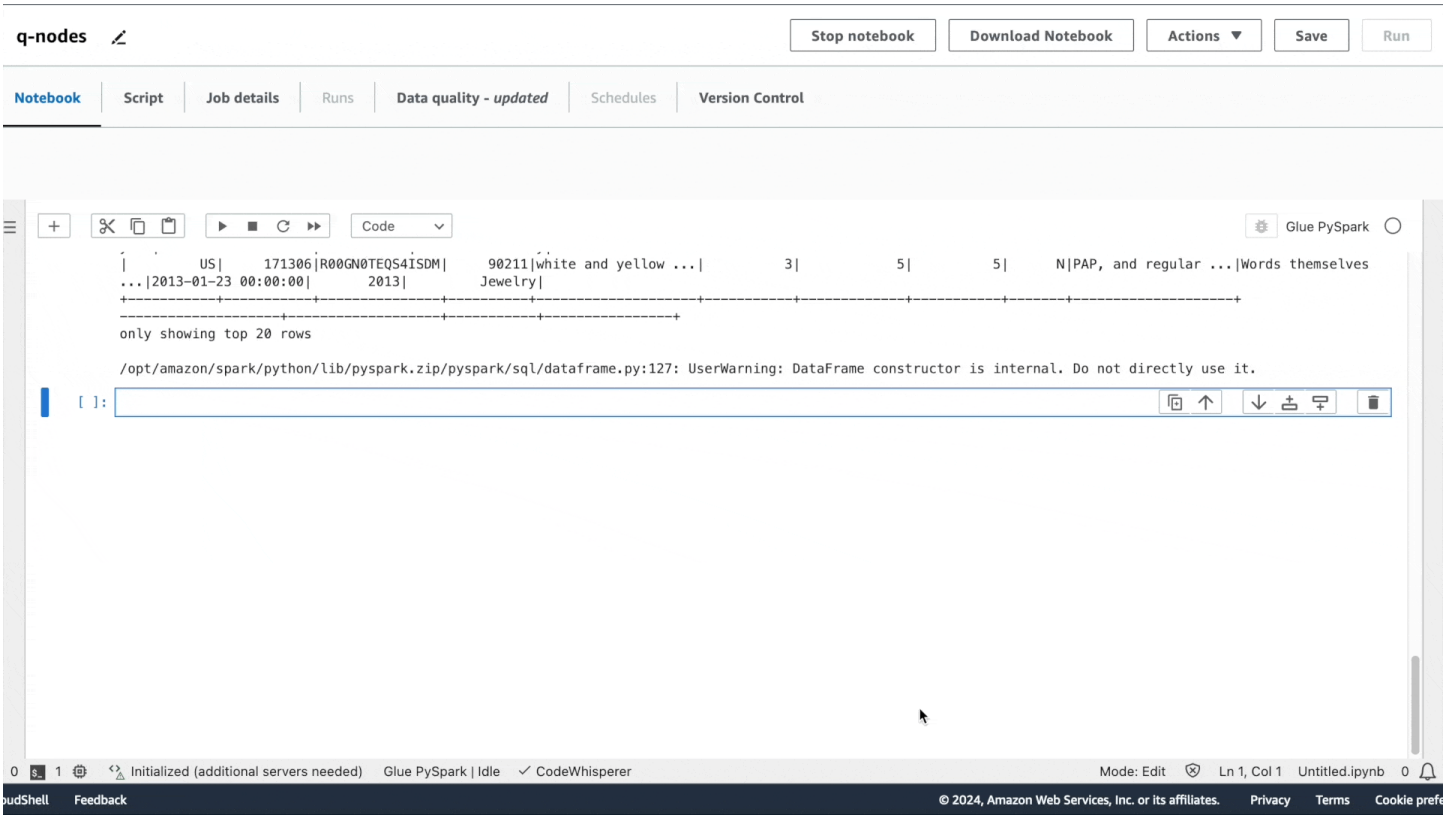
q-nodes
Stop notebook
Download Notebook
Actions
Save
Run
Notebook
Script
Job details
Runs
Data quality - updated
Schedules
Version Control
Code
Glue PySpark
only showing top 20 rows
/opt/amazon/spark/python/lib/pyspark.zip/pyspark/sql/dataframe.py:127: UserWarning: DataFrame constructor is internal. Do not directly use it.
[ ]:
Initialized (additional servers needed)
Glue PySpark | Idle
CodeWhisperer
Mode: Edit
Ln 1, Col 1
Untitled.ipynb
Feedback
© 2024, Amazon Web Services, Inc. or its affiliates.
Privacy
Terms

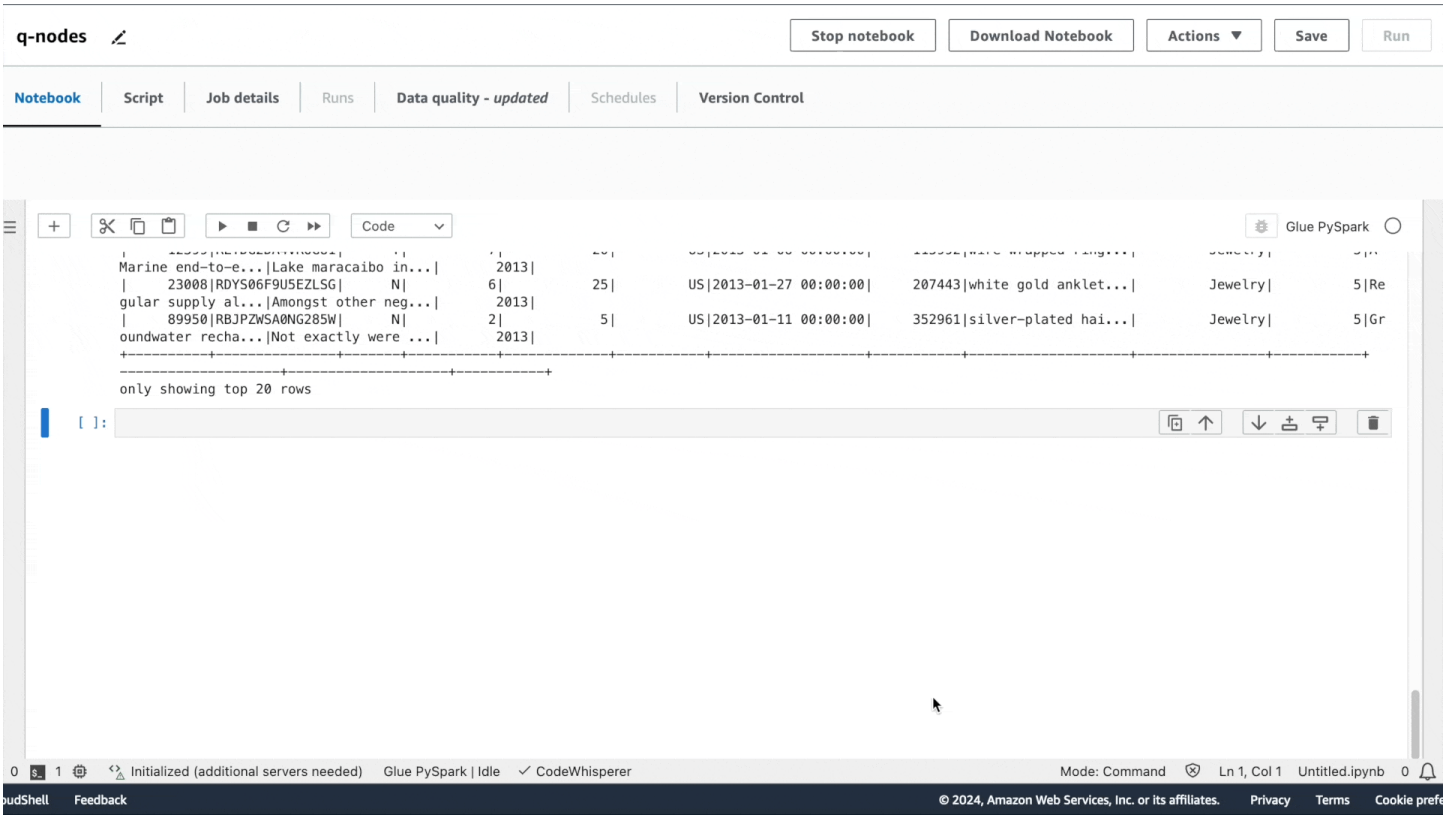
q-nodes
Stop notebook
Download Notebook
Actions
Save
Run
Notebook
Script
Job details
Runs
Data quality - updated
Schedules
Version Control
Code
Glue PySpark
only showing top 20 rows
[ ]:
Initialized (additional servers needed)
Glue PySpark | Idle
CodeWhisperer
Mode: Command
Ln 1, Col 1
Untitled.ipynb
Feedback
© 2024, Amazon Web Services, Inc. or its affiliates.
Privacy
Terms

Semelhante à experiência de chat do Amazon Q, o código é recomendado. Se você pressionar Tab, o código recomendado será escolhido.

É possível executar cada célula preenchendo as opções apropriadas para as fontes no código gerado. Em qualquer momento das execuções, é possível visualizar uma amostra do seu conjunto de dados usando o método `show()`.

É possível executar o caderno como um trabalho, seja programaticamente ou escolhendo Executar.

Prompts complexos

É possível gerar um script completo com um único prompt complexo. "Tenho dados JSON no S3 e dados no Oracle que precisam ser combinados. Forneça um script do Glue que leia as duas fontes, faça uma junção e, em seguida, grave os resultados no Redshift."

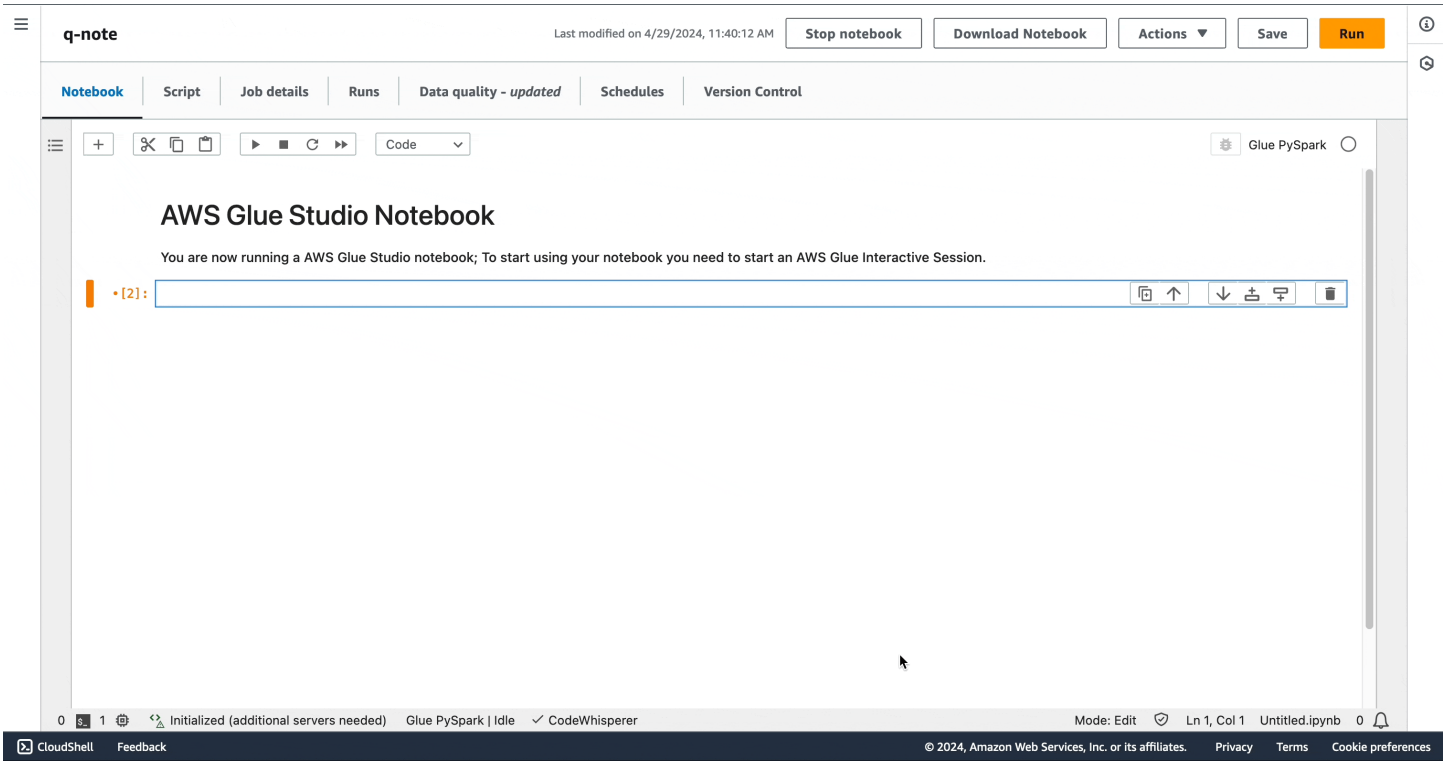

Você pode notar que, no caderno, a integração de dados do Amazon Q no AWS Glue gerou o mesmo trecho de código que foi gerado no chat do Amazon Q.

É possível executar o caderno como um trabalho escolhendo Executar ou programaticamente.

Usar o reconhecimento de contexto com o Amazon Q Data Integration no AWS Glue

Agora você pode criar trabalhos de processamento de dados com mais eficiência com a geração de código PySpark DataFrame baseada em consultas e com reconhecimento de contexto no Amazon Q Data Integration. Por exemplo, é possível usar esse prompt para gerar o código PySpark: "crie um trabalho para carregar dados de vendas da tabela 'analytics.salesorder' do Redshift usando a conexão 'erp_conn', filtre o valor do pedido abaixo de 50 dólares e salve no Amazon S3 em formato parquet".

O Amazon Q gerará o script com base em seu prompt e configurará o fluxo de trabalho de integração de dados com os detalhes fornecidos pela sua pergunta, como configurações de conexão, detalhes do esquema, nomes de bancos de dados/tabelas e especificações de colunas para transformações. Informações confidenciais, como senhas de opções de conexão, continuam a ser editadas.

Se as informações necessárias não forem fornecidas no seu prompt, o Amazon Q colocará espaços reservados nos quais você precisará atualizar o código gerado com os valores apropriados antes de executá-lo.

Veja a seguir exemplos de como usar o reconhecimento de contexto.

Exemplo: interações

Ler um arquivo do Amazon S3 e gravar em um bucket do 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/"
)
```

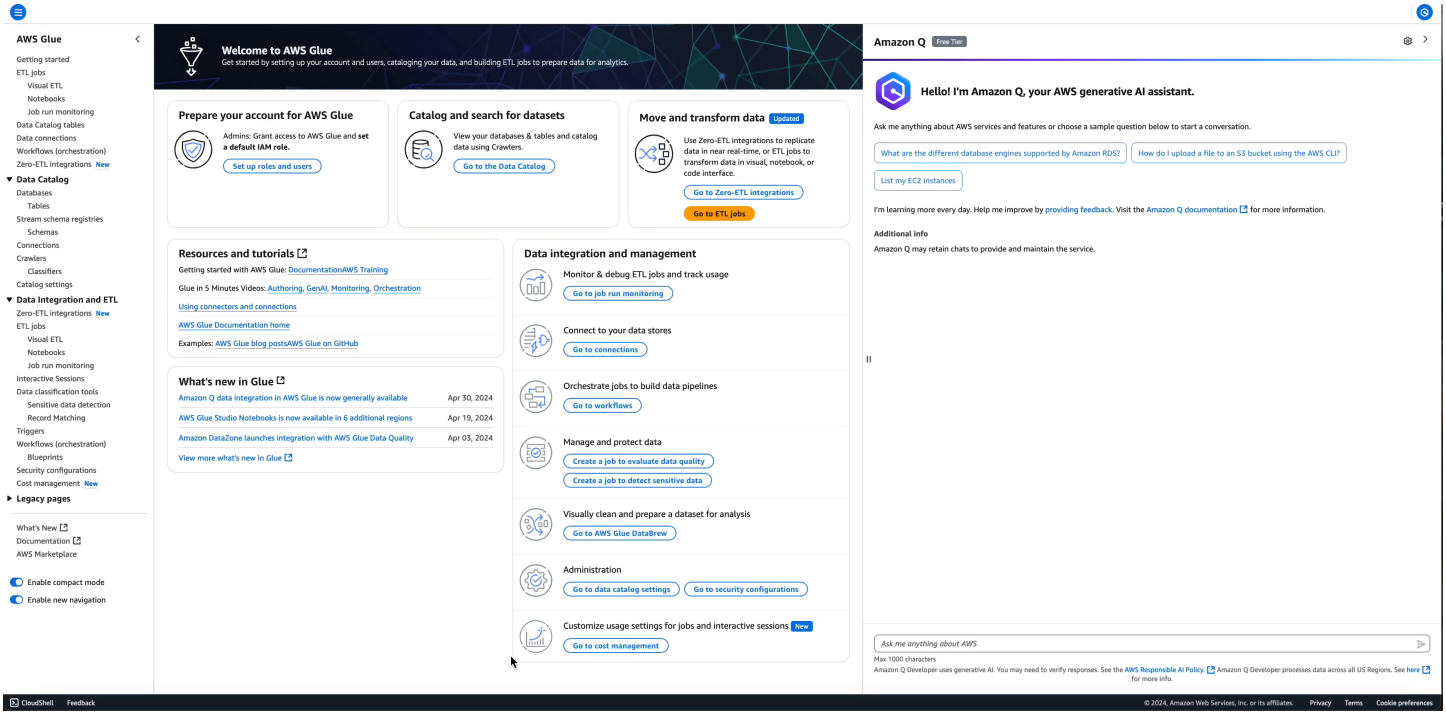

Obter dados do Lakehouse e gravar no banco de dados

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`

Para campos em que você não forneceu informações (por exemplo, o connectionName obrigatório destina-se ao coletor de dados do MySQL e o padrão é um espaço reservado <connection-name> no código gerado), um espaço reservado é mantido para você preencher as informações necessárias antes de executar o script.

Script gerado:

```
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,
)
```

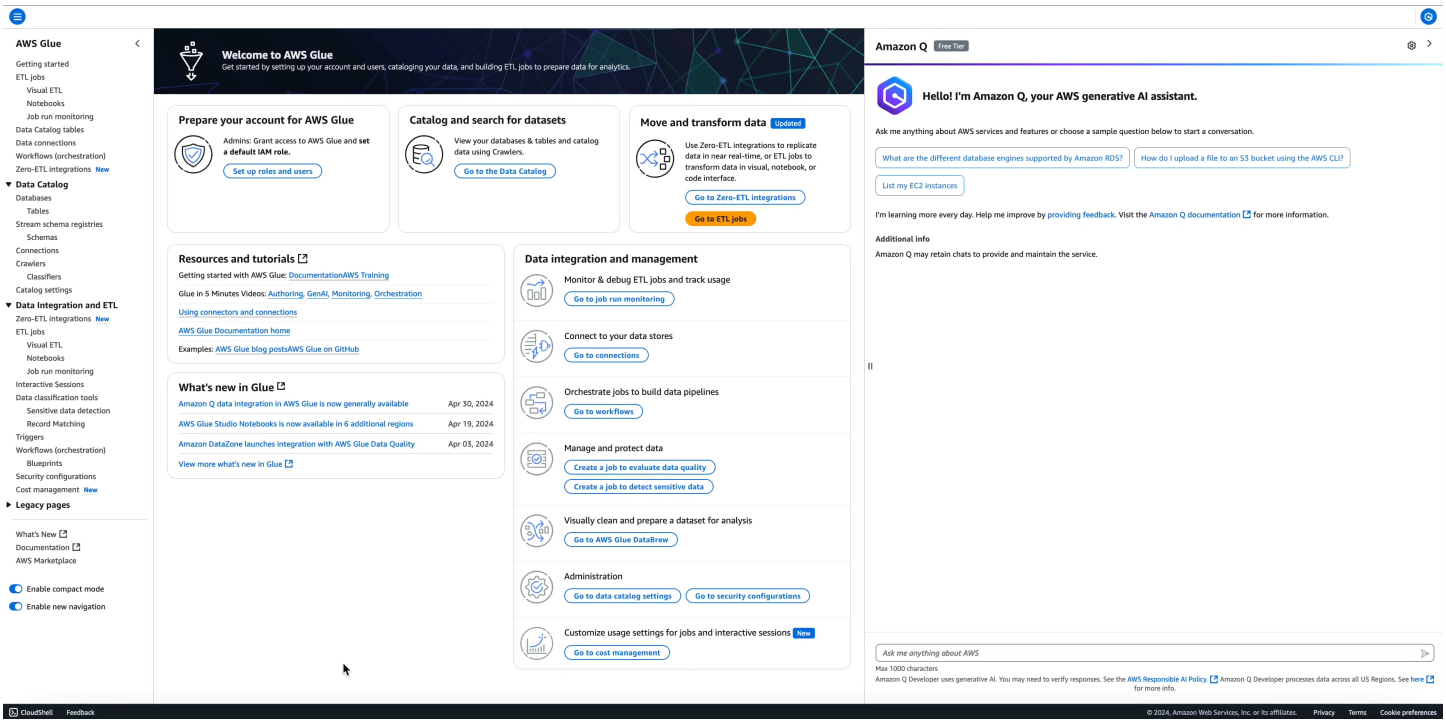

Exemplo: fluxo de trabalho de ETL completo

O exemplo a seguir demonstra como você pode pedir ao AWS Glue que crie um script do AWS Glue para concluir um fluxo de trabalho de ETL completo com o seguinte prompt: `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.`

O fluxo de trabalho contém a leitura de diferentes fontes de dados (duas tabelas do Catálogo de Dados do AWS Glue) e algumas transformações após a leitura por meio da junção do resultado de duas leituras, filtragem com base em alguma condição e gravação da saída transformada em um destino do Amazon S3 no formato CSV.

O trabalho gerado preencherá as informações detalhadas da fonte de dados, da transformação e da operação de sink com as informações correspondentes extraídas da pergunta do usuário, conforme mostrado a seguir.

```
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/"
)
```

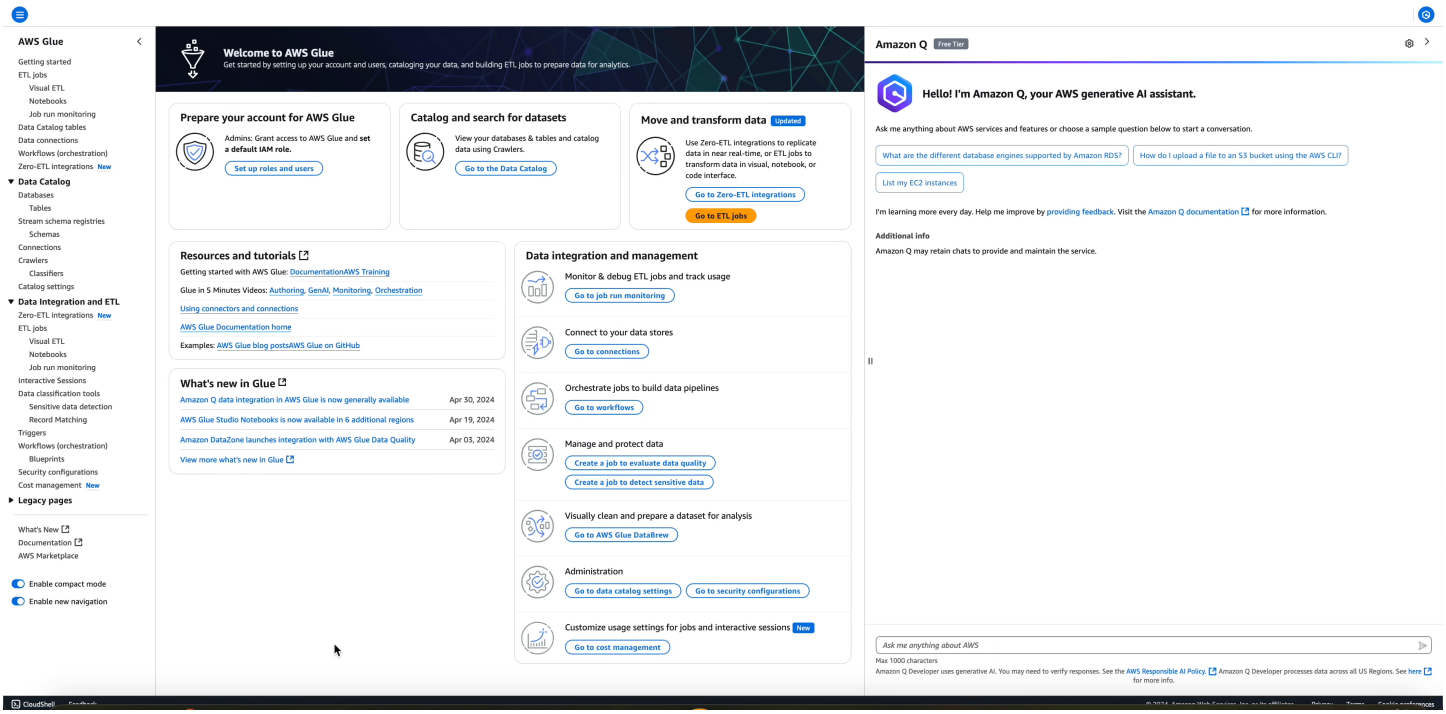

Limitações

- Transferência de contexto:
  - O recurso de reconhecimento de contexto só transfere o contexto da consulta anterior do usuário na mesma conversa. Ele não retém o contexto além da consulta imediatamente anterior.
- Suporte a configurações de nós:
  - Atualmente, o reconhecimento de contexto só oferece suporte a um subconjunto das configurações necessárias para vários nós.
  - O suporte para campos opcionais está planejado para as próximas versões.
- Disponibilidade:
  - Reconhecimento de contexto e suporte ao DataFrame estão disponíveis nos cadernos do Q Chat e do SageMaker Unified Studio. No entanto, esses recursos ainda não estão disponíveis nos cadernos do AWS Glue Studio.

Orquestração no AWS Glue

As seções a seguir fornecem mais informações sobre a orquestração de trabalhos no AWS Glue.

Tópicos

- Iniciar trabalhos e crawlers usando acionadores
- Realizar atividades de ETL complexas usando esquemas e fluxos de trabalho no AWS Glue
- Desenvolver esquemas no AWS Glue

Iniciar trabalhos e crawlers usando acionadores

No AWS Glue, você pode criar objetos do Data Catalog chamados acionadores, que podem ser usados para iniciar manual ou automaticamente um ou mais crawlers, ou extrair, transformar e carregar (ETL) trabalhos. Ao usar gatilhos, você pode projetar uma cadeia de trabalhos e crawlers dependentes.

> **Note**
>
> É possível fazer a mesma coisa definindo fluxos de trabalho. Os fluxos de trabalho são preferidos para a criação de operações ETL complexas com vários trabalhos. Para ter mais informações, consulte the section called “Realizar atividades de ETL complexas usando esquemas e fluxos de trabalho”.

Tópicos

- Gatilhos do AWS Glue
- Adição de acionadores
- Ativar e desativar acionadores

Gatilhos do AWS Glue

Quando acionado, um gatilho pode iniciar trabalhos e crawlers especificados. Um gatilho é acionado sob demanda, com base em uma programação ou em uma combinação de eventos.

> **Note**
>
> Apenas dois crawlers podem ser ativados por um único acionador. Se você quiser realizar crawling em vários armazenamentos de dados, use várias fontes para cada crawler, em vez de executar vários crawlers simultaneamente.

Um gatilho pode existir em um de vários estados. Um gatilho é `CREATED`, `ACTIVATED` ou `DEACTIVATED`. Existem também estados transitórios, como `ACTIVATING`. Para impedir temporariamente que um gatilho seja acionado, é possível desabilitá-lo. Você pode reabilitá-lo posteriormente.

Existem três tipos de gatilhos:

Programado

Um gatilho de tempo baseado em `cron`.

Você pode criar um gatilho para um conjunto de trabalhos ou crawlers com base em uma programação. Você pode especificar restrições, como a frequência de execução ou em quais dias da semana e a que horas os trabalhos ou crawlers são executados. Essas restrições são feitas com base no `cron`. Ao configurar a programação de um gatilho, considere os recursos e as limitações do cron. Por exemplo, se você optar por executar seu crawler no dia 31 de cada mês, lembre-se de que alguns meses não têm 31 dias. Para obter mais informações sobre o cron, consulte Programações baseadas em hora para trabalhos e crawlers.

Condicional

Um gatilho que é acionado quando um ou vários trabalhos ou crawlers satisfazem uma lista de condições.

Ao criar um gatilho condicional, você especifica uma lista de trabalhos e uma lista de crawlers a serem monitorados. Para cada trabalho ou crawler monitorado, você especifica um status a monitorar, como succeeded (bem-sucedido), failed (com falha), timed out (com tempo limite excedido) e assim por diante. O gatilho será acionado se os trabalhos ou crawlers monitorados forem finalizados com os status especificados. Você pode configurar o gatilho de modo a ser acionado quando um ou todos os eventos monitorados ocorrerem.

Por exemplo, você pode configurar um gatilho T1 para iniciar o trabalho J3 quando o trabalho J1 e J2 forem concluídos com êxito, e outro gatilho T2 para iniciar o trabalho J4 se houver falha no trabalho J1 ou no J2.

A tabela a seguir lista os estados de conclusão do trabalho e do crawler (eventos) que acionam a gatilho.

Estados de conclusão do trabalho	Estados de conclusão do crawler
• `SUCCEEDED` • `STOPPED` • `FAILED` • `TIMEOUT`	• `SUCCEEDED` • `FAILED` • `CANCELLED`

Sob demanda

Um gatilho que é acionado quando é ativado. Os gatilhos sob demanda nunca entram no estado `ACTIVATED` ou `DEACTIVATED`. Eles sempre permanecem no estado `CREATED`.

Para que eles estejam prontos para serem acionados assim que existirem, você pode definir um sinalizador para ativar gatilhos programados e condicionais ao criá-los.

> **Important**
>
> Os trabalhos ou crawlers executados como resultado da conclusão de outros trabalhos ou crawlers são chamados de dependentes. Os trabalhos ou crawlers dependentes só serão iniciados se o trabalho ou o crawler concluído tiver sido iniciado por um gatilho. Todos os trabalhos ou crawlers em uma cadeia de dependência devem ser descendentes de um único gatilho scheduled (programado) ou on-demand (sob demanda).

Transmitir parâmetros de trabalho com acionadores

Um gatilho pode transmitir parâmetros para os trabalhos que inicia. Os parâmetros incluem argumentos de trabalho, valor de tempo limite, configuração de segurança e muito mais. Se o gatilho iniciar vários trabalhos, os parâmetros serão transmitidos para cada trabalho.

Veja a seguir as regras para argumentos de trabalho transmitidos por um gatilho:

- Se a chave no par de chave/valor corresponder a um argumento de trabalho padrão, o argumento transmitido substituirá o argumento padrão. Se a chave não corresponder a um argumento padrão, o argumento será transmitido como um argumento adicional para o trabalho.
- Se a chave no par de chave/valor corresponder a um argumento não substituível, o argumento transmitido será ignorado.

Para obter mais informações, consulte the section called “Acionadores” na API do AWS Glue.

Adição de acionadores

É possível adicionar um gatilho usando o console do AWS Glue, a AWS Command Line Interface (AWS CLI) ou a API do AWS Glue.

> **Note**
>
> Atualmente, o console do AWS Glue oferece suporte somente a trabalhos, não a crawlers, ao trabalhar com gatilhos. Você pode usar a AWS CLI ou a API do AWS Glue para configurar gatilhos com trabalhos e crawlers.

Como adicionar um gatilho (console)

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em ETL, selecione Triggers (Gatilhos). Escolha Add trigger (Adicionar gatilhos).
3. Forneça as seguintes propriedades:

   Nome

   Atribua um nome exclusivo ao gatilho.

   Tipos de gatilho

   Especifique um dos seguintes:

   - Schedule (Programação): o gatilho é acionado em uma frequência e hora específicas.
   - Job events (Eventos de trabalho): um gatilho condicional. O gatilho é acionado quando um ou todos os trabalhos na lista correspondem ao seu status designado. Para que o gatilho

seja acionado, os trabalhos monitorados devem ter sido iniciados por um gatilho. Para qualquer trabalho que você escolher, só é possível observar um evento de trabalho (status de conclusão).

- On-demand (Sob demanda): o gatilho é acionado quando habilitado.

4. Executar o assistente de gatilho. Na página Review (Revisar) você pode ativar gatilhos Schedule (Programados) e de Job events (Eventos de trabalho) (condicionais) imediatamente selecionando Enable trigger on creation (Habilitar gatilho na criação).

Como adicionar um gatilho (AWS CLI)

- Digite um comando semelhante ao seguinte:

```
aws glue create-trigger --name MyTrigger --type SCHEDULED --schedule  "cron(0 12 *
 * ? *)" --actions CrawlerName=MyCrawler --start-on-creation
```

Esse comando cria um gatilho programado chamado `MyTrigger`, que é executado todos os dias às 12h UTC e inicia um crawler chamado `MyCrawler`. O gatilho é criado no estado ativado.

Para ter mais informações, consulte the section called “Gatilhos do AWS Glue”.

Programações baseadas em hora para trabalhos e crawlers

Você pode definir uma programação baseada em hora para seus crawlers e trabalhos no AWS Glue. A definição dessas programações usa a sintaxe cron semelhante à do Unix. Você especifica a hora em Tempo Universal Coordenado (UTC). Além disso, a precisão mínima para uma programação é de 5 minutos.

Para saber mais sobre como configurar trabalhos e crawlers para serem executados usando uma programação, consulte Iniciar trabalhos e crawlers usando acionadores.

Expressão cron

Expressões cron têm seis campos obrigatórios, que são separados por um espaço em branco.

Sintaxe

```
cron(Minutes Hours Day-of-month Month Day-of-week Year)
```

Campos	Valores	Curingas
Minutos	0–59	, - * /
Horas	0–23	, - * /
Dia do mês	1–31	, - * ? / L W
Mês	1-12 ou JAN-DEZ	, - * /
Dia da semana	1-7 ou SUN-SAT	, - * ? / L
Ano	1970–2199	, - * /

Curingas

- A , (vírgula) curinga inclui valores adicionais. No campo `Month`, `JAN,FEB,MAR` incluirá janeiro, fevereiro e março.
- O - (traço) curinga especifica intervalos. No campo `Day`, 1-15 incluiria os dias 1 a 15 do mês especificado.
- O * (asterisco) curinga inclui todos os valores no campo. No campo `Hours`, * incluirá cada hora.
- A / (barra) curinga especifica incrementos. No campo `Minutes`, você pode inserir **`1/10`** para especificar cada décimo minuto a partir do primeiro minuto da hora (por exemplo, o 11º, 21º e 31º minuto, etc).
- O curinga ? (interrogação) especifica um ou outro. No campo `Day-of-month`, você pode inserir `7` e, se não se importar com qual dia da semana era o sétimo, pode inserir ? no campo Dia da semana.
- O curinga L nos campos `Day-of-month` ou `Day-of-week` especifica o último dia do mês ou da semana.
- O curinga W no campo `Day-of-month` especifica um dia da semana. No campo `Day-of-month`, `3W` especifica o dia mais próximo do terceiro dia da semana do mês.

Limites

- Não é possível especificar os campos `Day-of-month` e `Day-of-week` na mesma expressão cron. Se você especificar um valor em um dos campos, deverá usar um ? (ponto de interrogação) no outro.
- As expressões cron que levam a taxas mais rápidas do que 5 minutos não têm suporte.

Exemplos

Ao criar uma programação, você pode usar os seguintes exemplos de strings cron.

Minutos	Horas	Dia do mês	Mês	Dia da semana	Ano	Significado
0	10	*	*	?	*	Executada às 10h (UTC) todos os dias
15	12	*	*	?	*	Executada às 12h15 (UTC) todos os dias
0	18	?	*	SEG-SEX	*	Executada às 18h (UTC) de segunda a sexta
0	8	1	*	?	*	Executada às 8h (UTC) todo o primeiro dia do mês

Minutos	Horas	Dia do mês	Mês	Dia da semana	Ano	Significado
0/15	*	*	*	?	*	Executada a cada 15 minutos
0/10	*	?	*	SEG-SEX	*	Executada a cada 10 minutos de segunda a sexta
0/5	8-17	?	*	SEG-SEX	*	Executada a cada 5 minutos de segunda a sexta entre 8h e 17h55 (UTC)

Por exemplo, para executar uma programação todos os dias às 12h15 UTC, especifique:

```
cron(15 12 * * ? *)
```

Ativar e desativar acionadores

Você pode ativar ou desativar um gatilho usando o console do AWS Glue, a AWS Command Line Interface (AWS CLI) ou a API do AWS Glue.

Como ativar ou desativar um gatilho (console)

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em ETL, selecione Triggers (Gatilhos).

3. Marque a caixa de seleção ao lado do gatilho desejado e, no menu Action (Ação), escolha Enable trigger (Habilitar gatilho) para ativar o gatilho ou Disable trigger (Desabilitar gatilho) para desativar o gatilho.

Como ativar ou desativar um gatilho (AWS CLI)

- Insira um dos seguintes comandos:

```
aws glue start-trigger --name MyTrigger

aws glue stop-trigger --name MyTrigger
```

  Ao iniciar um gatilho ele é ativado e ao interromper um gatilho ele é desativado. Quando você ativa um gatilho sob demanda, ele é acionado imediatamente.

Para ter mais informações, consulte the section called “Gatilhos do AWS Glue”.

Realizar atividades de ETL complexas usando esquemas e fluxos de trabalho no AWS Glue

Alguns dos processos complexos de extração, transformação e carregamento (ETL) da sua organização podem ser melhor implantados usando vários crawlers e trabalhos dependentes do AWS Glue. Usando fluxos de trabalho do AWS Glue, você pode projetar um processo complexo de ETL com vários trabalhos e crawlers, que o AWS Glue pode executar e rastrear como uma entidade única. Depois de criar um fluxo de trabalho e especificar os trabalhos, crawlers e acionadores no fluxo de trabalho, você pode executá-lo sob demanda ou em uma programação.

Tópicos

- Visão geral de fluxos de trabalho no AWS Glue
- Criar e desenvolver um fluxo de trabalho manualmente no AWS Glue
- Iniciar um fluxo de trabalho do AWS Glue com um evento do Amazon EventBridge
- Visualizar os eventos do EventBridge que iniciaram um fluxo de trabalho
- Executar e monitorar um fluxo de trabalho no AWS Glue
- Interromper uma execução de fluxo de trabalho
- Reparar e retomar uma execução de fluxo de trabalho

- Obter e configurar as propriedades de execução de fluxo de trabalho no AWS Glue
- Consultar fluxos de trabalho usando o AWS Glue API
- Restrições de esquema e fluxo de trabalho no AWS Glue
- Solucionar erros de esquema no AWS Glue
- Permissões para pessoas e funções de esquemas do AWS Glue

Visão geral de fluxos de trabalho no AWS Glue

No AWS Glue, você pode usar fluxos de trabalho para criar e visualizar atividades complexas de extração, transformação e carregamento (ETL) que envolvem vários crawlers, trabalhos e gatilhos. Cada fluxo de trabalho gerencia a execução e o monitoramento de todos os seus trabalhos e crawlers. À medida que um fluxo de trabalho executa cada componente, ele registra o progresso e o status de execução. Isso fornece a você uma visão geral das tarefa maior e os detalhes de cada etapa. O console do AWS Glue fornece uma representação visual de um fluxo de trabalho como um gráfico.

Você pode criar um fluxo de trabalho a partir de um blueprint do AWS Glue ou pode construir um fluxo de trabalho manualmente, um componente de cada vez, usando o AWS Management Console ou a AWS Glue API. Para obter mais informações sobre esquemas, consulte the section called “Visão geral dos esquemas”.

Os acionadores nos fluxos de trabalho podem ser acionar trabalhos e crawlers e podem ser disparados quando trabalhos e crawlers são concluídos. Usando acionadores, é possível criar grandes cadeias de trabalhos e crawlers interdependentes. Além dos acionadores em um fluxo de trabalho que definem dependências de trabalhos e crawlers, cada fluxo de trabalho tem um acionador de início. Existem três tipos de acionadores de início:

- Schedule (Programação): o fluxo de trabalho é iniciado de acordo com a programação definida por você. A programação pode ser diária, semanal, mensal e assim por diante, ou pode ser uma programação personalizada com base em uma expressão `cron`.
- On demand (Sob demanda): o fluxo de trabalho é iniciado manualmente pelo console do AWS Glue, API ou AWS CLI.
- EventBridge event (Evento do EventBridge): o fluxo de trabalho é iniciado após a ocorrência de um único evento do Amazon EventBridge ou de um lote de eventos do Amazon EventBridge. Com esse tipo de acionador, o AWS Glue pode ser um consumidor de eventos em uma arquitetura orientada por eventos. Qualquer evento do EventBridge pode iniciar um fluxo de trabalho. O mais

provável caso de uso é a chegada de um novo objeto em um bucket do Amazon S3 (a operação `PutObject` do S3).

Iniciar um fluxo de trabalho com um lote de eventos significa esperar até que um número especificado de eventos tenha sido recebido ou até que um determinado período de tempo tenha passado. Ao criar o acionador de evento do EventBridge, você pode, opcionalmente, especificar condições de lote. Se você especificar condições de lote, deverá especificar o tamanho do lote (número de eventos) e, opcionalmente, poderá especificar uma janela de lote (número de segundos). A janela padrão e máxima do lote é 900 segundos (15 minutos). A condição de lote que é atendida primeiro inicia o fluxo de trabalho. A janela de lote é iniciada quando o primeiro evento chega. Se você não especificar condições de lote ao criar um acionador, o tamanho do lote assumirá como padrão 1.

Quando o fluxo de trabalho é iniciado, as condições de lote são redefinidas e o acionador de evento começa a observar a próxima condição de lote a ser atendida para iniciar o fluxo de trabalho novamente.

A tabela a seguir mostra como o tamanho do lote e a janela do lote operam juntos para acionar um fluxo de trabalho.

Tamanho do lote	Janela do lote	Condição de acionamento resultante
10		O fluxo de trabalho é acionado após a chegada de dez eventos do EventBridge ou 15 minutos após a chegada do primeiro evento, o que ocorrer primeiro. (se o tamanho das janelas não for especificado, o padrão será 15 minutos).
10	Dois minutos	O fluxo de trabalho é acionado após a chegada de dez eventos do EventBridge ou dois minutos após a chegada do primeiro evento, o que ocorrer primeiro.
1		O fluxo de trabalho é acionado após a chegada do primeiro evento. O tamanho da janela é irrelevante. Se você não especificar condições de lote ao criar um acionador de evento do EventBridge, o tamanho do lote assumirá como padrão 1.

A operação de API `GetWorkflowRun` retorna a condição de lote que acionou o fluxo de trabalho.

Independentemente de como um fluxo de trabalho é iniciado, você pode especificar o número máximo de execuções de fluxo de trabalho simultâneas ao criar o fluxo de trabalho.

Se um evento ou lote de eventos iniciar uma execução de fluxo de trabalho que falha em algum momento, esse evento ou lote de eventos não será mais considerado para iniciar uma execução de fluxo de trabalho. Uma nova execução de fluxo de trabalho é iniciada somente quando o próximo evento ou lote de eventos chega.

> **Important**
>
> Limite o número total de trabalhos, crawlers e acionadores em um fluxo de trabalho a 100 ou menos. Se você incluir mais de 100, poderá receber erros ao tentar retomar ou interromper as execuções do fluxo de trabalho.

Uma execução de fluxo de trabalho não será iniciada se exceder o limite de simultaneidade definido para o fluxo de trabalho, mesmo que a condição do evento seja atendida. É aconselhável ajustar os limites de simultaneidade do fluxo de trabalho com base no volume de eventos esperado. O AWS Glue não tenta executar novamente o fluxo de trabalho que falha por causa de limites de simultaneidade excedidos. Da mesma forma, é aconselhável ajustar os limites de simultaneidade para trabalhos e crawlers dentro de fluxos de trabalho com base no volume de eventos esperado.

Propriedades de execução do fluxo de trabalho

Para compartilhar e gerenciar estados em uma execução de fluxo de trabalho, defina as propriedades de execução de fluxo de trabalho padrão. Essas propriedades, que são pares de nome/valor, estão disponíveis para todos os trabalhos no fluxo de trabalho. Usando o AWS Glue API, os trabalhos podem recuperar as propriedades de execução do fluxo de trabalho e modificá-las para trabalhos fornecidos posteriormente no fluxo de trabalho.

Grafo do fluxo de trabalho

A imagem a seguir mostra o gráfico de um fluxo de trabalho básico no console do AWS Glue. Seu fluxo de trabalho poderia ter dezenas de componentes.

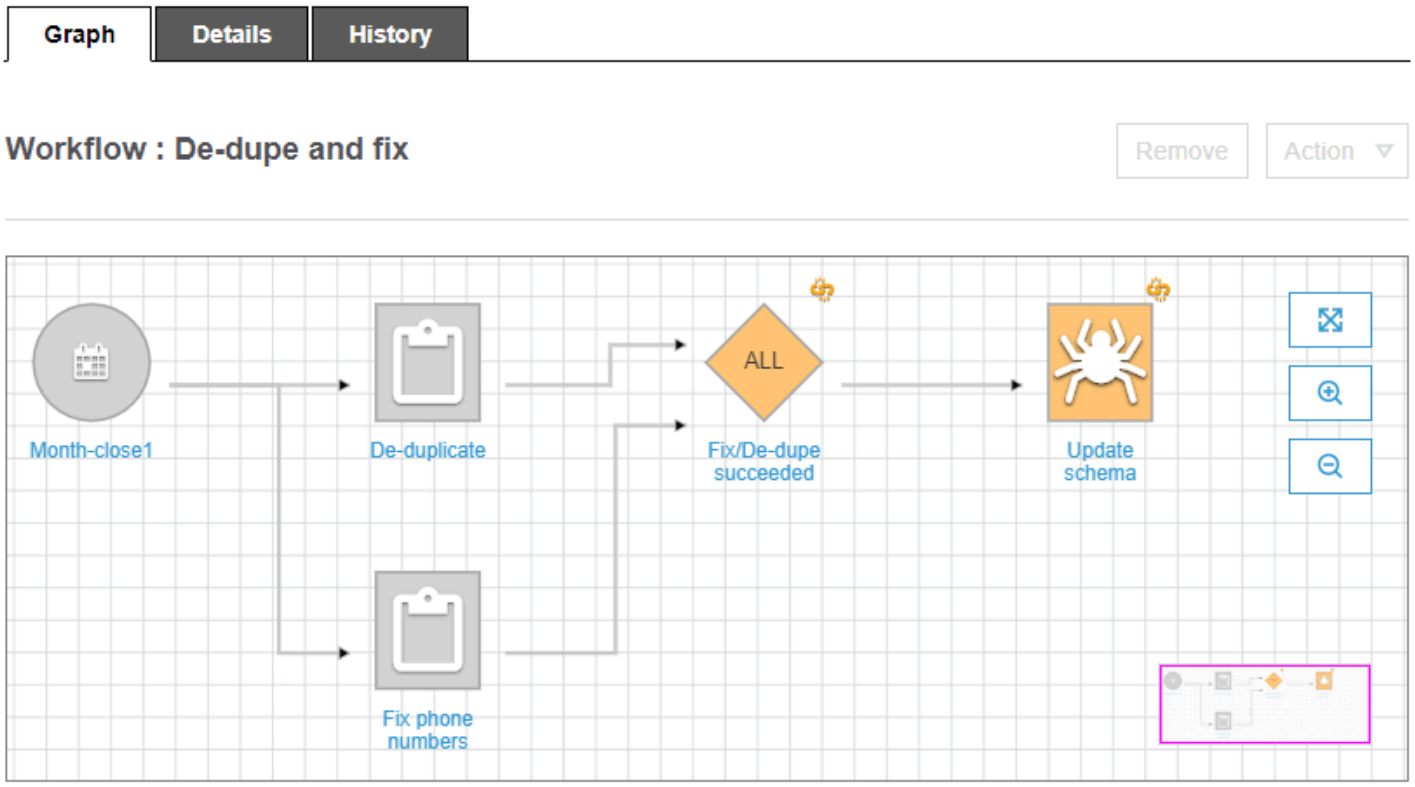

Esse fluxo de trabalho é iniciado por um acionador de programação, `Month-close1`, que inicia dois trabalhos, `De-duplicate` e `Fix phone numbers`. Após a conclusão bem-sucedida de ambos os trabalhos, um acionador de evento, `Fix/De-dupe succeeded`, inicia um crawler, `Update schema`.

Visualizações estáticas e dinâmicas do fluxo de trabalho

Para cada fluxo de trabalho, existe o conceito de visualização estática e dinâmica. A visualização estática indica o design do fluxo de trabalho. A visualização dinâmica é uma visualização do runtime que inclui as informações mais recentes de execução de cada um dos trabalhos e crawlers. As informações de execução incluem o status de sucesso e os detalhes de erros.

Quando um fluxo de trabalho estiver em execução, o console exibirá a visualização dinâmica graficamente, indicando os trabalhos que foram concluídos e os que ainda não foram executados. Também é possível recuperar uma visualização dinâmica de um fluxo de trabalho em execução usando o AWS Glue API. Para ter mais informações, consulte Consultar fluxos de trabalho usando o AWS Glue API.

Consulte também

- the section called “Criar um fluxo de trabalho com base em um esquema”
- the section called “Criar e desenvolver um fluxo de trabalho manualmente”
- Fluxos de trabalho (para a API de fluxos de trabalho)

Criar e desenvolver um fluxo de trabalho manualmente no AWS Glue

Use o console do AWS Glue para criar e construir manualmente um fluxo de trabalho um nó por vez.

Um fluxo de trabalho contém tarefas, crawlers e gatilhos. Antes de criar manualmente um fluxo de trabalho, crie os trabalhos e crawlers que o fluxo de trabalho deve incluir. É melhor especificar crawlers com execução sob demanda para fluxos de trabalho. É possível criar gatilhos durante o desenvolvimento do fluxo de trabalho ou clonar gatilhos existentes no fluxo de trabalho. Quando você clona um acionador, todos os objetos do catálogo associados ao acionador (os trabalhos ou crawlers que o acionam e os trabalhos ou crawlers que ele inicia) são adicionados ao fluxo de trabalho.

Important

Limite o número total de trabalhos, crawlers e acionadores em um fluxo de trabalho a 100 ou menos. Se você incluir mais de 100, poderá receber erros ao tentar retomar ou interromper as execuções do fluxo de trabalho.

Desenvolva o fluxo de trabalho ao adicionar gatilhos ao gráfico do fluxo de trabalho e ao definir os eventos monitorados e as ações para cada gatilho. Comece com um gatilho de início, que pode ser um gatilho sob demanda ou programado e conclua o gráfico adicionando gatilhos de evento (condicionais).

Etapa 1: Criar o fluxo de trabalho

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em ETL, selecione Workflows (Fluxos de trabalho).
3. Selecione Add workflow (Adicionar fluxo de trabalho) e preencha o formulário Add a new ETL workflow (Adicionar um novo fluxo de trabalho de ETL).

As propriedades de execução padrão opcional que você adicionar são disponibilizadas como argumentos para todas as tarefas no fluxo de trabalho. Para ter mais informações, consulte Obter e configurar as propriedades de execução de fluxo de trabalho no AWS Glue.

4. Selecione Add workflow (Adicionar fluxo de trabalho).

   O novo fluxo de trabalho é exibido na lista da página Workflows (Fluxos de trabalho).

Etapa 2: Adicionar um gatilho de início

1. Na página Workflows (Fluxos de trabalho), selecione o novo fluxo de trabalho. Em seguida, na parte inferior da página, certifique-se de que a guia Graph (Gráfico) esteja selecionada.
2. Selecione Add trigger (Adicionar gatilho) e na caixa de diálogo Add trigger (Adicionar gatilho), execute uma das seguintes ações:

   - Selecione Clone existing (Clonar existente), e escolha um gatilho para ser clonado. Em seguida, escolha Adicionar.

     O gatilho é exibido no gráfico com as tarefas e os crawlers que ele monitora e as tarefas e os crawlers que ele inicia.

     Se você selecionou o gatilho errado por engano, selecione o gatilho no gráfico e selecione Remove (Remover).
   - Selecione Add new (Adicionar novo) e preencha o formulário Add trigger (Adicionar gatilho).
     1. Para Trigger type (Tipo de acionador), selecione Schedule (Programação), On demand (Sob demanda) ou EventBridge event (Evento do EventBridge).

        Para o tipo de acionador Schedule (Programação), escolha uma das opções de Frequency (Frequência). Escolha Custom (Personalizado) para inserir uma expressão `cron`.

        Para o tipo de acionador EventBridge event (Evento do EventBridge), insira o Number of events (Número de eventos; tamanho do lote) e, opcionalmente, insira o Time delay (Tempo de atraso; janela de lote). Se você omitir o Time delay (Tempo de atraso), o padrão da janela do lote será 15 minutos. Para ter mais informações, consulte Visão geral de fluxos de trabalho no AWS Glue.
     2. Escolha Adicionar.

O gatilho é exibido no gráfico com um nó de espaço reservado (identificado como Add node (Adicionar nó)). No exemplo abaixo, o acionador de início é um acionador de programação chamado `Month-close1`.

Neste momento, o acionador ainda não está salvo.

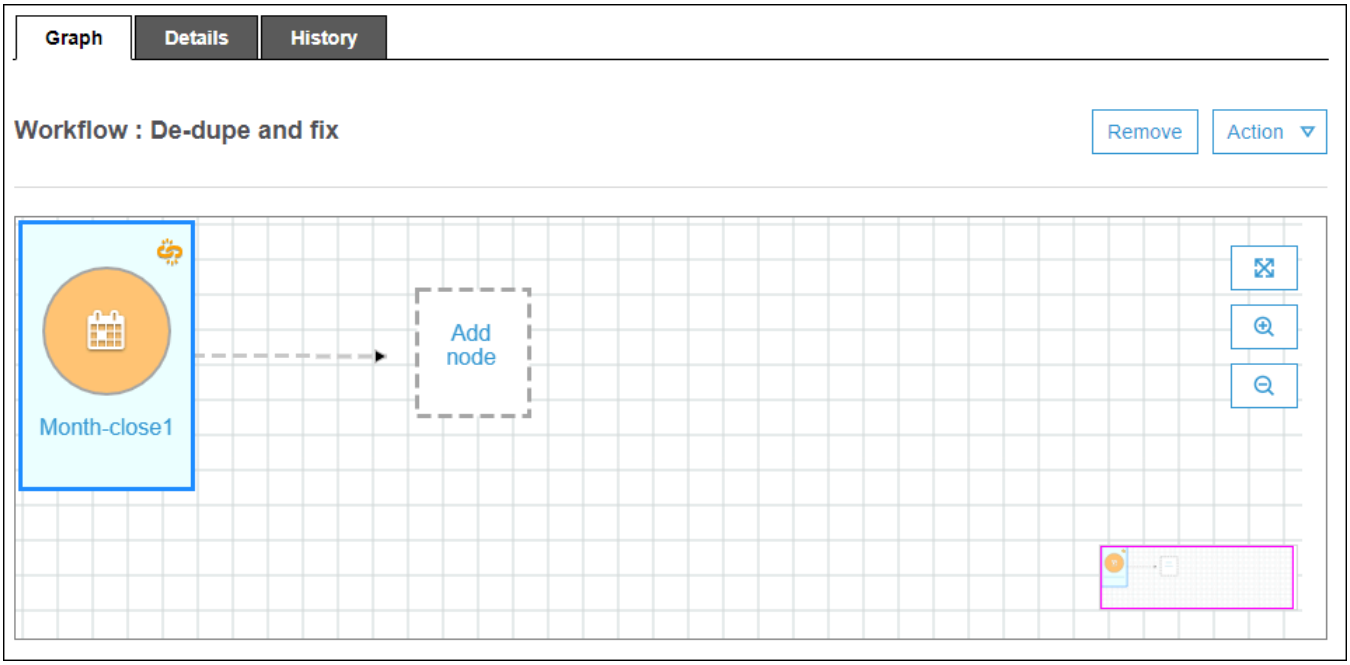

3. Se você adicionou um novo gatilho, execute estas etapas:

   a. Execute um destes procedimentos:

      - Escolha o nó de espaço reservado (Add node (Adicionar nó)).
      - Certifique-se de que o gatilho de início esteja selecionado e, no menu Action (Ação) acima do gráfico, selecione Add jobs/crawlers to trigger (Adicionar tarefas/crawlers ao gatilho).

   b. Na caixa de diálogo Add job(s) and crawler(s) to trigger (Adicionar tarefas e crawlers ao gatilho), selecione uma ou mais tarefas ou crawlers e selecione Add (Adicionar).

      O gatilho é salvo e as tarefas ou crawlers selecionados são exibidos no gráfico com conectores do gatilho.

      Se você adicionou tarefas ou crawlers errados por engano, pode selecionar o gatilho ou um conector e selecionar Remove (Remover).

Etapa 3: adicionar mais acionadores

Continue a construir o fluxo de trabalho adicionando mais acionadores do tipo Event (Evento). Para aumentar ou diminuir o zoom ou para ampliar a tela do gráfico, use os ícones à direita do gráfico. Para cada gatilho a ser adicionado, conclua as seguintes etapas:

> **Note**
>
> Não há nenhuma ação para salvar o fluxo de trabalho. Depois de adicionar o último acionador e atribuir ações a ele, o fluxo de trabalho será concluído e salvo. Você pode voltar a qualquer momento e adicionar mais nós.

1. Execute um destes procedimentos:

   - Para clonar um gatilho existente, certifique-se de que nenhum nó do gráfico esteja selecionado e, no menu Action (Ação), selecione Add trigger (Adicionar gatilho).
   - Para adicionar um novo gatilho que monitora uma tarefa ou um crawler específico no gráfico, selecione o nó da tarefa ou do crawler e selecione o nó do espaço reservado Add trigger (Adicionar gatilho).

     É possível adicionar mais tarefas ou crawlers a serem monitorados por esse gatilho em uma etapa posterior.
2. Na caixa de diálogo Add trigger (Adicionar gatilho), siga um destes procedimentos:

   - Selecione Add new (Adicionar novo) e preencha o formulário Add trigger (Adicionar gatilho). Em seguida, escolha Adicionar.

     O gatilho é exibido no gráfico. Você concluirá o gatilho em uma etapa posterior.
   - Selecione Clone existing (Clonar existente), e escolha um gatilho para ser clonado. Em seguida, escolha Adicionar.

     O gatilho é exibido no gráfico com as tarefas e os crawlers que ele monitora e as tarefas e os crawlers que ele inicia.

     Se você escolheu o gatilho errado por engano, selecione-o no gráfico e selecione Remove (Remover).
3. Se você adicionou um novo gatilho, execute estas etapas:

a. Selecione o novo gatilho.

   Como mostra o gráfico a seguir, o acionador `De-dupe/fix succeeded` está selecionado, e os nós de espaço reservado aparecem para (q) evento a ser monitorado e (2) ações.

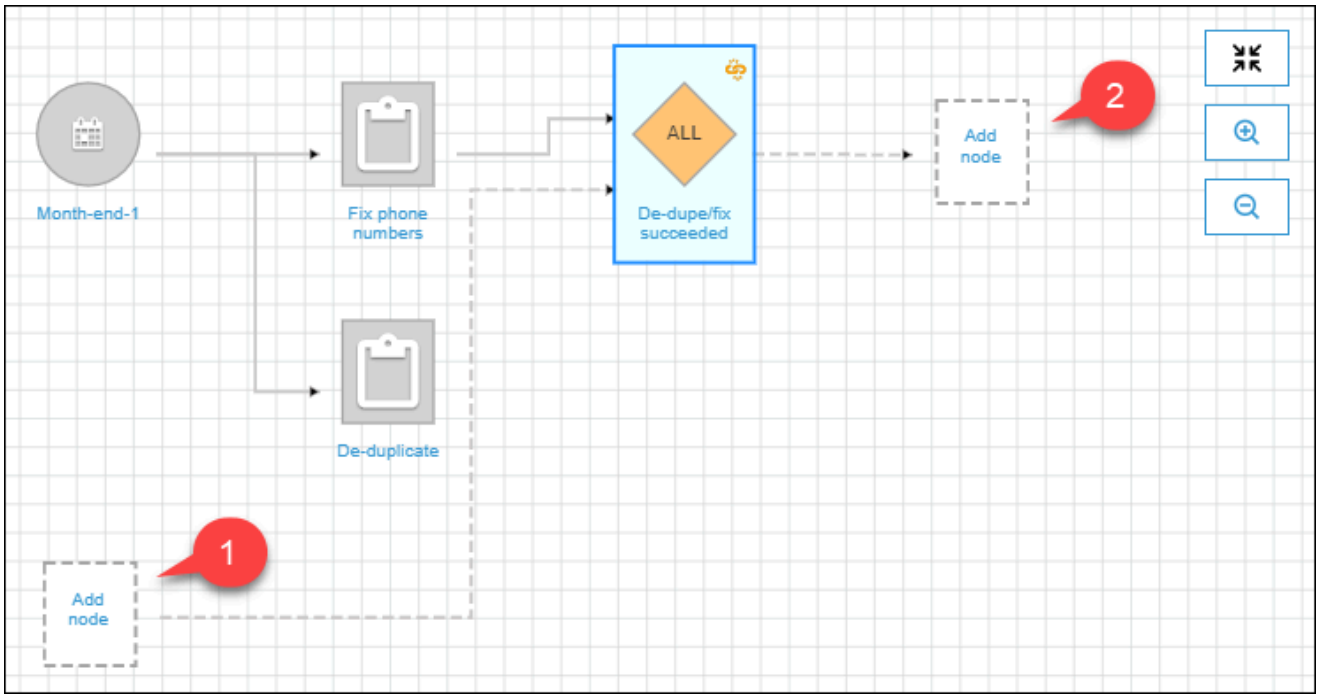

b. (Opcional caso o gatilho já esteja monitorando um evento e você queira adicionar mais tarefas ou crawlers para serem monitorados.) Escolha o nó de espaço reservado de eventos a serem monitorados e, na caixa de diálogo Add job(s) and crawler(s) to watch (Adicionar tarefas e crawlers a serem monitorados), selecione uma ou mais tarefas ou crawlers. Escolha um evento a ser monitorado (BEM-SUCEDIDO, COM FALHA, etc.) e selecione Add (Adicionar).

c. Certifique-se de que o gatilho esteja selecionado e escolha o nó de espaço reservado de ações.

d. Na caixa de diálogo Add job(s) and crawler(s) to watch (Adicionar tarefas e crawlers a serem monitorados), selecione uma ou mais tarefas e crawlers e selecione Add (Adicionar).

   As tarefas e os crawlers selecionados são exibidos no gráfico com conectores do gatilho.

Para obter mais informações sobre fluxos de trabalho e esquemas, consulte os tópicos a seguir.

- Visão geral de fluxos de trabalho no AWS Glue
- Executar e monitorar um fluxo de trabalho no AWS Glue

- Criar um fluxo de trabalho com base em um esquema no AWS Glue

Iniciar um fluxo de trabalho do AWS Glue com um evento do Amazon EventBridge

O Amazon EventBridge, também conhecido como CloudWatch Events, permite que você automatize seus produtos da AWS e responda automaticamente aos eventos do sistema, como problemas de disponibilidade da aplicação ou alterações de recursos. Os eventos dos serviços da AWS são entregues ao EventBridge quase em tempo real. Você pode escrever regras simples para indicar quais eventos são do seu interesse, e as ações automatizadas a serem tomadas quando um evento corresponder à regra.

Com suporte a EventBridge, o AWS Glue pode servir como produtor e consumidor de eventos em uma arquitetura orientada por eventos. Para fluxos de trabalho, o AWS Glue suporta qualquer tipo de evento do EventBridge como consumidor. O mais provável caso de uso é a chegada de um novo objeto em um bucket do Amazon S3. Se você tiver dados chegando em intervalos irregulares ou indefinidos, você poderá processar esses dados o mais próximo possível de suas chegadas.

> **Note**
>
> O AWS Glue não fornece entrega garantida de mensagens do EventBridge. O AWS Glue não realizará a eliminação de duplicação se o EventBridge fornecer mensagens duplicadas. Você deve gerenciar a idempotência com base no seu caso de uso.
> Certifique-se de configurar as regras do EventBridge corretamente para evitar o envio de eventos indesejados.

Antes de começar

Se você quiser iniciar um fluxo de trabalho com eventos de dados do Amazon S3, certifique-se de que os eventos do bucket do S3 de interesse sejam registrados no AWS CloudTrail e no EventBridge. Para fazer isso, você deve criar uma trilha do CloudTrail. Para obter mais informações, consulte Criar uma trilha para sua conta da AWS.

Para iniciar um fluxo de trabalho com um evento do EventBridge

> **Note**
>
> Nos comandos a seguir, substitua:
>
> - *<workflow-name>* pelo nome a ser atribuído ao fluxo de trabalho.
> - *<trigger-name>* pelo nome a ser atribuído ao acionador.
> - *<bucket-name>* pelo nome do bucket do Amazon S3.
> - *<account-id>* por um ID da conta da AWS válido.
> - *<region>* pelo nome da região (por exemplo, `us-east-1`).
> - *<rule-name>* pelo nome a ser atribuído à regra do EventBridge.

1. Verifique se você tem permissões do AWS Identity and Access Management (IAM) para criar e exibir regras e destinos do EventBridge. Veja a seguir um exemplo de política que você pode anexar. Você pode querer restringir o escopo para impor limites nas operações e recursos.

```
{
    "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. Crie uma função do IAM que o produto EventBridge possa assumir ao passar um evento para o AWS Glue.

a. Na página Criar perfil do console do IAM, escolha Serviço da AWS. Em seguida, escolha o produto CloudWatch Events.

b. Conclua o assistente Create role (Criar função). O assistente anexa automaticamente as políticas `CloudWatchEventsBuiltInTargetExecutionAccess` e `CloudWatchEventsInvocationAccess`.

c. Anexe a política em linha a seguir à função. Esta política permite que o produto EventBridge direcione eventos para o AWS Glue.

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:notifyEvent"
      ],
      "Resource": [
        "arn:aws:glue:<region>:<account-id>:workflow/<workflow-name>"
      ]
    }
  ]
}
```

3. Insira o comando a seguir para criar o fluxo de trabalho.

   Consulte criar fluxo de trabalho na Referência de comandos da AWS CLI para obter informações sobre mais parâmetros opcionais da linha de comando.

```
aws glue create-workflow --name <workflow-name>
```

4. Insira o seguinte comando para criar um acionador de evento do EventBridge para o fluxo de trabalho. Este será o acionador inicial para o fluxo de trabalho. Substitua *<actions>* pelas ações a serem executadas (os trabalhos e os crawlers a serem iniciados).

   Consulte criar trigger na Referência de comandos da AWS CLI para obter informações sobre como codificar o argumento `actions`.

```
aws glue create-trigger --workflow-name <workflow-name> --type EVENT --
name <trigger-name> --actions <actions>
```

Se desejar que o fluxo de trabalho seja acionado por um lote de eventos em vez de um único evento do EventBridge, insira o seguinte comando.

```
aws glue create-trigger --workflow-name <workflow-name> --type EVENT
 --name <trigger-name> --event-batching-condition BatchSize=<number-of-
events>,BatchWindow=<seconds> --actions <actions>
```

Para o argumento `event-batching-condition`, `BatchSize` é necessário e `BatchWindow` é opcional. Se `BatchWindow` for omitido, o padrão da janela será 900 segundos, que é a duração máxima da janela.

Example

O exemplo a seguir cria um acionador que inicia o fluxo de trabalho `eventtest` após a chegada de três eventos do EventBridge ou cinco minutos após a chegada do primeiro evento, o que ocorrer primeiro.

```
aws glue create-trigger --workflow-name eventtest --type EVENT --name objectArrival
 --event-batching-condition BatchSize=3,BatchWindow=300 --actions JobName=test1
```

5. Crie uma regra no Amazon EventBridge.

   a. Crie o objeto JSON para os detalhes da regra no editor de texto de sua preferência.

      O exemplo a seguir especifica o Amazon S3 como a origem do evento, `PutObject` como o nome do evento e o nome do bucket como um parâmetro de solicitação. Essa regra inicia um fluxo de trabalho quando um novo objeto chega ao bucket.

```
{
  "source": [
    "aws.s3"
  ],
  "detail-type": [
    "AWS API Call via CloudTrail"
  ],
  "detail": {
    "eventSource": [
      "s3.amazonaws.com"
    ],
    "eventName": [
```

```
      "PutObject"
    ],
    "requestParameters": {
      "bucketName": [
        "<bucket-name>"
      ]
    }
  }
}
```

Para iniciar o fluxo de trabalho quando um novo objeto chega a uma pasta dentro do bucket, você pode substituir o seguinte código por `requestParameters`.

```
    "requestParameters": {
      "bucketName": [
        "<bucket-name>"
      ]
      "key" : [{ "prefix" : "<folder1>/<folder2>/*"}}]
  }
```

b. Use sua ferramenta preferida para converter o objeto JSON de regra em uma string de escape.

```
{\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}
```

c. Execute o seguinte comando para criar um modelo de parâmetro JSON que você pode editar para especificar parâmetros de entrada para um comando `put-rule`. Salve a saída em um arquivo. Para este exemplo, o arquivo é chamado `ruleCommand`.

```
aws events put-rule --name <rule-name> --generate-cli-skeleton >ruleCommand
```

Para obter mais informações sobre o parâmetro `--generate-cli-skeleton`, consulte Gerar um esqueleto da AWS CLI e parâmetros de entrada usando um arquivo de entrada JSON ou YAML no Manual do usuário da interface da AWS Command Line.

O arquivo de saída deve ser como o a seguir.

```
{
    "Name": "",
    "ScheduleExpression": "",
    "EventPattern": "",
    "State": "ENABLED",
    "Description": "",
    "RoleArn": "",
    "Tags": [
        {
            "Key": "",
            "Value": ""
        }
    ],
    "EventBusName": ""
}
```

d. Edite o arquivo para opcionalmente remover parâmetros e especificar, no mínimo, os parâmetros `Name`, `EventPattern` e `State`. Para o parâmetro `EventPattern`, forneça a string de escape para os detalhes da regra que você criou em uma etapa anterior.

```
{
    "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**
>
> É melhor deixar a regra desabilitada até terminar de criar o fluxo de trabalho.

e. Insira o seguinte comando `put-rule`, que lê os parâmetros de entrada do arquivo `ruleCommand`.

```
aws events put-rule --name <rule-name> --cli-input-json file://ruleCommand
```

A seguinte saída indica sucesso.

```
{
    "RuleArn": "<rule-arn>"
}
```

6. Insira o comando a seguir para anexar a regra a um destino. O destino é o fluxo de trabalho no AWS Glue. Substitua *<role-name>* pela função criada por você no início deste procedimento.

```
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>
```

A seguinte saída indica sucesso.

```
{
    "FailedEntryCount": 0,
    "FailedEntries": []
}
```

7. Confirme a conexão bem-sucedida da regra e do destino inserindo o seguinte comando.

```
aws events list-rule-names-by-target --target-arn arn:aws:glue:<region>:<account-
id>:workflow/<workflow-name>
```

A seguinte saída indica sucesso, em que *<rule-name>* é o nome da regra que você criou.

```
{
    "RuleNames": [
        "<rule-name>"
    ]
}
```

8. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

9. Selecione o fluxo de trabalho e verifique se o acionador inicial e suas ações, os trabalhos ou crawlers que ele inicia, aparecem no gráfico do fluxo de trabalho. Em seguida, vá para o procedimento em Etapa 3: adicionar mais acionadores. Ou adicione mais componentes ao fluxo de trabalho usando a API do AWS Glue ou AWS Command Line Interface.

10. Quando o fluxo de trabalho estiver completamente especificado, habilite a regra.

```
aws events enable-rule --name <rule-name>
```

O fluxo de trabalho agora está pronto para ser iniciado por um evento do EventBridge ou lote de eventos.

Consulte também

- Manual do usuário do Amazon EventBridge
- Visão geral de fluxos de trabalho no AWS Glue
- Criar e desenvolver um fluxo de trabalho manualmente no AWS Glue

Visualizar os eventos do EventBridge que iniciaram um fluxo de trabalho

Você pode visualizar o ID do evento do Amazon EventBridge que iniciou seu fluxo de trabalho. Se o fluxo de trabalho foi iniciado por um lote de eventos, você pode exibir os IDs de evento de todos os eventos no lote.

Para fluxos de trabalho com um tamanho de lote maior que um, você também pode ver qual condição de lote iniciou o fluxo de trabalho: a chegada do número de eventos no tamanho do lote ou a validade da janela do lote.

Para exibir os eventos do EventBridge que iniciaram um fluxo de trabalho (console)

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Workflows (Fluxos de trabalho).
3. Selecione o fluxo de trabalho. Em seguida, na parte inferior, escolha a guia History (Histórico).
4. Selecione uma execução de fluxo de trabalho e escolha View run details (Visualizar detalhes da execução).
5. Na página de detalhes da execução, localize o campo Run properties (Propriedades de execução) e procure a chave aws:eventIds.

   O valor dessa chave é uma lista de IDs de eventos do EventBridge.

Para exibir os eventos do EventBridge que iniciaram um fluxo de trabalho (API da AWS)

- Inclua o seguinte código em seu 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` será uma lista de strings, em que cada string é um ID de evento.

> Consulte também
>
> - Manual do usuário do Amazon EventBridge
> - the section called “Visão geral de fluxos de trabalho”

Executar e monitorar um fluxo de trabalho no AWS Glue

Se o gatilho de início de um fluxo de trabalho for um gatilho sob demanda, será possível iniciar o fluxo de trabalho no console do AWS Glue. Conclua as etapas a seguir para executar e monitorar um fluxo de trabalho. Se o fluxo de trabalho falhar, é possível visualizar o gráfico de execução para determinar o nó que falhou. Para ajudar a solucionar problemas, se o fluxo de trabalho tiver sido criado de um blueprint, você poderá exibir a execução do blueprint para ver os valores dos parâmetros do blueprint usados para criar o fluxo de trabalho. Para ter mais informações, consulte the section called “Visualizar execuções de esquemas”.

Você executar e monitorar um fluxo de trabalho usando o console do AWS Glue, API ou o AWS Command Line Interface (AWS CLI).

Para executar e monitorar um fluxo de trabalho (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em ETL, selecione Workflows (Fluxos de trabalho).
3. Selecione um fluxo de trabalho. No menu Actions (Ações), selecione Run (Executar).
4. Confira a coluna Last run status (Status da última execução) na lista de fluxos de trabalho. Escolha o botão de atualização para exibir o status do fluxo de trabalho em andamento.

5. Enquanto o fluxo de trabalho estiver em execução, ou após a conclusão (ou falha), visualize os detalhes da execução concluindo as etapas a seguir.

   a. Certifique-se de que o fluxo de trabalho esteja selecionado e escolha a guia History (Histórico).

   b. Escolha a execução do fluxo de trabalho atual ou mais recente e escolha View run details (Visualizar detalhes da execução).

      O gráfico de runtime do fluxo de trabalho mostra o status de execução atual.

   c. Escolha qualquer nó no gráfico para exibir os detalhes e status dele.

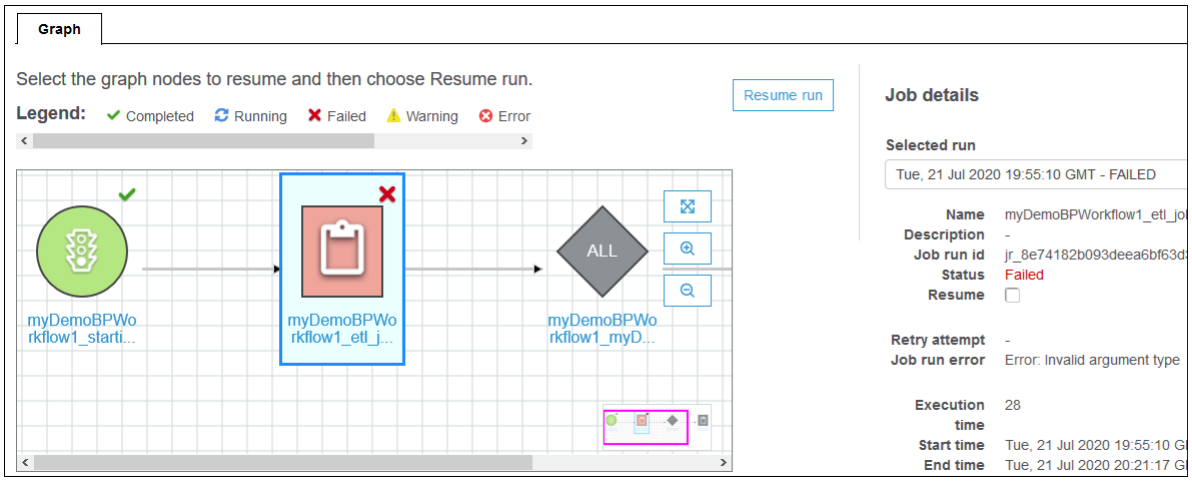

Para executar e monitorar um fluxo de trabalho (AWS CLI)

1. Insira o comando da a seguir. Substitua *<workflow-name>* pelo fluxo de trabalho a ser executado.

```
aws glue start-workflow-run --name <workflow-name>
```

   Se o fluxo de trabalho for iniciado com êxito, o comando retornará o ID de execução.

2. Visualize o status de execução do fluxo de trabalho usando o comando `get-workflow-run`. Forneça o nome do fluxo de trabalho e o ID de execução.

```
aws glue get-workflow-run --name myWorkflow --run-id
 wr_d2af14217e8eae775ba7b1fc6fc7a42c795aed3cbcd8763f9415452e2dbc8705
```

   Este é um exemplo de saída de comando.

```
{
    "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
        }
    }
}
```


Consulte também:

- the section called “Visão geral de fluxos de trabalho”
- the section called “Visão geral dos esquemas”

Interromper uma execução de fluxo de trabalho

É possível usar o console do AWS Glue, a AWS Command Line Interface (AWS CLI) ou a API do AWS Glue para interromper uma execução de fluxo de trabalho. Quando você interrompe uma execução de fluxo de trabalho, todos os crawlers e os trabalhos em execução são imediatamente encerrados, e os que ainda não foram iniciados nunca serão. Pode levar até um minuto para que todos os crawlers e os trabalhos em execução sejam interrompidos. O status de execução do fluxo

de trabalho passa de Em execução para Interrompendo e, quando a execução do fluxo de trabalho é completamente interrompida, o status passa para Interrompido.

Depois que a execução do fluxo de trabalho é interrompida, é possível visualizar o gráfico de execução para saber quais trabalhos e crawlers foram concluídos e quais nunca começaram. Assim, você pode determinar se é necessário executar alguma etapa para garantir a integridade dos dados. Interromper uma execução de fluxo de trabalho faz com que nenhuma operação de reversão automática seja executada.

Como interromper uma execução de fluxo de trabalho (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, em ETL, selecione Workflows (Fluxos de trabalho).
3. Escolha um fluxo de trabalho em execução e selecione a guia Histórico.
4. Escolha a execução do fluxo de trabalho e selecione Interromper execução.

   O status da execução muda para Interrompendo.
5. (Opcional) Escolha a execução do fluxo de trabalho, selecione Visualizar detalhes da execução e revise o gráfico de execução.

Como interromper uma execução de fluxo de trabalho (AWS CLI)

- Insira o comando da a seguir. Substitua *<workflow-name>* pelo nome do fluxo de trabalho e *<run-id>* pelo ID da execução do fluxo de trabalho a ser interrompida.

  ```
  aws glue stop-workflow-run --name <workflow-name> --run-id <run-id>
  ```

  Veja a seguir um exemplo do comando stop-workflow-run.

  ```
  aws glue stop-workflow-run --name my-workflow --run-id
   wr_137b88917411d128081069901e4a80595d97f719282094b7f271d09576770354
  ```

Reparar e retomar uma execução de fluxo de trabalho

Se um ou mais nós (trabalhos ou crawlers) em um fluxo de trabalho não forem concluídos com êxito, isso significa que o fluxo de trabalho foi executado apenas parcialmente. Depois de localizar as causas raiz e fazer correções, você pode selecionar um ou mais nós de onde retomar a execução do

fluxo de trabalho e, em seguida, retomá-la. Os nós selecionados e todos os nós que estão a jusante desses nós são então executados.

Tópicos

- Retomar uma execução de fluxo de trabalho: como funciona
- Retomar uma execução de fluxo de trabalho
- Observações e limitações para retomar execuções de fluxo de trabalho

Retomar uma execução de fluxo de trabalho: como funciona

Considere o fluxo de trabalho W1 no diagrama a seguir.

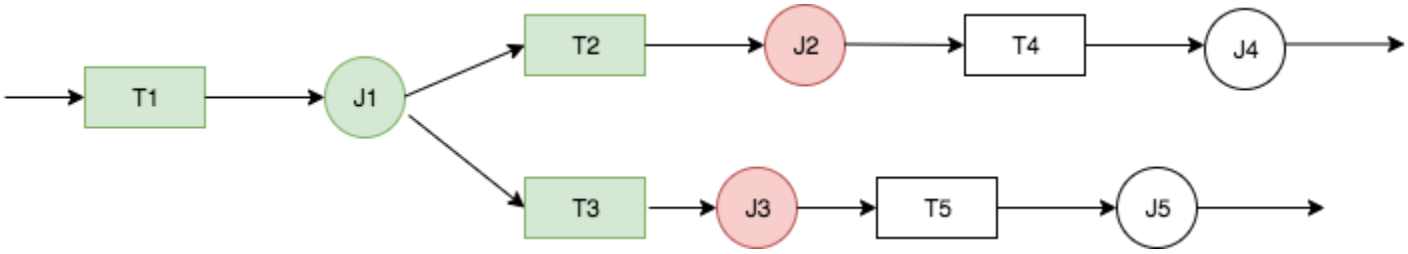

A execução do fluxo de trabalho prossegue da seguinte forma:

1. O acionador T1 inicia o trabalho J1.
2. A conclusão bem-sucedida de J1 aciona T2 e T3, que executam os trabalhos J2 e J3, respectivamente.
3. Os trabalhos J2 e J3 falham.
4. Os acionadores T4 e T5 dependem da conclusão bem-sucedida de J2 e J3, então eles não disparam, e os trabalhos J4 e J5 não são executados. O fluxo de trabalho W1 é executado apenas parcialmente.

Agora, suponha que os problemas que causaram a falha de J2 e J3 sejam corrigidos. J2 e J3 são selecionados como os pontos de partida para retomar a execução do fluxo de trabalho.

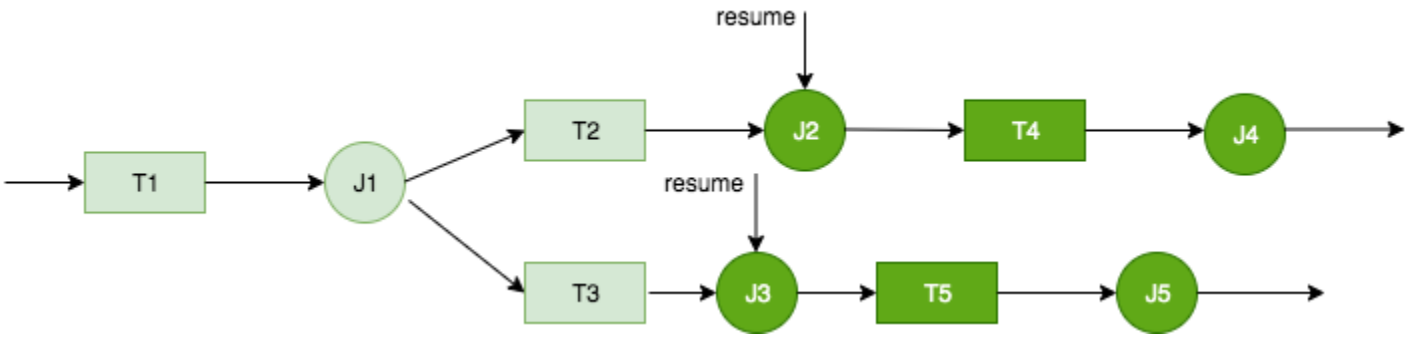

A execução do fluxo de trabalho é retomada da seguinte forma:

1. Os trabalhos J2 e J3 são executados com êxito.
2. Os acionadores T4 e T5 disparam.
3. Os trabalhos J4 e J5 são executados com êxito.

A execução do fluxo de trabalho retomado é rastreada como uma execução de fluxo de trabalho separada com um novo ID de execução. Ao exibir o histórico do fluxo de trabalho, você pode exibir o ID de execução anterior para qualquer execução do fluxo de trabalho. No exemplo na captura de tela a seguir, o fluxo de trabalho executado com o ID de execução `wr_c7a22...` (a segunda linha) tinha um nó que não foi concluído. O usuário corrigiu o problema e retomou a execução do fluxo de trabalho, o que resultou no ID de execução `wr_a07e55...` (a primeira linha).

> **Note**
>
> Para o resto desta discussão, o termo “execução do fluxo de trabalho retomado” refere-se à execução do fluxo de trabalho que foi criada quando a execução do fluxo de trabalho anterior foi retomada. A “execução do fluxo de trabalho original” refere-se à execução do fluxo de trabalho que foi executada apenas parcialmente e que precisava ser retomada.

Grafo de execução de fluxo de trabalho retomada

Em uma execução de fluxo de trabalho retomada, embora apenas um subconjunto de nós seja executado, o gráfico de execução é um gráfico completo. Ou seja, os nós que não foram executados no fluxo de trabalho retomado são copiados do gráfico de execução da execução do fluxo de trabalho original. Os nós de trabalho e crawler copiados executados na execução do fluxo de trabalho original incluem os detalhes da execução.

Considere novamente o fluxo de trabalho W1 no diagrama anterior. Quando a execução do fluxo de trabalho é retomada começando com J2 e J3, o gráfico para a execução do fluxo de trabalho retomado mostra todos os trabalhos, J1 a J5, e todos os acionadores, T1 a T5. Os detalhes da execução para J1 são copiados da execução do fluxo de trabalho original.

Snapshots da execução do fluxo de trabalho

Quando uma execução de fluxo de trabalho é iniciada, o AWS Glue tira um snapshot do gráfico de design do fluxo de trabalho naquele ponto no tempo. Esse snapshot é usado durante a execução do fluxo de trabalho. Se você fizer alterações em quaisquer acionadores após o início da execução, essas alterações não afetarão a execução do fluxo de trabalho atual. Os snapshots garantem que as execuções do fluxo de trabalho prossigam de maneira consistente.

Os snapshots tornam apenas os acionadores imutáveis. As alterações feitas em trabalhos e crawlers a jusante durante a execução do fluxo de trabalho entram em vigor para a execução atual.

Retomar uma execução de fluxo de trabalho

Siga estas etapas para retomar uma execução de fluxo de trabalho. Você pode retomar uma execução de fluxo de trabalho usando o console do AWS Glue, a API ou o AWS Command Line Interface (AWS CLI).

Como retomar a execução de um fluxo de trabalho (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

   Faça login como um usuário que tem permissões para exibir fluxos de trabalho e retomar execuções de fluxo de trabalho.

   > **Note**
   >
   > Para retomar execuções de fluxo de trabalho, você precisa da permissão `glue:ResumeWorkflowRun` do AWS Identity and Access Management (IAM).

2. No painel de navegação, escolha Workflows (Fluxos de trabalho).

3. Selecione um fluxo de trabalho e escolha a guia History (Histórico).
4. Selecione a execução do fluxo de trabalho que foi executada apenas parcialmente e escolha View run details (Visualizar detalhes da execução).
5. No gráfico de execução, selecione o primeiro (ou único) nó que deseja reiniciar e do qual deseja retomar a execução do fluxo de trabalho.
6. No painel de detalhes à direita do gráfico, selecione a caixa de seleção Resume (Retomar).

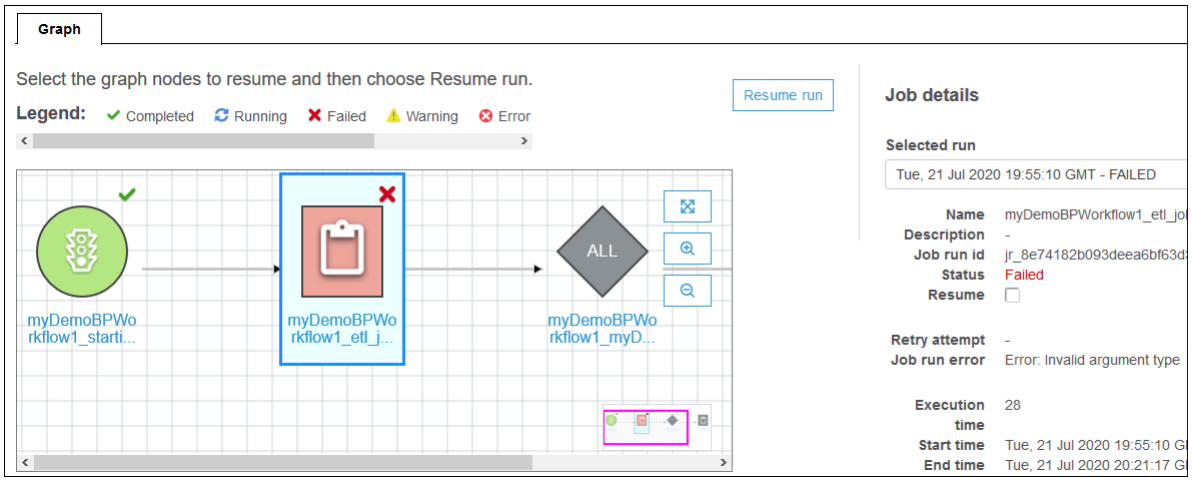

O nó muda de cor e mostra um pequeno ícone de retomada no canto superior direito.

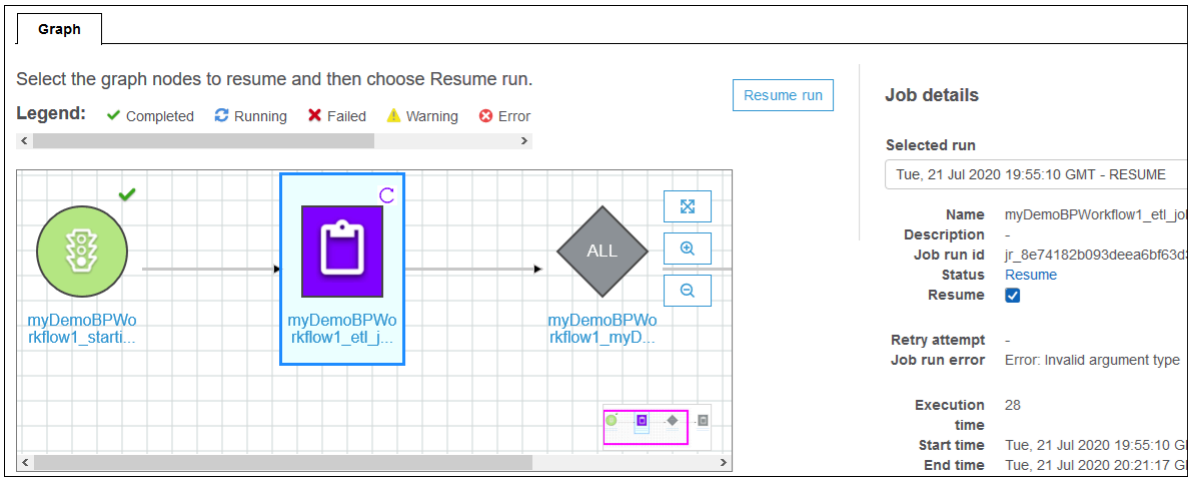

7. Conclua as duas etapas anteriores para que todos os nós adicionais reiniciem.
8. Selecione Resume run (Retomar execução).

Para retomar a execução de um fluxo de trabalho (AWS CLI)

1. Verifique se você tem a permissão `glue:ResumeWorkflowRun` do IAM.
2. Recupere os IDs de nós dos nós que você deseja reiniciar.

a. Execute o comando `get-workflow-run` para a execução do fluxo de trabalho original. Forneça o nome do fluxo de trabalho e o ID de execução, e adicione a opção `--include-graph`, conforme mostrado no exemplo a seguir. Obtenha o ID de execução na guia History (Histórico) no console, ou executando o comando `get-workflow`.

```
aws glue get-workflow-run --name cloudtrailtest1 --run-id
 wr_a07e55f2087afdd415a404403f644a4265278f68b13ba3da08c71924ebe3c3a8 --include-
graph
```

O comando retorna os nós e as bordas do gráfico como um objeto JSON grande.

b. Localize os nós de interesse pelas propriedades `Type` e `Name` dos objetos de nó.

A seguir, está um exemplo de objeto de nó da saída.

```
{
    "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. Obtenha o ID do nó da propriedade `UniqueId` do objeto de nó.

3. Execute o comando `resume-workflow-run`. Forneça o nome do fluxo de trabalho, o ID da execução e a lista de IDs de nós separados por espaços, conforme mostrado no exemplo a seguir.

```
aws glue resume-workflow-run --name cloudtrailtest1 --run-id
 wr_a07e55f2087afdd415a404403f644a4265278f68b13ba3da08c71924ebe3c3a8 --node-
ids wnode_ca1f63e918fb855e063aed2f42ec5762ccf71b80082ae2eb5daeb8052442f2f3
 wnode_d1b2563c503078b153142ee76ce545fe5ceef66e053628a786ddd74a05da86fd
```

O comando gera o ID de execução do fluxo de trabalho retomado (novo) e uma lista de nós que serão iniciados.

```
{
    "RunId": "wr_2ada0d3209a262fc1156e4291134b3bd643491bcfb0ceead30bd3e4efac24de9",
    "NodeIds": [
        "wnode_ca1f63e918fb855e063aed2f42ec5762ccf71b80082ae2eb5daeb8052442f2f3"
    ]
}
```

Note que, apesar do comando de exemplo `resume-workflow-run` ter listado dois nós para reiniciar, a saída de exemplo indicou que apenas um nó seria reiniciado. Isso ocorre porque um nó estava a jusante do outro, e o nó a jusante seria reiniciado de qualquer maneira pelo fluxo normal do fluxo de trabalho.

Observações e limitações para retomar execuções de fluxo de trabalho

Tenha em mente as seguintes observações e limitações ao retomar as execuções do fluxo de trabalho.

- Você pode retomar uma execução de fluxo de trabalho somente se ele estiver no estado `COMPLETED`.

> **Note**
>
> Mesmo que um ou mais nós em uma execução de fluxo de trabalho não sejam concluídos, o estado de execução do fluxo de trabalho é mostrado como `COMPLETED`. Certifique-se de

verificar o gráfico de execução para descobrir todos os nós que não foram concluídos com êxito.

- Você pode retomar uma execução de fluxo de trabalho de qualquer nó de trabalho ou crawler que a execução do fluxo de trabalho original tenha tentado executar. Não é possível retomar uma execução de fluxo de trabalho de um nó de acionador.
- Reiniciar um nó não redefine seu estado. Todos os dados que foram parcialmente processados não são revertidos.
- Você pode retomar a mesma execução de fluxo de trabalho várias vezes. Se um fluxo de trabalho retomado for executado apenas parcialmente, você poderá resolver o problema e retomar a execução retomada.
- Se você selecionar dois nós a serem reiniciados e eles dependerem um do outro, o nó a montante será executado antes do nó a jusante. Na verdade, selecionar o nó a montante é redundante, pois ele será executado de acordo com o fluxo normal do fluxo de trabalho.

Obter e configurar as propriedades de execução de fluxo de trabalho no AWS Glue

Use as propriedades da execução de fluxo de trabalho para compartilhar e gerenciar o estado entre os trabalhos no seu fluxo de trabalho do AWS Glue. Você pode definir as propriedades padrão da execução quando criar o fluxo de trabalho. Depois, enquanto os trabalhos são executados, eles podem recuperar os valores de propriedade da execução e, opcionalmente, modificá-los para a entrada de trabalhos que estarão no fluxo de trabalho mais tarde. Quando um trabalho modifica uma propriedade da execução, o novo valor existe somente para a execução do fluxo de trabalho. As propriedades de execução padrão não são afetadas.

Se sua tarefa do AWS Glue não fizer parte de um fluxo de trabalho, essas propriedades não serão definidas.

O seguinte exemplo de código Python de um trabalho de extração, transformação e carregamento (ETL) demonstra como obter as propriedades da execução do fluxo de trabalho.

```
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']
```

O código a seguir continua definindo a propriedade da execução `target_format` como `'csv'`.

```
workflow_params['target_format'] = 'csv'
glue_client.put_workflow_run_properties(Name=workflow_name, RunId=workflow_run_id,
 RunProperties=workflow_params)
```

Para obter mais informações, consulte as informações a seguir.

- Ação GetWorkflowRunProperties (Python: get_workflow_run_properties)
- Ação PutWorkflowRunProperties (Python: put_workflow_run_properties)

Consultar fluxos de trabalho usando o AWS Glue API

O AWS Glue fornece uma API avançada para gerenciar fluxos de trabalho. É possível recuperar uma visualização estática do fluxo de trabalho ou uma visualização dinâmica de um fluxo de trabalho em execução usando o AWS Glue API. Para ter mais informações, consulte Fluxos de trabalho.

Tópicos

- Consultar visualizações estáticas
- Consultar visualizações dinâmicas

Consultar visualizações estáticas

Use a operação de API `GetWorkflow` para obter uma visualização estática que indica o design de um fluxo de trabalho. Essa operação retorna um gráfico direcionado que consiste em nós e bordas, onde um nó representa um gatilho, uma tarefa ou um crawler. As bordas definem as relações entre os nós. Eles são representados por conectores (setas) no gráfico no console do AWS Glue.

Também é possível usar essa operação com bibliotecas populares de processamento de gráficos, como NetworkX, igraph, JGraphT e a Java Universal Network/Graph (JUNG) Framework. Como todas essas bibliotecas representam gráficos de forma semelhante, são necessárias transformações mínimas.

A visualização estática retornada por essa API é a visualização mais atualizada de acordo com a definição mais recente de gatilhos associados ao fluxo de trabalho.

Definição do grafo

Um gráfico do fluxo de trabalho G é um par ordenado (N, E), onde N é um conjunto de nós e E, um conjunto de bordas. O nó é um vértice no gráfico identificado por um número exclusivo. Um nó pode ser do tipo acionador, de trabalho ou crawler. Por exemplo: `{name:T1, type:Trigger, uniqueId:1}, {name:J1, type:Job, uniqueId:2}`.

A borda é uma tupla de pares do formulário (`src, dest`), onde `src` e `dest` são nós e há uma borda direcionada de `src` para `dest`.

Exemplo de como consultar uma visualização estática

Considere um gatilho condicional T, que aciona a tarefa J2 após a conclusão da tarefa J1.

```
J1 ---> T ---> J2
```

Nós: J1, T, J2

Bordas: (J1, T), (T, J2)

Consultar visualizações dinâmicas

Use a operação de API `GetWorkflowRun` para obter uma visualização dinâmica de um fluxo de trabalho em execução. Essa operação retorna a mesma visualização estática do gráfico com os metadados relacionados à execução do fluxo de trabalho.

Para a execução, nós que representam trabalhos na chamada `GetWorkflowRun` têm uma lista de execuções de trabalhos iniciadas como parte da última execução do fluxo de trabalho. É possível usar essa lista para exibir o status de execução de cada tarefa no próprio gráfico. Para dependências downstream que ainda não foram executadas, esse campo é definido como `null`. As informações no gráfico deixam você ciente do estado atual de qualquer fluxo de trabalho em determinado momento.

A visualização dinâmica retornada por essa API é baseada na visualização estática que estava presente quando a execução do fluxo de trabalho foi iniciada.

Exemplo de nós de runtime: `{name:T1, type: Trigger, uniqueId:1}`, `{name:J1, type:Job, uniqueId:2, jobDetails:{jobRuns}}`, `{name:C1, type:Crawler, uniqueId:3, crawlerDetails:{crawls}}`

Exemplo 1: visualização dinâmica

O exemplo a seguir ilustra um fluxo de trabalho simples de dois gatilhos.

- Nós: t1, j1, t2, j2
- Bordas: (t1, j1), (j1, t2), (t2, j2)

A resposta `GetWorkflow` contém o seguinte.

```
{
    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
        }
}
```

A resposta `GetWorkflowRun` contém o seguinte.

```
{
    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
        }
}
```

Exemplo 2: vários trabalhos com um acionador condicional

O exemplo a seguir mostra um fluxo de trabalho com várias tarefas e um gatilho condicional (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)
```

Restrições de esquema e fluxo de trabalho no AWS Glue

Veja a seguir as restrições de blueprint e fluxos de trabalho.

Restrições de esquema

Tenha em mente as seguintes restrições de blueprint:

- O blueprint deve ser registrado na mesma região da AWS em que reside o bucket do Amazon S3.
- Para compartilhar blueprints entre contas da AWS, você deve conceder as permissões de leitura no arquivo ZIP do blueprint no Amazon S3. Os clientes que tiverem permissão de leitura em um arquivo ZIP de blueprint podem registrar o blueprint em suas contas da AWS e usá-lo.
- O conjunto de parâmetros do blueprint é armazenado como um único objeto JSON. O comprimento máximo deste objeto é de 128 KB.
- O tamanho máximo do arquivo ZIP do blueprint descompactado é de 5 MB. O tamanho máximo compactado é de 1 MB.
- Limite o número total de trabalhos, crawlers e acionadores em um fluxo de trabalho a 100 ou menos. Se você incluir mais de 100, poderá receber erros ao tentar retomar ou interromper as execuções do fluxo de trabalho.

Restrições do fluxo de trabalho

Tenha em mente as seguintes restrições do fluxo de trabalho: Alguns desses comentários são mais direcionados a um usuário que esteja criando fluxos de trabalho manualmente.

- O tamanho máximo do lote para um acionador de evento do Amazon EventBridge é 100. O valor máximo da janela é 900 segundos (15 minutos).
- Um gatilho pode ser associado a somente um fluxo de trabalho.
- Somente um gatilho de início (sob demanda ou programação) é permitido.
- Se um trabalho ou crawler em um fluxo de trabalho for iniciado por um gatilho que está fora do fluxo de trabalho, nenhum gatilho interno do fluxo de trabalho que depender da conclusão do trabalho ou do crawler (com êxito ou não) será acionado.
- Da mesma forma, se um trabalho ou crawler em um fluxo de trabalho tiver acionadores que dependam da conclusão do trabalho ou do crawler (com êxito ou não), tanto dentro quanto fora do

fluxo de trabalho, e se o trabalho ou o crawler for iniciado dentro de um fluxo de trabalho, somente os acionadores internos desse fluxo de trabalho serão acionados após a conclusão do trabalho ou do crawler.

Solucionar erros de esquema no AWS Glue

Se você encontrar erros ao usar blueprints do AWS Glue, utilize as seguintes soluções para ajudar a encontrar a fonte dos problemas e corrigi-los.

Tópicos

- Erro: módulo PySpark ausente
- Erro: arquivo de configuração do blueprint ausente
- Erro: arquivo importado ausente
- Error: not authorized to perform iamPassRole on resource (Erro: não autorizado a executar iamPassRole no recurso)
- Erro: programação cron. inválida
- Erro: já existe um acionador com o mesmo nome
- Erro: workflow with name: foo already exists (o fluxo de trabalho com nome: foo já existe).
- Erro: módulo não encontrado no caminho layoutGenerator especificado
- Erro: erro de validação no campo Connections (Conexões)

Erro: módulo PySpark ausente

O AWS Glue retorna o erro “Unknown error executing layout generator function ModuleNotFoundError: No module named ‘pyspark’” (Erro desconhecido ao executar a função do gerador de layout ModuleNotFounderror: nenhum módulo chamado “pyspark”).

Ao descompactar o arquivo de blueprint, ele pode ser como um dos seguintes:

```
$ 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
```

No primeiro caso, todos os arquivos relacionados ao blueprint foram colocados em uma pasta chamada compactação e foi então convertido em um arquivo zip chamado compaction.zip.

No segundo caso, todos os arquivos necessários para o blueprint não foram incluídos em uma pasta e foram adicionados como arquivos raiz no arquivo zip compaction.zip.

Criar um arquivo em qualquer um dos formatos acima é permitido. No entanto, certifique-se de que `blueprint.cfg` tenha o caminho correto para o nome da função no script que gera o layout.

Exemplos

No caso 1: `blueprint.cfg` deve ter `layoutGenerator` como o seguinte:

```
layoutGenerator": "compaction.layout.generate_layout"
```

No caso 2: `blueprint.cfg` deve ter `layoutGenerator` como o seguinte:

```
layoutGenerator": "layout.generate_layout"
```

Se esse caminho não estiver incluído corretamente, você poderá ver um erro conforme indicado. Por exemplo, se tiver a estrutura de pastas conforme mencionado no caso 2 e tiver `layoutGenerator` indicado como no caso 1, você poderá ver o erro acima.

Erro: arquivo de configuração do blueprint ausente

O AWS Glue retorna o erro “Unknown error executing layout generator function FileNotFoundError: [Errno 2] No such file or directory: ‘/tmp/compaction/blueprint.cfg’” (Erro desconhecido executando a função do gerador de layout FileNotFoundError: [Errno 2] Nenhum arquivo ou diretório: “/tmp/compaction/blueprint.cfg”).

O blueprint.cfg deve ser colocado no nível raiz do arquivo ZIP ou dentro de uma pasta que tenha o mesmo nome que o arquivo ZIP.

Quando extraímos o arquivo ZIP do blueprint, blueprint.cfg deve ser encontrado em um dos seguintes caminhos. Se não for encontrado em um dos seguintes caminhos, você poderá ver o erro acima.

```
$ unzip compaction.zip
Archive:  compaction.zip
   creating: compaction/
  inflating: compaction/blueprint.cfg

$ unzip compaction.zip
Archive:  compaction.zip
  inflating: blueprint.cfg
```

Erro: arquivo importado ausente

O AWS Glue retorna o erro “Unknown error executing layout generator function FileNotFoundError: [Errno 2] No such file or directory: ‘demo-project/foo.py’” (Erro desconhecido executando a função do gerador de layout FileNotFoundError: [Errno 2] Nenhum arquivo ou diretório: “demo-project/foo.py”).

Se o script de geração de layout tiver funcionalidade para ler outros arquivos, certifique-se de fornecer um caminho completo para que o arquivo seja importado. Por exemplo, o script Conversion.py pode ser referenciado em Layout.py. Para obter mais informações, consulte Projeto de esquema de exemplo.

Error: not authorized to perform iamPassRole on resource (Erro: não autorizado a executar iamPassRole no recurso)

O AWS Glue retorna o erro “User: arn:aws:sts:: 123456789012:Assumed-Role/AWSGlueservicerole/Gluesession is not authorized to perform: iam:PassRole on resource: arn:aws:iam:: 123456789012:Role/AWSGlueservicerole” (Usuário: arn:aws:sts:: 123456789012:Assumed-Role/AWSGlueservicerole/Gluesession não está autorizado a realizar: iam:PassRole no recurso: arn:aws:iam:: 123456789012:Role/AWSGlueservicerole)

Se os trabalhos e os crawlers no fluxo de trabalho assumirem a mesma função que aquela passada para criar o fluxo de trabalho do blueprint, a função do blueprint precisará incluir a permissão `iam:PassRole` em si mesma.

Se os trabalhos e os crawlers no fluxo de trabalho assumirem uma função diferente da função passada para criar as entidades do fluxo de trabalho do blueprint, a função do blueprint precisará incluir a propriedade `iam:PassRole` nessa outra função em vez de na função do blueprint.

Para obter mais informações, consulte Permissões para perfis de esquema.

Erro: programação cron. inválida

O AWS Glue retorna o erro “The schedule cron(0 0 * * * *) is invalid” (A programação cron(0 0 * * * *) é inválida).

Forneça uma expressão cron. válida. Para obter mais informações, consulte Programações baseadas em hora para tarefas e crawlers.

Erro: já existe um acionador com o mesmo nome

O AWS Glue retorna o erro “Trigger with name 'foo_starting_trigger' already submitted with different configuration” (Acionador com o nome ‘foo_starting_trigger’ já enviado com configuração diferente).

Um blueprint não exige que você defina acionadores no script de layout para a criação do fluxo de trabalho. A criação do acionador é gerenciada pela biblioteca do blueprint com base nas dependências definidas entre duas ações.

A nomeação para os acionadores é a seguinte:

- Para o acionador inicial no fluxo de trabalho, a nomeação é <workflow_name>_starting_trigger.
- Para um nó (trabalho/crawler) no fluxo de trabalho que depende da conclusão de um ou vários nós upstream, o AWS Glue define um acionador com o nome <workflow_name>_<node_name>_trigger

Este erro significa que já existe um acionador com o mesmo nome. Você pode excluir o acionador existente e executar novamente a criação do fluxo de trabalho.

> **Note**
>
> Excluir um fluxo de trabalho não exclui os nós dentro do fluxo de trabalho. É possível que, embora o fluxo de trabalho seja excluído, os acionadores sejam deixados para trás. Devido a isso, você pode não receber um erro “workflow already exists” (o fluxo de trabalho já existe), mas você pode receber um erro “trigger already exists” (o acionador já existe) em um caso em que você cria um fluxo de trabalho, exclui e, em seguida, tenta recriá-lo com o mesmo nome do mesmo blueprint.

Erro: workflow with name: foo already exists (o fluxo de trabalho com nome: foo já existe).

O nome do fluxo de trabalho deve ser exclusivo. Tente com outro nome.

Erro: módulo não encontrado no caminho layoutGenerator especificado

O AWS Glue retorna o erro “Unknown error executing layout generator function ModuleNotFoundError: No module named ‘crawl_s3_locations’” (Erro desconhecido ao executar a função do gerador de layout ModuleNotFounderror: nenhum módulo chamado “crawl_s3_locations”).

```
layoutGenerator": "crawl_s3_locations.layout.generate_layout"
```

Por exemplo, se você tiver o caminho layoutGenerator acima, quando descompactar o arquivo de blueprint, ele precisará se parecer com o seguinte:

```
$ 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
```

Ao descompactar o arquivo, se o arquivo de blueprint se parecer com o seguinte, então você poderá obter o erro acima.

```
$ unzip crawl_s3_locations.zip
Archive:  crawl_s3_locations.zip
  inflating: blueprint.cfg
  inflating: layout.py
  inflating: README.md
```

Você pode ver que não há nenhuma pasta chamada `crawl_s3_locations` e, quando o caminho `layoutGenerator` refere-se ao arquivo de layout por meio do módulo `crawl_s3_locations`, você pode obter o erro acima.

Erro: erro de validação no campo Connections (Conexões)

O AWS Glue retorna o erro “Unknown error executing layout generator function TypeError: Value ['foo'] for key Connections should be of type <class 'dict'>!” (Erro desconhecido ao executar a função do gerador de layout TypeError: Valor ['foo'] para chave Conexões deve ser do tipo <class 'dict'>!).

Este é um erro de validação. O campo `Connections` na classe `Job` está esperando um dicionário e, em vez disso, uma lista de valores é fornecida, causando o erro.

```
User input was list of values
Connections= ['string']

Should be a dict like the following
Connections*=*{'Connections': ['string']}
```

Para evitar esses erros de runtime ao criar um fluxo de trabalho de um esquema, você pode validar as definições de fluxo de trabalho, trabalho e crawler, conforme descrito em Testar um esquema.

Consulte a sintaxe na Referência de classes de esquema do AWS Glue para definir o trabalho, crawler e fluxo de trabalho do AWS Glue no script de layout.

Permissões para pessoas e funções de esquemas do AWS Glue

A seguir estão as pessoas típicas e as políticas de permissões do AWS Identity and Access Management (IAM) sugeridas para pessoas e funções para os esquemas do AWS Glue.

Tópicos

- Pessoas de esquemas
- Permissões para pessoas de esquemas
- Permissões para perfis de esquema

Pessoas de esquemas

A seguir estão as pessoas normalmente envolvidas no ciclo de vida dos esquemas do AWS Glue.

Pessoa	Descrição
Desenvolvedor do AWS Glue	Desenvolve, testa e publica blueprints.

Pessoa	Descrição
Administrador da AWS Glue	Regista, mantém e concede permissões em blueprints.
Analista de dados	Executa blueprints para criar fluxos de trabalho.

Para ter mais informações, consulte the section called “Visão geral dos esquemas”.

Permissões para pessoas de esquemas

A seguir estão as permissões sugeridas para cada pessoa do blueprint.

Permissões de desenvolvedor do AWS Glue para esquemas

O desenvolvedor do AWS Glue deve ter permissões de gravação no bucket do Amazon S3 usado para publicar o esquema. Muitas vezes, o desenvolvedor registra o blueprint depois de carregá-lo. Nesse caso, o desenvolvedor precisa das permissões listadas em the section called “Permissões de administrador do AWS Glue para esquemas”. Além disso, se o desenvolvedor desejar testar o blueprint após seu registro, ele ou ela também precisará das permissões listadas em the section called “Permissões de analista de dados para esquemas”.

Permissões de administrador do AWS Glue para esquemas

A política a seguir concede permissões para registrar, visualizar e manter esquemas do AWS Glue.

> **Important**
>
> Na política a seguir, substitua *<s3-bucket-name>* e *<prefix>* com o caminho do Amazon S3 dos arquivos ZIP de blueprint carregados a serem registrados.

```
{
    "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>/*"
        }
    ]
}
```

Permissões de analista de dados para esquemas

A política a seguir concede permissões para executar blueprints e exibir o fluxo de trabalho resultante e seus componentes. Ela também concede `PassRole` para a função que o AWS Glue assume para criar o fluxo de trabalho resultante e seus componentes.

A política concede permissões em qualquer recurso. Se você deseja configurar o acesso minucioso a blueprints individuais, use o seguinte formato para ARNs de blueprint:

```
arn:aws:glue:<region>:<account-id>:blueprint/<blueprint-name>
```

> **Important**
>
> Na política a seguir, substitua *<account-id>* por uma conta da AWS válida e substitua *<role-name>* pelo nome da função usada para executar um blueprint. Consulte the section called “Permissões para perfis de esquema” para obter as permissões que essa função requer.

```
{
    "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>"
        }
    ]
}
```

Permissões para perfis de esquema

A seguir estão as permissões sugeridas para a função do IAM usada para criar um fluxo de trabalho a partir de um blueprint. A função deve ter uma relação de confiança com o `glue.amazonaws.com`.

> **Important**
>
> Na política a seguir, substitua *<account-id>* por uma conta da AWS válida e substitua *<role-name>* pelo nome da função.

```
{
    "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**
>
> Se os trabalhos e crawlers no fluxo de trabalho assumirem uma função diferente dessa, tal política deverá incluir a permissão `iam:PassRole` nessa outra função, em vez de na função de blueprint.

Desenvolver esquemas no AWS Glue

Sua organização pode ter um conjunto de casos de uso de ETL semelhantes que poderiam se beneficiar da capacidade de parametrizar um único fluxo de trabalho para lidar com todos eles. Para atender a essa necessidade, o AWS Glue permite que você defina esquemas, que você pode usar

para gerar fluxos de trabalho. Um blueprint aceita parâmetros, de modo que, a partir de um único blueprint, um analista de dados possa criar fluxos de trabalho diferentes para lidar com casos de uso de ETL semelhantes. Depois de criar um blueprint, é possível reutilizá-lo em departamentos, equipes e projetos diferentes.

Tópicos

- Visão geral dos esquemas no AWS Glue
- Desenvolver esquemas no AWS Glue
- Registrar um esquema no AWS Glue
- Visualizar esquemas no AWS Glue
- Atualizar um esquema no AWS Glue
- Criar um fluxo de trabalho com base em um esquema no AWS Glue
- Visualizar execuções de esquemas no AWS Glue

Visão geral dos esquemas no AWS Glue

> **Note**
>
> No momento, o recurso de esquemas não está disponível no console do AWS Glue nas seguintes regiões: Ásia-Pacífico (Jacarta) e Oriente Médio (EAU).

Os esquemas do AWS Glue fornecem uma maneira de criar e compartilhar fluxos de trabalho do AWS Glue. Quando há um processo de ETL complexo que poderia ser usado para casos de uso semelhantes, em vez de criar um fluxo de trabalho do AWS Glue para cada caso de uso, você pode criar um único esquema.

O blueprint especifica os trabalhos e crawlers a serem incluídos em um fluxo de trabalho e especifica os parâmetros que o usuário do fluxo fornece ao executar o blueprint para criar um fluxo de trabalho. O uso de parâmetros permite que um único blueprint gere fluxos de trabalho para os vários casos de uso semelhantes. Para obter mais informações sobre fluxos de trabalho, consulte Visão geral de fluxos de trabalho no AWS Glue.

Veja a seguir exemplos de casos de uso de blueprints:

- Você deseja particionar um conjunto de dados existente. Os parâmetros de entrada para o blueprint são caminhos de fonte e de destino do Amazon Simple Storage Service (Amazon S3) e uma lista de colunas de partição.
- Você deseja fazer um snapshot de uma tabela do Amazon DynamoDB em um armazenamento de dados SQL, como o Amazon RedShift. Os parâmetros de entrada para o esquema são o nome da tabela do DynamoDB e uma conexão do AWS Glue, que designa um cluster do Amazon RedShift e um banco de dados de destino.
- Você deseja converter dados em CSV em vários caminhos do Amazon S3 para Parquet. Você deseja que o fluxo de trabalho do AWS Glue inclua um crawler e um trabalho separados para cada caminho. Os parâmetros de entrada são o banco de dados de destino no catálogo de dados do AWS Glue e uma lista delimitada por vírgulas de caminhos do Amazon S3. Observe que nesse caso, o número de crawlers e trabalhos criados pelo fluxo de trabalho é variável.

Componentes do esquema

Um blueprint é um arquivo ZIP que contém os seguintes componentes:

- Um script gerador de layout Python

  Contém uma função que especifica o layout do fluxo de trabalho. Os crawlers e trabalhos a serem criados para o fluxo de trabalho, as propriedades do trabalho e do crawler e as dependências entre eles. A função aceita parâmetros de esquema e retorna uma estrutura de fluxo de trabalho (objeto JSON) que o AWS Glue usa para gerar o fluxo de trabalho. Como você usa um script Python para gerar o fluxo de trabalho, pode adicionar sua própria lógica adequada a seus casos de uso.
- Um arquivo de configuração

  Especifica o nome totalmente qualificado da função Python que gera o layout do fluxo de trabalho. Especifica também os nomes, tipos de dados e outras propriedades de todos os parâmetros do blueprint usados pelo script.
- (Opcional) scripts de ETL e arquivos complementares

  Como um caso de uso avançado, você pode parametrizar a localização dos scripts de ETL que seus trabalhos usam. Você pode incluir arquivos de script de trabalho no arquivo ZIP e especificar um parâmetro de blueprint para um local do Amazon S3 para o qual os scripts devem ser copiados. O script gerador de layout pode copiar os scripts de ETL para o local designado e especificá-lo como a propriedade de local do script do trabalho. Você também pode incluir quaisquer bibliotecas ou outros arquivos complementares, desde que seu script os manipule.

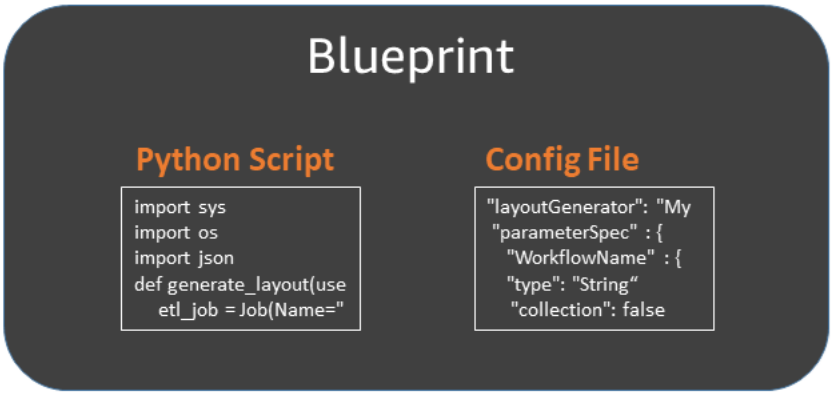

Execuções de blueprint

Quando você cria um fluxo de trabalho a partir de um esquema, o AWS Glue executa o esquema, que inicia um processo assíncrono para criar o fluxo de trabalho e os trabalhos, crawlers e acionadores que o fluxo de trabalho encapsula. O AWS Glue usa a execução do esquema para orquestrar a criação do fluxo de trabalho e seus componentes. Você visualizar o status do processo de criação exibindo o status de execução do blueprint. A execução do blueprint também armazena os valores que você forneceu para os parâmetros do blueprint.

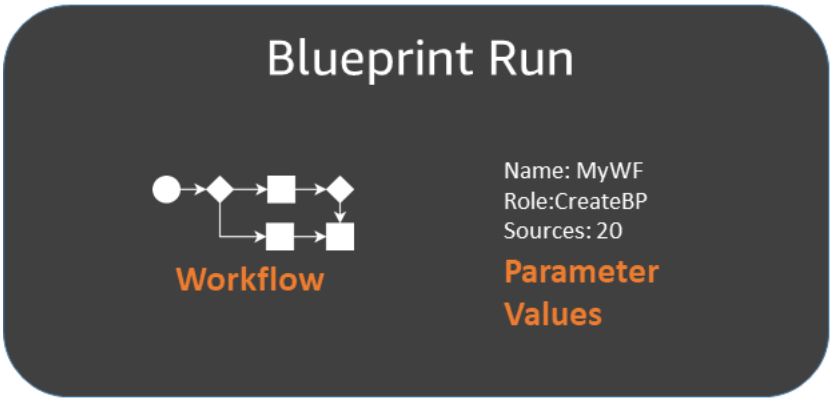

Você pode exibir execuções de esquemas usando o console do AWS Glue ou a AWS Command Line Interface (AWS CLI). Ao exibir ou solucionar problemas de um fluxo de trabalho, você sempre pode retornar à execução do blueprint para exibir os valores de parâmetro do blueprint usados para criar o fluxo de trabalho.

Ciclo de vida de um esquema

Os esquemas são desenvolvidos, testados e registrados com o AWS Glue e executados para criar fluxos de trabalho. Normalmente, há três pessoas envolvidas no ciclo de vida do blueprint.

Pessoa	Tarefas
Desenvolvedor do AWS Glue	• Escreve o script de layout do fluxo de trabalho e cria o arquivo de configuração. • Testa o esquema localmente usando bibliotecas fornecidas pelo serviço do AWS Glue. • Cria um arquivo ZIP do script, do arquivo de configura ção e dos arquivos complementares e o publica em um local no Amazon S3. • Adiciona uma política de bucket ao bucket do Amazon S3 que concede permissões de leitura em objetos de bucket para a conta da AWS do administrador do AWS Glue. • Concede permissões de leitura do IAM no arquivo ZIP no Amazon S3 para o administrador do AWS Glue.
Administrador da AWS Glue	• Registra o esquema com o AWS Glue. O AWS Glue faz uma cópia do arquivo ZIP em um local reservado do Amazon S3. • Concede permissões do IAM no blueprint aos analistas de dados.
Analista de dados	• Executa o blueprint para criar um fluxo de trabalho e fornece valores de parâmetro do blueprint. Verifica o status de execução do blueprint para garantir que o fluxo de trabalho e seus componentes tenham sido gerados com êxito. • Executa e soluciona problemas do fluxo de trabalho. Antes de executar o fluxo de trabalho, pode verificar o fluxo de trabalho exibindo o gráfico de design dele, no console do AWS Glue.

Consulte também

- Desenvolver esquemas no AWS Glue

- Criar um fluxo de trabalho com base em um esquema no AWS Glue
- Permissões para pessoas e funções de esquemas do AWS Glue

Desenvolver esquemas no AWS Glue

Como um desenvolvedor do AWS Glue, você pode criar e publicar esquemas que os analistas de dados podem usar para gerar fluxos de trabalho.

Tópicos

- Visão geral do desenvolvimento de esquemas
- Pré-requisitos para desenvolvimento de esquemas
- Gravar o código do esquema
- Projeto de esquema de exemplo
- Testar um esquema
- Publicar um esquema
- Referência de classes de esquema do AWS Glue
- Esquemas de exemplo

Consulte também

- Visão geral dos esquemas no AWS Glue

Visão geral do desenvolvimento de esquemas

A primeira etapa em seu processo de desenvolvimento é identificar um caso de uso comum que se beneficiaria de um blueprint. Um caso de uso típico envolve um problema de ETL recorrente que você acredita que deve ser resolvido de forma geral. Em seguida, projete um blueprint que implante o caso de uso generalizado e defina os parâmetros de entrada do blueprint que juntos podem definir um caso de uso específico a partir do caso de uso generalizado.

Um blueprint consiste em um projeto que contém um arquivo de configuração de parâmetros do blueprint e um script que define o layout do fluxo de trabalho a ser gerado. O layout define os trabalhos e crawlers (ou entidades na terminologia do script de blueprint) a serem criados.

Você não especifica diretamente nenhum acionador no script de layout. Em vez disso, você escreve um código para especificar as dependências entre os trabalhos e os crawlers criados pelo script. O AWS Glue gera os acionadores com base em suas especificações de dependências. A saída do script de layout é um objeto de fluxo de trabalho que contém especificações para todas as entidades de fluxo de trabalho.

Você constrói seu objeto de fluxo de trabalho usando as seguintes bibliotecas de esquema do AWS Glue:

- `awsglue.blueprint.base_resource`: uma biblioteca de recursos básicos usados pelas bibliotecas.
- `awsglue.blueprint.workflow`: uma biblioteca para definir uma classe `Workflow`.
- `awsglue.blueprint.job`: uma biblioteca para definir uma classe `Job`.
- `awsglue.blueprint.crawler`: uma biblioteca para definir uma classe `Crawler`.

As únicas outras bibliotecas que são suportadas para geração de layout são aquelas que estão disponíveis para o shell do Python.

Antes de publicar seu blueprint, você pode usar métodos definidos nas bibliotecas de blueprint para testá-lo localmente.

Quando estiver tudo pronto para você disponibilizar o blueprint aos analistas de dados, você empacota o script, o arquivo de configuração de parâmetros e quaisquer arquivos complementares, como scripts e bibliotecas adicionais, em um único ativo implantável. Em seguida, carrega o ativo no Amazon S3 e pede a um administrador para registrá-lo no AWS Glue.

Para obter mais informações sobre amostras de projetos de blueprint, consulte Projeto de esquema de exemplo e Esquemas de exemplo.

Pré-requisitos para desenvolvimento de esquemas

Para desenvolver esquemas, você deve ter familiaridade com o uso do AWS Glue e com a criação de scripts para trabalhos de ETL do Apache Spark ou trabalhos de shell do Python. Além disso, é necessário concluir as seguintes tarefas de configuração.

- Baixe quatro bibliotecas Python da AWS para usar em seus scripts de layout de blueprint.
- Configure os AWS SDKs.

- Configure o AWS CLI.

Baixar bibliotecas Python

Baixe as seguintes bibliotecas do GitHub e instale-as em seu projeto:

- 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

Configurar o AWS Java SDK

Para o AWS Java SDK, você deve adicionar um arquivo `jar` que inclui a API para blueprints.

1. Se você ainda não fez isso, configure o AWS SDK for Java.
   - Para Java 1.x, siga as instruções em Configurar o AWS SDK para Java no Guia do desenvolvedor do AWS SDK para Java.
   - Para Java 2.x, siga as instruções em Configurar o AWS SDK for Java 2.x no Guia do desenvolvedor do AWS SDK for Java 2.x.
2. Baixe o arquivo de cliente `jar` que tem acesso às APIs para blueprints.
   - Para Java 1.x: s3://awsglue-custom-blueprints-preview-artifacts/awsglue-java-sdk-preview/AWSGlueJavaClient-1.11.x.jar
   - Para Java 2.x: s3://awsglue-custom-blueprints-preview-artifacts/awsglue-java-sdk-v2-preview/AwsJavaSdk-Glue-2.0.jar
3. Adicione o cliente `jar` na frente do classpath Java para substituir o cliente do AWS Glue fornecido peloAWS Java SDK.

   ```
   export CLASSPATH=<path-to-preview-client-jar>:$CLASSPATH
   ```
4. (Opcional) teste o SDK com a seguinte aplicação Java. A aplicação deve exibir uma lista vazia.

   Substitua `accessKey` e `secretKey` com suas credenciais e `us-east-1` com a sua região.

   ```
   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");
        AWSCredentialsProvider 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));
    }
}
```

Configurar o AWS Python SDK

As seguintes etapas supõem que você tenha o Python versão 2.7 ou posterior, ou a versão 3.9 ou posterior, instalada no computador.

1. Baixe o seguinte arquivo wheel do boto3. Se solicitado a abrir ou salvar, salve o arquivo. s3://awsglue-custom-blueprints-preview-artifacts/aws-python-sdk-preview/boto3-1.17.31-py2.py3-none-any.whl
2. Baixe o seguinte arquivo wheel do botocore: s3://awsglue-custom-blueprints-preview-artifacts/aws-python-sdk-preview/botocore-1.20.31-py2.py3-none-any.whl
3. Verifique a versão do Python.

   ```
   python --version
   ```

4. Dependendo da sua versão do Python, insira os seguintes comandos (para Linux):

   - Para Python 2.7 ou posterior.

     ```
     python3 -m pip install --user virtualenv
     source env/bin/activate
     ```

- Para Python 3.9 ou posterior.

```
python3 -m venv python-sdk-test
source python-sdk-test/bin/activate
```

5. Instale o arquivo wheel do botocore.

```
python3 -m pip install <download-directory>/botocore-1.20.31-py2.py3-none-any.whl
```

6. Instale o arquivo wheel do boto3.

```
python3 -m pip install <download-directory>/boto3-1.17.31-py2.py3-none-any.whl
```

7. Configure suas credenciais e a região padrão nos arquivos `~/.aws/credentials` e `~/.aws/config`. Para obter mais informações, consulte Configuração da AWS CLI no Guia do usuário da AWS Command Line Interface.
8. (Opcional) teste a configuração. Os comandos a seguir devem retornar uma lista vazia.

   Substitua `us-east-1` pela sua região.

```
$ python
>>> import boto3
>>> glue = boto3.client('glue', 'us-east-1')
>>> glue.list_blueprints()
```

Configurar a pré-visualização da AWS CLI

1. Se você ainda o fez, instale e/ou atualize a AWS Command Line Interface (AWS CLI) em seu computador. A maneira mais fácil de fazer isso é com o `pip`, o utilitário de instalação do Python:

   ```
   pip install awscli --upgrade --user
   ```

   Você pode encontrar instruções completas de instalação da AWS CLI aqui: Instalar a AWS Command Line Interface.
2. Baixe o arquivo wheel da AWS CLI em: s3://awsglue-custom-blueprints-preview-artifacts/awscli-preview-build/awscli-1.19.31-py2.py3-none-any.whl
3. Instale o arquivo wheel da AWS CLI.

```
python3 -m pip install awscli-1.19.31-py2.py3-none-any.whl
```

4. Execute o comando `aws configure`. Configure as credenciais da AWS (incluindo chave de acesso e chave secreta) e a região da AWS. Você pode encontrar informações sobre a configuração da AWS CLI aqui: Configurar a AWS CLI.
5. Teste a AWS CLI. O comando a seguir deve retornar uma lista vazia.

   Substitua `us-east-1` pela sua região.

```
aws glue list-blueprints --region us-east-1
```

Gravar o código do esquema

Cada projeto de blueprint criado deve conter, no mínimo, os seguintes arquivos:

- Um script de layout Python que define o fluxo de trabalho. O script contém uma função que define as entidades (trabalhos e crawlers) em um fluxo de trabalho e as dependências entre elas.
- Um arquivo de configuração, `blueprint.cfg`, que define:
  - O caminho completo da função de definição de layout de fluxo de trabalho.
  - Os parâmetros que o blueprint aceita.

Tópicos

- Criar o script de layout do esquema
- Criar o arquivo de configuração
- Especificar parâmetros de esquema

Criar o script de layout do esquema

O script de layout do blueprint deve incluir uma função que gera as entidades em seu fluxo de trabalho. Você pode atribuir o nome que quiser a esta função. O AWS Glue usa o arquivo de configuração para determinar o nome totalmente qualificado da função.

Sua função de layout faz o seguinte:

- (Opcional) instancia a classe `Job` para criar objetos `Job` e transmite argumentos, como `Command` e `Role`. Essas são as propriedades de trabalho que você especificaria se estivesse criando o trabalho usando o console ou a API do AWS Glue.
- (Opcional) instancia a classe `Crawler` para criar objetos `Crawler` e transmite argumentos de nome, função e destino.
- Para indicar dependências entre os objetos (entidades de fluxo de trabalho), transmite os argumentos adicionais `DependsOn` e `WaitForDependencies` para `Job()` e `Crawler()`. Esses argumentos são explicados posteriormente nesta seção.
- Instancia a classe `Workflow` para criar o objeto de fluxo de trabalho que é retornado para o AWS Glue, transmitindo um argumento `Name`, um argumento `Entities` e um argumento opcional `OnSchedule`. O argumento `Entities` especifica todos os trabalhos e crawlers a serem incluídos no fluxo de trabalho. Para ver como construir um objeto `Entities`, consulte o projeto de exemplo mais adiante nesta seção.
- Retorna um objeto `Workflow`.

Para obter definições das classes `Job`, `Crawler` e `Workflow`, consulte Referência de classes de esquema do AWS Glue.

A função de layout aceita os seguintes argumentos:

Argumento	Descrição
`user_params`	Dicionário Python de nomes e valores de parâmetros do blueprint. Para ter mais informações, consulte Especificar parâmetros de esquema.
`system_params`	Dicionário Python contendo duas propriedades: `region` e `accountId` .

Aqui está um exemplo de script gerador de layout em um arquivo chamado `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
```

O script de exemplo importa as bibliotecas de blueprint necessárias e inclui uma função `generate_layout` que gera um fluxo de trabalho com dois trabalhos. Esse é um script muito simples. Um script mais complexo poderia empregar lógica e parâmetros adicionais para gerar um fluxo de trabalho com muitos trabalhos e crawlers, ou até mesmo um número variável de trabalhos e crawlers.

Usar o argumento DependsOn

O argumento `DependsOn` é uma representação de dicionário de uma dependência que esta entidade tem em outras entidades dentro do fluxo de trabalho. Ele tem o seguinte formato:

```
DependsOn = {dependency1 : state, dependency2 : state, ...}
```

As chaves nesse dicionário representam a referência ao objeto, e não o nome da entidade, enquanto os valores são strings que correspondem ao estado a ser vigiado. O AWS Glue infere os acionadores adequados. Para obter os estados válidos, consulte Estrutura de condição.

Por exemplo, um trabalho pode depender da conclusão bem-sucedida de um crawler. Se você definir um objeto de crawler chamado `crawler2` como segue:

```
crawler2 = Crawler(Name="my_crawler", ...)
```

Em seguida, um objeto dependendo de `crawler2` incluiria um argumento construtor, como:

```
DependsOn = {crawler2 : "SUCCEEDED"}
```

Por exemplo:

```
job1 = Job(Name="Job1", ..., DependsOn = {crawler2 : "SUCCEEDED", ...})
```

Se `DependsOn` for omitido para uma entidade, essa entidade dependerá do acionador de início do fluxo de trabalho.

Usar o argumento WaitForDependencies

O argumento `WaitForDependencies` define se um trabalho ou entidade de crawler deve esperar até que todas as entidades das quais depende sejam concluídas ou até que qualquer uma seja concluída.

Os valores permitidos são “AND” ou “ANY”.

Usar o argumento OnSchedule

O argumento `OnSchedule` para o construtor de classe `Workflow` é uma expressão `cron` que determina a definição do acionador inicial para um fluxo de trabalho.

Se esse argumento for especificado, o AWS Glue criará um acionador de programação com a programação correspondente. Se ele não for especificado, o acionador de início do fluxo de trabalho será um acionador sob demanda.

Criar o arquivo de configuração

O arquivo de configuração do blueprint é um arquivo obrigatório que define o ponto de entrada do script para gerar o fluxo de trabalho e os parâmetros que o blueprint aceita. O deve ser nomeado `blueprint.cfg`.

Veja a seguir um arquivo de configuração de exemplo.

```
{
    "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
     }
    }
}
```

A propriedade `layoutGenerator` especifica o nome totalmente qualificado da função no script que gera o layout.

A propriedade `parameterSpec` especifica os parâmetros que esse blueprint aceita. Para ter mais informações, consulte Especificar parâmetros de esquema.

> **Important**
>
> Seu arquivo de configuração deve incluir o nome do fluxo de trabalho como um parâmetro de blueprint ou você deve gerar um nome de fluxo de trabalho exclusivo no script de layout.

Especificar parâmetros de esquema

O arquivo de configuração contém especificações de parâmetro do blueprint em um objeto JSON `parameterSpec`. `parameterSpec` contém um ou mais objetos de parâmetro.

```
"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>": {
       ...
    }
  }
```

A seguir estão as regras para codificar cada objeto de parâmetro:

- O nome e o `type` do parâmetro são obrigatórios. Todas as outras propriedades são opcionais.
- Se você especificar a propriedade `defaultValue`, o parâmetro será opcional. Caso contrário, o parâmetro é obrigatório e o analista de dados que cria um fluxo de trabalho a partir do blueprint deve fornecer um valor para ele.
- Se você definir a propriedade `collection` como `true`, o parâmetro poderá ter uma coleção de valores. Coleções podem ser de qualquer tipo de dados.
- Se você especificar `allowedValues`, o console do AWS Glue exibirá uma lista suspensa de valores para o analista de dados escolher ao criar um fluxo de trabalho a partir do esquema.

Os seguintes valores são permitidos para o `type`:

Tipos de dados de parâmetro	Observações
`String`	-
`Integer`	-
`Double`	-

Tipos de dados de parâmetro	Observações
`Boolean`	Os possíveis valores são `true` e `false`. Gera uma caixa de seleção na página Create a workflow from <esquema> (Criar um fluxo de trabalho a partir de <esquema>) no console do AWS Glue.
`S3Uri`	Caminho completo do Amazon S3, começando com `s3://`. Gera um campo de texto e o botão Browse (Navegar) na página Create a workflow from <blueprint> (Criar um fluxo de trabalho a partir de <blueprint>).
`S3Bucket`	Somente nome do bucket do Amazon S3. Gera um seletor de bucket na página Create a workflow from <blueprint> (Criar um fluxo de trabalho a partir de <blueprint>).
`IAMRoleArn`	O nome do recurso da Amazon (ARN) da função do AWS Identity and Access Management (IAM). Gera um seletor de função na página Create a workflow from <blueprint> (Criar um fluxo de trabalho a partir de <blueprint>).
`IAMRoleName`	Nome de uma função do IAM. Gera um seletor de função na página Create a workflow from <blueprint> (Criar um fluxo de trabalho a partir de <blueprint>).

Projeto de esquema de exemplo

Uma conversão de formato de dados é um caso de uso frequente de extração, transformação e carregamento (ETL). Em workloads analíticas típicas, formatos de arquivo baseados em colunas, como Parquet ou ORC, são preferidos em relação a formatos de texto, como CSV ou JSON. Esse blueprint de exemplo permite converter dados de CSV/JSON/etc. em Parquet para arquivos no Amazon S3.

Esse blueprint obtém uma lista de caminhos do S3 definidos por um parâmetro de blueprint, converte os dados no formato Parquet e os grava no local do S3 especificado por outro parâmetro de blueprint. O script de layout cria um crawler e um trabalho para cada caminho. O script de layout também carrega o script de ETL no `Conversion.py` para um bucket do S3 especificado por outro parâmetro do blueprint. Em seguida, o script de layout especifica o script carregado como o script

de ETL para cada trabalho. O arquivo ZIP do projeto contém o script de layout, o script de ETL e o arquivo de configuração do blueprint.

Para obter mais informações sobre exemplos de projetos de blueprint, consulte Esquemas de exemplo.

A seguir está o script de layout, no arquivo `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
```

A seguir está o arquivo de configuração do blueprint correspondente `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."
        }
    }
}
```

O script a seguir no arquivo `Conversion.py` é o script de ETL carregado. Observe que ele preserva o esquema de particionamento durante a conversão.

```
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**
>
> Somente dois caminhos do Amazon S3 podem ser fornecidos como uma entrada para o blueprint de exemplo. Isso porque os acionadores do AWS Glue podem invocar apenas duas ações de crawler.

Testar um esquema

Enquanto você desenvolve seu código, você deve executar testes locais para verificar se o layout do fluxo de trabalho está correto.

Testes locais não geram trabalhos, crawlers ou acionadores do AWS Glue. Em vez disso, execute o script de layout localmente e use os métodos `to_json()` e `validate()` para imprimir objetos e encontrar erros. Esses métodos estão disponíveis em todas as três classes definidas nas bibliotecas.

Há duas maneiras de lidar com os argumentos `user_params` e `system_params` que o AWS Glue transmite para sua função de layout. Seu código de banco de teste pode criar um dicionário de valores de parâmetro de blueprint de exemplo e transmiti-lo para a função de layout como o argumento `user_params`. Ou você pode remover as referências a `user_params` e substituí-las por strings em código fixo.

Se o seu código usar as propriedades `region` e `accountId` no argumento `system_params`, você pode transmitir seu próprio dicionário para `system_params`.

Para testar um blueprint

1. Inicie um interpretador Python em um diretório com as bibliotecas ou carregue os arquivos de blueprint e as bibliotecas fornecidas em seu ambiente de desenvolvimento integrado (IDE) preferido.
2. Certifique-se de que o código importe as bibliotecas fornecidas.
3. Adicione código à sua função de layout para chamar `validate()` ou `to_json()` em qualquer entidade ou no objeto `Workflow`. Por exemplo, se o seu código criar um objeto `Crawler` chamado `mycrawler`, é possível chamar `validate()` como a seguir.

   ```
   mycrawler.validate()
   ```

Você pode imprimir `mycrawler` como a seguir:

```
print(mycrawler.to_json())
```

Se você chamar `to_json` em um objeto, não há necessidade de também chamar `validate()`, pois `to_json()` chama `validate()`.

É mais útil chamar esses métodos no objeto de fluxo de trabalho. Supondo que seu script nomeie o objeto de fluxo de trabalho `my_workflow`, valide e imprima o objeto de fluxo de trabalho da seguinte forma:

```
print(my_workflow.to_json())
```

Para obter mais informações sobre `to_json()` e `validate()`, consulte Classe Methods.

Você também pode importar `pprint` e formatar o estilo do objeto do fluxo de trabalho, conforme mostrado no exemplo mais adiante nesta seção.

4. Execute o código, corrija erros e, finalmente, remova quaisquer chamadas para `validate()` ou `to_json()`.

Example

O exemplo a seguir mostra como construir um dicionário de parâmetros de blueprint de exemplo e transmiti-lo como o argumento `user_params` para a função de layout `generate_compaction_workflow`. Ele também mostra como formatar o estilo do objeto de fluxo de trabalho gerado.

```
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)
```

Publicar um esquema

Depois de desenvolver um blueprint, você deve carregá-lo no Amazon S3. Você deve ter permissões de gravação no bucket do Amazon S3 usado para publicar o blueprint. Você também deve se

certificar de que o administrador do AWS Glue, que registrará o esquema, tenha acesso de leitura ao bucket do Amazon S3. Sobre políticas de permissões do AWS Identity and Access Management (IAM) sugeridas para pessoas e funções para esquemas do AWS Glue, consulte Permissões para pessoas e funções de esquemas do AWS Glue.

Para publicar um blueprint

1. Crie os scripts, os recursos e o arquivo de configuração do blueprint necessários.
2. Adicione todos os arquivos a um arquivo ZIP e carregue-o no Amazon S3. Use um bucket do S3 que esteja na mesma região na qual os usuários se registrarão e executarão o blueprint.

   Você pode criar um arquivo ZIP a partir da linha de comando usando o seguinte comando.

   ```
   zip -r folder.zip folder
   ```
3. Adicione uma política de bucket que conceda permissões de leitura à conta da AWS desejada. Veja a seguir um exemplo de política.

   ```
   {
       "Version": "2012-10-17",
       "Statement": [
           {
               "Effect": "Allow",
               "Principal": {
                   "AWS": "arn:aws:iam::111122223333:root"
               },
               "Action": "s3:GetObject",
               "Resource": "arn:aws:s3:::my-blueprints/*"
           }
       ]
   }
   ```
4. Conceda a permissão do IAM `s3:GetObject` no bucket do Amazon S3 para o administrador do AWS Glue ou para quem quer que esteja registrando esquemas. Para obter uma política de exemplo a conceder aos administradores, consulte Permissões de administrador do AWS Glue para esquemas.

Depois de concluir o teste local do seu esquema, você também pode querer testar um esquema no AWS Glue. Para testar um esquema no AWS Glue, ele deve ser registrado. Você pode limitar quem vê o blueprint registrado usando a autorização do IAM ou usando contas de teste separadas.

Consulte também:

- Registrar um esquema no AWS Glue

Referência de classes de esquema do AWS Glue

As bibliotecas para esquemas do AWS Glue definem três classes que você pode usar no script de layout do fluxo de trabalho: `Job`, `Crawler` e `Workflow`.

Tópicos

- Classe Job
- Classe Crawler
- Classe Workflow
- Classe Methods

Classe Job

A classe `Job` representa um trabalho de ETL do AWS Glue.

Argumentos construtores obrigatórios

Veja os argumentos construtores obrigatórios para a classe `Job`.

Nome do argumento	Tipo	Descrição
`Name`	`str`	O nome a ser atribuído ao trabalho. O AWS Glue adiciona um sufixo gerado aleatoriamente ao nome para distinguir o trabalho daqueles criados por outras execuções de esquema.
`Role`	`str`	O nome do recurso da Amazon (ARN) da função que o trabalho deve assumir ao executar.
`Command`	`dict`	Comando Job (Trabalho), conforme especificado em Estrutura JobCommand na documentação da API.

Argumentos construtores opcionais

Veja os argumentos construtores opcionais para a classe `Job`.

Nome do argumento	Tipo	Descrição
`DependsOn`	`dict`	Lista de entidades de fluxo de trabalho das quais o trabalho depende. Para ter mais informações, consulte Usar o argumento DependsOn.
`WaitForDependencies`	`str`	Indica se o trabalho deve esperar até que todas as entidades das quais depende sejam concluídas antes de executar ou até que qualquer uma seja concluída. Para ter mais informações, consulte Usar o argumento WaitForDependencies. Omita, se o trabalho depender de apenas uma entidade.
(Propriedades do trabalho)	-	Qualquer uma das propriedades do trabalho listadas em Estrutura Job na documentação da API do AWS Glue (exceto `CreatedOn` e `LastModifiedOn`).

Classe Crawler

A classe `Crawler` representa um crawler do AWS Glue.

Argumentos construtores obrigatórios

Veja os argumentos construtores obrigatórios para a classe `Crawler`.

Nome do argumento	Tipo	Descrição
`Name`	`str`	O nome a ser atribuído ao crawler. O AWS Glue adiciona um sufixo gerado aleatoriamente ao nome para distinguir o trabalho daqueles criados por outras execuções de esquema.

Nome do argumento	Tipo	Descrição
`Role`	`str`	ARN da função que o crawler deve assumir ao executar.
`Targets`	`dict`	Coleção de destinos a serem rastreados. Os argumentos construtores da classe `Targets` são definidos em Estrutura CrawlerTargets na documentação da API. Todos os argumentos construtores de `Targets` são opcionais, mas você deve informar pelo menos um.

Argumentos construtores opcionais

Veja os argumentos construtores opcionais para a classe `Crawler`.

Nome do argumento	Tipo	Descrição
`DependsOn`	`dict`	Lista de entidades de fluxo de trabalho das quais o crawler depende. Para ter mais informações, consulte Usar o argumento DependsOn.
`WaitForDependencies`	`str`	Indica se o crawler deve esperar até que todas as entidades das quais depende sejam concluídas antes de executar ou até que qualquer uma seja concluída. Para ter mais informações, consulte Usar o argumento WaitForDependencies. Omita, se o crawler depender de apenas uma entidade.
(Propriedades do crawler)	-	Qualquer uma das propriedades do crawler listadas em Estrutura Crawler na documenta ção da API do AWS Glue, com as seguintes exceções: • `State`

Nome do argumento	Tipo	Descrição
		• `CrawlElapsedTime` • `CreationTime` • `LastUpdated` • `LastCrawl` • `Version`

Classe Workflow

A classe `Workflow` representa um fluxo de trabalho do AWS Glue. O script de layout de fluxo de trabalho retorna um objeto `Workflow`. AWS Glue cria um fluxo de trabalho com base nesse objeto.

Argumentos construtores obrigatórios

Veja os argumentos construtores obrigatórios para a classe `Workflow`.

Nome do argumento	Tipo	Descrição
`Name`	`str`	O nome a ser atribuído ao fluxo de trabalho.
`Entities`	`Entities`	Uma coleção de entidades (trabalhos e crawlers) a serem incluídas no fluxo de trabalho. O construtor da classe `Entities` aceita um argumento `Jobs`, que é uma lista de objetos `Job`, e um argumento `Crawlers`, que é uma lista de objetos `Crawler`.

Argumentos construtores opcionais

Veja os argumentos construtores opcionais para a classe `Workflow`.

Nome do argumento	Tipo	Descrição
`Description`	`str`	Consulte Estrutura Workflow.

Nome do argumento	Tipo	Descrição
`DefaultRunProperties`	`dict`	Consulte Estrutura Workflow.
`OnSchedule`	`str`	Uma expressão `cron`.

Classe Methods

Todas as três classes incluem os seguintes métodos.

validate()

Valida as propriedades do objeto e, se forem encontrados erros, emite uma mensagem e sai. Não gera saída se não houver erros. Para a classe `Workflow`, chama a si mesma em cada entidade no fluxo de trabalho.

to_json()

Serializa o objeto em JSON. Também chama `validate()`. Para a classe `Workflow`, o objeto JSON inclui listas de trabalhos e crawlers e uma lista de acionadores gerados pelas especificações de dependência de trabalho e de crawler.

Esquemas de exemplo

Diversos projetos de esquema de exemplo estão disponíveis no repositório do Github de esquemas do AWS Glue. Tais amostras são apenas para referência e não se destinam à produção.

Os títulos dos projetos de exemplo são:

- Compaction (Compactação): esse blueprint cria um trabalho que compacta arquivos de entrada em blocos maiores com base no tamanho de arquivo desejado.
- Conversion (Conversão): esse blueprint converte arquivos de entrada em vários formatos de arquivo padrão no formato Apache Parquet, que é otimizado para workloads analíticas.
- Crawling Amazon S3 locations (Crawling de locais do Amazon S3): esse blueprint rastreia vários locais do Amazon S3 para adicionar tabelas de metadados ao Data Catalog.
- Custom connection to Data Catalog (Conexão personalizada com o Data Catalog): esse esquema acessa os armazenamentos de dados usando conectores personalizados do AWS Glue, lê os registros e preenche as definições no AWS Glue Data Catalog no esquema de registro.

- Encoding (Codificação): esse blueprint converte seus arquivos não UTF em arquivos codificados em UTF.
- Partitioning (Particionamento): esse blueprint cria um trabalho de particionamento que coloca os arquivos de saída em partições com base em chaves de partição específicas.
- Importing Amazon S3 data into a DynamoDB table (Importação de dados do Amazon S3 em uma tabela do DynamoDB): esse blueprint importa dados do Amazon S3 para uma tabela do DynamoDB.
- Standard table to governed (Tabela padrão a ser controlada): esse esquema importa uma tabela do AWSGlue Data Catalog para uma tabela do Lake Formation.

Registrar um esquema no AWS Glue

Após o desenvolvedor do AWS Glue codificar o esquema e carregar um arquivo ZIP no Amazon Simple Storage Service (Amazon S3), um administrador do AWS Glue deve registrar o esquema. Registrar o blueprint o torna disponível para uso.

Quando você registra um esquema, o AWS Glue copia o arquivo de esquema para um local reservado do Amazon S3. Em seguida, você pode excluir o arquivo do local de onde foi carregado.

Para registrar um blueprint, você precisa de permissões de leitura no local do Amazon S3 que contém o arquivo carregado. Você também precisa da permissão do AWS Identity and Access Management (IAM) `glue:CreateBlueprint`. Para obter as permissões sugeridas para um administrador do AWS Glue que deve registrar, visualizar e manter esquemas, consulte Permissões de administrador do AWS Glue para esquemas.

Você pode registrar um esquema usando o console do AWS Glue, a API do AWS Glue ou a AWS Command Line Interface (AWS CLI).

Para registrar um blueprint (console)

1. Verifique se você tem permissões de leitura (`s3:GetObject`) no arquivo ZIP de blueprint no Amazon S3.
2. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

   Faça login como um usuário que tem permissões para registrar um blueprint. Mude para a mesma região da AWS do bucket do Amazon S3 que contém o arquivo ZIP de esquema.
3. No painel de navegação, escolha Blueprints (Esquemas). Em seguida, na página Blueprints (Esquemas), escolha Add blueprint (Adicionar esquema).

4. Insira um nome de blueprint e uma descrição opcional.
5. Para o local do arquivo ZIP (S3), insira o caminho do Amazon S3 do arquivo ZIP de blueprint carregado. Inclua o nome do arquivo no caminho e o inicie com `s3://`.
6. (Opcional) adicione uma ou mais tags.
7. Escolha Add blueprint (Adicionar blueprint).

   A página Blueprints (Esquemas) retorna e mostra que o status do esquema é `CREATING`. Escolha o botão de atualização até que o status mude para `ACTIVE` ou `FAILED`.
8. Se o status for `FAILED`, selecione o blueprint e, no menu Actions (Ações), escolha View (Exibir).

   A página de detalhes mostra o motivo da falha. Se a mensagem do erro for “Unable to access object at location…” (Não foi possível acessar o objeto no local…) ou “Access denied on object at location…” (Acesso negado no objeto no local…), analise os seguintes requisitos:

   - O usuário ao qual você está conectado deve ter permissão de leitura no arquivo ZIP de blueprint no Amazon S3.
   - O bucket do Amazon S3 que contém o arquivo ZIP deve ter uma política de bucket que conceda permissão de leitura no objeto ao seu ID da conta da AWS. Para ter mais informações, consulte Desenvolver esquemas no AWS Glue.
   - O bucket do Amazon S3 que você está usando deve estar na mesma região em que você se conectou no console.
9. Certifique-se de que os analistas de dados tenham permissões no blueprint.

   A política do IAM sugerida para analistas de dados é mostrada em Permissões de analista de dados para esquemas. Essa política concede `glue:GetBlueprint` em qualquer recurso. Se sua política for mais minuciosa no nível do recurso, conceda permissões aos analistas de dados nesse recurso recém-criado.

Para registrar um blueprint (AWS CLI)

1. Insira o comando da a seguir.

```
aws glue create-blueprint --name <blueprint-name> [--description <description>] --
blueprint-location s3://<s3-path>/<archive-filename>
```

2. Para verificar o status do blueprint, insira o comando a seguir. Repita o comando até que o status vá para `ACTIVE` ou `FAILED`.

```
aws glue get-blueprint --name <blueprint-name>
```

Se o status for `FAILED` e a mensagem de erro for “Unable to access object at location…” (Não foi possível acessar o objeto no local…) ou “Access denied on object at location…” (Acesso negado no objeto no local…), analise os seguintes requisitos:

- O usuário ao qual você está conectado deve ter permissão de leitura no arquivo ZIP de blueprint no Amazon S3.
- O bucket do Amazon S3 que contém o arquivo ZIP deve ter uma política de bucket que conceda permissão de leitura no objeto ao seu ID da conta da AWS. Para ter mais informações, consulte Publicar um esquema.
- O bucket do Amazon S3 que você está usando deve estar na mesma região em que você se conectou no console.

Consulte também:

- Visão geral dos esquemas no AWS Glue

Visualizar esquemas no AWS Glue

Exiba um blueprint para revisar a descrição, o status e as especificações de parâmetros dele, e fazer o download do arquivo ZIP de esquema.

Você pode visualizar uma execução de esquema usando o console do AWS Glue, a API do AWS Glue ou a AWS Command Line Interface (AWS CLI).

Para exibir um blueprint (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação, escolha Blueprints (Esquemas).
3. Na página Blueprints (Esquemas), selecione um esquema. Em seguida, no menu Actions (Ações), escolha View (Exibir).

Para exibir um blueprint (AWS CLI)

- Insira o comando a seguir para exibir apenas o nome, a descrição e o status do blueprint. Substitua *<blueprint-name>* pelo nome do blueprint a ser exibido.

```
aws glue get-blueprint --name <blueprint-name>
```

A saída do comando é semelhante à seguinte.

```
{
    "Blueprint": {
        "Name": "myDemoBP",
        "CreatedOn": 1587414516.92,
        "LastModifiedOn": 1587428838.671,
        "BlueprintLocation": "s3://amzn-s3-demo-bucket1/demo/
DemoBlueprintProject.zip",
        "Status": "ACTIVE"
    }
}
```

Insira o seguinte comando para visualizar também as especificações de parâmetros.

```
aws glue get-blueprint --name <blueprint-name>  --include-parameter-spec
```

A saída do comando é semelhante à seguinte.

```
{
    "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"
```

```
    }
}
```

Adicione o argumento `--include-blueprint` para incluir um URL na saída que você pode colar em seu navegador para baixar o arquivo ZIP de esquema que o AWS Glue armazenou.

Consulte também:

- Visão geral dos esquemas no AWS Glue

Atualizar um esquema no AWS Glue

Você pode atualizar um blueprint se tiver um script de layout revisado, um conjunto revisado de parâmetros do blueprint ou arquivos de suporte revisados. Atualizar um blueprint cria uma nova versão.

A atualização de um blueprint não afeta os fluxos de trabalho existentes criados dele.

Você pode atualizar um esquema usando o console do AWS Glue, a API do AWS Glue ou a AWS Command Line Interface (AWS CLI).

O procedimento a seguir pressupõe que o desenvolvedor do AWS Glue criou e carregou um arquivo ZIP de esquema atualizado no Amazon S3.

Para atualizar um blueprint (console)

1. Verifique se você tem permissões de leitura (`s3:GetObject`) no arquivo ZIP de blueprint no Amazon S3.
2. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

   Faça login como um usuário que tem permissões para atualizar um blueprint. Mude para a mesma região da AWS do bucket do Amazon S3 que contém o arquivo ZIP de blueprint.
3. No painel de navegação, escolha Blueprints (Esquemas).
4. Na página Blueprints (Esquemas), selecione um esquema e, no menu Actions (Ações), escolha Edit (Editar).

5. Na página Edit a blueprint (Editar um blueprint), atualize Description (Descrição) ou ZIP archive location (S3) (Localização do arquivo ZIP [S3]) do blueprint. Certifique-se de incluir o nome do arquivo no caminho.
6. Escolha Salvar.

   A página Blueprints (Esquemas) retorna e mostra que o status do esquema é `UPDATING`. Escolha o botão de atualização até que o status mude para `ACTIVE` ou `FAILED`.
7. Se o status for `FAILED`, selecione o blueprint e, no menu Actions (Ações), escolha View (Exibir).

   A página de detalhes mostra o motivo da falha. Se a mensagem do erro for “Unable to access object at location…” (Não foi possível acessar o objeto no local…) ou “Access denied on object at location…” (Acesso negado no objeto no local…), analise os seguintes requisitos:

   - O usuário ao qual você está conectado deve ter permissão de leitura no arquivo ZIP de blueprint no Amazon S3.
   - O bucket do Amazon S3 que contém o arquivo ZIP deve ter uma política de bucket que conceda permissão de leitura no objeto ao seu ID da conta da AWS. Para ter mais informações, consulte Publicar um esquema.
   - O bucket do Amazon S3 que você está usando deve estar na mesma região em que você se conectou no console.

   > **Note**
   >
   > Se a atualização falhar, a próxima execução do blueprint usará a versão mais recente dele que tenha sido registrada ou atualizada com êxito.

Para atualizar um blueprint (AWS CLI)

1. Insira o comando da a seguir.

   ```
   aws glue update-blueprint --name <blueprint-name> [--description <description>] --
   blueprint-location s3://<s3-path>/<archive-filename>
   ```
2. Para verificar o status do blueprint, insira o comando a seguir. Repita o comando até que o status vá para `ACTIVE` ou `FAILED`.

```
aws glue get-blueprint --name <blueprint-name>
```

Se o status for `FAILED` e a mensagem de erro for “Unable to access object at location…” (Não foi possível acessar o objeto no local…) ou “Access denied on object at location…” (Acesso negado no objeto no local…), analise os seguintes requisitos:

- O usuário ao qual você está conectado deve ter permissão de leitura no arquivo ZIP de blueprint no Amazon S3.
- O bucket do Amazon S3 que contém o arquivo ZIP deve ter uma política de bucket que conceda permissão de leitura no objeto ao seu ID da conta da AWS. Para ter mais informações, consulte Publicar um esquema.
- O bucket do Amazon S3 que você está usando deve estar na mesma região em que você se conectou no console.

Consulte também

- Visão geral dos esquemas no AWS Glue

Criar um fluxo de trabalho com base em um esquema no AWS Glue

É possível criar um fluxo de trabalho do AWS Glue manualmente, adicionando um componente de cada vez, ou você pode criar um fluxo de trabalho a partir de um esquema do AWS Glue. O AWS Glue inclui esquemas para casos de uso comuns. Seus desenvolvedores do AWS Glue podem criar esquemas adicionais.

Important

Limite o número total de trabalhos, crawlers e gatilhos em um fluxo de trabalho para 100 ou menos. Se você incluir mais de 100, poderá receber erros ao tentar retomar ou interromper as execuções do fluxo de trabalho.

Ao usar um blueprint, você pode gerar rapidamente um fluxo de trabalho para um caso de uso específico com base no caso de uso generalizado definido pelo blueprint. Você define o caso de

uso específico fornecendo valores para os parâmetros do blueprint. Por exemplo, um blueprint que particiona um conjunto de dados pode ter os caminhos de fonte e de destino do Amazon S3 como parâmetros.

O AWS Glue cria um fluxo de trabalho a partir de um esquema executando o esquema. A execução do blueprint salva os valores de parâmetro fornecidos e é usada para rastrear o progresso e o resultado da criação do fluxo de trabalho e de seus componentes. Ao solucionar problemas de um fluxo de trabalho, você pode exibir a execução do blueprint para determinar os valores de parâmetro do blueprint usados para criar um fluxo de trabalho.

Para criar e exibir fluxos de trabalho, você precisa de determinadas permissões do IAM. Para ver uma sugestão de política do IAM, consulte Permissões de analista de dados para esquemas.

Você pode criar um fluxo de trabalho a partir de um esquema usando o console do AWS Glue, a API do AWS Glue ou a AWS Command Line Interface (AWS CLI).

Para criar um fluxo de trabalho a partir de um blueprint (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

   Faça login como um usuário que tem permissões para criar um fluxo de trabalho.
2. No painel de navegação, escolha Blueprints (Esquemas).
3. Selecione um blueprint e, no menu Actions (Ações), escolha Create workflow (Criar fluxo de trabalho).
4. Na página Create a workflow from <blueprint-name> (Criar um fluxo de trabalho a partir de <nome-do-blueprint>), insira as seguintes informações:

   Parâmetros do blueprint

   Estes variam dependendo do design do blueprint. Para dúvidas sobre os parâmetros, consulte o desenvolvedor. Os esquemas geralmente contêm um parâmetro para o nome do fluxo de trabalho.

   IAM role (Perfil do IAM)

   A função que o AWS Glue assume para criar o fluxo de trabalho e seus componentes. A função deve ter permissões para criar e excluir fluxos de trabalho, trabalhos, crawlers e acionadores. Para obter uma política sugerida para a função, consulte Permissões para perfis de esquema.
5. Selecione Enviar.

A página Blueprint Details (Detalhes do blueprint) é exibida, mostrando uma lista de execuções do blueprint na parte inferior.

6. Na lista de execuções do blueprint, verifique a execução do blueprint mais alta quanto ao status de criação do fluxo de trabalho.

   O status inicial é `RUNNING`. Escolha o botão de atualização até que o status mude para `SUCCEEDED` ou `FAILED`.

7. Execute um destes procedimentos:

   - Se o status de conclusão for `SUCCEEDED`, você pode ir para a página Workflows (Fluxos de trabalho), selecionar o fluxo de trabalho recém-criado e executá-lo. Antes de executar o fluxo de trabalho, você pode revisar o gráfico de design.
   - Se o status de conclusão for `FAILED`, selecione a execução do blueprint e, no menu Actions (Ações), escolha View (Exibir), para visualizar a mensagem de erro.

Para obter mais informações sobre fluxos de trabalho e esquemas, consulte os tópicos a seguir.

- Visão geral de fluxos de trabalho no AWS Glue
- Atualizar um esquema no AWS Glue
- Criar e desenvolver um fluxo de trabalho manualmente no AWS Glue

Visualizar execuções de esquemas no AWS Glue

Exiba uma execução de blueprint para ver as seguintes informações:

- Nome do fluxo de trabalho que foi criado.
- Valores de parâmetro do esquema que foram usados para criar o fluxo de trabalho.
- O status da operação de criação do fluxo de trabalho.

Você pode exibir uma execução de esquema usando o console do AWS Glue, a API do AWS Glue ou a AWS Command Line Interface (AWS CLI).

Para exibir uma execução de blueprint (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

2. No painel de navegação, escolha Blueprints (Esquemas).
3. Na página Blueprints (Esquemas), selecione um esquema. Em seguida, no menu Actions (Ações), escolha View (Exibir).
4. Na parte inferior da página Blueprint Details (Detalhes do blueprint), selecione uma execução de blueprint e, no menu Actions (Ações), escolha View (Exibir).

Para exibir uma execução de blueprint (AWS CLI)

- Insira o comando da a seguir. Substitua *<blueprint-name>* pelo nome do blueprint. Substitua *<blueprint-run-id>* pelo ID de execução do blueprint.

```
aws glue get-blueprint-run --blueprint-name <blueprint-name> --run-id <blueprint-run-id>
```

Consulte também:

- Visão geral dos esquemas no AWS Glue

AWS CloudFormation para AWS Glue

O AWS CloudFormation é um serviço que pode criar muitos recursos da AWS. O AWS Glue fornece operações de API para criar objetos no AWS Glue Data Catalog. No entanto, pode ser mais conveniente definir e criar objetos do AWS Glue e outros objetos de recurso relacionados da AWS em um arquivo de modelo do AWS CloudFormation. Em seguida, você pode automatizar o processo de criação de objetos.

O AWS CloudFormation fornece uma sintaxe simplificada, JSON (JavaScript Object Notation) ou YAML (YAML Ain't Markup Language), para expressar a criação de recursos da AWS. Você pode usar os modelos do AWS CloudFormation para definir os objetos do Data Catalog, como bancos de dados, tabelas, partições, crawlers, classificadores e conexões. Você também pode definir objetos ETL como trabalhos, acionadores e endpoints de desenvolvimento. Você cria um modelo que descreve todos os recursos da AWS desejados, e o AWS CloudFormation cuida do provisionamento e da configuração desses recursos para você.

Para obter mais informações, consulte O que é o AWS CloudFormation? e Trabalhar com modelos do AWS CloudFormation no Manual do usuário do AWS CloudFormation.

Se você planeja usar modelos do AWS CloudFormation compatíveis com o AWS Glue, como administrador, você deve conceder acesso ao AWS CloudFormation e às ações e aos serviços da AWS dos quais ele depende. Para conceder permissões para criar recursos do AWS CloudFormation, anexe a seguinte política aos usuários que trabalham com o AWS CloudFormation:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "cloudformation:*"
      ],
      "Resource": "*"
    }
  ]
}
```

A tabela a seguir contém as ações que um modelo do AWS CloudFormation pode realizar em seu nome. Ela inclui links para informações sobre os tipos de recursos da AWS e os tipos de propriedade que você pode adicionar a um modelo do AWS CloudFormation.

Recurso do AWS Glue	Modelo AWS CloudFormation	Exemplos do AWS Glue
Classificador	AWS::Glue::Classifier	Classificador grok, Classificador JSON, Classificador XML
Conexão	AWS::Glue::Connection	Conexão do MySQL
Crawler	AWS::Glue::Crawler	Crawler do Amazon S3, Crawler do MySQL
Banco de dados	AWS::Glue::Database	Banco de dados vazio, Banco de dados com tabelas
Endpoint de desenvolvimento	AWS::Glue::DevEndpoint	Endpoint de desenvolvimento
Trabalho	AWS::Glue::Job	Trabalho do Amazon S3, Trabalho do JDBC
Transformação de machine learning	AWS::Glue::MLTransform	Transformação de machine learning
Regras de qualidade de dados	AWS::Glue::DataQualityRuleset	Conjunto de regras de qualidade de dados, Conjunto de regras de qualidade de dados com o agendador do EventBridge
Partition	AWS::Glue::Partition	Partições de uma tabela
Tabela	AWS::Glue::Table	Tabela em um banco de dados
Trigger	AWS::Glue::Trigger	Acionador sob demanda, Acionador programado, Acionador condicional

Para começar, use os seguintes modelos de exemplo e personalize-os com seus próprios metadados. Em seguida, use o console do AWS CloudFormation para criar uma pilha do AWS CloudFormation para adicionar objetos ao AWS Glue e a todos os serviços associados. Muitos campos em um objeto do AWS Glue são opcionais. Esses modelos ilustram os campos que são obrigatórios ou necessários para um objeto do AWS Glue funcional.

Um modelo do AWS CloudFormation pode estar no formato JSON ou YAML. Nestes exemplos, o YAML é usado para facilitar a leitura. Os exemplos contêm comentários (#) para descrever os valores que são definidos nos modelos.

Os modelos do AWS CloudFormation podem incluir uma seção `Parameters`. Esta seção pode ser alterada no texto de exemplo ou quando o arquivo YAML for enviado para o console do AWS CloudFormation para criar uma pilha. A seção `Resources` do modelo contém a definição do AWS Glue e objetos relacionados. As definições de sintaxe de modelos do AWS CloudFormation pode conter propriedades que incluem uma sintaxe de propriedades mais detalhada. Nem todas as propriedades podem ser necessárias para criar um objeto do AWS Glue. Essas amostras mostram exemplos de valores para propriedades comuns para criar um objeto do AWS Glue.

Exemplo de modelo do AWS CloudFormation para um banco de dados do AWS Glue

Um banco de dados do AWS Glue no Data Catalog contém tabelas de metadados. O banco de dados consiste em poucas propriedades e pode ser criado no Data Catalog com um modelo do AWS CloudFormation. O modelo de exemplo a seguir é fornecido para você começar e para ilustrar o uso de pilhas do AWS CloudFormation com o AWS Glue. O único recurso criado pelo modelo de exemplo é um banco de dados chamado `cfn-mysampledatabase`. Você pode alterá-lo ao editar o texto do exemplo ou ao alterar o valor no console do AWS CloudFormation quando você enviar o YAML.

Veja a seguir exemplos de valores para as propriedades comuns para criar um banco de dados do AWS Glue. Para obter mais informações sobre o modelo de banco de dados do AWS CloudFormation para o AWS Glue, consulte 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
```

Exemplo de modelo do AWS CloudFormation para um banco de dados, uma tabela e uma partição do AWS Glue

Uma tabela do AWS Glue contém os metadados que definem a estrutura e o local dos dados que você deseja processar com seus scripts de ETL. Em uma tabela, você pode definir partições para paralelizar o processamento de seus dados. Uma partição é um bloco de dados definido com uma chave. Por exemplo, usando o mês como uma chave, todos os dados de janeiro estão contidos na mesma partição. No AWS Glue, bancos de dados podem conter tabelas, e tabelas podem conter partições.

O exemplo a seguir mostra como preencher um banco de dados, uma tabela e partições usando um modelo do AWS CloudFormation. O formato de dados base é `csv` e delimitado por uma vírgula (,). Como um banco de dados deve existir antes de poder conter uma tabela, e uma tabela deve existir antes que as partições possam ser criadas, o modelo usa a instrução `DependsOn` para definir a dependência desses objetos quando eles são criados.

Os valores neste exemplo definem uma tabela que contém dados de voo de um bucket do Amazon S3 publicamente disponível. Para ilustração, apenas algumas colunas dos dados e uma chave de particionamento são definidas. Quatro partições também são definidas no Data Catalog. Alguns campos para descrever o armazenamento do banco de dados também são mostrados nos campos `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
```

Exemplo de modelo do AWS CloudFormation para um classificador grok do AWS Glue

Um classificador do AWS Glue determina o esquema dos seus dados. Um tipo de classificador personalizado usa um padrão grok para corresponder aos seus dados. Se o padrão corresponder, o classificador personalizado será usado para criar o esquema da tabela e definir `classification` como o valor definido na definição do classificador.

Este exemplo cria um classificador que cria um esquema com uma coluna denominada `message` e define a classificação para `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
```

Exemplo de modelo do AWS CloudFormation para um classificador JSON do AWS Glue

Um classificador do AWS Glue determina o esquema dos seus dados. Um tipo de classificador personalizado usa uma string `JsonPath` que define os dados JSON para o classificador classificar. O AWS Glue oferece suporte a um subconjunto de operadores para `JsonPath`, conforme descrito em Gravando classificadores personalizados JsonPath.

Se o padrão for correspondente, o classificador personalizado será usado para criar o esquema da tabela.

Este exemplo cria um classificador que cria um esquema com cada registro na matriz `Records3` em um objeto.

```
---
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[*]
```

Exemplo de modelo do AWS CloudFormation para um classificador XML do AWS Glue

Um classificador do AWS Glue determina o esquema dos seus dados. Um tipo de classificador personalizado especifica uma tag XML para designar o elemento que contém cada registro em um documento XML que está sendo analisado. Se o padrão corresponder, o classificador personalizado

será usado para criar o esquema da tabela e definir `classification` como o valor definido na definição do classificador.

Este exemplo cria um classificador que cria um esquema com uma registro na tag `Record` e define a classificação como `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>
```

Exemplo de modelo do AWS CloudFormation de um crawler do AWS Glue para o Amazon S3

Um crawler do AWS Glue cria tabelas de metadados no Data Catalog que correspondem aos seus dados. Você pode usar essas definições de tabela como origens e destinos em trabalhos de ETL.

Este exemplo cria um crawler, a função do IAM necessária e um banco de dados do AWS Glue no Data Catalog. Quando esse crawler é executado, ele assume a função do IAM e cria uma tabela no banco de dados para os dados de voos públicos. A tabela é criada com o prefixo "`cfn_sample_1_`". A função do IAM criada por esse modelo permite permissões globais, caso você queira criar uma função personalizada. Nenhum classificador personalizado é definido por esse classificador. Os classificadores integrados do AWS Glue são usados por padrão.

Quando você envia esse exemplo para o console do AWS CloudFormation, é necessário confirmar se deseja criar a função do 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\"}}}"
```

Exemplo de modelo do AWS CloudFormation para uma conexão do AWS Glue

Uma conexão do AWS Glue no Data Catalog contém as informações do JDBC e de rede que são necessárias para se conectar a um banco de dados JDBC. Essas informações são usadas quando você se conecta a um banco de dados JDBC para rastrear ou executar trabalhos de ETL.

Este exemplo cria uma conexão com um banco de dados MySQL do Amazon RDS chamado `devdb`. Quando essa conexão é usada, uma função do IAM, as credenciais do banco de dados e os valores de conexão de rede também devem ser fornecidos. Consulte as informações dos campos necessários no modelo.

```
---
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.yyyyyyyyyyyyyy.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
```

Exemplo de modelo do AWS CloudFormation para um crawler do AWS Glue para o JDBC

Um crawler do AWS Glue cria tabelas de metadados no Data Catalog que correspondem aos seus dados. Você pode usar essas definições de tabela como origens e destinos em trabalhos de ETL.

Este exemplo cria um crawler, a função do IAM necessária e um banco de dados do AWS Glue no Data Catalog. Quando esse crawler é executado, ele assume a função do IAM e cria uma tabela no banco de dados para os dados de voo públicos que foram armazenados em um banco de dados MySQL. A tabela é criada com o prefixo "`cfn_jdbc_1_`". A função do IAM criada por esse modelo permite permissões globais, caso você queira criar uma função personalizada. Nenhum classificador personalizado pode ser definido para dados JDBC. Os classificadores integrados do AWS Glue são usados por padrão.

Quando você envia esse exemplo para o console do AWS CloudFormation, é necessário confirmar se deseja criar a função do 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\"}}}"
```

Exemplo do modelo do AWS CloudFormation de um trabalho do AWS Glue para o Amazon S3 ao Amazon S3

Um trabalho do AWS Glue no Data Catalog contém os valores de parâmetros que são necessários para executar um script no AWS Glue.

Este exemplo cria um trabalho que lê dados de voo de um bucket do Amazon S3 no formato `csv` e os grava em um arquivo Parquet do Amazon S3. O script que é executado por esse trabalho já deve existir. Você pode gerar um script de ETL para seu ambiente com o console do AWS Glue. Quando esse trabalho é executado, uma função do IAM com as permissões corretas também deve ser fornecida.

Os valores de parâmetro comuns são exibidos no modelo. Por exemplo, o padrão é 5 para `AllocatedCapacity` (DPUs).

```
---
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
```

Exemplo de modelo do AWS CloudFormation de um trabalho do AWS Glue para JDBC para o Amazon S3

Um trabalho do AWS Glue no Data Catalog contém os valores de parâmetros que são necessários para executar um script no AWS Glue.

Este exemplo cria um trabalho que lê dados de voo de um banco de dados MySQL do JDBC, conforme definido pela conexão denominada `cfn-connection-mysql-flights-1` e os grava em

um arquivo Parquet do Amazon S3. O script que é executado por esse trabalho já deve existir. Você pode gerar um script de ETL para seu ambiente com o console do AWS Glue. Quando esse trabalho é executado, uma função do IAM com as permissões corretas também deve ser fornecida.

Os valores de parâmetro comuns são exibidos no modelo. Por exemplo, o padrão é 5 para `AllocatedCapacity` (DPUs).

```
---
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
```

Exemplo de modelo do AWS CloudFormation para um acionador sob demanda do AWS Glue

Um acionador do AWS Glue no Data Catalog contém os valores de parâmetros que são necessários para iniciar uma execução de trabalho quando esse acionador é disparado. Um acionador sob demanda é acionado quando você o ativa.

Este exemplo cria um acionador sob demanda que inicia um trabalho denominado `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:
```

Exemplo de modelo do AWS CloudFormation para um acionador programado do AWS Glue

Um acionador do AWS Glue no Data Catalog contém os valores de parâmetros que são necessários para iniciar uma execução de trabalho quando esse acionador é disparado. Um acionador programado é acionado quando está habilitado e o temporizador cron é exibido.

Este exemplo cria um acionador programado que inicia um trabalho denominado `cfn-job-S3-to-S3-1`. O temporizador é uma expressão cron para executar o trabalho a cada 10 minutos em dias da semana.

```
---
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:
```

Exemplo de modelo do AWS CloudFormation para um acionador condicional do AWS Glue

Um acionador do AWS Glue no Data Catalog contém os valores de parâmetros que são necessários para iniciar uma execução de trabalho quando esse acionador é disparado. Um acionador condicional é acionado quando é ativado e suas condições são atendidas, como um trabalho sendo concluído com êxito.

Este exemplo cria um acionador condicional que inicia um trabalho denominado `cfn-job-S3-to-S3-1`. Esse trabalho começa quando o trabalho denominado `cfn-job-S3-to-S3-2` é concluído com êxito.

```
---
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
```

Exemplo de modelo do AWS CloudFormation para um endpoint de desenvolvimento do AWS Glue

Uma transformação de machine learning do AWS Glue é uma transformação personalizada para limpar seus dados. No momento, existe uma transformação disponível chamada FindMatches. A transformação FindMatches permite identificar registros duplicados ou correspondentes no seu conjunto de dados, mesmo quando os registros não têm um identificador exclusivo comum e quando não há campos com uma correspondência exata.

Essa amostra cria uma transformação de machine learning. Para obter mais informações sobre os parâmetros necessários para criar uma transformação de machine learning, consulte Correspondência de registros com o FindMatches do AWS Lake Formation.

```
---
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
```

Exemplo de modelo do AWS CloudFormation para um conjunto de regras do AWS Glue Data Quality

Um conjunto de regras de qualidade de dados do AWS Glue contém regras que podem ser avaliadas em uma tabela no catálogo de dados. Depois que o conjunto de regras é colocado na tabela de destino, você pode acessar o catálogo de dados e executar uma avaliação que executa seus dados de acordo com as regras do conjunto de regras. Essas regras podem variar desde a avaliação do número de linhas até a avaliação da integridade referencial em seus dados.

O exemplo a seguir é um modelo do CloudFormation que cria um conjunto de regras com uma variedade de regras na tabela de destino especificada.

```
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
```

Modelo da AWS CloudFormation de amostra para um conjunto de regras do AWS Glue Data Quality com o agendador do EventBridge

Um conjunto de regras de qualidade de dados do AWS Glue contém regras que podem ser avaliadas em uma tabela no catálogo de dados. Depois que o conjunto de regras é colocado na tabela de destino, você pode acessar o catálogo de dados e executar uma avaliação que executa seus dados de acordo com as regras do conjunto de regras. Em vez de precisar acessar manualmente o catálogo de dados para avaliar o conjunto de regras, você também pode adicionar um agendador do EventBridge em nosso modelo do CloudFormation para agendar essas avaliações do conjunto de regras para você em um intervalo cronometrado.

O exemplo a seguir é um modelo do CloudFormation que cria um conjunto de regras de qualidade de dados e um agendador do EventBridge para avaliar o conjunto de regras mencionado acima a cada cinco minutos.

```
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
  ScheduleDQEval:
    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" ] }
        '
```

Exemplo de modelo do AWS CloudFormation para um endpoint de desenvolvimento do AWS Glue

Um endpoint de desenvolvimento do AWS Glue é um ambiente que você pode usar para desenvolver e testar seus scripts do AWS Glue.

Este exemplo cria um endpoint de desenvolvimento com os valores mínimos de parâmetros de rede necessários para criá-lo com êxito. Para obter mais informações sobre os parâmetros necessários para configurar um endpoint de desenvolvimento, consulte Configurar redes para desenvolvimento para o AWS Glue.

Você fornece um ARN (nome do recurso da Amazon) da função do IAM existente para criar o endpoint de desenvolvimento. Forneça uma chave pública RSA válida e mantenha a chave privada correspondente disponível se você planeja criar um servidor de notebook no endpoint de desenvolvimento.

> **Note**
>
> Todo servidor de notebook que criar associado a um endpoint de desenvolvimento será gerenciado por você. Portanto, se você excluir o endpoint de desenvolvimento, deverá excluir a pilha do AWS CloudFormation no console do AWS CloudFormation se quiser excluir o servidor de notebook.

```
---
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
```

Guia de programação do AWS Glue

Um script contém o código que extrai os dados das fontes, os transforma e os carrega nos destinos. O AWS Glue executa um script quando inicia um trabalho.

Os scripts de ETL do AWS Glue são codificados em Python ou Scala. Embora todos os tipos de trabalho possam ser escritos em Python, os trabalhos do AWS Glue for Spark também podem ser escritos também no Scala. Quando você gera automaticamente a lógica do código fonte para um trabalho no AWS Glue Studio, o script é criado. Você pode editar este script ou fornecer seu próprio script para processar seu trabalho de ETL.

Fornecer seus próprios scripts personalizados

Os scripts executam o trabalho de extração, transformação e carregamento (ETL) no AWS Glue. Um script é criado quando você gera automaticamente a lógica do código fonte para um trabalho. É possível editar este script gerado ou fornecer seu próprio script personalizado.

Para fornecer seu próprio script personalizado no AWS Glue, siga estas etapas gerais:

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha a guia Trabalhos de ETL e, em seguida, visualize a seção Criar trabalho. Escolha uma opção de editor de scripts.
3. Em This job runs, escolha uma das seguintes opções:
   - Criar um novo script com código padronizado
   - Carregar e editar um script existente
4. Na tela Propriedades do trabalho, escolha o perfil do IAM exigido para que seu script personalizado seja executado. Para ter mais informações, consulte Gerenciamento de identidade e acesso do AWS Glue.
5. Escolha as conexões que seu script referencia. Esses objetos são necessários para se conectar aos armazenamentos de dados JDBC necessários.

   Uma interface de rede elástica é uma interface de rede virtual que você pode vincular a uma instância em uma nuvem virtual privada (VPC). Escolha a interface de rede elástica necessária para conexão com o armazenamento de dados que é usado no script.

6. Forneça as configurações adicionais, incluindo parâmetros, específicos para seu tipo de trabalho. Para obter mais informações sobre a configuração do tipo de trabalho, consulte a seção Criar trabalhos ETL visuais com o AWS Glue Studio.
7. Na guia Script, cole ou escreva o script personalizado.

Use o conteúdo dessa seção para orientar o processo de escrever o script personalizado.

Para obter mais informações sobre como adicionar trabalhos no AWS Glue, consulte Criar trabalhos ETL visuais com o AWS Glue Studio.

Para um guia detalhado, consulte o tutorial Add job no console do AWS Glue.

Programar scripts do Spark

O AWS Glue facilita a gravação ou a geração automática de scripts de extração, transformação e carregamento (ETL), além de testá-los e executá-los. Esta seção descreve as extensões do Apache Spark que o AWS Glue apresentou e fornece exemplos de como codificar e executar scripts de ETL em Python e Scala.

> **Important**
>
> Versões diferentes do AWS Glue oferecem suporte a versões diferentes do Apache Spark. Seu script personalizado deve ser compatível com a versão compatível do Apache Spark. Para obter informações sobre as versões do AWS Glue, consulte a Glue version job property.

Tópicos

- Tutorial: gravar um script do AWS Glue para Spark
- Programar scripts de ETL do AWS Glue em PySpark
- Programando scripts de ETL do AWS Glue no Scala
- Recursos e otimizações para programação de scripts de ETL do AWS Glue para Spark

Tutorial: gravar um script do AWS Glue para Spark

Este tutorial apresenta o processo de criação de scripts do AWS Glue. É possível executar scripts com base em um cronograma com trabalhos ou interativamente, com sessões interativas. Para

mais informações sobre trabalhos, consulte Criar trabalhos ETL visuais com o AWS Glue Studio. Para obter mais informações sobre sessões interativas, consulte the section called “Visão geral das sessões interativas do AWS Glue”.

O editor visual do AWS Glue Studio oferece uma interface gráfica sem código para a criação de trabalhos do AWS Glue. Scripts do AWS Glue dão suporte a trabalhos visuais. Eles dão acesso ao conjunto expandido de ferramentas disponíveis para trabalhar com os programas do Apache Spark. É possível acessar APIs nativas do Spark e também bibliotecas do AWS Glue que facilitam os fluxos de trabalho de extração, transformação e carregamento (ETL) de dentro de um script do AWS Glue.

Neste tutorial, você extrai, transforma e carrega um conjunto de dados de multas de estacionamento. O script que faz esse trabalho tem forma e função idênticas ao gerado em Facilitando ETL com o AWS Glue Studio no Blog AWS Big Data, que apresenta o editor visual do AWS Glue Studio. Ao executar esse script em um trabalho, você pode compará-lo com trabalhos visuais e ver como os scripts de ETL do AWS Glue funcionam. Assim, você fica preparado para usar funcionalidades adicionais que ainda não estão disponíveis em trabalhos visuais.

Neste tutorial você usa a linguagem e as bibliotecas do Python. Há funcionalidades similares disponíveis no Scala. Após examinar este tutorial, você deve ser capaz de gerar e inspecionar um exemplo de script do Scala para entender como executar o processo de criação de scripts de ETL do AWS Glue para Scala.

Pré-requisitos

Este tutorial tem os seguintes pré-requisitos:

- Os mesmos pré-requisitos da publicação no blog do AWS Glue Studio, que instrui você a executar um modelo AWS CloudFormation.

  Esse modelo usa o Catálogo de Dados do AWS Glue para gerenciar o conjunto de dados de multas de estacionamento disponível em `s3://aws-bigdata-blog/artifacts/gluestudio/`. Ele cria os seguintes recursos que serão referenciados:
- AWS Glue StudioRole(Função): o perfil do IAM para a execução de trabalhos da AWS Glue
- AWS Glue StudioAmazon S3Bucket: nome do bucket do Amazon S3 para armazenamento de arquivos relacionados ao blog
- AWS Glue StudioTicketsYYZDB: banco de dados do AWS Glue Data Catalog
- AWS Glue StudioTableTickets: tabela do Data Catalog para ser usada como origem
- AWS Glue StudioTableTrials: tabela do Data Catalog para ser usada como origem

- AWS Glue StudioParkingTicketCount: tabela do Data Catalog para ser usada como destino
- O script gerado na publicação do blog do AWS Glue Studio. Caso a publicação no blog mude, o script também está disponível no texto a seguir.

Gerar um exemplo de script

Você pode usar o editor visual do AWS Glue Studio como uma poderosa ferramenta de geração de código para criar uma estrutura para o script que você deseja criar. Você usará essa ferramenta para criar um exemplo de script.

Se você quiser pular essas etapas, o script será fornecido.

Exemplo de script do tutorial

```
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()
```

Para gerar um exemplo de script

1. Conclua o tutorial do AWS Glue Studio. Para concluir este tutorial, consulte Criação de um trabalho no AWS Glue Studio a partir de um exemplo de trabalho.
2. Navegue até a guia Script na página do trabalho, conforme mostrado na captura de tela a seguir:

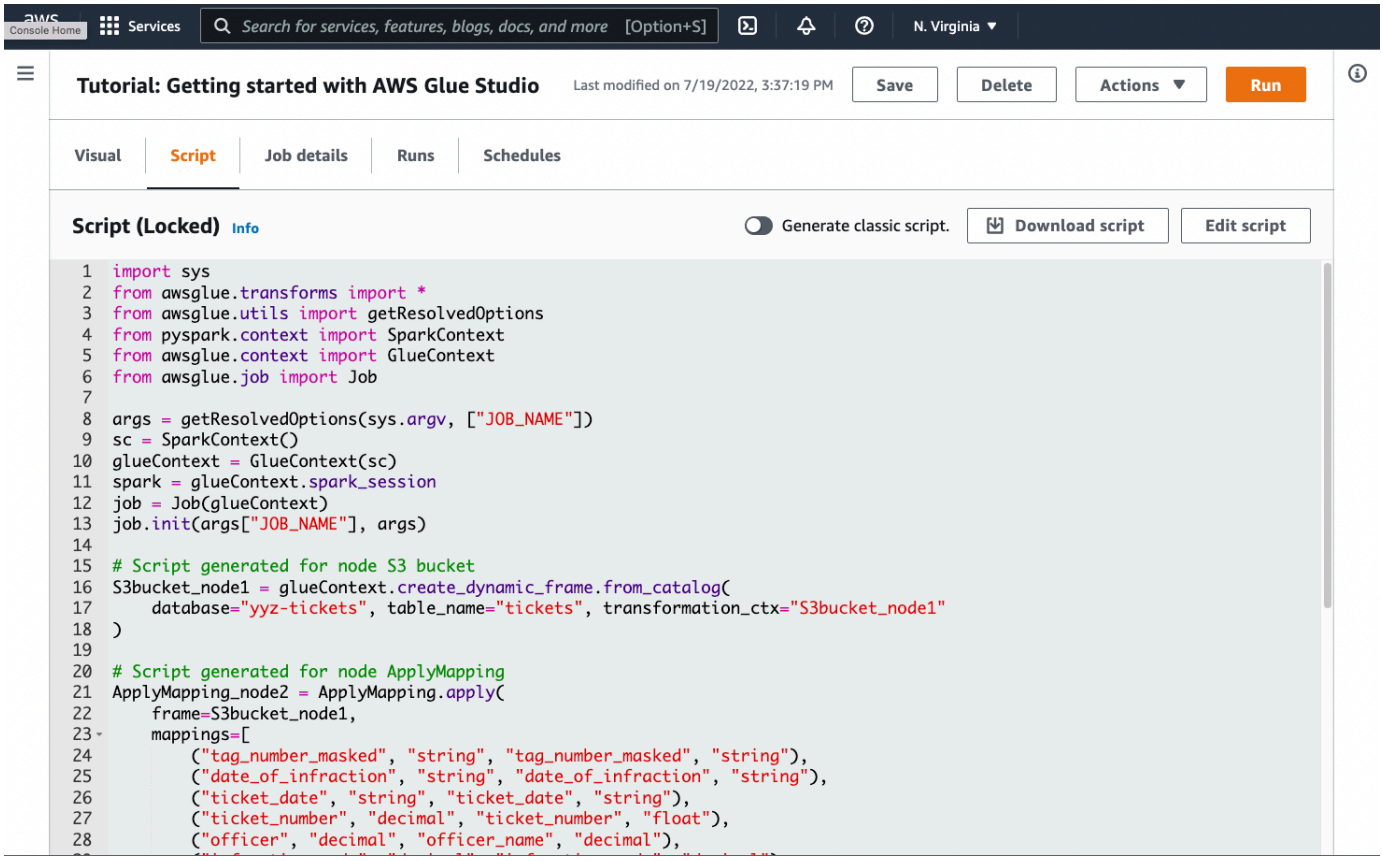

3. Copie o conteúdo completo da guia Script. Ao definir a linguagem do script em Job details (Detalhes do trabalho), você pode alternar entre gerar código para Python ou Scala.

Etapa 1. Criar um trabalho e colar seu script

Nesta etapa, você cria um trabalho do AWS Glue no AWS Management Console. Essa ação define uma configuração que permite que o AWS Glue execute seu script. Essa ação também cria um local para você armazenar e editar seu script.

Como criar um trabalho

1. No AWS Management Console, navegue até a página inicial do AWS Glue.
2. No painel de navegação lateral, escolha Jobs (Trabalhos).
3. Escolha Spark script editor (Editor de scripts do Spark) em Create job (Criar trabalho) e, em seguida, escolha Create (Criar).
4. Opcional: cole o texto completo do seu script no painel Script (Script). Você também tem a opção de acompanhar o tutorial.

Etapa 2. Importar bibliotecas do AWS Glue

Você precisa configurar seu script para interagir com código e configuração que sejam definidos fora do script. Esse trabalho é feito nos bastidores no AWS Glue Studio.

Nesta etapa, você executará as ações a seguir.

- Importe e inicialize um objeto `GlueContext`. Do ponto de vista de criação do script, essa é a importação mais importante. Essa ação expõe métodos padrão para definir conjuntos de dados de origem e destino, que são o ponto de partida para qualquer script de ETL. Para saber mais a respeito da classe `GlueContext`, consulte Classe GlueContext.
- Inicialize um `SparkContext` e `SparkSession`. Fazer isso permite que você configure o mecanismo Spark disponível dentro do trabalho do AWS Glue. Você não precisará usá-lo diretamente nos scripts introdutórios do AWS Glue.
- Chame `getResolvedOptions` para preparar seus argumentos de trabalho para uso no script. Para obter mais informações sobre como resolver parâmetros de trabalho, consulte the section called “getResolvedOptions”.
- Inicialize um `Job`. O objeto de `Job` define a configuração e rastreia o estado de diversoss recursos opcionais do AWS Glue. Seu script pode ser executado sem um objeto de `Job`, mas a prática recomendada é inicializá-lo para que você não se confunda se esses recursos forem integrados posteriormente.

  Um desses recursos está nos marcadores de trabalho, que você pode configurar opcionalmente neste tutorial. Saiba mais sobre marcadores de trabalho na seção a seguir, the section called “Opcional: habilitar marcadores de trabalho”.

Neste procedimento, você vai escrever o código a seguir. Esse código é uma parte do script de exemplo gerado.

```
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)
```

Para importar bibliotecas do AWS Glue

- Copie essa seção de código e cole-a no editor de Script.

> **Note**
>
> Talvez você considere a ação de copiar o código uma prática inadequada de engenharia. Neste tutorial, sugerimos isso para incentivar você a nomear consistentemente suas principais variáveis em todos os scripts de ETL do AWS Glue.

Etapa 3. Extrair dados de uma fonte

Em qualquer processo de ETL, primeiro é necessário definir um conjunto de dados de origem que você deseje alterar. No editor visual do AWS Glue Studio, você fornece essas informações criando um nó Source (Origem).

Nesta etapa, você fornece ao método `create_dynamic_frame.from_catalog` um `database` e um `table_name` para extrair dados de uma origem configurada no AWS Glue Data Catalog.

Na etapa anterior, você inicializou um objeto `GlueContext`. Você usa esse objeto para encontrar métodos que são usados para configurar origens, como `create_dynamic_frame.from_catalog`.

Neste procedimento, você escreverá o código a seguir usando `create_dynamic_frame.from_catalog`. Esse código é uma parte do script de exemplo gerado.

```
S3bucket_node1 = glueContext.create_dynamic_frame.from_catalog(
    database="yyz-tickets", table_name="tickets", transformation_ctx="S3bucket_node1"
    )
```

Para extrair dados de uma fonte

1. Confira a documentação para encontrar um método em `GlueContext` para extrair dados de uma fonte definida no AWS Glue Data Catalog. Esses métodos estão documentados em the section called “GlueContext”. Escolha o método create_dynamic_frame.from_catalog. Chame esse método em `glueContext`.

2. Confira a documentação para `create_dynamic_frame.from_catalog`. Esse método requer os parâmetros `database` e `table_name`. Forneça os parâmetros necessários para `create_dynamic_frame.from_catalog`.

   O AWS Glue Data Catalog armazena informações sobre a localização e o formato dos dados de origem e foi configurado na seção de pré-requisitos. Você não precisa fornecer diretamente essas informações ao seu script.

3. Opcional: forneça o parâmetro `transformation_ctx` ao método para oferecer suporte aos marcadores do trabalho. Você pode aprender sobre marcadores de trabalho na seção a seguir, the section called “Opcional: habilitar marcadores de trabalho”.

> **Note**
>
> Métodos comuns para extrair dados
> the section called “create_dynamic_frame_from_catalog” é usado para se conectar a tabelas no AWS Glue Data Catalog.
> Caso precise fornecer diretamente ao seu trabalho uma configuração que descreva a estrutura e o local da sua fonte, consulte o método the section called “create_dynamic_frame_from_options”. Você precisará fornecer parâmetros mais detalhados descrevendo seus dados do que seria necessário ao usar `create_dynamic_frame.from_catalog`.
> Consulte a documentação complementar sobre `format_options` e `connection_parameters` para identificar os parâmetros necessários. Para obter uma explicação sobre como fornecer informações sobre o formato de dados de origem ao script, consulte the section called “Opções de formato de dados”. Para obter uma explicação sobre como fornecer ao script informações sobre a localização dos dados de origem, consulte the section called “Parâmetros de conexão”.
> Se você estiver lendo informações de uma fonte de transmissão, forneça ao seu trabalho as informações da fonte por meio do método the section called “create_data_frame_from_catalog” ou the section called “create_data_frame_from_options”.
> Observe que esses métodos retornam `DataFrames` do Apache Spark.
> Nosso código gerado chama `create_dynamic_frame.from_catalog`, enquanto a documentação de referência faz referência a `create_dynamic_frame_from_catalog`. Em última análise, esses métodos chamam o mesmo código e estão incluídos para que você possa escrever um código mais limpo. Você pode verificar isso visualizando o código-fonte do nosso wrapper Python, disponível em aws-glue-libs.

Etapa 4. Transformar dados com o AWS Glue

Depois de extrair os dados da fonte em um processo de ETL, você precisa descrever como deseja alterar seus dados. Você fornece essas informações criando um nó Transform (Transformação) no editor visual do AWS Glue Studio.

Nesta etapa, forneça ao método `ApplyMapping` um mapa dos nomes e tipos de campos atuais e desejados para transformar seu `DynamicFrame`.

Você executa as seguintes transformações.

- Descartar as quatro chaves `location` e `province`.
- Alterar o nome de `officer` para `officer_name`.
- Alterar o tipo de `ticket_number` e `set_fine_amount` para `float`.

`create_dynamic_frame.from_catalog` fornece a você um objeto `DynamicFrame`. Um `DynamicFrame` representa um conjunto de dados no AWS Glue. AWS As transformações do Glue são operações que alteram `DynamicFrames`.

> **Note**
>
> O que é um `DynamicFrame`?
> Um `DynamicFrame` é uma abstração que permite conectar um conjunto de dados com uma descrição dos nomes e tipos de entradas nos dados. No Apache Spark, há uma abstração similar chamada DataFrame. Para obter uma explicação sobre DataFrames, consulte o Spark SQL Guide (Guia de SQL do Spark).
> Com `DynamicFrames`, você pode descrever esquemas de conjuntos de dados dinamicamente. Considere um conjunto de dados com uma coluna de preço, em que algumas entradas armazenam o preço como uma string e outras armazenam o preço como uma dupla. O AWS O Glue calcula um esquema rapidamente, criando um registro autodescritivo para cada linha.
> Campos inconsistentes (como preço) são representados explicitamente com um tipo (`ChoiceType`) no esquema do quadro. Você pode lidar com campos inconsistentes descartando-os com `DropFields` ou solucionando-os com `ResolveChoice`. Essas são transformações que estão disponíveis no `DynamicFrame`. Em seguida, você pode gravar seus dados de volta em seu data lake com `writeDynamicFrame`.

Você pode chamar muitas das mesmas transformações a partir de métodos na classe `DynamicFrame`, que pode levar a scripts mais fáceis de ler. Para obter mais informações sobre o `DynamicFrame`, consulte the section called “DynamicFrame”.

Neste procedimento, você escreverá o código a seguir usando `ApplyMapping`. Esse código é uma parte do script de exemplo gerado.

```
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",
)
```

Para transformar dados com o AWS Glue

1. Examine a documentação para identificar uma transformação para alterar e descartar campos. Para obter detalhes, consulte the section called “GlueTransform”. Escolha a transformação `ApplyMapping`. Para obter mais informações sobre o `ApplyMapping`, consulte the section called “ApplyMapping”. Chame `apply` no objeto de transformação `ApplyMapping`.

   > **Note**
   >
   > O que é o `ApplyMapping`?
   > `ApplyMapping` pega um `DynamicFrame` e o transforma. Ele obtém uma lista de tuplas que representa transformações nos campos, um “mapeamento”. Os dois primeiros elementos de tupla, um nome e um tipo de campo, são usados para identificar um campo no quadro. Os dois segundos parâmetros também são um nome e um tipo de campo.

ApplyMapping converterá o campo de origem no nome e tipo de destino em um novo `DynamicFrame`, que será retornado. Campos que não forem fornecidos serão descartados no valor retornado.
Em vez de chamar `apply`, você pode chamar a mesma transformação com o método `apply_mapping` no `DynamicFrame` para criar um código mais fluente e legível. Para obter mais informações, consulte the section called “apply_mapping”.

2. Para identificar os parâmetros necessários, confira a documentação sobre `ApplyMapping`. Consulte the section called “ApplyMapping”. Você descobrirá que esse método requer os parâmetros `frame` e `mappings`. Forneça os parâmetros necessários para `ApplyMapping`.
3. Opcional: forneça `transformation_ctx` ao método para dar suporte a marcadores de trabalho. Você pode aprender sobre marcadores de trabalho na seção a seguir, the section called “Opcional: habilitar marcadores de trabalho”.

> **Note**
>
> Funcionalidade do Apache Spark
> Fornecemos as transformações para agilizar os fluxos de trabalho de ETL em seu trabalho. Você também tem acesso às bibliotecas que estão disponíveis em um programa do Spark no seu trabalho, criadas para uso mais geral. Para usá-las, converta entre `DynamicFrame` e `DataFrame`.
> É possível criar um `DataFrame` com the section called “toDF”. Em seguida, você pode usar os métodos disponíveis no DataFrame para transformar seu conjunto de dados. Para obter mais informações sobre esses métodos, consulte DataFrame. Em seguida, você pode converter ao contrário com the section called “fromDF” para usar operações do AWS Glue para carregar sua estrutura em um destino.

Etapa 5. Carregar dados em um destino

Depois de transformar seus dados, normalmente você armazena os dados transformados em um local diferente da fonte. Você executa essa operação criando um nó meta no editor visual do AWS Glue Studio.

Nesta etapa, você fornecerá ao método `write_dynamic_frame.from_options` um `connection_type`, `connection_options`, `format` e `format_options` para carregar dados em um bucket de destino no Amazon S3.

Na Etapa 1, você inicializou um objeto `GlueContext`. No AWS Glue, é nesse local que você encontrará os métodos que são usados para configurar destinos, de maneira semelhante às fontes.

Neste procedimento, você escreverá o código a seguir usando `write_dynamic_frame.from_options`. Esse código é uma parte do script de exemplo gerado.

```
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",
    )
```

Para carregar dados em um destino

1. Confira a documentação a fim de encontrar um método para carregar dados em um bucket de destino do Amazon S3. Esses métodos estão documentados em the section called “GlueContext”. Escolha o método the section called “write_dynamic_frame_from_options”. Chame esse método em `glueContext`.

   > **Note**
   >
   > Métodos comuns para carregar dados
   >
   > `write_dynamic_frame.from_options` é o método mais comum usado para carregar dados. Ele oferece suporte a todos os destino disponíveis no AWS Glue. Se você estiver gravando em um destino JDBC definido em uma conexão do AWS Glue, use o método the section called “write_dynamic_frame_from_jdbc_conf”. As conexões do AWS Glue armazenam informações sobre como estabelecer conexão com uma fonte de dados. Isso elimina a necessidade de fornecer essas informações no `connection_options`. No entanto, você ainda precisa usar `connection_options` para fornecer `dbtable`.
   >
   > `write_dynamic_frame.from_catalog` não é um método comum para carregar dados. Esse método atualiza o AWS Glue Data Catalog sem atualizar o conjunto de dados subjacente, sendo usado em combinação com outros processos que alteram o conjunto de dados subjacente. Para obter mais informações, consulte the section called “Atualizar o esquema e adicionar novas partições”.

2. Confira a documentação para the section called “write_dynamic_frame_from_options”. Esse método requer `frame`, `connection_type`, `format`, `connection_options` e `format_options`. Chame esse método em `glueContext`.

   a. Consulte a documentação suplementar sobre `format_options` e `format` para identificar os parâmetros necessários. Para obter uma explicação sobre os formatos de dados, consulte the section called “Opções de formato de dados”.

   b. Consulte a documentação suplementar sobre `connection_type` e `connection_options` para identificar os parâmetros necessários. Para obter uma explicação sobre as conexões, consulte the section called “Parâmetros de conexão”.

   c. Forneça os parâmetros necessários para `write_dynamic_frame.from_options`. Esse método tem uma configuração similar a `create_dynamic_frame.from_options`.

3. Opcional: forneça `transformation_ctx` a `write_dynamic_frame.from_options` para dar suporte a marcadores de trabalho. Você pode aprender sobre marcadores de trabalho na seção a seguir, the section called “Opcional: habilitar marcadores de trabalho”.

Etapa 6. Confirmar o objeto **`Job`**

Você inicializou um objeto `Job` na Etapa 1. Poderá ser necessário realizar manualmente seu ciclo de vida no final do script se determinados recursos opcionais precisarem disso para funcionar corretamente, como ao usar marcadores de trabalho. Esse trabalho é feito nos bastidores no AWS Glue Studio.

Nessa etapa, Chame o método `commit` no objeto `Job`.

Neste procedimento, você vai escrever o código a seguir. Esse código é uma parte do script de exemplo gerado.

```
job.commit()
```

Para confirmar o objeto **`Job`**

1. Caso ainda não tenha feito isso, execute as etapas opcionais descritas nas seções anteriores para incluir `transformation_ctx`.
2. Chame `commit`.

Opcional: habilitar marcadores de trabalho

Em cada etapa anterior, você recebeu instruções para definir parâmetros `transformation_ctx`. Isso está relacionado a um recurso chamado marcadores de trabalho.

Com marcadores de trabalho, você pode economizar tempo e dinheiro com trabalhos executados de maneira recorrente, em comparação com conjuntos de dados nos quais trabalhos anteriores podem ser facilmente rastreados. Os marcadores de trabalho acompanham o progresso de uma transformação do AWS Glue em um conjunto de dados de execuções anteriores. Ao rastrear os locais em que as execuções anteriores terminaram, o AWS Glue pode limitar o trabalho a linhas que não tenham sido processadas anteriormente. Para obter mais informações sobre marcadores de trabalho, consulte the section called “Rastrear dados processados usando marcadores de trabalho”.

Para ativar os marcadores de trabalho, primeiro adicione as declarações de `transformation_ctx` às nossas funções fornecidas, conforme descrito nos exemplos anteriores. O estado do marcador de trabalho é mantido em todas as execuções. Parâmetros de `transformation_ctx` são chaves usadas para acessar esse estado. Sozinhas, essas declarações não farão nada. Você também precisa ativar o recurso na configuração do seu trabalho.

Neste procedimento, você habilita os marcadores de trabalho usando o AWS Management Console.

Para definir marcadores de trabalho

1. Acesse a seção Job details (Detalhes de trabalho) do seu trabalho correspondente.
2. Defina Job bookmark (Marcador de trabalho) como Enable (Habilitar).

Etapa 7. Execute seu código como um trabalho

Nesta etapa, você executa seu trabalho para verificar se concluiu este tutorial com êxito. Isso é feito com o clique de um botão, como no editor visual do AWS Glue Studio.

Para executar seu código como um trabalho

1. Escolha Untitled job (Trabalho sem título) na barra de título para editar e definir o nome do seu trabalho.
2. Acesse a guia Job details (Detalhes do trabalho). Atribua um IAM Role (Perfil do IAM) ao seu trabalho. Você pode usar o que foi criado pelo modelo do AWS CloudFormation nos pré-requisitos para o tutorial do AWS Glue Studio. Se tiver concluído esse tutorial, ele deve estar disponível como `AWS Glue StudioRole`.

3. Escolha Save (Salvar) para salvar seu script.
4. Escolha Run (Executar) para executar seu trabalho.
5. Navegue até a guia Runs (Execuções) para verificar se seu trabalho foi concluído.
6. Navegue até *amzn-s3-demo-bucket*, o destino para `write_dynamic_frame.from_options`. Confirme se o resultado corresponde às suas expectativas.

Para obter mais informações sobre como configurar e gerenciar trabalhos, consulte the section called "Fornecer seus próprios scripts personalizados".

Mais informações

As bibliotecas e métodos do Apache Spark estão disponíveis nos scripts do AWS Glue. Você pode consultar a documentação do Spark para entender o que pode fazer com as bibliotecas incluídas. Para obter mais informações, consulte a seção de exemplos do repositório de origem do Spark.

O AWS Glue 2.0+ inclui várias bibliotecas comuns do Python por padrão. Também existem mecanismos para carregar suas próprias dependências em um trabalho do AWS Glue em um ambiente Scala ou Python. Consulte the section called "Bibliotecas Python" para obter informações sobre dependências do Python.

Para obter mais exemplos sobre como usar os recursos do AWS Glue no Python, consulte the section called "Exemplos de Python". Os trabalhos no Scala e no Python têm paridade de recursos; sendo assim, nossos exemplos do Python devem dar algumas ideias sobre como executar trabalhos semelhantes no Scala.

Programar scripts de ETL do AWS Glue em PySpark

É possível encontrar exemplos de código Python e utilitários para o AWS Glue no repositório de exemplos do AWS Glue no site do GitHub.

Usar o Python com o AWS Glue

O AWS Glue oferece suporte a uma extensão do dialeto PySpark Python para criar scripts de trabalhos de extração, transformação e carregamento (ETL). Esta seção descreve como usar o Python em scripts de ETL e com a API do AWS Glue.

- Configurar Python para uso com o AWS Glue

- Chamar APIs do AWS Glue no Python
- Usar bibliotecas Python com o AWS Glue
- Exemplos de código Python do AWS Glue

Extensões PySpark do AWS Glue

O AWS Glue criou as seguintes extensões para o dialeto PySpark Python.

- Acessar parâmetros usando `getResolvedOptions`
- Tipos de extensão do PySpark
- Classe DynamicFrame
- Classe DynamicFrameCollection
- Classe DynamicFrameWriter
- Classe DynamicFrameReader
- Classe GlueContext

Transformações PySpark do AWS Glue

O AWS Glue criou as seguintes classes de transformação para uso em operações de ETL do PySpark.

- Classe de base GlueTransform
- Classe ApplyMapping
- Classe DropFields
- Classe DropNullFields
- Classe ErrorsAsDynamicFrame
- Classe FillMissingValues
- Classe Filter
- Classe FindIncrementalMatches
- Classe FindMatches
- Classe FlatMap
- Classe Join
- Classe Map

- Classe MapToCollection
- mergeDynamicFrame
- Classe Relationalize
- Classe RenameField
- Classe ResolveChoice
- Classe SelectFields
- Classe SelectFromCollection
- Classe Spigot
- Classe SplitFields
- Classe SplitRows
- Classe Unbox
- Classe UnnestFrame

Configurar Python para uso com o AWS Glue

Use o Python para desenvolver seus scripts de ETL para trabalhos do Spark. As versões do Python compatíveis para trabalhos de ETL dependem da versão do AWS Glue do trabalho. Para obter mais informações sobre versões do AWS Glue, consulte Glue version job property.

Para configurar o sistema para usar o Python com o AWS Glue

Siga estas etapas para instalar o Python e invocar as APIs do AWS Glue.

1. Se você ainda não tem o Python instalado, faça download dele e instale-o acessando a página de download Python.org.
2. Instale a AWS Command Line Interface (AWS CLI) conforme descrito na Documentação da AWS CLI.

   A AWS CLI não é necessária para usar o Python. No entanto, instalar e configurar a CLI é uma maneira conveniente de configurar a AWS com as credenciais da sua conta e verificar se elas funcionam.
3. Instale o AWS SDK for Python (Boto 3), conforme descrito no Guia de início rápido do Boto3.

   As APIs de recursos do Boto 3 ainda não estão disponíveis no AWS Glue. Atualmente, apenas as APIs de cliente do Boto 3 podem ser usadas.

> Para obter mais informações sobre o Boto 3, consulte Conceitos básicos do AWS SDK for Python (Boto3).

É possível encontrar exemplos de código Python e utilitários para o AWS Glue no repositório de exemplos do AWS Glue no site do GitHub.

Chamar APIs do AWS Glue no Python

Observação: as APIs de recursos do Boto 3 ainda não estão disponíveis no AWS Glue. Atualmente, apenas as APIs de cliente do Boto 3 podem ser usadas.

Nomes de API do AWS Glue em Python

Os nomes de API do AWS Glue em Java e em outras linguagens de programação geralmente misturam letras maiúsculas e minúsculas. No entanto, quando chamados no Python, esses nomes genéricos são alterados para minúsculas, com partes do nome separadas por caracteres de sublinhado para deixá-los com uma aparência mais familiar para usuários do Python. Na documentação de referência da API do AWS Glue, esses nomes do Python estão listados entre parênteses, após os nomes genéricos com letras minúsculas e maiúsculas misturadas.

Embora as letras dos nomes de API do AWS Glue sejam transformadas em minúsculas, seus nomes de parâmetros permanecem em letras maiúsculas. Lembre-se disso porque os parâmetros devem ser transmitidos pelo nome ao chamar APIs do AWS Glue, conforme descrito na seção a seguir.

Transmitir e acessar parâmetros de Python no AWS Glue

Nas chamadas do Python para APIs do AWS Glue, é melhor transmitir os parâmetros explicitamente por nome. Por exemplo:

```
job = glue.create_job(Name='sample', Role='Glue_DefaultRole',
                      Command={'Name': 'glueetl',
                               'ScriptLocation': 's3://my_script_bucket/scripts/
my_etl_script.py'})
```

O Python cria um dicionário das tuplas de nome/valor que você especifica como argumentos para um script de ETL em um Estrutura Job ou Estrutura JobRun. Em seguida, o Boto 3 transmite para o AWS Glue no formato JSON por meio de uma chamada de API REST. Isso significa que você não pode confiar na ordem dos argumentos ao acessá-los no seu script.

Por exemplo, suponha que você esteja iniciando um `JobRun` em uma função de handler Lambda do Python e queira especificar vários parâmetros. Seu código será parecido com este:

```
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 } )
```

Para acessar esses parâmetros de forma confiável no seu script de ETL, especifique-os pelo nome usando a função `getResolvedOptions` do AWS Glue e, em seguida, acesse-os no dicionário resultante:

```
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']
```

Se você quiser transmitir um argumento que seja uma string JSON aninhada, para preservar o valor do parâmetro à medida que ele é transmitido para o seu trabalho de ETL do AWS Glue, você deve codificar a string de parâmetro antes de iniciar a execução do trabalho e, em seguida, decodificar a string de parâmetro antes de fazer referência ao script de trabalho. Por exemplo, considere a seguinte string de argumento:

```
glue_client.start_job_run(JobName = "gluejobname", Arguments={
"--my_curly_braces_string": '{"a": {"b": {"c": [{"d": {"e": 42}}]}}}'
})
```

Para transmitir esse parâmetro corretamente, você deve codificar o argumento como uma string codificada em 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}")
...
```

Exemplo: criar e executar um trabalho

O exemplo a seguir mostra como chamar APIs do AWS Glue usando Python para criar e executar um trabalho de ETL.

Para criar e executar um trabalho

1. Crie uma instância do cliente AWS Glue:

   ```
   import boto3
   glue = boto3.client(service_name='glue', region_name='us-east-1',
                 endpoint_url='https://glue.us-east-1.amazonaws.com')
   ```

2. Crie um trabalho. Você precisa usar `glueetl` como o nome do comando de ETL, conforme mostrado no código a seguir:

   ```
   myJob = glue.create_job(Name='sample', Role='Glue_DefaultRole',
                           Command={'Name': 'glueetl',
   ```

```
                                    'ScriptLocation': 's3://my_script_bucket/
scripts/my_etl_script.py'})
```

3. Inicie uma nova execução do trabalho que você criou na etapa anterior:

```
myNewJobRun = glue.start_job_run(JobName=myJob['Name'])
```

4. Veja o status do trabalho:

```
status = glue.get_job_run(JobName=myJob['Name'], RunId=myNewJobRun['JobRunId'])
```

5. Imprima o estado atual da execução do trabalho:

```
print(status['JobRun']['JobRunState'])
```

Usar bibliotecas Python com o AWS Glue

O AWS Glue permite que você instale módulos e bibliotecas Python adicionais para uso com ETL do AWS Glue.

Tópicos

- Instalar bibliotecas Python adicionais no AWS Glue 5.0 usando o arquivo requirements.txt
- Instalar módulos Python adicionais com pip no AWS Glue 2.0 ou posterior
- Inclusão de arquivos Python com recursos nativos do PySpark
- Scripts de programação que usam transformações visuais
- Módulos do Python já fornecidos no AWS Glue
- Compactar bibliotecas para inclusão
- Carregar bibliotecas do Python em cadernos do AWS Glue Studio
- Carregar bibliotecas Python em um endpoint de desenvolvimento
- Usar bibliotecas Python em trabalho ou JobRun

Instalar bibliotecas Python adicionais no AWS Glue 5.0 usando o arquivo requirements.txt

No AWS Glue 5.0, você pode fornecer o arquivo `requirements.txt` padrão de fábrica para gerenciar as dependências da biblioteca Python. Para fazer isso, forneça os seguintes dois parâmetros de trabalho:

- Chave: `--python-modules-installer-option`

  Valor: `-r`
- Chave: `--additional-python-modules`

  Valor: `s3://path_to_requirements.txt`

Os nós do AWS Glue 5.0 carregam inicialmente as bibliotecas Python especificadas em `requirements.txt`. Exemplo de requirements.txt:

```
awswrangler==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
```

Instalar módulos Python adicionais com pip no AWS Glue 2.0 ou posterior

O AWS Glue usa o Python Package Installer (pip3) para instalar módulos adicionais a serem usados pelo ETL do AWS Glue. Você pode usar o parâmetro `--additional-python-modules` com uma lista de módulos do Python separados por vírgulas para adicionar um novo módulo ou alterar a versão de um módulo existente. Você pode instalar distribuições personalizadas de uma biblioteca carregando a distribuição para o Amazon S3 e incluindo o caminho para o objeto do Amazon S3 na sua lista de módulos.

Você pode transmitir opções adicionais para o pip3 com o parâmetro `--python-modules-installer-option`. Por exemplo, você pode transmitir `"--upgrade"` para atualizar os pacotes especificados por `"--additional-python-modules"`. Para obter mais exemplos, consulte Desenvolver módulos do Python de um wheel para workloads de ETL do Spark usando o AWS Glue 2.0.

Se suas dependências do Python dependerem provisoriamente de código compilado nativo, você poderá se deparar com a seguinte limitação: o AWS Glue não é compatível com a compilação de código nativo no ambiente de trabalho. No entanto, os trabalhos do AWS Glue são executados em

um ambiente Amazon Linux 2. Talvez você possa fornecer suas dependências nativas em formato compilado por meio de um distribuível Wheel.

Por exemplo, para atualizar ou adicionar um novo módulo `scikit-learn`, use a seguinte chave-valor: `"--additional-python-modules", "scikit-learn==0.21.3"`.

Além disso, dentro da opção `--additional-python-modules`, você pode especificar um caminho do Amazon S3 para um módulo wheel do Python. Por exemplo:

```
--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
```

Especifique `--additional-python-modules` no campo Parâmetros de trabalho do console do AWS Glue ou alterando os argumentos do trabalho no AWS SDK. Para obter mais informações sobre como configurar parâmetros de trabalho, consulte the section called “Parâmetros de trabalho”.

Inclusão de arquivos Python com recursos nativos do PySpark

O AWS Glue usa PySpark para incluir arquivos Python em trabalhos de ETL do AWS Glue. Recomenda-se usar `--additional-python-modules` para gerenciar suas dependências quando disponíveis. Você pode usar o parâmetro de trabalho `--extra-py-files` para incluir arquivos Python. As dependências devem ser hospedadas no Amazon S3, e o valor do argumento deve ser uma lista delimitada por vírgulas de caminhos do Amazon S3 sem espaços. Essa funcionalidade se comporta como o gerenciamento de dependências do Python que você usaria com o Spark. Para obter mais informações sobre o gerenciamento de dependências do Python no Spark, consulte a página Using PySpark Native Features (Usar recursos nativos do PySpark) na documentação do Apache Spark. `--extra-py-files` é útil em casos nos quais seu código adicional não está empacotado ou quando você está migrando um programa Spark com uma cadeia de ferramentas existente para gerenciar dependências. Para que suas ferramentas de dependência sejam passíveis de manutenção, você precisará empacotar suas dependências antes de enviá-las.

Scripts de programação que usam transformações visuais

Ao criar uma tarefa do AWS Glue usando a interface visual do AWS Glue Studio, é possível transformar seus dados com nós de transformação de dados gerenciados e transformações visuais personalizadas. Para obter mais informações sobre nós de transformações de dados gerenciados, consulte the section called “Transformar dados com transformações gerenciadas do AWS Glue”. Para obter mais informações sobre transformações visuais personalizadas, consulte the section

called “ Transformar dados com transformações visuais personalizadas ”. Os scripts que usam transformações visuais só poderão ser gerados quando a Linguagem do trabalho estiver configurada para usar Python.

Ao gerar uma tarefa do AWS Glue usando transformações visuais, o AWS Glue Studio incluirá essas transformações no ambiente de runtime usando o parâmetro `--extra-py-files` na configuração da tarefa. Para obter mais informações sobre parâmetros de trabalho, consulte the section called “Parâmetros de trabalho”. Ao fazer alterações em um script gerado ou em um ambiente de runtime, será necessário preservar essa configuração de trabalho para que seu script seja executado com êxito.

Módulos do Python já fornecidos no AWS Glue

Para alterar a versão desses módulos fornecidos, forneça novas versões com o parâmetro de trabalho `--additional-python-modules`.

AWS Glue version 5.0

O AWS Glue versão 5.0 inclui os seguintes módulos do Python prontos para uso:

- aiobotocore==2.13.1
- aiohappyeyeballs==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
- charset-normalizer==3.3.2
- contourpy==1.2.1
- cycler==0.12.1
- fonttools==4.53.1
- frozenlist==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
- packaging==24.1
- pandas==2.2.2
- pillow==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
- requests==2.32.2
- s3fs==2024.6.1
- s3transfer==0.10.2
- seaborn==0.13.2
- setuptools==59.6.0
- six==1.16.0
- tenacity==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

O AWS Glue versão 4.0 inclui os seguintes módulos do Python prontos para uso:

- aiobotocore==2.4.1
- aiohttp==3.8.3
- aioitertools==0.11.0
- aiosignal==1.3.1
- async-timeout==4.0.2
- asynctest==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
- plotly==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

O AWS Glue versão 3.0 inclui os seguintes módulos do Python prontos para uso:

- aiobotocore==1.4.2
- aiohttp==3.8.3
- aioitertools==0.11.0
- aiosignal==1.3.1
- async-timeout==4.0.2
- asynctest==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

O AWS Glue versão 2.0 inclui os seguintes módulos do Python prontos para uso:

- 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

Compactar bibliotecas para inclusão

A menos que uma biblioteca esteja contida em um único arquivo `.py`, ela precisará ser compactada em uma pasta `.zip`. O diretório do pacote deve estar na raiz do arquivo e precisa conter um arquivo `__init__.py` para o pacote. Em seguida, o Python poderá importar o pacote normalmente.

Se a sua biblioteca contém um único módulo Python em um arquivo `.py`, você não precisará compactá-la em uma pasta `.zip`.

Carregar bibliotecas do Python em cadernos do AWS Glue Studio

Para especificar bibliotecas do Python nos cadernos do AWS Glue Studio, consulte Instalação de módulos Python adicionais.

Carregar bibliotecas Python em um endpoint de desenvolvimento

Se você estiver usando diferentes conjuntos de bibliotecas para diferentes scripts de ETL, poderá configurar um endpoint de desenvolvimento separado para cada conjunto ou substituir os arquivos `.zip` da biblioteca carregados pelo seu endpoint de desenvolvimento sempre que os scripts são alternados.

Você pode usar o console para especificar um ou mais arquivos .zip da biblioteca para um endpoint de desenvolvimento ao criá-lo. Depois de atribuir um nome e uma função do IAM, escolha Script Libraries and job parameters (optional) (Bibliotecas de script e parâmetros de trabalho [opcional]) e insira o caminho completo do Amazon S3 para o arquivo `.zip` da sua biblioteca na caixa Python library path (Caminho da biblioteca Python). Por exemplo:

```
s3://bucket/prefix/site-packages.zip
```

Se quiser, você poderá especificar vários caminhos completos para arquivos, separando-os com vírgulas, mas sem espaços, da seguinte maneira:

```
s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/lib_X.zip
```

Se você atualizar esses arquivos `.zip` posteriormente, poderá usar o console para importá-los novamente para o seu endpoint de desenvolvimento. Navegue até o endpoint do desenvolvedor em questão, marque a caixa de seleção ao lado e escolha Update ETL libraries no menu Action.

De forma semelhante, você pode especificar arquivos de biblioteca usando as APIs do AWS Glue. Ao criar um endpoint de desenvolvimento chamando Ação CreateDevEndpoint (Python: create_dev_endpoint), você pode especificar um ou mais caminhos completos para bibliotecas no parâmetro `ExtraPythonLibsS3Path`. Essa chamada é semelhante à seguinte:

```
dep = glue.create_dev_endpoint(
            EndpointName="testDevEndpoint",
            RoleArn="arn:aws:iam::123456789012",
            SecurityGroupIds="sg-7f5ad1ff",
            SubnetId="subnet-c12fdba4",
```

```
            PublicKey="ssh-rsa AAAAB3NzaC1yc2EAAAADAQABAAABAQCtp04H/y...",
            NumberOfNodes=3,
            ExtraPythonLibsS3Path="s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/
lib_X.zip")
```

Ao atualizar um endpoint de desenvolvimento, você também pode atualizar as bibliotecas que ele carrega usando um objeto DevEndpointCustomLibraries e definindo o parâmetro `UpdateEtlLibraries` como `True` ao chamar UpdateDevEndpoint (update_dev_endpoint).

Usar bibliotecas Python em trabalho ou JobRun

Ao criar um novo trabalho no console, você pode especificar um ou mais arquivos .zip de biblioteca escolhendo a opção Script Libraries and job parameters (optional) (Bibliotecas de script e parâmetros de trabalho [opcional]) e inserindo os caminhos completos das bibliotecas do Amazon S3, da mesma maneira como você faria ao criar um endpoint de desenvolvimento:

```
s3://bucket/prefix/lib_A.zip,s3://bucket_B/prefix/lib_X.zip
```

Se você estiver chamando CreateJob (create_job), poderá especificar um ou mais caminhos completos para bibliotecas padrão usando o parâmetro padrão `--extra-py-files`, da seguinte maneira:

```
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'})
```

Assim, quando estiver iniciando um JobRun, você poderá substituir a configuração da biblioteca padrão por uma diferente:

```
runId = glue.start_job_run(JobName='sampleJob',
                           Arguments={'--extra-py-files': 's3://bucket/prefix/
lib_B.zip'})
```

Exemplos de código Python do AWS Glue

- Exemplo de código: juntar e relacionar dados

- Exemplo de código: preparo de dados usando ResolveChoice, Lambda e ApplyMapping

Exemplo de código: juntar e relacionar dados

Este exemplo usa um conjunto de dados obtidos por download no site http://everypolitician.org/ para o bucket `sample-dataset` no Amazon Simple Storage Service (Amazon S3): `s3://awsglue-datasets/examples/us-legislators/all`. O conjunto de dados contém dados no formato JSON sobre os legisladores dos Estados Unidos e os assentos que eles ocuparam na Câmara dos Deputados e no Senado Americano e foi ligeiramente modificado e disponibilizado em um bucket público do Amazon S3 para a finalidade deste tutorial.

Você pode encontrar o código-fonte para este exemplo no arquivo `join_and_relationalize.py` no repositório de exemplos do AWS Glue no site do GitHub.

Usando esses dados, você realizará os procedimentos a seguir:

- Use um crawler do AWS Glue para classificar objetos armazenados em um bucket público do Amazon S3 e salvar seus esquemas no catálogo de dados do Glue da AWS.
- Examine os metadados e esquemas da tabela resultantes do rastreamento.
- Escreva um script Python de extração, transferência e carregamento (ETL) que usa os metadados no Data Catalog para fazer o seguinte:
  - Juntar dados nos diferentes arquivos de fonte em uma única tabela de dados (ou seja, desnormalizar os dados).
  - Filtrar a tabela reunida em tabelas separadas por tipo de legislador.
  - Gravar dados resultantes em arquivos Apache Parquet separados para análise posterior.

A forma preferida de depurar scripts do Python ou do PySpark durante a execução na AWS é usar cadernos no AWS Glue Studio.

Etapa 1: crawling de dados no bucket do Amazon S3

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Siga as etapas em Configurar um crawler para criar um novo crawler que possa fazer crawling no conjunto de dados `s3://awsglue-datasets/examples/us-legislators/all` em um banco de dados nomeado `legislators` no AWS Glue Data Catalog. Os dados de exemplo já estão nesse bucket público do Amazon S3.

3. Execute o novo crawler e, em seguida, verifique o banco de dados `legislators`.

   O crawler cria as seguintes tabelas de metadados:

   - `persons_json`
   - `memberships_json`
   - `organizations_json`
   - `events_json`
   - `areas_json`
   - `countries_r_json`

   Esta é uma coleção seminormalizada de tabelas que contêm legisladores e suas histórias.

Etapa 2: adicionar o script de boilerplate ao caderno do endpoint de desenvolvimento

Cole o seguinte script de boilerplate no caderno do endpoint de desenvolvimento para importar as bibliotecas do AWS Glue necessárias e configure um único `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())
```

Etapa 3: examinar os esquemas dos dados no Data Catalog

Em seguida, você pode facilmente criar e examinar um DynamicFrame a partir do AWS Glue Data Catalog e examinar os esquemas dos dados. Por exemplo, para ver o esquema da tabela `persons_json`, adicione o seguinte ao seu caderno:

```
persons = glueContext.create_dynamic_frame.from_catalog(
            database="legislators",
            table_name="persons_json")
print "Count: ", persons.count()
```

```
persons.printSchema()
```

Veja a seguir a saída das chamadas de impressão:

```
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
```

Cada pessoa na tabela é membro de algum órgão do Congresso dos EUA.

Para visualizar o esquema da tabela `memberships_json`, digite o seguinte:

```
memberships = glueContext.create_dynamic_frame.from_catalog(
```

```
                database="legislators",
                table_name="memberships_json")
print "Count: ", memberships.count()
memberships.printSchema()
```

A saída é a seguinte:

```
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
```

As `organizations` são partidos e as duas Câmaras do Congresso, o Senado e a Câmara dos Deputados. Para visualizar o esquema da tabela `organizations_json`, digite o seguinte:

```
orgs = glueContext.create_dynamic_frame.from_catalog(
           database="legislators",
           table_name="organizations_json")
print "Count: ", orgs.count()
orgs.printSchema()
```

A saída é a seguinte:

```
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
```

Etapa 4: filtrar os dados

Em seguida, mantenha apenas os campos desejados e renomeie `id` como `org_id`. O conjunto de dados é pequeno o suficiente para que você possa vê-lo por completo.

O `toDF()` converte um `DynamicFrame` em um `DataFrame` do Apache Spark, para que você possa aplicar as transformações já existentes no Apache Spark SQL:

```
orgs = orgs.drop_fields(['other_names',
                         'identifiers']).rename_field(
                             'id', 'org_id').rename_field(
                                'name', 'org_name')
orgs.toDF().show()
```

Veja a saída a seguir:

```
+--------------+--------------------+--------------------+--------------------+-----
+-----------+--------------------+
|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|
+--------------+--------------------+--------------------+--------------------+-----
+-----------+--------------------+
```

Digite o seguinte para visualizar `organizations` que aparecem em `memberships`:

```
memberships.select_fields(['organization_id']).toDF().distinct().show()
```

Veja a saída a seguir:

```
+--------------------+
|     organization_id|
+--------------------+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+--------------------+
```

Etapa 5: integrar tudo

Agora, use o AWS Glue para juntar essas tabelas relacionais e criar uma tabela de histórico completa do legislador `memberships` e suas correspondentes `organizations`.

1. Primeiro, junte `persons` e `memberships` em `id` e `person_id`.
2. Em seguida, junte o resultado com `orgs` em `org_id` e `organization_id`.
3. Coloque os campos redundantes `person_id` e `org_id`.

Você pode fazer todas essas operações em uma linha de código (extensa):

```
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()
```

A saída é a seguinte:

```
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
```

Agora você tem a tabela final que pode usar para análise. Você pode gravar em um formato compacto e eficiente para análise (ou seja, Parquet) que permita a execução de SQL no AWS Glue, no Amazon Athena ou no Amazon Redshift Spectrum.

A seguinte chamada grava a tabela em vários arquivos para suportar leituras paralelas rápidas ao fazer a análise posteriormente:

```
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")
```

Para colocar todos os dados do histórico em um único arquivo, você precisa convertê-los em um quadro de dados, reparticioná-los e gravá-los:

```
s_history = l_history.toDF().repartition(1)
s_history.write.parquet('s3://glue-sample-target/output-dir/legislator_single')
```

Se preferir, você pode separá-los por "Senado" e "Câmara":

```
l_history.toDF().write.parquet('s3://glue-sample-target/output-dir/legislator_part',
                               partitionBy=['org_name'])
```

Etapa 6: transformar os dados para bancos de dados relacionais

O AWS Glue facilita a gravação dos dados em bancos de dados relacionais, como o Amazon RedShift, mesmo com dados semiestruturados. Ele oferece uma transformação `relationalize`, que nivela `DynamicFrames` independentemente da complexidade dos objetos no quadro.

Usando o `l_history` `DynamicFrame` neste exemplo, transmita o nome da tabela raiz (`hist_root`) e um caminho de trabalho temporário para `relationalize`. Isso retorna um `DynamicFrameCollection`. Você pode então os nomes dos `DynamicFrames` nessa coleção:

```
dfc = l_history.relationalize("hist_root", "s3://glue-sample-target/temp-dir/")
dfc.keys()
```

Veja a seguir a saída da chamada `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` quebrou a tabela de histórico em seis novas tabelas: uma tabela raiz que contém um registro para cada objeto no `DynamicFrame`, e tabelas auxiliares para as matrizes. O gerenciamento de matrizes em bancos de dados relacionais geralmente é pouco satisfatório, principalmente porque essas matrizes ficam grandes. Separar as matrizes em diferentes tabelas torna as consultas muito mais rápidas.

Em seguida, verifique a separação examinando `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()
```

Veja a seguir a saída da chamada `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|
+---+-----+-----------------------+-------------------------+
```

O campo `contact_details` era uma matriz de estruturas no `DynamicFrame` original. Cada elemento dessas matrizes é uma linha separada na tabela auxiliar, indexada por `index`. Aqui, `id` é uma chave externa na tabela `hist_root` com a chave `contact_details`:

```
dfc.select('hist_root').toDF().where(
    "contact_details = 10 or contact_details = 75").select(
       ['id', 'given_name', 'family_name', 'contact_details']).show()
```

Esta é a saída:

```
+--------------------+----------+-----------+---------------+
|                  id|given_name|family_name|contact_details|
+--------------------+----------+-----------+---------------+
|f4fc30ee-7b42-432...|      Mike|       Ross|             10|
|e3c60f34-7d1b-4c0...|   Shelley|     Capito|             75|
+--------------------+----------+-----------+---------------+
```

Nestes comandos, as expressões `toDF()` e `where` são usadas para filtrar as linhas que você quer ver.

Portanto, ao juntar a tabela `hist_root` e as tabelas auxiliares, você pode fazer o seguinte:

- Carregar dados em bancos de dados sem suporte de matriz.
- Consultar cada item individual em uma matriz usando o SQL.

Armazene e acesse com segurança suas credenciais do Amazon Redshift com uma conexão do AWS Glue. Para obter informações sobre como criar suas próprias conexões, consulte Conectar a dados.

Agora está tudo pronto para gravar seus dados em uma conexão alternando por um `DynamicFrames` de cada vez:

```
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)
```

Suas configurações de conexão serão diferentes de acordo com o tipo de banco de dados relacional:

- Para obter instruções sobre como gravar no Amazon Redshift, consulte the section called “Conexões do Redshift”.
- Para outros bancos de dados, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.

Conclusão

De modo geral, o AWS Glue é muito flexível. Com ele, você usa algumas linhas de código para escrever o que normalmente levaria dias. Você pode encontrar todos os scripts de ETL de fonte para destino no arquivo Python `join_and_relationalize.py` nos exemplos do AWS Glue no GitHub.

Exemplo de código: preparo de dados usando ResolveChoice, Lambda e ApplyMapping

O conjunto de dados que é usado neste exemplo consiste nos dados de pagamento de um provedor da Medicare obtidos por download em dois conjuntos de dados do Data.CMS.gov:

“Inpatient Prospective Payment System Provider Summary for the Top 100 Diagnosis-Related Groups - FY2011” e “Inpatient Charge Data FY 2011”. Depois de fazer download dos dados, nós os modificamos para apresentar alguns registros errados ao final do arquivo. Esse arquivo modificado está localizado em um bucket público do Amazon S3 em `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv`.

Você pode encontrar o código-fonte para este exemplo no arquivo `data_cleaning_and_lambda.py` nos exemplos do AWS Glue do repositório GitHub.

A forma preferida de depurar scripts do Python ou do PySpark durante a execução na AWS é usar cadernos no AWS Glue Studio.

Etapa 1: crawling de dados no bucket do Amazon S3

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Seguindo o processo descrito em Configurar um crawler, crie um novo crawler que possa fazer crawling no arquivo `s3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv` e colocar os metadados resultantes em um banco de dados chamado `payments` no AWS Glue Data Catalog.
3. Execute o novo crawler e, em seguida, verifique o banco de dados `payments`. Você deve descobrir que o crawler criou uma tabela de metadados nomeada `medicare` no banco de dados depois de ler o início do arquivo para determinar seu formato e delimitador.

   O esquema da nova tabela `medicare` será o seguinte:

```
Column  name                                Data type
================================================
drg 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
```

Etapa 2: adicionar o script de boilerplate ao caderno do endpoint de desenvolvimento

Cole o seguinte script de boilerplate no caderno do endpoint de desenvolvimento para importar as bibliotecas do AWS Glue necessárias e configure um único `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())
```

Etapa 3: comparar diferentes análises de esquema

Em seguida, você poderá ver se o esquema que foi reconhecido por um `DataFrame` do Apache Spark é igual àquele que seu crawler do AWS Glue gravou. Execute este código:

```
medicare = spark.read.format(
   "com.databricks.spark.csv").option(
   "header", "true").option(
   "inferSchema", "true").load(
   's3://awsglue-datasets/examples/medicare/Medicare_Hospital_Provider.csv')
medicare.printSchema()
```

Veja a seguir a saída da chamada `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)
```

Em seguida, veja o esquema gerado por um AWS Glue `DynamicFrame`:

```
medicare_dynamicframe = glueContext.create_dynamic_frame.from_catalog(
       database = "payments",
       table_name = "medicare")
medicare_dynamicframe.printSchema()
```

A saída de `printSchema` é a seguinte:

```
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
```

O `DynamicFrame` gera um esquema em que `provider id` pode ser um tipo `long` ou `string`. O esquema `DataFrame` lista `Provider Id` como um tipo `string`, e o Data Catalog lista `provider id` como um tipo `bigint`.

Qual está correto? Existem dois registros no final do arquivo (de 160 mil registros) com valores `string` na coluna em questão. Estes são os registros errados que foram apresentados para ilustrar um problema.

Para resolver esse tipo de problema, o AWS Glue `DynamicFrame` apresenta o conceito de um tipo de escolha. Neste caso, o `DynamicFrame` mostra que os valores `long` e `string` podem ser exibidos na coluna. O crawler do AWS Glue não obteve os valores `string` porque considerou apenas um prefixo de 2 MB dos dados. O `DataFrame` do Apache Spark considerou todo o conjunto

de dados, mas foi forçado a atribuir o tipo mais geral à coluna, ou seja, `string`. Na verdade, o Spark recorre frequentemente ao caso mais geral quando há tipos complexos ou variações com os quais ele não está familiarizado.

Para consultar a coluna `provider id`, resolva primeiro o tipo de escolha. Você pode usar o método de transformação `resolveChoice` no seu `DynamicFrame` para converter os valores `string` para `long` com uma opções `cast:long`:

```
medicare_res = medicare_dynamicframe.resolveChoice(specs = [('provider
 id','cast:long')])
medicare_res.printSchema()
```

A saída de `printSchema` agora é:

```
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
```

Em que o valor era uma `string` que não podia ser convertida, o AWS Glue inseriu `null`.

Outra opção é converter o tipo de escolha para `struct`, que mantém valores de ambos os tipos.

Em seguida, veja as linhas que eram anômalas:

```
medicare_res.toDF().where("'provider id' is NULL").show()
```

Você verá o seguinte:

```
+--------------------+----------+--------------+----------------------+------------
+-------------+----------------+-----------------------------------+---------------
+----------------------+---------------------+------------------------+
|      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|
+--------------------+----------+--------------+----------------------+------------
+-------------+----------------+-----------------------------------+---------------
+----------------------+---------------------+------------------------+
```

Agora, remova os dois registros malformados, da seguinte forma:

```
medicare_dataframe = medicare_res.toDF()
medicare_dataframe = medicare_dataframe.where("'provider id' is NOT NULL")
```

Etapa 4: mapear os dados e usar as funções Lambda do Apache Spark

O AWS Glue ainda não oferece suporte diretamente às funções Lambda, também conhecidas como funções definidas pelo usuário. No entanto, você sempre pode converter um `DynamicFrame` de e para um `DataFrame` do Apache Spark para utilizar as funcionalidades do Spark e os recursos especiais de `DynamicFrames`.

Em seguida, transforme as informações de pagamento em números para que os mecanismos de análise, como Amazon RedShift ou Amazon Athena, possam fazer seus respectivas análises mais rapidamente:

```
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()
```

A saída da chamada de show é a seguinte:

```
+--------+-------+-------+
|     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
```

Estas são todas as strings nos dados. Podemos usar o eficiente método de transformação apply_mapping para soltar, renomear, converter e aninhar os dados de modo que outros idiomas e sistemas de programação de dados possam acessá-los facilmente:

```
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()
```

A saída de `printSchema` é a seguinte:

```
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
```

Direcionando os dados de volta para um `DataFrame` do Spark, algo parecido com isto será exibido:

```
medicare_nest_dyf.toDF().show()
```

A saída é a seguinte:

```
+--------------------+--------------------+--------------+--------------------+
|                 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
```

Etapa 5: gravar os dados no Apache Parquet

O AWS Glue facilita a escrita dos dados em um formato como o Apache Parquet, que os bancos de dados relacionais possam efetivamente consumir:

```
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")
```

Referência de extensões PySpark do AWS Glue

O AWS Glue criou as seguintes extensões para o dialeto PySpark Python.

- Acessar parâmetros usando `getResolvedOptions`
- Tipos de extensão do PySpark
- Classe DynamicFrame
- Classe DynamicFrameCollection
- Classe DynamicFrameWriter
- Classe DynamicFrameReader
- Classe GlueContext

Acessar parâmetros usando **`getResolvedOptions`**

A função do utilitário AWS Glue `getResolvedOptions(args, options)` concede a você acesso aos argumentos transmitidos para o seu script quando você executa um trabalho. Para usar essa função, comece importando-a do módulo `utils` do AWS Glue junto com o `sys`:

```
import sys
from awsglue.utils import getResolvedOptions
```

`getResolvedOptions(args, options)`

- `args` – A lista de argumentos contida em `sys.argv`.
- `options` – Uma matriz Python dos nomes de argumentos que você quer recuperar.

Example Recuperar argumentos transmitidos para um JobRun

Suponha que você tenha criado um JobRun em um script, talvez dentro de uma função do 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 } )
```

Para recuperar os argumentos transmitidos, você pode usar a função `getResolvedOptions`, da seguinte maneira:

```
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']
```

Observe que cada um dos argumentos são definidos como começando com dois hifens e, então, referenciados no script sem os hifens. Os argumentos usam apenas sublinhados, não hífens. Seus argumentos precisam seguir essa convenção para serem resolvidos.

Tipos de extensão do PySpark

Os tipos usados pelas extensões de PySpark do AWS Glue.

DataType

A classe base para outros tipos do AWS Glue.

`__init__(properties={})`

- `properties` – Propriedades do tipo de dados (opcional).

`typeName(cls)`

Retorna o tipo da classe do AWS Glue (ou seja, o nome da classe com "Tipo" removido do final).

- `cls` – Uma instância de classe do AWS Glue derivada de `DataType`.

`jsonValue( )`

Retorna um objeto JSON que contém o tipo de dados e as propriedades da classe:

```
{
  "dataType": typeName,
  "properties": properties
}
```

Derivativos AtomicType e Simple

Herda e estende a classe DataType e serve como a classe base para todos os tipos de dados atômicos do AWS Glue.

`fromJsonValue(cls, json_value)`

Inicializa uma instância de classe com valores de um objeto JSON.

- `cls` – Uma instância de classe de tipo do AWS Glue a ser inicializada.
- `json_value` – O objeto JSON de onde os pares de valor-chave serão carregados.

Os seguintes tipos são derivados simples da classe AtomicType:

- `BinaryType` – Dados binários.
- `BooleanType` – Valores boolianos.
- `ByteType` – Um valor de bytes.
- `DateType` – Um valor de data e hora.
- `DoubleType` – Um valor com ponto flutuante duplo.
- `IntegerType` – Um valor inteiro.
- `LongType` – Um valor inteiro extenso.
- `NullType` – Um valor nulo.
- `ShortType` – Um valor inteiro curto.
- `StringType` – Uma string de texto.
- `TimestampType` – Um valor de data e hora (geralmente em segundos, a partir de 01/01/1970).
- `UnknownType` – Um valor de tipo não identificado.

DecimalType(AtomicType)

Herda e estende a classe AtomicType para representar um número decimal (um número expresso em dígitos decimais, em oposição aos números binários de base 2).

`__init__(precision=10, scale=2, properties={})`

- `precision` - O número de dígitos no número decimal (opcional; o padrão é 10).
- `scale` – O número de dígitos à direita da vírgula decimal (opcional, o padrão é 2).
- `properties` – As propriedades do número decimal (opcional).

EnumType(AtomicType)

Herda e estende a classe AtomicType para representar uma enumeração de opções válidas.

`__init__(options)`

- `options` – Uma lista de opções sendo enumeradas.

tipos de coleção

- ArrayType(DataType)
- ChoiceType(DataType)
- MapType(DataType)
- Field(Object)
- StructType(DataType)
- EntityType(DataType)

ArrayType(DataType)

`__init__(elementType=UnknownType(), properties={})`

- `elementType` – O tipo dos elementos na matriz (opcional, o padrão é UnknownType).
- `properties` – Propriedades da matriz (opcional).

ChoiceType(DataType)

`__init__(choices=[], properties={})`

- `choices` – Uma lista das opções possíveis (opcional).
- `properties` – As propriedades dessas opções (opcional).

`add(new_choice)`

Adiciona uma nova opção à lista de opções possíveis.

- `new_choice` – A opção a ser adicionada à lista de opções possíveis.

`merge(new_choices)`

Combina uma lista de novas opções com a lista de opções existentes.

- `new_choices` – Uma lista de novas opções a ser combinada com a lista de opções existentes.

MapType(DataType)

`__init__(valueType=UnknownType, properties={})`

- `valueType` – O tipo dos valores no mapa (opcional, o padrão é UnknownType).
- `properties` – Propriedades do mapa (opcional).

Field(Object)

Cria um objeto de campo de um objeto que deriva de DataType.

`__init__(name, dataType, properties={})`

- `name` – O nome a ser atribuído ao campo.
- `dataType` – O objeto a ser criado a partir de um campo.
- `properties` – Propriedades do campo (opcional).

StructType(DataType)

Define uma estrutura de dados (`struct`).

`__init__(fields=[], properties={})`

- `fields` – Uma lista dos campos (do tipo `Field`) a ser incluída na estrutura (opcional).
- `properties` – Propriedades da estrutura (opcional).

`add(field)`

- `field` – Um objeto do tipo `Field` a ser adicionado à estrutura.

`hasField(field)`

Retorna `True` se essa estrutura tiver um campo com o mesmo nome ou `False` caso contrário.

- `field` – O nome de um campo ou um objeto do tipo `Field` cujo nome está sendo usado.

`getField(field)`

- `field`: um nome de um campo ou um objeto do tipo `Field` cujo nome está sendo usado. Se a estrutura tiver um campo com o mesmo, ele será retornado.

EntityType(DataType)

`__init__(entity, base_type, properties)`

Esta classe ainda não foi implementada.

outros tipos

- DataSource(object)
- DataSink(object)

DataSource(object)

`__init__(j_source, sql_ctx, name)`

- `j_source` – A fonte de dados.
- `sql_ctx` – O contexto SQL.
- `name` – O nome da fonte de dados.

`setFormat(format, **options)`

- `format` – O formato a ser configurado para a fonte de dados.
- `options` – Uma coleção de opções a ser configurada para a fonte de dados. Para obter mais informações sobre essas opções de formato, consulte the section called “Opções de formato de dados”.

`getFrame()`

Retorna um `DynamicFrame` para a fonte de dados.

DataSink(object)

`__init__(j_sink, sql_ctx)`

- `j_sink` – O depósito a ser criado.
- `sql_ctx` – O contexto SQL para o depósito de dados.

`setFormat(format, **options)`

- `format` – O formato a ser configurado para o depósito de dados.
- `options` – Uma coleção de opções a ser configurada para o depósito de dados. Para obter mais informações sobre essas opções de formato, consulte the section called “Opções de formato de dados”.

`setAccumulableSize(size)`

- `size` – O tamanho acumulável a ser configurado, em bytes.

`writeFrame(dynamic_frame, info="")`

- `dynamic_frame` – O `DynamicFrame` a ser escrito.
- `info` – Informações sobre o `DynamicFrame` (opcional).

`write(dynamic_frame_or_dfc, info="")`

Escreve `DynamicFrame` ou `DynamicFrameCollection`.

- `dynamic_frame_or_dfc` – Um objeto `DynamicFrame` ou `DynamicFrameCollection` a ser escrito.
- `info` – Informações sobre `DynamicFrame` ou `DynamicFrames` a serem escritas (opcional).

Classe DynamicFrame

Uma das principais abstrações no Apache Spark é o `DataFrame` do SparkSQL, que é semelhante à construção `DataFrame` encontrada no R e Pandas. Um `DataFrame` é semelhante a uma tabela e é

compatível com operações de estilo funcional (mapear/reduzir/filtrar etc.) e operações SQL (select, project, aggregate).

`DataFrames` são potentes e amplamente utilizados, mas têm limitações em relação às operações de extração, transformação e carregamento (ETL). Mais importante, eles exigem que um esquema seja especificado antes que qualquer dado seja carregado. O SparkSQL soluciona essa questão fazendo duas transmissões sobre dados: a primeira para inferir o esquema e a segunda para carregar os dados. No entanto, essa inferência é limitada e não corrige a desorganização de dados. Por exemplo, o mesmo campo pode ser de um tipo diferente em registros diferentes. O Apache Spark muitas vezes desiste e relata o tipo como `string` usando o texto do campo original. Ele pode estar incorreto, e convém ter controle mais preciso sobre como as discrepâncias do esquema são resolvidas. Para grandes conjuntos de dados, uma transmissão adicional sobre os dados de origem pode ser proibitivamente dispendiosa.

Para resolver essas limitações, o AWS Glue apresenta o `DynamicFrame`. Um `DynamicFrame` é semelhante a `DataFrame`, mas cada registro se autodescrevente, então nenhum esquema é necessário inicialmente. Em vez disso, o AWS Glue calcula um esquema instantaneamente quando necessário e codifica explicitamente inconsistências de esquema usando um tipo de escolha (ou união). Você pode resolver essas inconsistências para tornar seus conjuntos de dados compatíveis com armazenamentos de dados que exigem um esquema fixo.

Da mesma forma, um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. Ele é igual a uma linha em um `DataFrame` do Spark, exceto pelo fato de que ele pode se autodescrever e ser usado para dados que não estão em conformidade com um esquema fixo. Ao usar o AWS Glue com o PySpark, você normalmente não manipula `DynamicRecords` independentes. Em vez disso, você transformará o conjunto de dados junto por meio de seu `DynamicFrame`.

Você pode converter `DynamicFrames` de e para `DataFrames` depois de resolver as inconsistências de esquema.

— construção —

- __init__
- fromDF
- toDF

__init__

`__init__(jdf, glue_ctx, name)`

- `jdf` – Uma referência ao quadro de dados na Java Virtual Machine (JVM).
- `glue_ctx` – Um objeto Classe GlueContext.
- `name` – Uma string de nome opcional, vazia por padrão.

fromDF

`fromDF(dataframe, glue_ctx, name)`

Converte um `DataFrame` em um `DynamicFrame`, transformando campos `DataFrame` em campos `DynamicRecord`. Retorna um novo `DynamicFrame`.

Um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. Ele é semelhante a uma linha em um `DataFrame` do Spark, exceto pelo fato de que ele pode se autodescrever e ser usado para dados que não estão em conformidade com um esquema fixo.

Essa função espera que as colunas com nomes duplicados em seu `DataFrame` já tenham sido resolvidas.

- `dataframe` – O `DataFrame` Apache Spark SQL a ser convertido (obrigatório).
- `glue_ctx` – O objeto Classe GlueContext que especifica o contexto para essa transformação (obrigatório).
- `name`: o nome do `DynamicFrame` resultante (opcional desde o AWS Glue 3.0).

toDF

`toDF(options)`

Converte um `DynamicFrame` a um `DataFrame` do Apache Spark, transformando campos `DynamicRecords` em `DataFrame`. Retorna um novo `DataFrame`.

Um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. Ele é semelhante a uma linha em um `DataFrame` do Spark, exceto pelo fato de que ele pode se autodescrever e ser usado para dados que não estão em conformidade com um esquema fixo.

- `options`: uma lista de opções. Permite especificar opções adicionais para o processo de conversão. Algumas opções válidas que você pode usar com o parâmetro “options”:

- `format`: especifica o formato dos dados, como json, csv, parquet).
- `separater or sep`: para arquivos CSV, especifica o delimitador.
- `header`: para arquivos CSV, indica se a primeira linha é um cabeçalho (verdadeiro/falso).
- `inferSchema`: direciona o Spark para inferir o esquema automaticamente (verdadeiro/falso).

Este é um exemplo de uso do parâmetro “options” com o método “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",
  "ïnferSchema": "true"
})
```

Especifique o tipo de destino se você escolher o tipo de ação `Project` e `Cast`. Os exemplos incluem o seguinte.

```
>>>toDF([ResolveOption("a.b.c", "KeepAsStruct")])
>>>toDF([ResolveOption("a.b.c", "Project", DoubleType())])
```

— informações —

- contagem
- esquema
- printSchema
- show

- repartição
- coalesce

contagem

`count( )` – Retorna o número de linhas no `DataFrame` subjacente.

esquema

`schema( )` – Retorna o esquema deste `DynamicFrame` ou, se não estiver disponível, o esquema do `DataFrame` subjacente.

Para obter mais informações sobre os tipos de `DynamicFrame` que compõem esse esquema, consulte the section called “Tipos”.

printSchema

`printSchema( )` – Imprime o esquema do `DataFrame` subjacente.

show

`show(num_rows)` – Imprime um número de linhas especificado do `DataFrame` subjacente.

repartição

`repartition(numPartitions)`: retorna um novo `DynamicFrame` com `numPartitions` partições.

coalesce

`coalesce(numPartitions)`: retorna um novo `DynamicFrame` com `numPartitions` partições.

— transformações —

- apply_mapping
- drop_fields
- filtrar
- ingressar
- mapear
- mergeDynamicFrame
- relationalize

- rename_field
- resolveChoice
- select_fields
- spigot
- split_fields
- split_rows
- unbox
- the section called “união”
- unnest
- unnest_ddb_json
- write

apply_mapping

`apply_mapping(mappings, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Aplica um mapeamento declarativo a um `DynamicFrame` e retorna um novo `DynamicFrame` com esses mapeamentos aplicados aos campos que você especificar. Os campos não especificados são omitidos do novo `DynamicFrame`.

- `mappings`: uma lista de tuplas de mapeamento (obrigatório). Cada uma é composta por: coluna de fonte, tipo de fonte, coluna de destino, tipo de destino.

  Se houver um ponto "`.`" no nome da coluna de origem, será necessário colocá-lo entre crases "```". Por exemplo, para mapear `this.old.name` (string) para `thisNewName`, você pode usar a seguinte tupla:

  ```
  ("`this.old.name`", "string", "thisNewName", "string")
  ```

- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar apply_mapping para renomear campos e alterar os tipos de campo

O exemplo de código a seguir mostra como usar o método `apply_mapping` para renomear campos selecionados e alterar os tipos de campo.

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: juntar e relacionar dados e siga as instruções em Etapa 1: crawling de dados no bucket do 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()
```

Saída

```
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)`

Chama a transformação Classe FlatMap para remover campos de um `DynamicFrame`. Retorna um novo `DynamicFrame` com os campos especificados descartados.

- `paths`: uma lista de cadeias de caracteres. Cada um contém o caminho completo para um nó de campo que você deseja descartar. É possível usar notação de pontos para especificar campos aninhados. Por exemplo, se campo `first` for secundário do campo `name` na árvore, especifique `"name.first"` para o caminho.

  Se houver um literal `.` no nome de um nó de campo, será necessário colocá-lo entre crases (`` ` ``).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar drop_fields para remover campos de um **`DynamicFrame`**

Este código de exemplo usa o método `drop_fields` para remover campos aninhados e de nível superior selecionados de um `DynamicFrame`.

Exemplo de conjunto de dados

O exemplo usa o seguinte conjunto de dados que é representado pela tabela `EXAMPLE-FRIENDS-DATA` no código:

```
{"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}]}
```

Código de exemplo

```
# 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()
```

Saída

```
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
```

filtrar

`filter(f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Retorna um novo `DynamicFrame` que contém todos os `DynamicRecords` no `DynamicFrame` de entrada que satisfazem uma função `f` predicada especificada.

- `f`: a função predicada a ser aplicada a `DynamicFrame`. A função precisa ter um `DynamicRecord` como um argumento e retornar True, se `DynamicRecord` atender aos requisitos de filtro, ou False, caso contrário (obrigatório).

  Um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. É semelhante a uma linha em um `DataFrame` do Spark, exceto pelo fato de que pode se autodescrever e ser usado para dados que não estejam em conformidade com um esquema fixo.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar filter para obter uma seleção filtrada de campos

Este exemplo usa o método `filter` para criar um novo `DynamicFrame` que inclui uma seleção filtrada de outros campos do `DynamicFrame`.

Assim como o método `map`, `filter` usa uma função como um argumento que é aplicado a cada registro no `DynamicFrame` original. A função usa um registro como entrada e retorna um valor booleano. Se o valor de retorno for true, o registro será incluído no `DynamicFrame` resultante. Se for false, o registro será omitido.

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: preparo de dados usando ResolveChoice, Lambda e ApplyMapping e siga as instruções em Etapa 1: crawling de dados no bucket do 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())
```

Saída

```
Unfiltered record count:  163065
Filtered record count:   564
```

ingressar

`join(paths1, paths2, frame2, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Executa uma junção de igualdade com outro `DynamicFrame` e retorna o `DynamicFrame` resultante.

- `paths1` – Uma lista das chaves neste quadro para realizar a junção.
- `paths2` – Uma lista das chaves em outro quadro para realizar a junção.
- `frame2` - O outro `DynamicFrame` para realizar a junção.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar join para combinar **`DynamicFrames`**

Este exemplo usa o método `join` para realizar uma junção em três `DynamicFrames`. O AWS Glue executa a junção com base nas chaves de campo que você fornece. O `DynamicFrame` resultante contém linhas dos dois quadros originais em que as chaves especificadas correspondem.

A transformação do `join` mantém todos os campos intactos. Isso significa que os campos que você especificar para correspondência serão exibidos no DynamicFrame resultante, mesmo que sejam redundantes e contenham as mesmas chaves. Neste exemplo, usamos `drop_fields` para remover essas chaves redundantes após a junção.

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: juntar e relacionar dados e siga as instruções em Etapa 1: crawling de dados no bucket do 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()
```

Saída

```
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
```

mapear

`map(f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Retorna um novo `DynamicFrame` que resulta da aplicação da função de mapeamento especificada a todos os registros no `DynamicFrame` original.

- `f`: a função de mapeamento a ser aplicada a todos os registros em `DynamicFrame`. A função precisa levar um `DynamicRecord` como um argumento e retornar um novo `DynamicRecord` (obrigatório).

  Um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. É semelhante a uma linha em um `DataFrame` do Apache Spark, exceto pelo fato de que pode se autodescrever e ser usado para dados que não estejam em conformidade com um esquema fixo.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info`: uma cadeira de caracteres que é associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

Exemplo: usar map para aplicar uma função a cada registro em um **`DynamicFrame`**

Este exemplo mostra como usar o método `map` para aplicar uma função a cada registro de um `DynamicFrame`. Especificamente, este exemplo aplica uma função chamada `MergeAddress` para cada registro para mesclar vários campos de endereço em um único tipo `struct`.

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: preparo de dados usando ResolveChoice, Lambda e ApplyMapping e siga as instruções em Etapa 1: crawling de dados no bucket do 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()
```

Saída

```
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)`

Mescla esse `DynamicFrame` com uma preparação `DynamicFrame` de acordo com as chaves primárias especificadas para identificar registros. Registros duplicados (com as mesmas chaves primárias) não são eliminados. Se não houver nenhum registro correspondente no quadro de preparação, todos os registros (incluindo os duplicados) serão retidos da origem. Se o quadro de preparação tiver registros correspondentes, os do quadro de preparação substituirão os da origem no AWS Glue.

- `stage_dynamic_frame`: o `DynamicFrame` de preparação para mesclar.
- `primary_keys` a lista de campos de chave primária para corresponder aos registros da fonte e quadros dinâmicos de preparação.
- `transformation_ctx`: uma string exclusiva usada para recuperar os metadados sobre a transformação atual (opcional).
- `options`: uma string de pares nome-valor JSON que fornecem informações adicionais para essa transformação. Esse argumento não é usado no momento.
- `info`: uma `String`. Qualquer string a ser associada a erros nessa transformação.
- `stageThreshold`: uma `Long`. O número de erros na transformação para a qual o processamento precisa apresentar falhas.
- `totalThreshold`: uma `Long`. O número total de erros até esta transformação (inclusive) para os quais o processamento precisa apresentar falhas.

Este método retorna um novo `DynamicFrame` obtido ao mesclar este `DynamicFrame` com a preparação `DynamicFrame`.

O `DynamicFrame` retornado contém registro A nestes casos:

- Se `A` existir no quadro de origem e no quadro de preparação, o `A` do quadro de preparação será retornado.
- Se `A` estiver na tabela de origem e `A.primaryKeys` não estiver no `stagingDynamicFrame`, `A` não será atualizado na tabela de preparação.

O quadro de origem e o quadro de preparação não precisam ter o mesmo esquema.

Exemplo: use mergeDynamicFrame para mesclar dois **`DynamicFrames`** com base em uma chave primária

O exemplo de código a seguir mostra como usar o método `mergeDynamicFrame` para mesclar um `DynamicFrame` com uma “preparação” `DynamicFrame` com base na chave primária `id`.

Exemplo de conjunto de dados

O exemplo usa dois `DynamicFrames` de um `DynamicFrameCollection` chamado `split_rows_collection`. Está é uma lista de limites no `split_rows_collection`.

```
dict_keys(['high', 'low'])
```

Código de exemplo

```
# 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()
```

Saída

```
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 DynamicFrame 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)`

Converte um `DynamicFrame` em um formulário que se encaixa em um banco de dados relacional. Relacionar um `DynamicFrame` é especialmente útil quando você deseja mover dados de um ambiente NoSQL como o DynamoDB para um banco de dados relacional como o MySQL.

A transformação gera uma lista de quadros separando colunas aninhadas e colunas de matriz dinâmica. A coluna de matriz dinâmica pode ser adicionada à tabela raiz usando a chave de união gerada durante a fase de desaninhamento.

- `root_table_name` – O nome da a tabela raiz.
- `staging_path`: o caminho onde o método pode armazenar partições de tabelas dinâmicas no formato CSV (opcional). As tabelas dinâmicas são lidas novamente nesse caminho.
- `options` – Um dicionário de parâmetros opcionais.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar relationalize para nivelar um esquema aninhado em um **`DynamicFrame`**

Este exemplo de código usa o método `relationalize` para nivelar um esquema aninhado em um formulário que se encaixa em um banco de dados relacional.

Exemplo de conjunto de dados

O exemplo usa um `DynamicFrame` chamado `legislators_combined` com o esquema a seguir. `legislators_combined` tem vários campos aninhados, como `links`, `images` e `contact_details` que serão nivelados pela transformação `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
```

Código de exemplo

```
# 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()
```

Saída

A saída a seguir permite comparar o esquema do campo aninhado chamado `contact_details` com a tabela criada pela transformação `relationalize`. Observe que os registros da tabela apontam para a tabela principal usando uma chave estrangeira chamada `id` e uma coluna `index` que representa as posições da matriz.

```
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)`

Renomeia um campo neste `DynamicFrame` e retorna um novo `DynamicFrame` com o campo renomeado.

- `oldName` – O caminho completo para o nó que você quer renomear.

  Se o nome antigo contiver pontos, `RenameField` não funcionará a menos que você coloque acentos graves em torno dele (`). Por exemplo, para substituir `this.old.name` por `thisNewName`, você chamaria rename_field da seguinte maneira.

  ```
  newDyF = oldDyF.rename_field("`this.old.name`", "thisNewName")
  ```

- `newName` – O novo nome, como um caminho completo.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar rename_field para renomear campos em um **`DynamicFrame`**

Este exemplo de código usa o método `rename_field` para renomear campos em um `DynamicFrame`. Observe que o exemplo usa o encadeamento de métodos para renomear vários campos ao mesmo tempo.

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: juntar e relacionar dados e siga as instruções em Etapa 1: crawling de dados no bucket do Amazon S3.

Código de exemplo

```
# 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()
```

Saída

```
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)`

Resolve um tipo de escolha neste `DynamicFrame` e retorna o novo `DynamicFrame`.

- `specs`: uma lista de ambiguidades específicas para resolver, cada uma na forma de uma tupla: `(field_path, action)`.

  Há duas maneiras de usar `resolveChoice`. A primeira é usar o argumento `specs` para indicar uma sequência de colunas específicas e como resolvê-las. O outro modo para `resolveChoice` é usar o argumento `choice` para especificar uma única resolução para todos os `ChoiceTypes`.

  Valores para `specs` são especificados como tuplas compostas de pares `(field_path, action)`. O valor `field_path` identifica um elemento ambíguo específico, e o valor `action` identifica a resolução correspondente. A seguir estão as ações possíveis:

  - `cast:`*`type`*: tenta converter todos os valores para o tipo especificado. Por exemplo: `cast:int`.
  - `make_cols`: converte cada tipo distinto em uma coluna com o nome *`columnName_type`*. Ele resolve uma possível ambiguidade ao nivelar os dados. Por exemplo, se `columnA` puder ser `int` ou `string`, a resolução seria produzir duas colunas chamadas `columnA_int` e `columnA_string` no `DynamicFrame` resultante.
  - `make_struct`: resolve uma possível ambiguidade usando um `struct` para representar os dados. Por exemplo, se os dados em uma coluna pudessem ser um `int` ou `string`, usar a ação `make_struct` produziria uma coluna de estruturas no `DynamicFrame`. Cada estrutura contém um `int` e um `string`.
  - `project:`*`type`*: resolve uma possível ambiguidade projetando todos os dados para um dos possíveis tipos de dados. Por exemplo, se os dados em uma coluna pudessem ser um `int` ou `string`, usar a ação `project:string` produzirá uma coluna de estruturas no `DynamicFrame` resultante, onde todos os valores `int` foram convertidos em strings.

  Se o `field_path` identifica um array, insira colchetes vazios após o nome do array para evitar ambiguidades. Por exemplo, vamos supor que você esteja trabalhando com dados estruturados da seguinte maneira:

```
"myList": [
  { "price": 100.00 },
  { "price": "$100.00" }
]
```

Você pode selecionar a versão numérica em vez da versão string do preço definindo `field_path` como `"myList[].price"` e `action` como `"cast:double"`.

> **Note**
>
> É possível usar somente um dos parâmetros `specs` e `choice`. Se o parâmetro `specs` não for `None`, o parâmetro `choice` precisará ser uma string vazia. Por outro lado, se o `choice` não for uma string vazia, o parâmetro `specs` precisará ser `None`.

- `choice`: especifica uma única resolução para todos os `ChoiceTypes`. É possível usar essa ação em casos em que a lista completa de `ChoiceTypes` for desconhecida antes do runtime. Além das ações listadas anteriormente para `specs`, esse modo também aceita a seguinte ação:
  - `match_catalogChoiceType`: tenta converter cada para o tipo correspondente na tabela do Data Catalog especificada.
- `database`: banco de dados do Data Catalog a ser usado com a ação `match_catalog`.
- `table_name`: a tabela do Data Catalog a ser usada com a ação `match_catalog`.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados até esta transformação (inclusive) em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `catalog_id`: o ID do catálogo do Data Catalog sendo acessado (o ID da conta do Data Catalog). Quando definido como `None` (valor padrão), ele usa o ID do catálogo da conta de chamada.

Exemplo: usar resolveChoice para lidar com uma coluna que contém vários tipos

Este exemplo de código usa o método `resolveChoice` para especificar como lidar com uma coluna `DynamicFrame` que contém valores de vários tipos. O exemplo demonstra duas maneiras comuns de lidar com uma coluna com tipos diferentes:

- Converter a coluna em um único tipo de dados.
- Reter todos os tipos em colunas separadas.

Exemplo de conjunto de dados

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: preparo de dados usando ResolveChoice, Lambda e ApplyMapping e siga as instruções em Etapa 1: crawling de dados no bucket do Amazon S3.

O exemplo usa um `DynamicFrame` chamado `medicare` com o seguinte esquema:

```
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
```

Código de exemplo

```
# 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()
```

Saída

```
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)`

Retorna um novo `DynamicFrame` que contém os campos selecionados.

- `paths`: uma lista de cadeias de caracteres. Cada cadeia de caracteres é um caminho para um nó de nível superior que você deseja selecionar.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar select_fields para criar um novo **`DynamicFrame`** com os campos escolhidos

O exemplo de código a seguir mostra como usar o método `select_fields` para criar um novo `DynamicFrame` com uma lista escolhida de campos de um `DynamicFrame` existente.

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: juntar e relacionar dados e siga as instruções em Etapa 1: crawling de dados no bucket do 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()
```

Saída

```
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`

Simplifica colunas aninhadas em um `DynamicFrame` que estão especificamente na estrutura JSON do DynamoDB e retorna um novo `DynamicFrame` simplificado. Se houver vários tipos ou um tipo de mapa em um tipo de lista, os elementos na lista não serão simplificados. Observe que esse é um tipo específico de transformação que se comporta de forma diferente da transformação `unnest` comum e requer que os dados já estejam na estrutura JSON do DynamoDB. Para mais informações, consulte JSON do DynamoDB.

Por exemplo, o esquema de uma leitura de uma exportação com a estrutura JSON do DynamoDB pode se parecer com o seguinte:

```
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
```

A transformação `simplify_ddb_json()` converteria isso em:

```
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
```

Exemplo: use simplify_ddb_json para invocar uma simplificação JSON do DynamoDB

Esse exemplo de código usa o método `simplify_ddb_json` para utilizar o conector de exportação para DynamoDB do AWS Glue, invocar uma simplificação JSON do DynamoDB e imprimir o número de partições.

Código de exemplo

```
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={})`

Grava registros de exemplo em um destino específico para ajudar você a verificar as transformações realizadas pelo seu trabalho.

- `path`: o caminho para o destino no qual a gravação será feita (obrigatório).
- `options`: pares de chave-valor que especificam opções (opcional). A opção `"topk"` especifica que os primeiros registros k devem ser gravados. A opção `"prob"` especifica a probabilidade (como um número decimal) de escolher um determinado registro. Ele pode ser usado na seleção de registros para gravar.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).

Exemplo: usar spigot para gravar campos de exemplo de um **`DynamicFrame`** no Amazon S3

Este exemplo de código usa o método `spigot` para gravar registros de amostra em um bucket do Amazon S3 depois de aplicar a transformação `select_fields`.

Exemplo de conjunto de dados

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: juntar e relacionar dados e siga as instruções em Etapa 1: crawling de dados no bucket do Amazon S3.

O exemplo usa um `DynamicFrame` chamado `persons` com o seguinte esquema:

```
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
```

Código de exemplo

```
# 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}
)
```

Saída

Veja a seguir um exemplo dos dados gravados por `spigot` no Amazon S3. Como o código de exemplo especificou `options={"topk": 10}`, os dados de exemplo contêm os primeiros 10 registros.

```
{"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)`

Retorna um novo `DynamicFrameCollection` que contém dois `DynamicFrames`. O primeiro `DynamicFrame` contém todos os nós que foram separados, e o segundo contém os nós restantes.

- `paths` – Uma lista de strings, cada uma é um caminho completo para um nó que você quer separar em um novo `DynamicFrame`.
- `name1` – Uma string de nome para `DynamicFrame` a ser separado.
- `name2` – Uma string de nome para `DynamicFrame` que permanece após os nós especificados terem sido separados.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar split_fields para dividir os campos selecionados em um **`DynamicFrame`** separado

Este exemplo de código usa o método `split_fields` para dividir uma lista de campos especificados em uma lista separada `DynamicFrame`.

Exemplo de conjunto de dados

O exemplo usa um DynamicFrame chamado `l_root_contact_details` que é de uma coleção chamada `legislators_relationalized`.

`l_root_contact_details` tem o seguinte esquema e entradas:

```
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|
...
```

Código de exemplo

```
# 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()
```

Saída

```
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)`

Separa uma ou mais linhas em um `DynamicFrame` em um novo `DynamicFrame`.

O método retorna um novo `DynamicFrameCollection` que contém dois `DynamicFrames`. O primeiro `DynamicFrame` contém todas as linhas que foram separadas, e o segundo contém as linhas restantes.

- `comparison_dict`: um dicionário em que a chave é o caminho para uma coluna e o valor é outro dicionário para mapear comparadores a valores aos quais os valores das colunas são comparados. Por exemplo, `{"age": {">": 10, "<": 20}}` separa todas as linhas cujo valor na coluna de idade é maior do que 10 e menor do que 20.
- `name1` – Uma string de nome para `DynamicFrame` a ser separado.
- `name2` – Uma string de nome para `DynamicFrame` que permanece após os nós especificados terem sido separados.

- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar split_rows para dividir linhas em um **`DynamicFrame`**

Este exemplo de código usa o método `split_rows` para dividir linhas em um `DynamicFrame` com base no valor do campo `id`.

Exemplo de conjunto de dados

O exemplo usa um `DynamicFrame` chamado `l_root_contact_details` que é selecionado em uma coleção chamada `legislators_relationalized`.

`l_root_contact_details` tem o seguinte esquema e entradas:

```
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|
+---+-----+-----------------------+-------------------------+
```

Código de exemplo

```
# 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()
```

Saída

```
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|              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|
+---+-----+----------------------+--------------------------+
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)

Descompacta (reformata) um campo de string em um `DynamicFrame` e retorna um novo `DynamicFrame` que contém os `DynamicRecords` descompactados.

Um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. É semelhante a uma linha em um `DataFrame` do Apache Spark, exceto pelo fato de que pode se autodescrever e ser usado para dados que não estejam em conformidade com um esquema fixo.

- `path` – Um caminho completo para o nó de string que você quer descompactar.
- `format`: uma especificação de formato (opcional). Usado para uma conexão do Amazon S3 ou do AWS Glue com suporte a vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para conhecer os formatos compatíveis.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `options`: um ou mais dos seguintes itens:
  - `separator`: uma string que contém o caractere de separação.
  - `escaper`: uma string que contém o caractere de escape.
  - `skipFirst`: um valor booleano que indica se a primeira instância deve ser ignorada.
  - `withSchema`: uma string contendo uma representação JSON do esquema do nó. O formato da representação JSON de um esquema é definido pela saída de `StructType.json()`.
  - `withHeader`: um valor booleano que indica se há um cabeçalho incluído.

Exemplo: usar unbox para descompactar um campo de string em um struct

Este exemplo de código usa o método `unbox` para desempacotar ou reformatar um campo de string em um `DynamicFrame` em um campo do tipo struct.

Exemplo de conjunto de dados

O exemplo usa um `DynamicFrame` chamado `mapped_with_string` com os seguintes esquema e entradas:

Observe o campo chamado `AddressString`. Esse é o campo que o exemplo descompacta em um 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|
...
```

Código de exemplo

```
# 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()
```

Saída

```
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
```

união

`union(frame1, frame2, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)`

União de dois DynamicFrames. Retorna DynamicFrame contendo todos os registros dos dois DynamicFrames de entrada. Essa transformação pode retornar resultados diferentes da união de dois DataFrames com dados equivalentes. Se você precisar do comportamento de união do Spark DataFrame, considere usar `toDF`.

- `frame1` - Primeiro DynamicFrame para a união.
- `frame2` - Segundo DynamicFrame para a união.
- `transformation_ctx` - (opcional) Uma string exclusiva usada para identificar estatísticas/informações de estado
- `info` - (opcional) Qualquer string a ser associada a erros na transformação
- `stageThreshold` - (opcional) Número máximo de erros na transformação até que o processamento ocorra um erro
- `totalThreshold` - (opcional) Número máximo de erros totais até que o processamento apresente erros.

unnest

`unnest(transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

Desfaz o aninhamento de objetos em um `DynamicFrame`, transformando-os em objetos de nível superior, e retorna um novo `DynamicFrame` não aninhado.

- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold`: o número de erros encontrados durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.
- `totalThreshold`: o número de erros encontrados antes e durante essa transformação em que o processo deve falhar (opcional). O padrão é zero, o que indica que o processo não deve falhar.

Exemplo: usar unnest para transformar campos aninhados em campos de nível superior

Este exemplo de código usa o método `unnest` para nivelar todos os campos aninhados em um `DynamicFrame` em campos de nível superior.

Exemplo de conjunto de dados

O exemplo usa um `DynamicFrame` chamado `mapped_medicare` com o esquema a seguir. Observe que o campo `Address` é o único campo que contém dados aninhados.

```
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
```

Código de exemplo

```
# 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()
```

Saída

```
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

Desaninha colunas aninhadas em um `DynamicFrame` que estão especificamente na estrutura JSON do DynamoDB e retorna um novo `DynamicFrame` não aninhado. Colunas que pertençam a uma matriz de tipos de estrutura não serão desaninhadas. Observe que esse é um tipo específico de transformação de desaninhamento que se comporta diferentemente da transformação `unnest` comum e requer que os dados já estejam na estrutura JSON do DynamoDB. Para mais informações, consulte JSON do DynamoDB.

`unnest_ddb_json(transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)`

- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string a ser associada com o erro na geração de relatórios desta transformação (opcional).
- `stageThreshold` – O número de erros encontrados durante esta transformação em que o processo deve falhar (opcional: zero por padrão, indicando que o processo não deve apresentar falha).

- `totalThreshold` – O número de erros encontrados incluindo esta transformação em que o processo deve falhar (opcional: zero por padrão, indicando que o processo não deve apresentar falha).

Por exemplo, o esquema de uma leitura de uma exportação com a estrutura JSON do DynamoDB pode ter a seguinte aparência:

```
root
|-- Item: struct
|    |-- ColA: struct
|    |    |-- S: string
|    |-- ColB: struct
|    |    |-- S: string
|    |-- ColC: struct
|    |    |-- N: string
|    |-- ColD: struct
|    |    |-- L: array
|    |    |    |-- element: null
```

A transformação `unnest_ddb_json()` converteria isso em:

```
root
|-- ColA: string
|-- ColB: string
|-- ColC: string
|-- ColD: array
|    |-- element: null
```

O exemplo de código a seguir mostra como usar o conector de exportação para DynamoDB do AWS Glue, invocar um desaninhamento de JSON do DynamoDB e imprimir o número de partições:

```
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)`

Obtém um DataSink(object) do tipo de conexão especificado em Classe GlueContext deste `DynamicFrame`, e o usa para formatar e gravar o conteúdo desse `DynamicFrame`. Retorna o novo `DynamicFrame` formatado e gravado conforme especificado.

- `connection_type`: o tipo de conexão a ser usado. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` e `oracle`.
- `connection_options`: a opção de conexão a ser usada (opcional). Para um `connection_type` do `s3`, um caminho do Amazon S3 é definido.

  ```
  connection_options = {"path": "s3://aws-glue-target/temp"}
  ```

  Para conexões JDBC, várias propriedades devem ser definidas. Observe que o nome do banco de dados deve fazer parte do URL. Ele também pode ser incluído nas opções de conexão.

  > **Warning**
  >
  > Não é recomendável armazenar senhas no script. Considere usar `boto3` para recuperá-los do AWS Secrets Manager ou do catálogo de dados do AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

- `format`: uma especificação de formato (opcional). Essa ação é usada para um Amazon Simple Storage Service (Amazon S3) ou uma conexão do AWS Glue que ofereça suporte a vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `format_options`: as opções de formato para o formato especificado. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `accumulator_size`: o tamanho cumulativo a ser usado, em bytes (opcional).

— erros —

- assertErrorThreshold
- errorsAsDynamicFrame
- errorsCount
- stageErrorsCount

assertErrorThreshold

`assertErrorThreshold( )`: uma afirmação para erros nas transformações que criaram este `DynamicFrame`. Retorna um `Exception` do `DataFrame` subjacente.

errorsAsDynamicFrame

`errorsAsDynamicFrame( )` – Retorna um `DynamicFrame` com registros de erro aninhados.

Exemplo: usar errorsAsDynamicFrame para visualizar registros de erros

O código de exemplo a seguir mostra como usar o método `errorsAsDynamicFrame` para visualizar um registro de erro para um `DynamicFrame`.

Exemplo de conjunto de dados

O exemplo usa o conjunto de dados a seguir, que você pode carregar para o Amazon S3 como JSON. O segundo registro está mal formado. Dados malformados geralmente interrompem a análise de arquivos quando usamos o SparkSQL. No entanto, o `DynamicFrame` reconhece problemas de malformação e transforma linhas malformadas em registros de erros que você pode solucionar individualmente.

```
{"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}
```

Código de exemplo

```
# 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]))
```

Saída

```
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/awsglue/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/awsglue/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.handleErr(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( )` – Retorna o número total de erros em um `DynamicFrame`.

stageErrorsCount

`stageErrorsCount` – Retorna o número de erros que ocorreram no processo de criação deste `DynamicFrame`.

Classe DynamicFrameCollection

Um `DynamicFrameCollection` é um dicionário de objetos Classe DynamicFrame, em que as chaves são os nomes de `DynamicFrames` e os valores são os objetos `DynamicFrame`.

__init__

`__init__(dynamic_frames, glue_ctx)`

- `dynamic_frames` – Um dicionários de objetos Classe DynamicFrame.
- `glue_ctx` – Um objeto Classe GlueContext.

Chaves

`keys( )` – Retorna uma lista das chaves nesta coleção, que geralmente consiste nos nomes de valores correspondentes `DynamicFrame`.

Valores

`values(key)` – Retorna uma lista de valores `DynamicFrame` nesta coleção.

Selecionar

`select(key)`

Retorna o `DynamicFrame` que corresponde à chave especificada (que geralmente é o nome do `DynamicFrame`).

- `key` – Uma chave no `DynamicFrameCollection`, que geralmente representa o nome de um `DynamicFrame`.

Mapa

`map(callable, transformation_ctx="")`

Usa uma função transmitida para criar e retornar um novo `DynamicFrameCollection` com base em `DynamicFrames` nesta coleção.

- `callable` – Uma função que usa `DynamicFrame` e o contexto de transformação especificado como parâmetros e retorna um `DynamicFrame`.
- `transformation_ctx` – Um contexto de transformação a ser usado por algo que pode ser chamado (opcional).

Flatmap

`flatmap(f, transformation_ctx="")`

Usa uma função transmitida para criar e retornar um novo `DynamicFrameCollection` com base em `DynamicFrames` nesta coleção.

- `f` – Uma função que usa um `DynamicFrame` como um parâmetro e retorna um `DynamicFrame` ou `DynamicFrameCollection`.
- `transformation_ctx` – Um contexto de transformação a ser usado pela função (opcional).

Classe DynamicFrameWriter

Métodos

- __init__
- from_options
- from_catalog
- from_jdbc_conf

__init__

`__init__(glue_context)`

- `glue_context` – O Classe GlueContext a ser usado.

from_options

`from_options(frame, connection_type, connection_options={}, format=None, format_options={}, transformation_ctx="")`

Escreve um `DynamicFrame` usando a conexão e o formato especificados.

- `frame` – O `DynamicFrame` a ser escrito.
- `connection_type`: o tipo de conexão. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` e `oracle`.
- `connection_options` – Opções de conexão, como caminho e tabela de banco de dados (opcional). Para um `connection_type` do `s3`, um caminho do Amazon S3 é definido.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Para conexões JDBC, várias propriedades devem ser definidas. Observe que o nome do banco de dados deve fazer parte do URL. Ele também pode ser incluído nas opções de conexão.

> **Warning**
>
> Não é recomendável armazenar senhas no script. Considere usar `boto3` para recuperá-los do AWS Secrets Manager ou do catálogo de dados do AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

A propriedade `dbtable` é o nome da tabela JDBC. Para armazenamentos de dados JDBC que oferecem suporte a esquemas dentro de um banco de dados, especifique `schema.table-name`. Se um esquema não for fornecido, o esquema "público" padrão será usado.

Para ter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.

- `format`: uma especificação de formato (opcional). Essa ação é usada para um Amazon Simple Storage Service (Amazon S3) ou uma conexão do AWS Glue que ofereça suporte a vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.

- `format_options`: as opções de formato para o formato especificado. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `transformation_ctx` – Um contexto de transformação a ser usado (opcional).

from_catalog

`from_catalog(frame, name_space, table_name, redshift_tmp_dir="", transformation_ctx="")`

Escreve um `DynamicFrame` usando o banco de dados do catálogo e o nome da tabela especificados.

- `frame` – O `DynamicFrame` a ser escrito.
- `name_space` – O mecanismo de banco de dados a ser usado.
- `table_name` – O `table_name` a ser usado.
- `redshift_tmp_dir`: um diretório temporário do Amazon RedShift a ser usado (opcional).
- `transformation_ctx` – Um contexto de transformação a ser usado (opcional).
- `additional_options`: opções adicionais fornecidas ao AWS Glue.

  Para gravar em tabelas governadas pelo Lake Formation, você pode usar estas opções adicionais:

  - `transactionId`: (string) o ID da transação no qual fazer a gravação na tabela governada. Esta transação já não pode ser confirmada ou anulada, ou a gravação falhará.
  - `callDeleteObjectsOnCancel` : (booleano, opcional) Se definido como `true` (padrão), o AWS Glue chama automaticamente a API `DeleteObjectsOnCancel` após o objeto ser gravado no Amazon S3. Para obter mais informações, consulte DeleteObjectsOnCancel no Guia do desenvolvedor do AWS Lake Formation.

  Example Exemplo: gravação em uma tabela governada no 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="")`

Escreve um `DynamicFrame` usando as informações de conexão JDBC especificadas.

- `frame` – O `DynamicFrame` a ser escrito.
- `catalog_connection` – Uma conexão de catálogo a ser usada.
- `connection_options` – Opções de conexão, como caminho e tabela de banco de dados (opcional).
- `redshift_tmp_dir`: um diretório temporário do Amazon RedShift a ser usado (opcional).
- `transformation_ctx` – Um contexto de transformação a ser usado (opcional).

Exemplo para write_dynamic_frame

Este exemplo grava a saída localmente usando um `connection_type` do S3 com um argumento de caminho POSIX em `connection_options`, o que permite gravar no armazenamento local.

```
glueContext.write_dynamic_frame.from_options(\
frame = dyf_splitFields,\
connection_options = {'path': '/home/glue/GlueLocalOutput/'},\
connection_type = 's3',\
format = 'json')
```

Classe DynamicFrameReader

— métodos —

- __init__
- from_rdd
- from_options
- from_catalog

__init__

`__init__(glue_context)`

- `glue_context` – O Classe GlueContext a ser usado.

from_rdd

`from_rdd(data, name, schema=None, sampleRatio=None)`

Lê um `DynamicFrame` de um Conjunto de dados resiliente distribuído (RDD).

- `data` – O conjunto de dados onde a leitura será feita.
- `name` – O nome onde a leitura será feita.
- `schema` – O esquema a ser lido (opcional).
- `sampleRatio` – A proporção da amostra (opcional).

from_options

`from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx="")`

Lê um `DynamicFrame` usando a conexão e o formato especificados.

- `connection_type`: o tipo de conexão. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle`, `dynamodb` e `snowflake`.
- `connection_options` – Opções de conexão, como caminho e tabela de banco de dados (opcional). Para obter mais informações, consulte Tipos de conexão e opções para ETL no AWS Glue para Spark. Para um `connection_type` do `s3`, os caminhos do Amazon S3 são definidos em uma matriz.

  ```
  connection_options = {"paths": [ "s3://amzn-s3-demo-bucket/object_a", "s3://amzn-s3-demo-bucket/object_b"]}
  ```

  Para conexões JDBC, várias propriedades devem ser definidas. Observe que o nome do banco de dados deve fazer parte do URL. Ele também pode ser incluído nas opções de conexão.

> **Warning**
>
> Não é recomendável armazenar senhas no script. Considere usar `boto3` para recuperá-los do AWS Secrets Manager ou do catálogo de dados do AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

Para uma conexão JDBC que realiza leituras paralelas, você pode definir a opção hashfield. Por exemplo:

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path" , "hashfield": "month"}
```

Para obter mais informações, consulte Leitura de tabelas JDBC em paralelo.

- `format`: uma especificação de formato (opcional). Essa ação é usada para um Amazon Simple Storage Service (Amazon S3) ou uma conexão do AWS Glue que ofereça suporte a vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `format_options`: as opções de formato para o formato especificado. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `push_down_predicate`: filtra partições sem a necessidade de listar e ler todos os arquivos no seu conjunto de dados. Para obter mais informações, consulte Pré-filtragem usando a aplicação de predicados.

from_catalog

`from_catalog(database, table_name, redshift_tmp_dir="", transformation_ctx="", push_down_predicate="", additional_options={})`

Lê um `DynamicFrame` usando o namespace do catálogo e o nome da tabela especificados.

- `database` – O banco de dados onde a leitura será feita.
- `table_name` – O nome da tabela onde a leitura será feita.
- `redshift_tmp_dir`: um diretório temporário do Amazon Redshift a ser usado (opcional se não estiver lendo dados do Redshift).
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `push_down_predicate`: filtra partições sem a necessidade de listar e ler todos os arquivos no seu conjunto de dados. Para obter mais informações, consulte Pré-filtragem usando a aplicação de predicados.
- `additional_options`: opções adicionais fornecidas ao AWS Glue.
  - Para usar uma conexão JDBC que realiza leituras paralelas, você pode definir as opções `hashfield`, `hashexpression` ou `hashpartitions`. Por exemplo:

    ```
    additional_options = {"hashfield": "month"}
    ```

    Para obter mais informações, consulte Leitura de tabelas JDBC em paralelo.
  - Para transmitir uma expressão de catálogo para filtrar com base nas colunas de índice, você pode consultar o opção `catalogPartitionPredicate`.

    `catalogPartitionPredicate`: você pode transmitir uma expressão de catálogo para filtrar com base nas colunas de índice. Isso leva a filtragem para o lado do servidor. Para obter mais informações, consulte Índices de partição do AWS Glue. Observe que `push_down_predicate` e `catalogPartitionPredicate` usam sintaxes diferentes. O primeiro usa a sintaxe padrão do Spark SQL e o outro usa o analisador JSQL.

    Para obter mais informações, consulte Gerenciar partições para saída de ETL no AWS Glue.

Classe GlueContext

Encapsula o objeto SparkContext do Apache SparkSQL e, portanto, fornece mecanismos para interagir com a plataforma do Apache Spark.

__init__

`__init__(sparkContext)`

- `sparkContext` – O contexto do Apache Spark a ser usado.

Criando

- __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)`

Cria um objeto `DataSource` que pode ser usado para ler `DynamicFrames` a partir de fontes externas.

- `connection_type`: o tipo de conexão a ser usado, por exemplo, Amazon Simple Storage Service (Amazon S3), Amazon Redshift e JDBC. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` e dynamodb.
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `options` – Uma coleção de pares nome-valor opcionais. Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.

Veja a seguir um exemplo de uso do `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="")`

Retorna um `DynamicFrame` que é criado a partir de um conjunto de dados resiliente distribuído (RDD) do Apache Spark.

- `data` – A fonte de dados a ser usada.
- `name` – O nome dos dados a serem usados.
- `schema` – O esquema a ser usado (opcional).
- `sample_ratio` – A proporção da amostra a ser usada (opcional).
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).

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)`

Retorna um `DynamicFrame` que é criado usando um banco de dados do Data Catalog e o nome da tabela. Ao usar esse método, você fornece `format_options` por meio das propriedades de tabela especificadas do catálogo de dados do AWS Glue e outras opções por meio do argumento `additional_options`.

- `Database` – O banco de dados onde a leitura será feita.
- `table_name` – O nome da tabela onde a leitura será feita.
- `redshift_tmp_dir`: um diretório temporário do Amazon Redshift a ser usado (opcional).
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `push_down_predicate`: filtra partições sem a necessidade de listar e ler todos os arquivos no seu conjunto de dados. Para fontes e limitações compatíveis, consulte Otimizar leituras com pushdown no AWS Glue ETL. Para obter mais informações, consulte Pré-filtragem usando a aplicação de predicados.
- `additional_options` – Uma coleção de pares nome-valor opcionais. As opções possíveis incluem as listadas em Tipos e opções de conexão para ETL no AWS Glue para Spark, exceto

para endpointUrl, streamName, bootstrap.servers, security.protocol, topicName, classification e delimiter. Outra opção suportada é catalogPartitionPredicate:

catalogPartitionPredicate: você pode transmitir uma expressão de catálogo para filtrar com base nas colunas de índice. Isso leva a filtragem para o lado do servidor. Para obter mais informações, consulte Índices de partição do AWS Glue. Observe que push_down_predicate e catalogPartitionPredicate usam sintaxes diferentes. O primeiro usa a sintaxe padrão do Spark SQL e o outro usa o analisador JSQL.

- catalog_id: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando None (Nenhum), o ID da conta do chamador padrão é usado.

create_dynamic_frame_from_options

create_dynamic_frame_from_options(connection_type, connection_options={}, format=None, format_options={}, transformation_ctx = "")

Retorna um DynamicFrame criado com a conexão e o formato especificados.

- connection_type: o tipo de conexão, por exemplo, Amazon S3, Amazon Redshift e JDBC. Os valores válidos incluem s3, mysql, postgresql, redshift, sqlserver, oracle e dynamodb.
- connection_options: opções de conexão, como caminhos e tabela de banco de dados (opcional). Para um connection_type do s3, uma lista de caminhos do Amazon S3 é definida.

```
connection_options = {"paths": ["s3://aws-glue-target/temp"]}
```

Para conexões JDBC, várias propriedades devem ser definidas. Observe que o nome do banco de dados deve fazer parte do URL. Ele também pode ser incluído nas opções de conexão.

> **Warning**
>
> Não é recomendável armazenar senhas no script. Considere usar boto3 para recuperá-los do AWS Secrets Manager ou do catálogo de dados do AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

A propriedade `dbtable` é o nome da tabela JDBC. Para armazenamentos de dados JDBC que oferecem suporte a esquemas dentro de um banco de dados, especifique `schema.table-name`. Se um esquema não for fornecido, o esquema "público" padrão será usado.

Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.

- `format`: uma especificação de formato. É usado para uma conexão do Amazon S3 ou do AWS Glue com suporte para vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `format_options`: as opções de formato para o formato especificado. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `push_down_predicate`: filtra partições sem a necessidade de listar e ler todos os arquivos no seu conjunto de dados. Para fontes e limitações compatíveis, consulte Otimizar leituras com pushdown no AWS Glue ETL. Para obter mais informações, consulte Pré-filtragem usando a aplicação de predicados.

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)`

Retorna um modelo `DynamicFrame` que é criado usando um banco de dados do Data Catalog e o nome da tabela. O `DynamicFrame` contém apenas os primeiros `num` registros de uma fonte de dados.

- `database` – O banco de dados onde a leitura será feita.
- `table_name` – O nome da tabela onde a leitura será feita.
- num - O número máximo de registros no quadro dinâmico de amostra retornado.
- `redshift_tmp_dir`: um diretório temporário do Amazon Redshift a ser usado (opcional).
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).

- `push_down_predicate`: filtra partições sem a necessidade de listar e ler todos os arquivos no seu conjunto de dados. Para obter mais informações, consulte Pré-filtragem usando a aplicação de predicados.
- `additional_options` – Uma coleção de pares nome-valor opcionais. As opções possíveis incluem as listadas em Tipos e opções de conexão para ETL no AWS Glue para Spark, exceto para `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` e `delimiter`.
- `sample_options` - Parâmetros para controlar o comportamento de amostragem (opcional). Parâmetros disponíveis atuais para fontes do Amazon S3:
  - `maxSamplePartitions` - O número máximo de partições que a amostragem lerá. O valor padrão é 10
  - `maxSampleFilesPerPartition` - O número máximo de partições que a amostragem lerá em uma partição. O valor padrão é 10

    Esses parâmetros ajudam a reduzir o tempo consumido pela listagem de arquivos. Por exemplo, suponha que o conjunto de dados tenha 1.000 partições e cada partição tenha 10 arquivos. Se você definir `maxSamplePartitions`= 10 e `maxSampleFilesPerPartition`= 10, em vez de listar todos os 10.000 arquivos, a amostragem listará e lerá apenas as primeiras 10 partições com os primeiros 10 arquivos em cada: 10*10 = 100 arquivos no total.
- `catalog_id`: o ID do catálogo do Data Catalog sendo acessado (o ID da conta do Data Catalog). Definido como `None` por padrão. O `None` é definido como padrão para o ID do catálogo da conta de chamada no serviço.

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 = "")`

Retorna um modelo `DynamicFrame` criado com a conexão e o formato especificados. O `DynamicFrame` contém apenas os primeiros `num` registros de uma fonte de dados.

- `connection_type`: o tipo de conexão, por exemplo, Amazon S3, Amazon Redshift e JDBC. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle` e `dynamodb`.

- `connection_options`: opções de conexão, como caminhos e tabela de banco de dados (opcional). Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.
- `num` - O número máximo de registros no quadro dinâmico de amostra retornado.
- `sample_options` - Parâmetros para controlar o comportamento de amostragem (opcional). Parâmetros disponíveis atuais para fontes do Amazon S3:
  - `maxSamplePartitions` - O número máximo de partições que a amostragem lerá. O valor padrão é 10
  - `maxSampleFilesPerPartition` - O número máximo de partições que a amostragem lerá em uma partição. O valor padrão é 10

    Esses parâmetros ajudam a reduzir o tempo consumido pela listagem de arquivos. Por exemplo, suponha que o conjunto de dados tenha 1.000 partições e cada partição tenha 10 arquivos. Se você definir `maxSamplePartitions`= 10 e `maxSampleFilesPerPartition`= 10, em vez de listar todos os 10.000 arquivos, a amostragem listará e lerá apenas as primeiras 10 partições com os primeiros 10 arquivos em cada: 10*10 = 100 arquivos no total.
- `format`: uma especificação de formato. É usado para uma conexão do Amazon S3 ou do AWS Glue com suporte para vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `format_options`: as opções de formato para o formato especificado. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `push_down_predicate`: filtra partições sem a necessidade de listar e ler todos os arquivos no seu conjunto de dados. Para obter mais informações, consulte Pré-filtragem usando a aplicação de predicados.

add_ingestion_time_columns

`add_ingestion_time_columns(dataFrame, timeGranularity = "")`

Acrescenta colunas de tempo de ingestão, como `ingest_year`, `ingest_month`, `ingest_day`, `ingest_hour`, `ingest_minute`, para o `DataFrame` de entrada. Essa função é gerada automaticamente no script gerado pelo AWS Glue, quando você especifica uma tabela do catálogo de dados com o Amazon S3 como destino. Essa função atualiza automaticamente a partição com colunas de tempo de ingestão na tabela de saída. Isso permite que os dados de saída sejam

particionados automaticamente no tempo de ingestão sem exigir colunas de tempo de ingestão explícitas nos dados de entrada.

- `dataFrame`: o `dataFrame` ao qual anexar as colunas de tempo de ingestão.
- `timeGranularity`: o detalhamento das colunas de tempo. Os valores válidos são “`day`”, “`hour`” e “`minute`”. Por exemplo, se “`hour`” é transmitido para a função, o `dataFrame` original terá as colunas de tempo “`ingest_year`”, “`ingest_month`”, “`ingest_day`” e “`ingest_hour`” anexadas.

Retorna o quadro de dados após anexar as colunas de detealhamento de tempo.

Exemplo:

```
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 = {})`

Retorna um `DataFrame` que é criado usando informações de uma tabela do Data Catalog.

- `database`: o banco de dados do Data Catalog do qual fazer a leitura.
- `table_name`: o nome da tabela do Data Catalog da qual fazer a leitura.
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `additional_options` – Uma coleção de pares nome-valor opcionais. As opções possíveis incluem as listadas em Tipos e opções de conexão para ETL no AWS Glue para Spark para fontes de transmissão, como `startingPosition`, `maxFetchTimeInMs` e `startingOffsets`.
  - `useSparkDataSource`: quando definido como true, força o AWS Glue a usar a API do Spark Data Source nativa para ler a tabela. A API do Spark Data Source é compatível nos seguintes formatos: AVRO, binário, CSV, JSON, ORC, Parquet e texto. Em uma tabela do Data Catalog, você especifica o formato usando a propriedade `classification`. Para saber mais sobre a API do Spark Data Source, consulte a documentação oficial do Apache Spark.

    O uso de `create_data_frame_from_catalog` com `useSparkDataSource` apresenta os seguintes benefícios:

- Retorna diretamente um `DataFrame` e fornece uma alternativa a `create_dynamic_frame.from_catalog().toDF()`.
- É compatível com o controle de permissão no nível da tabela do AWS Lake Formation para formatos nativos.
- É compatível com a leitura de formatos de data lake sem controle de permissão no nível da tabela do AWS Lake Formation. Para obter mais informações, consulte Usar estruturas de data lake com trabalhos do AWS Glue ETL.

Quando você ativa o `useSparkDataSource`, pode adicionar qualquer fonte as opções do Spark Data Source ao `additional_options`, conforme necessário. AWS O Glue passa essas opções diretamente para o leitor do Spark.

- `useCatalogSchema`: quando definido como true, o AWS Glue aplica o esquema do Data Catalog ao `DataFrame` resultante. Caso contrário, o leitor infere o esquema a partir dos dados. Quando você habilita o `useCatalogSchema`, deve também definir `useSparkDataSource` como true.

Limitações

Considere as seguintes limitações ao usar a opção `useSparkDataSource`:

- Quando você usa `useSparkDataSource`, o AWS Glue cria um novo `DataFrame` em uma sessão separada do Spark que é diferente da sessão original do Spark.
- A filtragem de partições do Spark DataFrame não funciona com os seguintes recursos do AWS Glue.
  - Marcadores de trabalho
  - Excluir classes de armazenamento do Amazon S3
  - Predicados de partição de catálogo

  Para usar a filtragem de partições com esses recursos, você pode usar o predicado de pushdown do AWS Glue. Para obter mais informações, consulte Pré-filtragem usando a aplicação de predicados. A filtragem em colunas não particionadas não é afetada.

  O script de exemplo a seguir demonstra a maneira incorreta de realizar a filtragem de partições com a opção `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'")
```

O exemplo de script a seguir demonstra a maneira correta de usar um predicado de pushdown para realizar a filtragem de partições com a opção `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'")
```

Exemplo: criar uma tabela CSV usando o leitor de fonte de dados do 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 = "")`

Essa API foi descontinuada. No lugar dela, use a API `getSource()`. Retorna um `DataFrame` criado com a conexão e o formato especificados. Use essa função apenas com fontes de transmissão do AWS Glue.

- `connection_type`: o tipo de conexão de transmissão. Os valores válidos são `kinesis` e `kafka`.
- `connection_options`: opções de conexão, que são diferentes para Kinesis e Kafka. Você pode encontrar a lista de todas as opções de conexão para cada origem dos dados de transmissão em Tipos e opções de conexão para ETL no AWS Glue para Spark. Observe as seguintes diferenças nas opções de conexão de transmissão:
  - As fontes de transmissão do Kinesis exigem `streamARN`, `startingPosition`, `inferSchema` e `classification`.
  - As fontes de transmissão do Kafka exigem `connectionName`, `topicName`, `startingOffsets`, `inferSchema` e `classification`.
- `format`: uma especificação de formato. É usado para uma conexão do Amazon S3 ou do AWS Glue com suporte para vários formatos. Para obter informações sobre os formatos compatíveis, consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark.
- `format_options`: as opções de formato para o formato especificado. Para obter informações sobre as opções de formato compatíveis, consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark.
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).

Exemplo para fonte de transmissão do 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)
```

Exemplo para fonte de transmissão do 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)`

Aplica a `batch_function` transmitida para cada microlote lido a partir da fonte de transmissão.

- `frame`: o DataFrame que contém o microlote atual.
- `batch_function`: uma função que será aplicada para cada microlote.
- `options`: uma coleção de pares de chave-valor que contém informações sobre como processar microlotes. São necessárias as seguintes opções:
  - `windowSize`: a quantidade de tempo gasto no processamento de cada lote.
  - `checkpointLocation`: o local onde os pontos de verificação são armazenados para o trabalho de ETL de transmissão.
  - `batchMaxRetries`: o número máximo de novas tentativas deste lote em caso de falha. O valor padrão é 3. Essa opção só pode ser configurada para o Glue versão 2.0 e posterior.

Exemplo:

```
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
        )
```

Trabalhar com conjuntos de dados no 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="")

Exclui arquivos do Amazon S3 para as tabelas e os bancos de dados do catálogo especificados. Se todos os arquivos em uma partição forem excluídos, essa partição também será removida do catálogo. Não oferecemos suporte à ação purge_table em tabelas registradas no Lake Formation.

Se quiser recuperar objetos excluídos, você pode habilitar o versionamento de objeto no bucket do Amazon S3. Quando um objeto é excluído de um bucket que não tem o versionamento de objeto habilitado, o objeto não pode ser recuperado. Para obter mais informações sobre como recuperar objetos excluídos em um bucket habilitado para versionamento, consulte Como posso recuperar um objeto do Amazon S3 que foi excluído? na Central de Conhecimento do AWS Support.

- `catalog_id`: o ID do catálogo do Data Catalog sendo acessado (o ID da conta do Data Catalog). Definido como `None` por padrão. O `None` é definido como padrão para o ID do catálogo da conta de chamada no serviço.
- `database` – O mecanismo de banco de dados a ser usado.
- `table_name`: o nome da tabela a ser usada.
- `options`: opções para filtrar arquivos a serem excluídos e para geração do arquivo manifesto.
  - `retentionPeriod`: especifica um período em quantidade de horas para reter arquivos. Os arquivos mais recentes do que o período de retenção serão mantidos. Definido como 168 horas (7 dias) por padrão.
  - `partitionPredicate`: as partições que satisfazem esse predicado são excluídas. Os arquivos dentro do período de retenção nessas partições não são excluídos. Definido como `""`, vazio por padrão.
  - `excludeStorageClasses`: os arquivos com classe de armazenamento no conjunto `excludeStorageClasses` não são excluídos. O padrão é `Set()`, um conjunto vazio.
  - `manifestFilePath`: um caminho opcional para a geração do arquivo manifesto. Todos os arquivos que foram removidos com êxito são registrados no `Success.csv`, e os que falharam no `Failed.csv`
- `transformation_ctx` – O contexto de transformação a ser usado (opcional). Usado no caminho do arquivo de manifesto.

Example

```
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="")`

Exclui arquivos do caminho Amazon S3 especificado recursivamente.

Se quiser recuperar objetos excluídos, você pode habilitar o versionamento de objeto no bucket do Amazon S3. Quando um objeto é excluído de um bucket que não tem o versionamento de objeto habilitado, ele não pode ser recuperado. Para obter mais informações sobre como recuperar objetos

excluídos em um bucket habilitado para versionamento, consulte Como posso recuperar um objeto do Amazon S3 que foi excluído? na Central de Conhecimento do Suporte.

- `s3_path`: o caminho no Amazon S3 dos arquivos a serem excluídos no formato `s3://<bucket>/<prefix>/`
- `options`: opções para filtrar arquivos a serem excluídos e para geração do arquivo manifesto.
  - `retentionPeriod`: especifica um período em quantidade de horas para reter arquivos. Os arquivos mais recentes do que o período de retenção serão mantidos. Definido como 168 horas (7 dias) por padrão.
  - `excludeStorageClasses`: os arquivos com classe de armazenamento no conjunto `excludeStorageClasses` não são excluídos. O padrão é `Set()`, um conjunto vazio.
  - `manifestFilePath`: um caminho opcional para a geração do arquivo manifesto. Todos os arquivos que foram removidos com êxito são registrados no `Success.csv`, e os que falharam no `Failed.csv`
- `transformation_ctx` – O contexto de transformação a ser usado (opcional). Usado no caminho do arquivo de manifesto.

Example

```
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)`

Move a classe de armazenamento dos arquivos armazenados no Amazon S3 para o banco de dados e tabela do catálogo especificados.

É possível fazer a transição entre duas classes de armazenamento quaisquer. Nas classes de armazenamento `DEEP_ARCHIVE` e `GLACIER` e, você pode fazer a transição para essas classes. No entanto, você usaria um `S3 RESTORE` para fazer a transição das classes de armazenamento `GLACIER` e `DEEP_ARCHIVE`.

Se você estiver executando trabalhos de ETL do AWS Glue que leiam arquivos ou partições do Amazon S3, pode excluir alguns tipos de classe de armazenamento do Amazon S3. Para obter mais informações, consulte Excluir classes de armazenamento do Amazon S3.

- `database` – O mecanismo de banco de dados a ser usado.
- `table_name`: o nome da tabela a ser usada.
- `transition_to`: a classe de armazenamento do Amazon S3 para onde mover.
- `options`: opções para filtrar arquivos a serem excluídos e para geração do arquivo manifesto.
  - `retentionPeriod`: especifica um período em quantidade de horas para reter arquivos. Os arquivos mais recentes do que o período de retenção serão mantidos. Definido como 168 horas (7 dias) por padrão.
  - `partitionPredicate`: as partições que satisfazem esse predicado são movidas. Os arquivos dentro do período de retenção nessas partições não são transicionados. Definido como `""`, vazio por padrão.
  - `excludeStorageClasses`: os arquivos com classe de armazenamento no conjunto `excludeStorageClasses` não são movidos. O padrão é `Set()`, um conjunto vazio.
  - `manifestFilePath`: um caminho opcional para a geração do arquivo manifesto. Todos os arquivos que foram transicionados com êxito são registrados no `Success.csv`, e os que falharam no `Failed.csv`
  - `accountId`: o ID da conta da Amazon Web Services para executar a transformação de transição. Obrigatório para essa transformação.
  - `roleArn`: a função da AWS para executar a transformação de transição. Obrigatório para essa transformação.
- `transformation_ctx` – O contexto de transformação a ser usado (opcional). Usado no caminho do arquivo de manifesto.
- `catalog_id`: o ID do catálogo do Data Catalog sendo acessado (o ID da conta do Data Catalog). Definido como `None` por padrão. O `None` é definido como padrão para o ID do catálogo da conta de chamada no serviço.

Example

```
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="")`

Move a classe de armazenamento dos arquivos no caminho do Amazon S3 especificado recursivamente.

É possível fazer a transição entre duas classes de armazenamento quaisquer. Nas classes de armazenamento `DEEP_ARCHIVE` e `GLACIER` e, você pode fazer a transição para essas classes. No entanto, você usaria um `S3 RESTORE` para fazer a transição das classes de armazenamento `GLACIER` e `DEEP_ARCHIVE`.

Se você estiver executando trabalhos de ETL do AWS Glue que leiam arquivos ou partições do Amazon S3, pode excluir alguns tipos de classe de armazenamento do Amazon S3. Para obter mais informações, consulte Excluir classes de armazenamento do Amazon S3.

- `s3_path`: o caminho no Amazon S3 dos arquivos a serem movidos no formato `s3://<bucket>/<prefix>/`
- `transition_to`: a classe de armazenamento do Amazon S3 para onde mover.
- `options`: opções para filtrar arquivos a serem excluídos e para geração do arquivo manifesto.
  - `retentionPeriod`: especifica um período em quantidade de horas para reter arquivos. Os arquivos mais recentes do que o período de retenção serão mantidos. Definido como 168 horas (7 dias) por padrão.
  - `partitionPredicate`: as partições que satisfazem esse predicado são movidas. Os arquivos dentro do período de retenção nessas partições não são transicionados. Definido como `""`, vazio por padrão.
  - `excludeStorageClasses`: os arquivos com classe de armazenamento no conjunto `excludeStorageClasses` não são movidos. O padrão é `Set()`, um conjunto vazio.
  - `manifestFilePath`: um caminho opcional para a geração do arquivo manifesto. Todos os arquivos que foram transicionados com êxito são registrados no `Success.csv`, e os que falharam no `Failed.csv`
  - `accountId`: o ID da conta da Amazon Web Services para executar a transformação de transição. Obrigatório para essa transformação.
  - `roleArn`: a função da AWS para executar a transformação de transição. Obrigatório para essa transformação.

- `transformation_ctx` – O contexto de transformação a ser usado (opcional). Usado no caminho do arquivo de manifesto.

Example

```
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"})
```

Extração

- extract_jdbc_conf

extract_jdbc_conf

`extract_jdbc_conf(connection_name, catalog_id = None)`

Retorna um `dict` com chaves com as propriedades de configuração do objeto de conexão da AWS Glue no catálogo de dados.

- `user`: o nome de usuário do banco de dados.
- `password`: a senha do banco de dados.
- `vendor`: especifica um fornecedor (`mysql`, `postgresql`, `oracle`, `sqlserver` etc.).
- `enforceSSL`: uma string booleana indicando se é necessária uma conexão segura.
- `customJDBCCert`: use um certificado de cliente específico no caminho do Amazon S3 indicado.
- `skipCustomJDBCCertValidation`: uma string booleana indicando se o `customJDBCCert` deve ser validado por uma autoridade de certificação.
- `customJDBCCertString`: informações adicionais sobre o certificado personalizado, específicas para o tipo de driver.
- `url`: (obsoleto) URL do JDBC apenas com protocolo, servidor e porta.
- `fullUrl`: URL do JDBC como inserido quando a conexão foi criada (disponível no AWS Glue versão 3.0 ou posterior).

Exemplo de recuperação de configurações do 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'}
```

Transações

- start_transaction
- commit_transaction
- cancel_transaction

start_transaction

`start_transaction(read_only)`

Iniciar uma nova transação. Chama internamente a API startTransaction do Lake Formation.

- `read_only`: (booleano) indica se esta transação deve ser somente de leitura ou de leitura e gravação. As gravações feitas usando um ID de transação somente de leitura serão rejeitadas. As transações somente de leitura não precisam ser confirmadas.

Retorna o ID da transação.

commit_transaction

`commit_transaction(transaction_id, wait_for_commit = True)`

Tenta confirmar a transação especificada. `commit_transaction` pode retornar antes que a transação tenha terminado de confirmar. Chama internamente a API commitTransaction do Lake Formation.

- `transaction_id` : (string) a transação a ser confirmada.
- `wait_for_commit`: (booleano) Determina se `commit_transaction` retorna imediatamente. O valor padrão é true. Se for falso, `commit_transaction` sonda e aguarda até que a transação seja confirmada. A quantidade de tempo de espera é restrita a 1 minuto usando recuo exponencial com um máximo de 6 tentativas.

Retorna um booleano para indicar se a confirmação foi feita ou não.

cancel_transaction

`cancel_transaction(transaction_id)`

Tenta cancelar a transação especificada. Retorna uma exceção `TransactionCommittedException` se a transação tiver sido confirmada anteriormente. Chama internamente a API cancelTransaction do Lake Formation.

- `transaction_id`: (string) a transação a ser cancelada.

Writing

- 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)`

Obtém um objeto `DataSink` que pode ser usado para escrever `DynamicFrames` em fontes externas. Verifique o `format` do SparkSQL primeiro para garantir a obtenção do depósito esperado.

- `connection_type`: o tipo de conexão a ser usado, como Amazon S3, Amazon Redshift e JDBC. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle`, `kinesis` e `kafka`.
- `format` – o formato do SparkSQL a ser usado (opcional).
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `options`: uma coleção de pares nome-valor usados para especificar as opções de conexão. Alguns dos valores possíveis são:
  - `user` e `password`:pPara autorização

- `url`:o endpoint para o datastore
- `dbtable`: o nome da tabela de destino.
- `bulkSize`: grau de paralelismo para operações de inserção

As opções que você pode especificar dependem do tipo de conexão. Consulte Tipos e opções de conexão para ETL no AWS Glue para Spark para obter valores e exemplos adicionais.

Exemplo:

```
>>> 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 = "")`

Escreve e retorna um `DynamicFrame` usando a conexão e o formato especificados.

- `frame` – O `DynamicFrame` a ser escrito.
- `connection_type`: o tipo de conexão, por exemplo, Amazon S3, Amazon Redshift e JDBC. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver`, `oracle`, `kinesis` e `kafka`.
- `connection_options` – Opções de conexão, como caminho e tabela de banco de dados (opcional). Para um `connection_type` do `s3`, um caminho do Amazon S3 é definido.

  ```
  connection_options = {"path": "s3://aws-glue-target/temp"}
  ```

  Para conexões JDBC, várias propriedades devem ser definidas. Observe que o nome do banco de dados deve fazer parte do URL. Ele também pode ser incluído nas opções de conexão.

  > **Warning**
  >
  > Não é recomendável armazenar senhas no script. Considere usar `boto3` para recuperá-los do AWS Secrets Manager ou do catálogo de dados do AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

A propriedade `dbtable` é o nome da tabela JDBC. Para armazenamentos de dados JDBC que oferecem suporte a esquemas dentro de um banco de dados, especifique `schema.table-name`. Se um esquema não for fornecido, o esquema "público" padrão será usado.

Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.

- `format`: uma especificação de formato. É usado para uma conexão do Amazon S3 ou do AWS Glue com suporte para vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `format_options`: as opções de formato para o formato especificado. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `transformation_ctx` – Um contexto de transformação a ser usado (opcional).

write_from_options

`write_from_options(frame_or_dfc, connection_type, connection_options={}, format={}, format_options={}, transformation_ctx = "")`

Escreve e retorna o código `DynamicFrame` ou `DynamicFrameCollection` criado com as informações de conexão e formato especificadas.

- `frame_or_dfc` – O código `DynamicFrame` ou `DynamicFrameCollection` a ser escrito.
- `connection_type`: o tipo de conexão, por exemplo, Amazon S3, Amazon Redshift e JDBC. Os valores válidos incluem `s3`, `mysql`, `postgresql`, `redshift`, `sqlserver` e `oracle`.
- `connection_options` – Opções de conexão, como caminho e tabela de banco de dados (opcional). Para um `connection_type` do `s3`, um caminho do Amazon S3 é definido.

```
connection_options = {"path": "s3://aws-glue-target/temp"}
```

Para conexões JDBC, várias propriedades devem ser definidas. Observe que o nome do banco de dados deve fazer parte do URL. Ele também pode ser incluído nas opções de conexão.

> **Warning**
>
> Não é recomendável armazenar senhas no script. Considere usar `boto3` para recuperá-los do AWS Secrets Manager ou do catálogo de dados do AWS Glue.

```
connection_options = {"url": "jdbc-url/database", "user": "username",
 "password": passwordVariable,"dbtable": "table-name", "redshiftTmpDir": "s3-tempdir-path"}
```

A propriedade `dbtable` é o nome da tabela JDBC. Para armazenamentos de dados JDBC que oferecem suporte a esquemas dentro de um banco de dados, especifique `schema.table-name`. Se um esquema não for fornecido, o esquema "público" padrão será usado.

Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.

- `format`: uma especificação de formato. É usado para uma conexão do Amazon S3 ou do AWS Glue com suporte para vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `format_options`: as opções de formato para o formato especificado. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para obter os formatos compatíveis.
- `transformation_ctx` – Um contexto de transformação a ser usado (opcional).

write_dynamic_frame_from_catalog

`write_dynamic_frame_from_catalog(frame, database, table_name, redshift_tmp_dir, transformation_ctx = "", additional_options = {}, catalog_id = None)`

Grava e retorna um `DynamicFrame` usando um banco de dados e uma tabela do Data Catalog.

- `frame` – O `DynamicFrame` a ser escrito.

- `Database`: o banco de dados do Data Catalog que contém a tabela.
- `table_name`: o nome da tabela do Data Catalog associada ao destino.
- `redshift_tmp_dir`: um diretório temporário do Amazon RedShift a ser usado (opcional).
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `additional_options` – Uma coleção de pares nome-valor opcionais.
- `catalog_id`: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando None (Nenhum), o ID da conta do chamador padrão é usado.

write_data_frame_from_catalog

`write_data_frame_from_catalog(frame, database, table_name, redshift_tmp_dir, transformation_ctx = "", additional_options = {}, catalog_id = None)`

Grava e retorna um `DataFrame` usando um banco de dados e uma tabela do Data Catalog. Esse método é compatível com a gravação nos formatos de data lake (Hudi, Iceberg e Delta Lake). Para obter mais informações, consulte Usar estruturas de data lake com trabalhos do AWS Glue ETL.

- `frame` – O `DataFrame` a ser escrito.
- `Database`: o banco de dados do Data Catalog que contém a tabela.
- `table_name`: o nome da tabela do Data Catalog associada ao destino.
- `redshift_tmp_dir`: um diretório temporário do Amazon Redshift a ser usado (opcional).
- `transformation_ctx` – O contexto de transformação a ser usado (opcional).
- `additional_options` – Uma coleção de pares nome-valor opcionais.
  - `useSparkDataSink`: quando definido como true, força o AWS Glue a usar a API Spark Data Sink nativa para gravar na tabela. Ao habilitar esta opção, você pode também adicionar qualquer uma das opções de Spark Data Source como `additional_options` conforme necessário. AWS O Glue passa essas opções diretamente para o gravador do Spark.
- `catalog_id`: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando você não especifica um valor, será usado o ID padrão da conta do chamador.

Limitações

Considere as seguintes limitações ao usar a opção `useSparkDataSink`:

- A opção enableUpdateCatalog não é compatível quando você usa a opção useSparkDataSink.

Exemplo: gravação em uma tabela Hudi usando o gravador do Spark Data Source

```
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)

Escreve e retorna um DynamicFrame usando as informações de conexão JDBC especificadas.

- frame – O DynamicFrame a ser escrito.
- catalog_connection – Uma conexão de catálogo a ser usada.

- `connection_options` – Opções de conexão, como caminho e tabela de banco de dados (opcional). Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.
- `redshift_tmp_dir`: um diretório temporário do Amazon RedShift a ser usado (opcional).
- `transformation_ctx` – Um contexto de transformação a ser usado (opcional).
- `catalog_id`: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando None (Nenhum), o ID da conta do chamador padrão é usado.

write_from_jdbc_conf

`write_from_jdbc_conf(frame_or_dfc, catalog_connection, connection_options={}, redshift_tmp_dir = "", transformation_ctx = "", catalog_id = None)`

Escreve e retorna um código `DynamicFrame` ou `DynamicFrameCollection` usando as informações de conexão JDBC especificadas.

- `frame_or_dfc` – O código `DynamicFrame` ou `DynamicFrameCollection` a ser escrito.
- `catalog_connection` – Uma conexão de catálogo a ser usada.
- `connection_options` – Opções de conexão, como caminho e tabela de banco de dados (opcional). Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark.
- `redshift_tmp_dir`: um diretório temporário do Amazon RedShift a ser usado (opcional).
- `transformation_ctx` – Um contexto de transformação a ser usado (opcional).
- `catalog_id`: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando None (Nenhum), o ID da conta do chamador padrão é usado.

Referência de transformações PySpark do AWS Glue

O AWS Glue fornece as transformações integradas a seguir que você pode usar em operações de ETL do PySpark. Os seus dados passam de transformação para transformação em uma estrutura de dados chamada DynamicFrame, que é a extensão de uma `DataFrame` do Apache Spark SQL. O `DynamicFrame` contém os dados, e você referencia o esquema para processar os dados.

A maioria dessas transformações também existe como métodos da classe `DynamicFrame`. Para obter mais informações, consulte Transformações DynamicFrame.

- Classe de base GlueTransform
- Classe ApplyMapping
- Classe DropFields
- Classe DropNullFields
- Classe ErrorsAsDynamicFrame
- Classe EvaluateDataQuality
- Classe FillMissingValues
- Classe Filter
- Classe FindIncrementalMatches
- Classe FindMatches
- Classe FlatMap
- Classe Join
- Classe Map
- Classe MapToCollection
- mergeDynamicFrame
- Classe Relationalize
- Classe RenameField
- Classe ResolveChoice
- Classe SelectFields
- Classe SelectFromCollection
- Classe Simplify_ddb_json
- Classe Spigot
- Classe SplitFields
- Classe SplitRows
- Classe Unbox
- Classe UnnestFrame

Classe de base GlueTransform

A classe base que todas as classes `awsglue.transforms` herdam.

Todas as classes definem um método `__call__`. Elas substituem os métodos da classe `GlueTransform` listados nas seções a seguir ou são chamadas usando o nome de classe, por padrão.

Métodos

- apply(cls, *args, **kwargs)
- name(cls)
- describeArgs(cls)
- describeReturn(cls)
- describeTransform(cls)
- describeErrors(cls)
- describe(cls)

apply(cls, *args, **kwargs)

Aplica a transformação chamando a classe de transformação e, em seguida, retorna o resultado.

- `cls` – O objeto de classe `self`.

name(cls)

Retorna o nome da classe de transformação derivada.

- `cls` – O objeto de classe `self`.

describeArgs(cls)

- `cls` – O objeto de classe `self`.

Retorna uma lista de dicionários, cada um correspondente a um argumento nomeado, no seguinte formato:

```
[
  {
    "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)"
  },
...
]
```

Gera uma exceção `NotImplementedError` quando chamado em uma transformação derivada em que não foi implementado.

describeReturn(cls)

- `cls` – O objeto de classe `self`.

Retorna um dicionário com informações sobre o tipo de retorno, no seguinte formato:

```
{
  "type": "(return type)",
  "description": "(description of output)"
}
```

Gera uma exceção `NotImplementedError` quando chamado em uma transformação derivada em que não foi implementado.

describeTransform(cls)

Retorna uma string que descreve a transformação.

- `cls` – O objeto de classe `self`.

Gera uma exceção `NotImplementedError` quando chamado em uma transformação derivada em que não foi implementado.

describeErrors(cls)

- `cls` – O objeto de classe `self`.

Retorna uma lista de dicionários, cada um descrevendo uma possível exceção lançada pela transformação, no seguinte formato:

```
[
  {
    "type": "(type of error)",
    "description": "(description of error)"
  },
...
]
```

describe(cls)

- `cls` – O objeto de classe `self`.

Retorna um objeto com o seguinte formato:

```
{
  "transform" : {
    "name" : cls.name( ),
    "args" : cls.describeArgs( ),
    "returns" : cls.describeReturn( ),
    "raises" : cls.describeErrors( ),
    "location" : "internal"
  }
}
```

Classe ApplyMapping

Aplica um mapeamento em um `DynamicFrame`.

Exemplo

Recomendamos usar o método `DynamicFrame.apply_mapping()` para aplicar um mapeamento em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar apply_mapping para renomear campos e alterar os tipos de campo.

Métodos

- __call__
- apply
- name
- describeArgs

- describeReturn
- describeTransform
- describeErrors
- Descrever

__call__(frame, mappings, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Aplica um mapeamento declarativo a um `DynamicFrame` especificado.

- `frame`: o `DynamicFrame` em que o mapeamento será aplicado (obrigatório).
- `mappings`: uma lista de tuplas de mapeamento (obrigatório). Cada uma é composta por: coluna de fonte, tipo de fonte, coluna de destino, tipo de destino.

  Se a coluna de origem tiver um ponto "`.`" no nome, será necessário colocar crases "```" em torno dela. Por exemplo, para mapear `this.old.name` (string) para `thisNewName`, você pode usar a seguinte tupla:

  ```
  ("`this.old.name`", "string", "thisNewName", "string")
  ```
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info`: uma cadeira de caracteres que é associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

Retorna somente os campos do `DynamicFrame` que são especificados nas tuplas de "mapeamento".

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe DropFields

Descartar campos em um `DynamicFrame`.

Exemplo

Recomendamos usar o método `DynamicFrame.drop_fields()` para descartar campos de um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar drop_fields para remover campos de um `DynamicFrame`.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Descrever

__call__(frame, paths, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Colocar nós em um `DynamicFrame`.

- `frame`: o `DynamicFrame` onde os nós serão descartados (obrigatório).
- `paths` – Uma lista de caminhos completos para os nós a serem descartados (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

Retorna um novo `DynamicFrame` sem os campos especificados.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe DropNullFields

Descarta todos os campos nulos em um `DynamicFrame` cujos tipos são `NullType`. São campos com valores ausentes ou nulos em todos os registros no conjunto de dados `DynamicFrame`.

Exemplo

Este exemplo usa `DropNullFields` para criar um novo `DynamicFrame` no qual os campos do tipo `NullType` foram descartados. Para demonstrar `DropNullFields`, adicionamos uma nova coluna do tipo null chamada `empty_column` ao conjunto de dados `persons` já carregado.

> **Note**
>
> Para acessar o conjunto de dados usado neste exemplo, consulte Exemplo de código: juntar e relacionar dados e siga as instruções em Etapa 1: crawling de dados no bucket do 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()
```

Saída

```
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
```

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Descrever

__call__(frame, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Descarta todos os campos nulos em um `DynamicFrame` cujos tipos são `NullType`. São campos com valores ausentes ou nulos em todos os registros no conjunto de dados `DynamicFrame`.

- `frame`: `DynamicFrame` onde os campos nulos serão descartados (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

Retorna um novo `DynamicFrame` sem campos nulos.

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

Classe ErrorsAsDynamicFrame

Retorna um `DynamicFrame` que contém registros aninhados de erros que ocorreram durante a criação da origem `DynamicFrame`.

Exemplo

Recomendamos usar o método `DynamicFrame.errorsAsDynamicFrame()` para recuperar e visualizar registros de erros. Para visualizar um código de exemplo, consulte Exemplo: usar errorsAsDynamicFrame para visualizar registros de erros.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Descrever

__call__(frame)

Retorna um `DynamicFrame` que contém registros de erros aninhados que estão relacionados ao `DynamicFrame` de origem.

- `frame` – O `DynamicFrame` de origem (obrigatório).

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

Classe EvaluateDataQuality

Avalia um conjunto de regras de qualidade de dados em relação a um `DynamicFrame` e retorna um novo `DynamicFrame` com os resultados da avaliação.

Exemplo

O código de exemplo a seguir demonstra como avaliar a qualidade dos dados para um `DynamicFrame` e, em seguida, visualizar os resultados de qualidade dos dados.

```
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()
```

Saída

```
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}|
+----------------------+-------+-------------+--------------------------------------+
```

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, ruleset, publishing_options = {})

- `frame`: o `DynamicFrame` cuja qualidade de dados você deseja avaliar.
- `ruleset`: um conjunto de regras em Data Quality Definition Language (DQDL) no formato de string. Para saber mais sobre DQDL, consulte o guia de Referência de Data Quality Definition Language (DQDL).
- `publishing_options`: um dicionário que especifica as seguintes opções para publicar resultados e métricas de avaliação:
  - `dataQualityEvaluationContext`: uma string que especifica o namespace com o qual o AWS Glue deve publicar as métricas e os resultados de qualidade dos dados do Amazon CloudWatch. As métricas agregadas aparecem no CloudWatch, enquanto os resultados completos aparecem na interface do AWS Glue Studio.
    - Obrigatório: Não
    - Valor padrão: `default_context`

- `enableDataQualityCloudWatchMetrics`: especifica se os resultados da avaliação de qualidade dos dados devem ser publicados no CloudWatch. Você especifica um namespace para as métricas usando a opção `dataQualityEvaluationContext`.
  - Obrigatório: Não
  - Valor padrão: False
- `enableDataQualityResultsPublishing`: especifica se os resultados de qualidade dos dados devem estar visíveis na guia Data Quality (Qualidade de dados) na interface do AWS Glue Studio.
  - Obrigatório: Não
  - Valor padrão: true
- `resultsS3Prefix`: especifica o local no Amazon S3 em que o AWS Glue pode gravar os resultados da avaliação de qualidade dos dados.
  - Obrigatório: Não
  - Valor padrão: "" (string vazia)

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe FillMissingValues

A classe `FillMissingValues` localiza valores null e strings vazias em um `DynamicFrame` especificado e usa métodos de machine learning, como regressão linear e floresta aleatória, para prever os valores ausentes. O trabalho de ETL usa os valores no conjunto de dados de entrada para treinar o modelo de machine learning, que então prevê quais devem ser os valores ausentes.

> **Tip**
>
> Se você usar conjuntos de dados incrementais, cada conjunto incremental será usado como dados de treinamento para o modelo de machine learning, portanto, os resultados podem não ser tão precisos.

Para importar:

```
from awsglueml.transforms import FillMissingValues
```

Métodos

- Aplicar

apply(frame, missing_values_column, output_column ="", transformation_ctx ="", info ="", stageThreshold = 0, totalThreshold = 0)

Preenche os valores ausentes de um quadro dinâmico em uma coluna especificada e retorna um novo quadro com estimativas em uma nova coluna. Para linhas sem valores ausentes, o valor da coluna especificada é duplicado para a nova coluna.

- `frame`: o `DynamicFrame` no qual preencher valores ausentes. Obrigatório.
- `missing_values_column`: a coluna que contém valores ausentes (valores `null` e strings vazias). Obrigatório.
- `output_column`: o nome da nova coluna que conterá valores estimados para todas as linhas cujo valor estava ausente. Opcional; o padrão é o nome da `missing_values_column` seguida do sufixo `"_filled"`.

- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold` – O número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional, o padrão é zero).
- `totalThreshold` – O número máximo de erros que podem ocorrer antes que o processamento falhe (opcional, o padrão é zero).

Retorna um novo `DynamicFrame` com uma coluna adicional que contém estimativas para linhas com valores ausentes e o valor presente para outras linhas.

Classe Filter

Cria um novo `DynamicFrame` que contém registros do `DynamicFrame` de entrada que satisfazem uma função predicada especificada.

Exemplo

Recomendamos usar o método `DynamicFrame.filter()` para filtrar registros em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar filter para obter uma seleção filtrada de campos.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0))

Retorna um novo `DynamicFrame` que é criado selecionando registros do `DynamicFrame` de entrada que satisfazem uma função predicada especificada.

- `frame` – O `DynamicFrame` de origem ao qual a função de filtro especificada será aplicada (obrigatório).
- `f`: a função predicada a ser aplicada a cada `DynamicRecord` no `DynamicFrame`. A função precisa ter um `DynamicRecord` como argumento e retornar True, se `DynamicRecord` atender aos requisitos de filtro, ou False, se não atender (obrigatório).

  Um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. É semelhante a uma linha em um `DataFrame` do Spark, exceto pelo fato de que pode se autodescrever e ser usado para dados que não estejam em conformidade com um esquema fixo.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info`: uma cadeira de caracteres que é associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe FindIncrementalMatches

Identifica registros correspondentes no `DynamicFrame` incremental e existente e cria um novo `DynamicFrame` com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

Para importar:

```
from awsglueml.transforms import FindIncrementalMatches
```

Métodos

- Aplicar

apply(existingFrame, incrementalFrame, transformId, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0, enforcedMatches = none, computeMatchConfidenceScores = 0)

Identifica registros correspondentes no `DynamicFrame` de entrada e cria um novo `DynamicFrame` com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

- `existingFrame`: o `DynamicFrame` existente e pré-correspondido em que aplicar a transformação FindIncrementalMatches. Obrigatório.
- `incrementalFrame`: o `DynamicFrame` incremental em que aplicar a transformação FindIncrementalMatches para corresponder a `existingFrame`. Obrigatório.
- `transformId`: o ID exclusivo associado à transformação FindIncrementalMatches a ser aplicado em registros no `DynamicFrames`. Obrigatório.
- `transformation_ctx`: uma string única que é usada para identificar informações de estado/ estatística. Opcional.
- `info`: uma string a ser associada a erros na transformação. Opcional.
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe. Opcional. O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe. Opcional. O padrão é zero.

- `enforcedMatches`: o `DynamicFrame` usado para impor correspondências. Opcional. O padrão é Nenhum.
- `computeMatchConfidenceScores`: um valor booleano que indica se a pontuação de confiança deve ser calculada para cada grupo de registros correspondentes. Opcional. O padrão é falso.

Retorna um novo `DynamicFrame` com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

Classe FindMatches

Identifica registros correspondentes no `DynamicFrame` de entrada e cria um novo `DynamicFrame` com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

Para importar:

```
from awsglueml.transforms import FindMatches
```

Métodos

- Aplicar

apply(frame, transformId, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0, enforcedMatches = none, computeMatchConfidenceScores = 0)

Identifica registros correspondentes no `DynamicFrame` de entrada e cria um novo `DynamicFrame` com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

- `frame`: o `DynamicFrame` em que aplicar a transformação FindMatches. Obrigatório.
- `transformId`: o ID exclusivo associado à transformação FindMatches a ser aplicado em registros no `DynamicFrame`. Obrigatório.
- `transformation_ctx`: uma string única que é usada para identificar informações de estado/ estatística. Opcional.
- `info`: uma string a ser associada a erros na transformação. Opcional.
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe. Opcional. O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe. Opcional. O padrão é zero.

- `enforcedMatches`: o `DynamicFrame` usado para impor correspondências. Opcional. O padrão é Nenhum.
- `computeMatchConfidenceScores`: um valor booleano que indica se a pontuação de confiança deve ser calculada para cada grupo de registros correspondentes. Opcional. O padrão é falso.

Retorna um novo `DynamicFrame` com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

Classe FlatMap

Aplica uma transformação a cada `DynamicFrame` do conjunto. Os resultados não são reduzidos a um único `DynamicFrame`, mas preservados como um conjunto.

Exemplos de FlatMap

O trecho de exemplo a seguir demonstra como usar a transformação `ResolveChoice` em um conjunto de quadros dinâmicos quando aplicada a um `FlatMap`. Os dados usados para entrada estão no JSON localizado no endereço Amazon S3 reservado `s3://bucket/path-for-data/sample.json` e contêm os dados a seguir.

Exemplo de dados 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"
    ]
}]
```

Example Aplique ResolveChoice a uma DynamicFrameCollection e mostre a saída.

```
#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","busines
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**
>
> Ao chamar `FlatMap.apply`, o parâmetro `frame_name` deve ser `"frame"`. Nenhum outro valor é aceito atualmente.

Exemplo de saída

```
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"
    ]
}
```

Métodos

- __call__
- Aplicar
- Nome
- describeArgs
- describeReturn

- describeTransform
- describeErrors
- Descrever

__call__(dfc, BaseTransform, frame_name, transformation_ctx = "", **base_kwargs)

Aplica uma transformação para cada `DynamicFrame` em uma coleção e nivela os resultados.

- `dfc` – O `DynamicFrameCollection` em que o flatmap será aplicado (obrigatório).
- `BaseTransform` – Uma transformação de `GlueTransform` a ser aplicada a cada membro da coleção (obrigatório).
- `frame_name` – O nome do argumento para o qual os elementos da coleção serão transmitidos (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `base_kwargs` – Os argumentos a serem transmitidos à transformação base (obrigatório).

Retorna um novo `DynamicFrameCollection` criado aplicando a transformação a cada `DynamicFrame` na origem `DynamicFrameCollection`.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe Join

Executa uma junção de igualdade em dois `DynamicFrames`.

Exemplo

Recomendamos usar o método `DynamicFrame.join()` para juntar `DynamicFrames`. Para visualizar um código de exemplo, consulte Exemplo: usar join para combinar `DynamicFrames`.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Descrever

__call__(frame1, frame2, keys1, keys2, transformation_ctx = "")

Executa uma junção de igualdade em dois `DynamicFrames`.

- `frame1` – O primeiro `DynamicFrame` da junção (obrigatório).
- `frame2` – O segundo `DynamicFrame` da junção (obrigatório).
- `keys1` – As chaves para junção do primeiro quadro (obrigatório).
- `keys2` – As chaves para junção do segundo quadro (obrigatório).

- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).

Retorna um novo `DynamicFrame`, que é criado juntando os dois `DynamicFrames`.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe Map

Cria um novo `DynamicFrame` aplicando uma função a todos os registros no `DynamicFrame` de entrada.

Exemplo

Recomendamos usar o método `DynamicFrame.map()` para aplicar uma função a todos os registros em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar map para aplicar uma função a cada registro em um `DynamicFrame`.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- Descrever

__call__(frame, f, transformation_ctx="", info="", stageThreshold=0, totalThreshold=0)

Retorna um novo `DynamicFrame` que resulta da aplicação da função especificada a todos os `DynamicRecords` no `DynamicFrame` original.

- `frame`: o `DynamicFrame` original ao qual a função de mapeamento deverá ser aplicada (obrigatório).
- `f`: a função a ser aplicada a todos os `DynamicRecords` no `DynamicFrame`. A função precisa usar um `DynamicRecord` como argumento e retornar um novo `DynamicRecord` que seja produzido pelo mapeamento (obrigatório).

  Um `DynamicRecord` representa um registro lógico em um `DynamicFrame`. É semelhante a uma linha em um `DataFrame` do Apache Spark, exceto pelo fato de que pode se autodescrever e ser usado para dados que não estejam em conformidade com um esquema fixo.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

Retorna um novo `DynamicFrame` que resulta da aplicação da função especificada a todos os `DynamicRecords` no `DynamicFrame` original.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe MapToCollection

Aplica uma transformação a cada `DynamicFrame` no `DynamicFrameCollection` especificado.

Métodos

- __call__
- Aplicar
- Nome
- describeArgs
- describeReturn
- describeTransform
- describeErrors

- Descrever

__call__(dfc, BaseTransform, frame_name, transformation_ctx = "", **base_kwargs)

Aplica uma função de transformação a cada `DynamicFrame` no `DynamicFrameCollection` especificado.

- `dfc` – O `DynamicFrameCollection` no qual a função de transformação deverá ser aplicada (obrigatório).
- `callable` – Uma função de transformação que pode ser chamada para ser aplicada a cada membro da coleção (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).

Retorna um novo `DynamicFrameCollection` criado aplicando a transformação a cada `DynamicFrame` na origem `DynamicFrameCollection`.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe Relationalize

Nivela um esquema aninhado em um `DynamicFrame` e cria colunas dinâmicas de matriz a partir do quadro nivelado.

Exemplo

Recomendamos usar o método `DynamicFrame.relationalize()` para relacionalizar um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar relationalize para nivelar um esquema aninhado em um `DynamicFrame`.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, staging_path=None, name='roottable', options=None, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Relacionaliza um `DynamicFrame` e produz uma lista de quadros que são gerados desaninhando colunas aninhadas e criando colunas dinâmicas de matriz. Uma coluna de matriz dinâmica pode ser adicionada à tabela raiz usando a chave de união gerada durante a fase de desaninhamento.

- `frame`: o `DynamicFrame` a ser relacionalizado (obrigatório).
- `staging_path`: o caminho onde o método pode armazenar partições de tabelas dinâmicas no formato CSV (opcional). As tabelas dinâmicas são lidas novamente nesse caminho.
- `name` – O nome da tabela raiz (opcional).

- `options` – Um dicionário de parâmetros opcionais. Não utilizado no momento.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe RenameField

Renomeia um nó em um `DynamicFrame`.

Exemplo

Recomendamos usar o método `DynamicFrame.rename_field()` para renomear um campo em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar rename_field para renomear campos em um `DynamicFrame`.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, old_name, new_name, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Renomeia um nó em um `DynamicFrame`.

- `frame` – O `DynamicFrame` no qual o nó será renomeado (obrigatório).
- `old_name`: o caminho completo para o nó a ser renomeado (obrigatório).

  Se o nome antigo tiver pontos, o RenameField não funcionará a menos que você posicione os acentos graves (``) ao seu redor. Por exemplo, para substituir `this.old.name` por `thisNewName`, você chamaria RenameField, da seguinte maneira:

  ```
  newDyF = RenameField(oldDyF, "`this.old.name`", "thisNewName")
  ```

- `new_name`: o novo nome, incluindo o caminho completo (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.

- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe ResolveChoice

Resolve um tipo de escolha dentro de um `DynamicFrame`.

Exemplo

Recomendamos usar o método `DynamicFrame.resolveChoice()` para lidar com campos que contêm vários tipos em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar resolveChoice para lidar com uma coluna que contém vários tipos.

Métodos

- __call__
- apply

- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, specs = none, choice = "", transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Fornece informações para resolver tipos ambíguos dentro de um `DynamicFrame`. Retorna o `DynamicFrame` resultante.

- `frame` – O `DynamicFrame` no qual o tipo de escolha será resolvido (obrigatório).
- `specs`: uma lista de ambiguidades específicas para resolver, cada uma na forma de uma tupla: `(path, action)`. O valor `path` identifica um elemento ambíguo específico, e o valor `action` identifica a resolução correspondente.

  É possível usar somente um dos parâmetros `spec` e `choice`. Se o parâmetro `spec` não for `None`, o parâmetro `choice` precisará ser uma string vazia. Por outro lado, se o `choice` não for uma string vazia, o parâmetro `spec` precisará ser `None`. Se nenhum dos parâmetros for fornecido, o AWS Glue tentará analisar o esquema e usá-lo para resolver ambiguidades.

  É possível especificar uma das seguintes estratégias de resolução na porção `action` de uma tupla `specs`:

  - `cast`: permite especificar um tipo a ser convertido (por exemplo: `cast:int`).
  - `make_cols`: resolve uma possível ambiguidade ao nivelar os dados. Por exemplo, se `columnA` puder ser `int` ou `string`, a resolução é produzir duas colunas chamadas `columnA_int` e `columnA_string` no `DynamicFrame` resultante.
  - `make_struct`: resolve uma ambiguidade em potencial usando um struct para representar os dados. Por exemplo, se os dados em uma coluna pudessem ser um `int` ou `string`, usar a ação `make_struct` produzirá uma coluna de estruturas no `DynamicFrame` resultante, com cada uma contendo `int` e `string`.
  - `project`: resolve uma possível ambiguidade retendo somente valores de um tipo especificado no `DynamicFrame` resultante Por exemplo, se os dados em uma coluna `ChoiceType`

pudessem ser um `int` ou uma `string`, especificar uma ação `project:string` descartaria valores do `DynamicFrame` resultante que não fossem do tipo `string`.

Se o `path` identifica um array, insira colchetes vazios após o nome do array para evitar ambiguidades. Por exemplo, vamos supor que você esteja trabalhando com dados estruturados da seguinte maneira:

```
"myList": [
  { "price": 100.00 },
  { "price": "$100.00" }
]
```

Você pode selecionar a versão numérica em vez da versão string do preço definindo `path` como `"myList[].price"` e `action` como `"cast:double"`.

- `choice`: a ação de resolução padrão se o parâmetro `specs` for `None`. Se o parâmetro `specs` não for `None`, isso deve ser configurado como uma string vazia.

  Além das ações `specs` listadas anteriormente, este modo também aceita a seguinte ação:

  - `MATCH_CATALOGChoiceType`: tenta converter cada para o tipo correspondente na tabela do Data Catalog especificada.
- `database`: o banco de dados do AWS Glue Data Catalog a ser usado com a escolha `MATCH_CATALOG` (obrigatório para `MATCH_CATALOG`).
- `table_name`: o nome da tabela do AWS Glue Data Catalog a ser usado com a ação `MATCH_CATALOG` (obrigatório para `MATCH_CATALOG`).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe SelectFields

A classe `SelectFields` cria um novo `DynamicFrame` com base em um `DynamicFrame` existente e mantém somente os campos que você especificar. `SelectFields` oferece uma funcionalidade semelhante a uma instrução SQL `SELECT`.

Exemplo

Recomendamos usar o método `DynamicFrame.select_fields()` para selecionar campos de um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar select_fields para criar um novo `DynamicFrame` com os campos escolhidos.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn

- describeTransform
- describeErrors
- Descrever

__call__(frame, paths, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Recebe campos (nós) em um `DynamicFrame`.

- `frame`: o `DynamicFrame` onde os campos serão selecionados (obrigatório).
- `paths` – Uma lista de caminhos completos para os campos a serem selecionados (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info`: uma cadeira de caracteres que é associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

Retorna um novo `DynamicFrame` que contém somente os campos especificados.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe SelectFromCollection

Seleciona um `DynamicFrame` em `DynamicFrameCollection`.

Exemplo

Este exemplo usa `SelectFromCollection` para selecionar um `DynamicFrame` de um `DynamicFrameCollection`.

Exemplo de conjunto de dados

O exemplo seleciona dois `DynamicFrames` de um `DynamicFrameCollection` chamado `split_rows_collection`. Está é uma lista de limites no `split_rows_collection`.

```
dict_keys(['high', 'low'])
```

Código de exemplo

```
# 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()
```

Saída

```
+---+-----+-----------------------+-----------------------+
| 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
```

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(dfc, key, transformation_ctx = "")

Obtém um `DynamicFrame` de `DynamicFrameCollection`.

- `dfc`: a `DynamicFrameCollection` da qual o `DynamicFrame` deve ser selecionado (obrigatório).
- `key` – A chave do `DynamicFrame` a ser selecionada (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe Simplify_ddb_json

Simplifica colunas aninhadas em um `DynamicFrame` que estão especificamente na estrutura JSON do DynamoDB e retorna um novo `DynamicFrame` simplificado.

Exemplo

Recomendamos usar o método `DynamicFrame.simplify_ddb_json()` para simplificar colunas aninhadas em um `DynamicFrame` que estão especificamente na estrutura JSON do DynamoDB. Para visualizar um código de exemplo, consulte Exemplo: use simplify_ddb_json para invocar uma simplificação JSON do DynamoDB.

Classe Spigot

Grava registros de exemplo em um destino específico para ajudar você a verificar as transformações realizadas pelo seu trabalho da AWS Glue.

Exemplo

Recomendamos usar o método `DynamicFrame.spigot()` para gravar um subconjunto de registros de um `DynamicFrame` em um destino especificado. Para visualizar um código de exemplo,

consulte Exemplo: usar spigot para gravar campos de exemplo de um `DynamicFrame` no Amazon S3.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, path, options, transformation_ctx = "")

Grava registros de amostra em um destino especificado durante uma transformação.

- `frame` – O `DynamicFrame` para spigot (obrigatório).
- `path`: o caminho para o destino no qual a gravação será feita (obrigatório).
- `options`: pares de chave-valor JSON que especificam opções (opcional). A opção `"topk"` especifica que os primeiros registros k devem ser gravados. A opção `"prob"` especifica a probabilidade (como um número decimal) de selecionar um determinado registro. Isso pode ser usado na seleção de registros para gravar.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply

name(cls)

Herdado de `GlueTransform` name

describeArgs(cls)

Herdado de `GlueTransform` describeArgs

describeReturn(cls)

Herdado de `GlueTransform` describeReturn

describeTransform(cls)

Herdado de `GlueTransform` describeTransform

describeErrors(cls)

Herdado de `GlueTransform` describeErrors

describe(cls)

Herdado de `GlueTransform` describe

Classe SplitFields

Separa um `DynamicFrame` em dois novos, por campos especificados.

Exemplo

Recomendamos usar o método `DynamicFrame.split_fields()` para dividir campos em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar split_fields para dividir os campos selecionados em um `DynamicFrame` separado.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, paths, name1 = none, name2 = none, transformation_ctx = "", info = "", stageThreshold = 0, totalThreshold = 0)

Separa um ou mais campos em um `DynamicFrame` em um novo `DynamicFrame` e cria outro novo `DynamicFrame` que contém os campos que permaneceram.

- `frame` – O `DynamicFrame` de origem a ser separado em dois novos (obrigatório).
- `paths` – Uma lista de caminhos completos para os campos a serem separados (obrigatório).
- `name1`: o nome a ser atribuído ao `DynamicFrame` que conterá os campos a serem divididos (opcional). Se nenhum nome for fornecido, o nome da estrutura de origem será usado com "1" anexado.
- `name2`: o nome a ser atribuído ao `DynamicFrame` que conterá os campos que permanecerão após aqueles especificados terem sido separados (opcional). Se nenhum nome for informado, o nome da estrutura de origem será usado com "2" anexado.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe SplitRows

Cria um `DynamicFrameCollection` que contém dois `DynamicFrames`. Um `DynamicFrame` contém apenas as linhas especificadas a serem separadas e o outro contém todas as linhas restantes.

Exemplo

Recomendamos usar o método `DynamicFrame.split_rows()` para dividir linhas em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar split_rows para dividir linhas em um `DynamicFrame`.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, comparison_dict, name1="frame1", name2="frame2", transformation_ctx = "", info = none, stageThreshold = 0, totalThreshold = 0)

Separa uma ou mais linhas em um `DynamicFrame` em um novo `DynamicFrame`.

- `frame` – O `DynamicFrame` de origem a ser separado em dois novos (obrigatório).
- `comparison_dict`: um dicionário em que a chave é o caminho completo para uma coluna e o valor é outro dicionário para mapear comparadores a valores aos quais os valores das colunas são comparados. Por exemplo, `{"age": {">": 10, "<": 20}}` separa as linhas onde o valor de "age" está entre 10 e 20, incluindo as linhas nas quais "age" está fora do intervalo (obrigatório).
- `name1` – O nome a ser atribuído a `DynamicFrame` que conterá as linhas a serem separadas (opcional).
- `name2` – O nome a ser atribuído a `DynamicFrame` que conterá as linhas que permanecerão após as linhas especificadas terem sido separadas (opcional).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe Unbox

Descompacta (reformata) um campo de string em um `DynamicFrame`.

Exemplo

Recomendamos usar o método `DynamicFrame.unbox()` para descompactar um campo em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar unbox para descompactar um campo de string em um struct.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, path, format, transformation_ctx = "", info="", stageThreshold=0, totalThreshold=0, **options)

Descompacta um campo de string em um `DynamicFrame`.

- `frame`: o `DynamicFrame` no qual um campo será descompactado (obrigatório).
- `path` – O caminho completo para o `StringNode` a ser descompactado (obrigatório).
- `format`: uma especificação de formato (opcional). É usado para uma conexão do Amazon S3 ou do AWS Glue que oferece suporte a vários formatos. Consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark para conhecer os formatos compatíveis.
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).

- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.
- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.
- `separator` – Um token de separação (opcional).
- `escaper` – Um token de escape (opcional).
- `skipFirst` – `True` se a primeira linha de dados tiver que ser ignorada ou `False` caso contrário (opcional).
- withSchema: uma string que contém o esquema de descompactação dos dados (opcional). Isso sempre deve ser criado usando `StructType.json`.
- `withHeader` – `True` se os dados descompactados incluírem um cabeçalho ou `False` caso contrário (opcional).

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe UnnestFrame

Desaninha um `DynamicFrame`, nivela objetos aninhados com elementos de nível superior e gera chaves de união para objetos de matriz.

Exemplo

Recomendamos usar o método `DynamicFrame.unnest()` para nivelar estruturas aninhadas em um `DynamicFrame`. Para visualizar um código de exemplo, consulte Exemplo: usar unnest para transformar campos aninhados em campos de nível superior.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(frame, transformation_ctx = "", info="", stageThreshold=0, totalThreshold=0)

Desaninha um `DynamicFrame`, nivela objetos aninhados com elementos de nível superior e gera chaves de união para objetos de matriz.

- `frame` - O `DynamicFrame` a ser desaninhado (obrigatório).
- `transformation_ctx` – Uma string única que é usada para identificar informações de estado (opcional).
- `info` – Uma string associada a erros na transformação (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional). O padrão é zero.

- `totalThreshold`: o número máximo de erros que podem ocorrer em geral antes que falhe (opcional). O padrão é zero.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe FlagDuplicatesInColumn

A transformação `FlagDuplicatesInColumn` retorna uma nova coluna com um valor especificado em cada linha que indica se o valor na coluna de origem da linha corresponde a um valor em uma linha anterior da coluna de origem. Quando as correspondências são encontradas, elas são marcadas como duplicatas. A ocorrência inicial não é marcada porque não corresponde a uma linha anterior.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.transforms import *
```

```
sc = SparkContext()
spark = SparkSession(sc)

datasource1 = spark.read.json("s3://${BUCKET}/json/zips/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
```

Saída

A transformação `FlagDuplicatesInColumn` adicionará uma nova coluna “flag_col” ao DataFrame “df_output”. Essa coluna conterá um valor de string indicando se a linha correspondente tem um valor duplicado na coluna “cidade” ou não. Se uma linha tiver um valor cidade” duplicado, o "flag_col" conterá o valor "true_string" "True”. Se uma linha tiver um valor exclusivo de "cidade", o "flag_col" conterá o valor "false_string" "False".

O DataFrame “df_output” resultante conterá todas as colunas do DataFrame “datasource1” original, além da coluna “flag_col” adicional indicando valores duplicados de “cidade”.

Métodos

- __call__
- apply
- 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)

A transformação `FlagDuplicatesInColumn` retorna uma nova coluna com um valor especificado em cada linha que indica se o valor na coluna de origem da linha corresponde a um valor em uma linha anterior da coluna de origem. Quando as correspondências são encontradas, elas são marcadas como duplicatas. A ocorrência inicial não é marcada porque não corresponde a uma linha anterior.

- `source_column`: nome da coluna de origem.
- `target_column`: nome da coluna de destino.
- `true_string`: string a ser inserida na coluna de destino quando o valor da coluna de origem duplica um valor anterior nessa coluna.
- `false_string`: string a ser inserida na coluna de destino quando o valor da coluna de origem é diferente dos valores anteriores dessa coluna.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe FormatPhoneNumber

A transformação `FormatPhoneNumber` retorna uma coluna na qual uma string de número de telefone é convertida em um valor formatado.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será:

```
```

```
+---------------+
| phone|
+---------------+
|(408) 341-5669|
|(408) 341-5669|
+---------------+
```

A transformação `FormatPhoneNumber` usa a "source_column" como `"telefone"` e a "default_region" como `"EUA"`.

A transformação formata com sucesso os dois números de telefone, independentemente do formato inicial, no formato padrão dos EUA "(408) 341-5669".

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column, phone_number_format=None, default_region=None, default_region_column=None)

A transformação `FormatPhoneNumber` retorna uma coluna na qual uma string de número de telefone é convertida em um valor formatado.

- `source_column`: o nome de uma coluna existente.
- `phone_number_format`: o formato para o qual converter o número de telefone. Se nenhum formato for especificado, o padrão será `E.164`, um formato de número de telefone padrão reconhecido internacionalmente. Entre os valores válidos estão os seguintes:
  - E164 (omitir o ponto após E)

- `default_region`: um código de região válido que consiste em duas ou três letras maiúsculas que especifica a região do número de telefone quando nenhum código de país está presente no próprio número. No máximo, uma das `defaultRegion` ou `defaultRegionColumn` pode ser fornecida.
- `default_region_column`: o nome de uma coluna do tipo `Country` de dado avançado. O código da região da coluna especificada é usado para determinar o código do país para o número de telefone quando nenhum código de país está presente no próprio número. No máximo, uma das `defaultRegion` ou `defaultRegionColumn` pode ser fornecida.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe FormatCase

A transformação `FormatCase` altera cada string em uma coluna para o tipo de caso especificado.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A transformação `FormatCase` converterá os valores na coluna "cidade" em minúsculas com base no parâmetro ‘case_type="lower"`. O DataFrame "df_output" resultante conterá todas as colunas do DataFrame "datasource1" original, mas com os valores da coluna "cidade" em minúsculas.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column, case_type)

A transformação `FormatCase` altera cada string em uma coluna para o tipo de caso especificado.

- `source_column`: o nome de uma coluna existente.
- `case_type`: os tipos de casos compatíveis são `CAPITAL`, `LOWER`, `UPPER` e `SENTENCE`.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe FillWithMode

A transformação `FillWithMode` formata uma coluna de acordo com o formato do número de telefone especificado. Você também pode especificar a lógica de desempate, em que alguns dos valores são idênticos. Por exemplo, considere os seguintes dados de entrada: `1 2 2 3 3 4`

Um modeType de `MINIMUM` faz com que `FillWithMode` retorne 2 como o valor do modo. Se modeType for `MAXIMUM`, o modo será 3. Para `AVERAGE`, o modo é 2,5.

Exemplo

```
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
```

Saída

A saída do código será:

```
```
+---------------+---------------+
|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|
+---------------+---------------+
```

A transformação `FillWithMode` do módulo “awsglue.data_quality” é aplicada ao DataFrame “input_df”. Ela substitui os valores “null” na coluna `source_column_1` pelo valor máximo (“mode_type="maximum"”) dos valores não nulos nessa coluna.

Nesse caso, o valor máximo na coluna `source_column_1` é “1055.123”. Portanto, os valores “null” em `source_column_1` são substituídos por “1055.123” no DataFrame de saída “df_output”.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column, mode_type)

A transformação `FillWithMode` formata o caso das cadeias de caracteres em uma coluna.

- `source_column`: o nome de uma coluna existente.
- `mode_type`: como resolver valores de empate nos dados. Esse valor deve ser um entre `MINIMUM`, `NONE`, `AVERAGE` ou `MAXIMUM`.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe FlagDuplicateRows

A transformação `FlagDuplicateRows` retorna uma nova coluna com um valor especificado em cada linha que indica se essa linha corresponde exatamente a uma linha anterior no conjunto de dados. Quando as correspondências são encontradas, elas são marcadas como duplicatas. A ocorrência inicial não é marcada porque não corresponde a uma linha anterior.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será um PySpark DataFrame com uma coluna `flag_row` adicional que indica se uma linha é duplicada ou não, com base na coluna `source_column_1`. O DataFrame “df_output” resultante conterá as seguintes linhas:

```
```
+---------------+---------------+--------+
|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
+---------------+---------------+--------+
```
```

A coluna `flag_row` indica se uma linha é duplicada ou não. A "true_string" é definida como "True" e a "false_string" é definida como "False". O "target_index" é definido como 1, o que significa que a coluna `flag_row` será inserida na segunda posição (índice 1) no DataFrame de saída.

Métodos

- __call__
- apply
- 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)

A transformação `FlagDuplicateRows` retorna uma nova coluna com um valor especificado em cada linha que indica se essa linha corresponde exatamente a uma linha anterior no conjunto de dados. Quando as correspondências são encontradas, elas são marcadas como duplicatas. A ocorrência inicial não é marcada porque não corresponde a uma linha anterior.

- `true_string`: valor a ser inserido se a linha corresponder a uma linha anterior.
- `false_string`: valor a ser inserido se a linha for exclusiva.
- `target_column`: nome da nova coluna inserida no conjunto de dados.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe RemoveDuplicates

A transformação `RemoveDuplicates` exclui uma linha inteira se um valor duplicado é encontrado em uma coluna de origem selecionada.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será um quadro de dados PySpark com duplicatas removidas com base na coluna `source_column_1`. O DataFrame “df_output” resultante conterá as seguintes linhas:

```
```
+---------------+---------------+
|source_column_1|source_column_2|
+---------------+---------------+
105.111	13.12
13.12	13.12
null	13.12
+---------------+---------------+
```
```

Observe que as linhas com valores `source_column_1` de “13.12” e “null” aparecem apenas uma vez no quadro de dados de saída, pois as duplicatas foram removidas com base na coluna `source_column_1`.

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_column)

A transformação `RemoveDuplicates` exclui uma linha inteira se um valor duplicado é encontrado em uma coluna de origem selecionada.

- `source_column`: o nome de uma coluna existente.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe MonthName

A transformação `MonthName` cria uma nova coluna, contendo o nome do mês, a partir de uma string que representa uma data.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será:

```
+------------+------------+
| 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 |
+------------+------------+
```

A transformação `MonthName` usa a "source_column" como `"column_1"` e a "target_column" como `"target_column"`. Ela tenta extrair o nome do mês das sequências de data e hora na coluna `"column_1"` e coloca na coluna `"target_column"`. Se a string de data e hora estiver em um formato não reconhecido ou não puder ser analisada, o valor `"target_column"` será definido como "null".

A transformação extrai com sucesso o nome do mês de vários formatos de data e hora, como "20-12-2018", "12/20/2018", "02/02/2009", "2013-02-21 06:35:45.658505" e "02 de agosto de 2009".

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform

- describeErrors
- describe

__call__ (spark_context, data_frame, target_column, source_column=Nenhum, value=Nenhum)

A transformação `MonthName` cria uma nova coluna, contendo o nome do mês, a partir de uma string que representa uma data.

- `source_column`: o nome de uma coluna existente.
- `value`: uma sequência de caracteres para avaliar.
- `target_column`: um nome para a coluna recém-criada.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe isEven

A transformação `IsEven` retorna um valor booleano em uma nova coluna que indica se a coluna ou o valor de origem é par. Se a coluna ou o valor de origem for decimal, o resultado será falso.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será:

```
```
+-------------+-------------+
|source_column|target_column|
+-------------+-------------+
```
```

```
| 5| Not even|
| 0| Even|
| -1| Not even|
| 2| Even|
| null| null|
+------------+------------+
```

A transformação `IsEven` usa a "source_column" como "source_column" e a "target_column" como "target_column". Ela verifica se o valor na `"source_column"` é par ou não. Se o valor for par, ela define o valor `"target_column"` como “true_string” “Par”. Se o valor for ímpar, ela define o valor `"target_column"` como "false_string" “Não é par”. Se o valor `"source_column"` for "null", o valor `"target_column"` será definido como "null".

A transformação identifica corretamente os números pares (0 e 2) e define o valor `"target_column"` como “Par”. Para números ímpares (5 e -1), define o valor `"target_column"` como "Não é par". Para o valor "null" na `"source_column"`, o valor `"target_column"` é definido como "null".

Métodos

- __call__
- apply
- 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)

A transformação `IsEven` retorna um valor booleano em uma nova coluna que indica se a coluna ou o valor de origem é par. Se a coluna ou o valor de origem for decimal, o resultado será falso.

- `source_column`: o nome de uma coluna existente.
- `target_column`: o nome da nova coluna a ser criada.

- `true_string`: uma string que indica se o valor é par.
- `false_string`: uma string que indica se o valor não é par.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe CryptographicHash

A transformação `CryptographicHash` aplica um algoritmo aos valores de hash na coluna.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será:

```
```
+---+------------+------------------+------------------+
| id| phone | id_hashed | phone_hashed |
+---+------------+------------------+------------------+
| 1| 1234560000 | QUI1zXTJiXmfIb... | juDBAmiRnnO3g... |
```
```

```
| 2| 1234560001 | ZAUWiZ3dVTzCo... | vC8lgUqBVDMNQ... |
| 3| 1234560002 | ZP4VvZWkqYifu... | Kl3QAkgswYpzB... |
| 4| 1234560003 | 3u8vO3wQ8EQfj... | CPBzK1P8PZZkV... |
| 5| 1234560004 | eWkQJk4zAOIzx... | aLf7+mHcXqbLs... |
| 6| 1234560005 | xtI9fZCJZCvsa... | dy2DFgdYWmr0p... |
| 7| 1234560006 | iW9hew7jnHuOf... | wwfGMCOEv6oOv... |
| 8| 1234560007 | H9V1pqvgkFhfS... | g9WKhagIXy9ht... |
| 9| 1234560008 | xDhEuHaxAUbU5... | b3uQLKPY+Q5vU... |
| 10| 1234560009 | GRN6nFXkxk349... | VJdsKt8VbxBbt... |
+---+------------+------------------+------------------+
```

A transformação calcula os hashes criptográficos dos valores nas colunas “id” e “phone” usando o algoritmo e a chave secreta especificados e codifica os hashes no formato Base64. O DataFrame “df_output” resultante contém todas as colunas do DataFrame “input_df” original, além das colunas “id_hashed” e “phone_hashed” adicionais com os hashes computados.

Métodos

- __call__
- apply
- 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)

A transformação `CryptographicHash` aplica um algoritmo aos valores de hash na coluna.

- `source_columns`: uma matriz de colunas existentes.
- `secret_id`: o ARN da chave secreta do Secrets Manager. A chave usada no algoritmo do prefixo do código de autenticação de mensagens por hash (HMAC) para hash das colunas de origem.
- `secret_version`: optional. O padrão é a versão mais recente do segredo.

- `entity_type_filter`: matriz opcional de tipos de entidades. Pode ser usada para criptografar somente as PII detectadas na coluna de texto livre.
- `create_secret_if_missing`: booleano opcional. Se verdadeiro, tentará criar o segredo em nome do chamador.
- `algorithm`: o algoritmo usado para fazer o hash de seus dados. Valores de enumeração válidos: MD5, SHA1, SHA256, SHA512, HMAC_MD5, HMAC_SHA1, HMAC_SHA256, HMAC_SHA512.

aplicar(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Descriptografar classe

A transformação `Decrypt` é decifrada dentro do AWS Glue. Os dados também podem ser descriptografados fora do AWS Glue com o SDK de criptografia da AWS. Se o ARN da chave

KMS fornecida não corresponder ao que foi usado para criptografar a coluna, a operação de descriptografia falhará.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será um PySpark DataFrame com a coluna "id" original e a coluna "telefone" descriptografada:

```
```
+---+------------+
| id| phone|
+---+------------+
1	1234560000
2	1234560001
3	1234560002
4	1234560003
5	1234560004
6	1234560005
7	1234560006
8	1234560007
9	1234560008
10	1234560009
+---+------------+
```
```

A transformação `Encrypt` usa "source_columns" como `["phone"]` e "kms_key_arn" como o valor da variável de ambiente "$ {KMS}". A transformação criptografa os valores na coluna "telefone" usando a chave KMS especificada. O DataFrame criptografado "df_encrypt" é então passado para a transformação `Decrypt` do módulo "awsglue.pii". Ele usa "source_columns" como `["telefone"]` e "kms_key_arn" como o valor da variável de ambiente "$ {KMS}". A transformação descriptografa os valores criptografados na coluna "telefone" usando a mesma chave KMS. O DataFrame "df_decrypt" resultante contém a coluna "id" original e a coluna "telefone" descriptografada.

Métodos

- __call__
- apply
- name
- describeArgs

- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_columns, kms_key_arn)

A transformação `Decrypt` é decifrada dentro do AWS Glue. Os dados também podem ser descriptografados fora do AWS Glue com o SDK de criptografia da AWS. Se o ARN da chave KMS fornecida não corresponder ao que foi usado para criptografar a coluna, a operação de descriptografia falhará.

- `source_columns`: uma matriz de colunas existentes.
- `kms_key_arn`: o ARN da chave do AWS Key Management Service a ser usado para descriptografar as colunas de origem.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Criptografar classe

A transformação `Encrypt` criptografa as colunas de origem usando a chave do AWS Key Management Service. A transformação `Encrypt` pode criptografar até 128 MiB por célula. Ela tentará preservar o formato na decodificação. Para preservar o tipo de dado, os metadados do tipo de dado devem ser serializados para menos de 1 KB. Caso contrário, você deve definir o parâmetro `preserve_data_type` como falso. Os metadados do tipo de dado serão armazenados em texto simples no contexto de criptografia.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será um PySpark DataFrame com a coluna “id” original e uma coluna adicional contendo os valores criptografados da coluna “telefone”.

```
```
+---+------------+------------------------+
| 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
+---+------------+------------------------+
```
```

A transformação `Encrypt` usa "source_columns" como `["phone"]` e "kms_key_arn" como o valor da variável de ambiente "$ {KMS}". A transformação criptografa os valores na coluna "telefone" usando a chave KMS especificada. O DataFrame `df_encrypt` resultante contém a coluna “d” original, a coluna “telefone” original e uma coluna adicional chamada “telefone_criptografado” contendo os valores criptografados da coluna “telefone”.

Métodos

- __call__
- apply
- name

- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__(spark_context, data_frame, source_columns, kms_key_arn, entity_type_filter=None, preserve_data_type=None)

A transformação `Encrypt` criptografa as colunas de origem usando a chave do AWS Key Management Service.

- `source_columns`: uma matriz de colunas existentes.
- `kms_key_arn`: o ARN da chave do AWS Key Management Service a ser usado para criptografar as colunas de origem.
- `entity_type_filter`: matriz opcional de tipos de entidades. Pode ser usada para criptografar somente as PII detectadas na coluna de texto livre.
- `preserve_data_type`: booleano opcional. O valor padrão é verdadeiro. Se for falso, o tipo de dado não será armazenado.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe IntToIP

A transformação `IntToIp` converte o valor inteiro da coluna de origem ou outro valor no valor IPv4 correspondente na coluna de destino e retorna o resultado em uma nova coluna.

Exemplo

```
from pyspark.context import SparkContext
from pyspark.sql import SparkSession
from awsgluedi.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
```

Saída

A saída será:

```
```
+---------------+---------------+
|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
+---------------+---------------+
```
```

A transformação `IntToIp.apply` usa a `source_column` como `"source_column_int"` e a `target_column` como `"target_column"` e converte os valores inteiros na coluna `source_column_int` em sua representação de endereço IPv4 correspondente e armazena o resultado na coluna "target_column".

Para valores inteiros válidos dentro do intervalo de endereços IPv4 (0 a 4294967295), a transformação os converte com êxito em sua representação de endereço IPv4 (por exemplo, 192.0.0.1, 0.0.0.0, 10.0.0.10, 255.255.255.255).

Para valores inteiros fora do intervalo válido (por exemplo, 4294967296, -1), o valor de "target_column" é definido como "null". Para valores "null" na coluna "source_column_int", o valor de "target_column" também é definido como "null".

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__ (spark_context, data_frame, target_column, source_column=Nenhum, value=Nenhum)

A transformação `IntToIp` converte o valor inteiro da coluna de origem ou outro valor no valor IPv4 correspondente na coluna de destino e retorna o resultado em uma nova coluna.

- `sourceColumn`: o nome de uma coluna existente.
- `value`: uma sequência de caracteres para avaliar.
- `targetColumn`: o nome da nova coluna a ser criada.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Classe IpToInt

A transformação `IpToInt` converte o valor do Protocolo de Internet versão 4 (IPv4) da coluna de origem ou outro valor no valor inteiro correspondente na coluna de destino e retorna o resultado em uma nova coluna.

Exemplo

Para o AWS Glue 4.0 e versões posteriores, crie ou atualize argumentos de trabalho com `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()
```

Saída

A saída será:

```
```
+----------------+---------------+
|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
+----------------+---------------+
```
```

A transformação `IpToInt` usa a "source_column" como `"source_column_ip"` e a "target_column" como `"target_column"` e converte as cadeias de endereço IPv4 válidas na coluna "source_column_ip" em sua representação inteira correspondente de 32 bits, armazenando o resultado na coluna "target_column".

Para strings de endereço IPv4 válidas (por exemplo, "192.0.0.1", “10.10.10", “1.2.3.4"), a transformação as converte com êxito em sua representação inteira (por exemplo, 3221225473, 168427722, 16909060). Para strings que não são endereços IPv4 válidos (por exemplo, URLs, strings que não são IP, como “abc”, formatos IP inválidos, como “abc.abc.abc.abc”), o valor de

"target_column" é definido como "null". Para valores "null" na coluna "source_column_ip", o valor de "target_column" também é definido como "null".

Métodos

- __call__
- apply
- name
- describeArgs
- describeReturn
- describeTransform
- describeErrors
- describe

__call__ (spark_context, data_frame, target_column, source_column=Nenhum, value=Nenhum)

A transformação `IpToInt` converte o valor do Protocolo de Internet versão 4 (IPv4) da coluna de origem ou outro valor no valor inteiro correspondente na coluna de destino e retorna o resultado em uma nova coluna.

- `sourceColumn`: o nome de uma coluna existente.
- `value`: uma sequência de caracteres para avaliar.
- `targetColumn`: o nome da nova coluna a ser criada.

apply(cls, *args, **kwargs)

Herdado de `GlueTransform` apply.

name(cls)

Herdado de `GlueTransform` name.

describeArgs(cls)

Herdado de `GlueTransform` describeArgs.

describeReturn(cls)

Herdado de `GlueTransform` describeReturn.

describeTransform(cls)

Herdado de `GlueTransform` describeTransform.

describeErrors(cls)

Herdado de `GlueTransform` describeErrors.

describe(cls)

Herdado de `GlueTransform` describe.

Transformações da integração de dados

Para o AWS Glue 4.0 e versões posteriores, crie ou atualize argumentos de trabalho com `key: --enable-glue-di-transforms, value: true`.

Exemplo de script de trabalho:

```
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
```

Exemplo de sessões usando cadernos

```
%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
```

Exemplo de sessões usando AWS CLI

```
aws glue create-session --default-arguments "--enable-glue-di-transforms=true"
```

Transformações DI:

- Classe FlagDuplicatesInColumn
- Classe FormatPhoneNumber
- Classe FormatCase
- Classe FillWithMode
- Classe FlagDuplicateRows
- Classe RemoveDuplicates
- Classe MonthName
- Classe isEven
- Classe CryptographicHash
- Descriptografar classe
- Criptografar classe
- Classe IntToIP
- Classe IpToInt

Maven: empacotar o plug-in com aplicações do Spark

Você pode empacotar a dependência de transformações com suas aplicações e distribuições do Spark (versão 3.3) adicionando a dependência de plug-in em seu `pom.xml` do Maven enquanto desenvolve aplicações do Spark localmente.

```
<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>
```

Ou pode baixar os binários diretamente dos artefatos do AWS Glue Maven e incluí-los na aplicação do Spark como indicado a seguir.

```
#!/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/
```

Programando scripts de ETL do AWS Glue no Scala

É possível encontrar exemplos de código Scala e utilitários para o AWS Glue no Repositório de exemplos do AWS Glue no site do GitHub.

O AWS Glue oferece suporte a uma extensão do dialeto PySpark Scala para criação de scripts de trabalhos de extração, transformação e carregamento (ETL). As seções a seguir descrevem como usar a biblioteca Scala do AWS Glue e a API do AWS Glue em scripts de ETL e fornecem documentação de referência para a biblioteca.

Sumário

- Usar o Scala para programar scripts de ETL do AWS Glue
  - Testar um programa de ETL Scala em um caderno Jupyter em um endpoint de desenvolvimento
  - Testar um programa de ETL Scala em um Scala REPL
- Exemplo de script do Scala: ETL de transmissão
- APIs na biblioteca Scala no AWS Glue
  - com.amazonaws.services.glue
  - com.amazonaws.services.glue.ml
  - com.amazonaws.services.glue.dq
  - com.amazonaws.services.glue.types
  - com.amazonaws.services.glue.util
  - APIs ChoiceOption em Scala no AWS Glue
    - Característica ChoiceOption
    - Objeto ChoiceOption
      - Def apply
    - Classe do caso ChoiceOptionWithResolver
    - Classe do caso MatchCatalogSchemaChoiceOption
  - Classe abstrata DataSink

- Def writeDynamicFrame
- Def pyWriteDynamicFrame
- Def WriteDataFrame
- Def pyWriteDataFrame
- Def setCatalogInfo
- Def supportsFormat
- Def setFormat
- Def withFormat
- Def setAccumulableSize
- Def getOutputErrorRecordsAccumulable
- Def errorsAsDynamicFrame
- Objeto DataSink
  - Def recordMetrics
- Característica DataSource Scala do AWS Glue
- APIs DynamicFrame em Scala do AWS Glue
  - Classe DynamicFrame em Scala do AWS Glue
    - Val errorsCount
    - Def applyMapping
    - Def assertErrorThreshold
    - Def count
    - Def dropField
    - Def dropFields
    - Def dropNulls
    - Def errorsAsDynamicFrame
    - Def filter
    - Def getName
    - Def getNumPartitions
    - Def getSchemaIfComputed
    - Def isSchemaComputed
    - Def javaToPython

- Def join
- Def map
- Def mergeDynamicFrames
- Def printSchema
- Def recomputeSchema
- Def relationalize
- Def renameField
- Def repartition
- Def resolveChoice
- Def schema
- Def selectField
- Def selectFields
- Def show
- Def simplifyDDBJson
- Def spigot
- Def splitFields
- Def splitRows
- Def stageErrorsCount
- Def toDF
- Def unbox
- Def unnest
- Def unnestDDBJson
- Def withFrameSchema
- Def withName
- Def withTransformationContext

- O objeto DynamicFrame
  - Def apply
  - Def emptyDynamicFrame
  - Def fromPythonRDD
  - Def ignoreErrors

        - Def inlineErrors
        - Def newFrameWithErrors
- Classe DynamicRecord em Scala do AWS Glue
    - Def addField
    - Def dropField
    - Def setError
    - Def isError
    - Def getError
    - Def clearError
    - Def write
    - Def readFields
    - Def clone
    - Def schema
    - Def getRoot
    - Def toJson
    - Def getFieldNode
    - Def getField
    - Def hashCode
    - Def equals
    - Objeto DynamicRecord
        - Def apply
    - Característica RecordTraverser
- APIs GlueContext em Scala do AWS Glue
    - def addIngestionTimeColumns
    - def createDataFrameFromOptions
    - forEachBatch
    - def getCatalogSink
    - def getCatalogSource
    - def getJDBCSink
    - def getSink

        - def getSinkWithFormat
        - def getSource
        - def getSourceWithFormat
        - def getSparkSession
        - def startTransaction
        - def commitTransaction
        - def cancelTransaction
        - def this
        - def this
        - def this
- MappingSpec
    - Classe do caso MappingSpec
    - Objeto MappingSpec
    - Val orderingByTarget
    - Def apply
    - Def apply
    - Def apply
- APIs ResolveSpec no Scala do AWS Glue
    - Objeto ResolveSpec
        - Def
        - Def
    - Classe do caso ResolveSpec
        - Métodos def ResolveSpec
- APIs ArrayNode em Scala do AWS Glue
    - Classe do caso ArrayNode
        - Métodos def de ArrayNode
- APIs BinaryNode em Scala do AWS Glue
    - Classe do caso BinaryNode
        - Campos val BinaryNode
        - Métodos def BinaryNode

- APIs BooleanNode em Scala no AWS Glue
  - Classe do caso BooleanNode
    - Campos val BooleanNode
    - Métodos def BooleanNode
- APIs de ByteNode de Scala do AWS Glue
  - Classe do caso ByteNode
    - Campos val ByteNode
    - Métodos def ByteNode
- APIs de DateNode de Scala do AWS Glue
  - Classe do caso DateNode
    - Campos val DateNode
    - Métodos def DateNode
- APIs DecimalNode em Scala no AWS Glue
  - Classe do caso DecimalNode
    - Campos val DecimalNode
    - Métodos def DecimalNode
- APIs DoubleNode em Scala no AWS Glue
  - Classe do caso DoubleNode
    - Campos val DoubleNode
    - Métodos def DoubleNode
- APIs DynamicNode em Scala no AWS Glue
  - Classe DynamicNode
    - Métodos def DynamicNode
  - Objeto DynamicNode
    - Métodos def DynamicNode
- Classe EvaluateDataQuality
  - Def apply
  - Exemplo
- APIs FloatNode em Scala do AWS Glue
  - Classe do caso FloatNode

        - Campos val FloatNode
        - Métodos def FloatNode
- Classe FillMissingValues
    - Def apply
- Classe FindMatches
    - Def apply
- Classe FindIncrementalMatches
    - Def apply
- APIs de IntegerNode de Scala do AWS Glue
    - Classe do caso IntegerNode
        - Campos val IntegerNode
        - Métodos def IntegerNode
- APIs LongNode em Scala do AWS Glue
    - Classe do caso LongNode
        - Campos val LongNode
        - Métodos def LongNode
- APIs MapLikeNode no Scala do AWS Glue
    - Classe MapLikeNode
        - Métodos def MapLikeNode
- APIs MapNode no Scala do AWS Glue
    - Classe do caso MapNode
        - Métodos def MapNode
- APIs NullNode no Scala do AWS Glue
    - Classe NullNode
    - Objeto do caso NullNode
- APIs ObjectNode no Scala do AWS Glue
    - Objeto ObjectNode
        - Métodos def ObjectNode
    - Classe do caso ObjectNode
        - Métodos def ObjectNode

- APIs ScalarNode no Scala do AWS Glue
  - Classe ScalarNode
    - Métodos def ScalarNode
  - Objeto ScalarNode
    - Métodos def ScalarNode
- APIs ShortNode no Scala do AWS Glue
  - Classe do caso ShortNode
    - Campos val ShortNode
    - Métodos def ShortNode
- APIs StringNode no Scala do AWS Glue
  - Classe do caso StringNode
    - Campos val StringNode
    - Métodos def StringNode
- APIs TimestampNode no Scala do AWS Glue
  - Classe do caso TimestampNode
    - Campos val TimestampNode
    - Métodos def TimestampNode
- APIs GlueArgParser em Scala no AWS Glue
  - Objeto GlueArgParser
    - Métodos def GlueArgParser
- APIs de trabalho em Scala do AWS Glue
  - Objeto Job
    - Métodos def Job

Usar o Scala para programar scripts de ETL do AWS Glue

Você pode gerar automaticamente um programa Scala de extração, transformação e carga (ETL) usando o console do AWS Glue e modificá-lo conforme necessário antes de atribui-lo a um trabalho. Ou, você pode escrever seu próprio programa do zero. Para obter mais informações, consulte Configurar propriedades de trabalho para trabalhos do Spark no AWS Glue. Em seguida, o AWS Glue compila seu programa Scala no servidor antes de executar o trabalho associado.

Para ter certeza de que seu programa compila sem erros e é executado como esperado, é muito importante carregá-lo em um endpoint de desenvolvimento em um REPL (Read-Eval-Print Loop) ou em um caderno Jupyter e testá-lo antes de executá-lo em um trabalho. Como o processo de compilação ocorre no servidor, você não terá uma boa visibilidade dos problemas que ocorrem lá.

Testar um programa de ETL Scala em um caderno Jupyter em um endpoint de desenvolvimento

Para testar um programa Scala em um endpoint de desenvolvimento do AWS Glue, configure o endpoint de desenvolvimento conforme descrito em Adicionar um endpoint de desenvolvimento.

Em seguida, conecte-o a um caderno Jupyter que esteja em execução localmente na sua máquina ou remotamente em um servidor de cadernos do Amazon EC2. Para instalar uma versão local de um caderno Jupyter, siga as instruções em Tutorial: caderno Jupyter no JupyterLab.

A única diferença entre executar o código Scala e executar o código PySpark no seu notebook é que você deve iniciar cada parágrafo no notebook com o seguinte:

```
%spark
```

Isso impede que o servidor do notebook seja padronizado para o tipo do PySpark do intérprete Spark.

Testar um programa de ETL Scala em um Scala REPL

Você pode testar um programa Scala em um endpoint do desenvolvedor usando o Scala REPL do AWS Glue. Siga as instruções em Tutorial: usar um caderno do SageMaker AI, exceto no final do comando SSH para REPL, substitua `-t gluepyspark` por `-t glue-spark-shell`. Isso invoca o Scala REPL do AWS Glue.

Para fechar o REPL quando você concluir, digite `sys.exit`.

Exemplo de script do Scala: ETL de transmissão

Example

O script de exemplo a seguir se conecta ao Amazon Kinesis Data Streams, usa um esquema do Data Catalog para analisar um fluxo de dados, une o fluxo a um conjunto de dados estático no Amazon S3 e gera os resultados unidos no Amazon S3 em formato 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 na biblioteca Scala no AWS Glue

O AWS Glue oferece suporte a uma extensão do dialeto PySpark Scala para trabalhos de extração, transformação e carregamento (ETL) em script. As seções a seguir descrevem as APIs na biblioteca Scala do AWS Glue.

com.amazonaws.services.glue

O pacote com.amazonaws.services.glue na biblioteca Scala do AWS Glue contém as seguintes APIs:

- ChoiceOption
- DataSink
- Característica do DataSource
- DynamicFrame

- DynamicRecord
- GlueContext
- MappingSpec
- ResolveSpec

com.amazonaws.services.glue.ml

O pacote com.amazonaws.services.glue.ml na biblioteca de Scala do AWS Glue contém as seguintes APIs:

- FillMissingValues
- FindIncrementalMatches
- FindMatches

com.amazonaws.services.glue.dq

O pacote com.amazonaws.services.glue.ml na biblioteca Sacal da AWS Gluecontém as seguintes APIs:

- EvaluateDataQuality

com.amazonaws.services.glue.types

O pacote com.amazonaws.services.glue.types na biblioteca Scala do AWS Glue contém as seguintes 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

O pacote com.amazonaws.services.glue.util na biblioteca Scala do AWS Glue contém as seguintes APIs:

- GlueArgParser
- Trabalho

APIs ChoiceOption em Scala no AWS Glue

Tópicos

- Característica ChoiceOption
- Objeto ChoiceOption
- Classe do caso ChoiceOptionWithResolver
- Classe do caso MatchCatalogSchemaChoiceOption

Pacote: com.amazonaws.services.glue

Característica ChoiceOption

```
trait ChoiceOption extends Serializable
```

Objeto ChoiceOption

ChoiceOption

```
object ChoiceOption
```

Uma estratégia geral para determinar a opção aplicável a todos os nós `ChoiceType` em um `DynamicFrame`.

- `val CAST`
- `val MAKE_COLS`
- `val MAKE_STRUCT`
- `val MATCH_CATALOG`
- `val PROJECT`

Def apply

```
def apply(choice: String): ChoiceOption
```

Classe do caso ChoiceOptionWithResolver

```
case class ChoiceOptionWithResolver(name: String, choiceResolver: ChoiceResolver)
 extends ChoiceOption {}
```

Classe do caso MatchCatalogSchemaChoiceOption

```
case class MatchCatalogSchemaChoiceOption() extends ChoiceOption {}
```

Classe abstrata DataSink

Tópicos

- Def writeDynamicFrame
- Def pyWriteDynamicFrame
- Def WriteDataFrame

- Def pyWriteDataFrame
- Def setCatalogInfo
- Def supportsFormat
- Def setFormat
- Def withFormat
- Def setAccumulableSize
- Def getOutputErrorRecordsAccumulable
- Def errorsAsDynamicFrame
- Objeto DataSink

Pacote: com.amazonaws.services.glue

```
abstract class DataSink
```

O gravador analógico a um `DataSource`. O `DataSink` encapsula um destino e um formato no qual um `DynamicFrame` pode ser gravado.

Def writeDynamicFrame

```
def writeDynamicFrame( frame : DynamicFrame,
                       callSite : CallSite = CallSite("Not provided", "")
                     ) : DynamicFrame
```

Def pyWriteDynamicFrame

```
def pyWriteDynamicFrame( frame : DynamicFrame,
                         site : String = "Not provided",
                         info : String = "" )
```

Def WriteDataFrame

```
def writeDataFrame(frame: DataFrame,
                   glueContext: GlueContext,
                   callSite: CallSite = CallSite("Not provided", "")
                   ): DataFrame
```

Def pyWriteDataFrame

```
def pyWriteDataFrame(frame: DataFrame,
                     glueContext: GlueContext,
                     site: String = "Not provided",
                     info: String = ""
                     ): DataFrame
```

Def 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
```

Def setAccumulableSize

```
def setAccumulableSize( size : Int ) : Unit
```

Def getOutputErrorRecordsAccumulable

```
def getOutputErrorRecordsAccumulable : Accumulable[List[OutputError], OutputError]
```

Def errorsAsDynamicFrame

```
def errorsAsDynamicFrame : DynamicFrame
```

Objeto DataSink

```
object DataSink
```

Def recordMetrics

```
def recordMetrics( frame : DynamicFrame,
                   ctxt : String
                 ) : DynamicFrame
```

Característica DataSource Scala do AWS Glue

Pacote: com.amazonaws.services.glue

Uma interface de alto nível para produzir um `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
}
```

APIs DynamicFrame em Scala do AWS Glue

Pacote: com.amazonaws.services.glue

Sumário

- Classe DynamicFrame em Scala do AWS Glue
  - Val errorsCount
  - Def applyMapping
  - Def assertErrorThreshold
  - Def count
  - Def dropField
  - Def dropFields
  - Def dropNulls
  - Def errorsAsDynamicFrame
  - Def filter
  - Def getName
  - Def getNumPartitions

- Def getSchemaIfComputed
- Def isSchemaComputed
- Def javaToPython
- Def join
- Def map
- Def mergeDynamicFrames
- Def printSchema
- Def recomputeSchema
- Def relationalize
- Def renameField
- Def repartition
- Def resolveChoice
- Def schema
- Def selectField
- Def selectFields
- Def show
- Def simplifyDDBJson
- Def spigot
- Def splitFields
- Def splitRows
- Def stageErrorsCount
- Def toDF
- Def unbox
- Def unnest
- Def unnestDDBJson
- Def withFrameSchema
- Def withName
- Def withTransformationContext

- O objeto DynamicFrame
  - Def apply

- Def emptyDynamicFrame
- Def fromPythonRDD
- Def ignoreErrors
- Def inlineErrors
- Def newFrameWithErrors

Classe DynamicFrame em Scala do AWS Glue

Pacote: 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 = {} )
```

Um `DynamicFrame` é uma coleção distribuída de objetos autodescritivos DynamicRecord.

`DynamicFrames` são projetados para fornecer um modelo de dados flexível para operações de ETL (extração, transformação e carregamento). Eles não exigem um esquema para criar e podem ser usados para ler e transformar dados com valores e tipos confusos ou inconsistentes. Um esquema pode ser calculado sob demanda para as operações que precisam de um.

`DynamicFrame` fornece uma variedade de transformações para limpeza de dados e ETL. Eles também suportam conversão de e para os DataFrames SparkSQL para integração com o código existente e as muitas operações de análise que os DataFrames fornecem.

Os seguintes parâmetros são compartilhados em muitas das transformações do AWS Glue que constroem `DynamicFrames`:

- `transformationContext`: o identificador para esse `DynamicFrame`. O `transformationContext` é usado como uma chave para o estado do marcador de trabalho que é mantido nas execuções.

- `callSite`: fornece informações de contexto para o relatório de erros. Esses valores são definidos automaticamente quando chamados do Python.
- `stageThreshold` — O número máximo de registros de erros permitido a partir da computação desse `DynamicFrame` antes de lançar uma exceção, excluindo os registros presentes no `DynamicFrame` anterior.
- `totalThreshold` – O número máximo de registros de erros totais antes que uma exceção seja lançada, incluindo os de quadros anteriores.

Val errorsCount

```
val errorsCount
```

O número de registros de erros neste `DynamicFrame`. Isso inclui erros de operações anteriores.

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` — Uma sequência de mapeamentos para construir um novo `DynamicFrame`.
- `caseSensitive`: informa se deve ou não tratar as colunas de origem como colunas que diferenciam letras maiúsculas de minúsculas. Definir essa opção como false pode ajudar na integração com armazenamentos que não diferenciam maiúsculas de minúsculas, como o AWS Glue Data Catalog.

Seleciona, projeta e converte colunas com base em uma sequência de mapeamentos.

Cada mapeamento é composto por uma coluna e um tipo de origem e uma coluna e um tipo de destino. Mapeamentos podem ser especificados como um objeto 4-tuple (`source_path`, `source_type`, `target_path`, `target_type`) or a MappingSpec que contém a mesma informação.

Além de usar mapeamentos para projeções simples e da conversão, você pode usar os mapeamentos para aninhar ou desaninhar campos, separando os componentes do caminho com '`.`' (ponto).

Por exemplo, digamos que você tem um `DynamicFrame` com o seguinte esquema.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: struct
  |    |-- state: string
  |    |-- zip: int
}}}
```

Você pode fazer a seguinte chamada para desaninhar os campos `state` e `zip`.

```
{{{
  df.applyMapping(
   Seq(("name", "string", "name", "string"),
       ("age", "int", "age", "int"),
       ("address.state", "string", "state", "string"),
       ("address.zip", "int", "zip", "int")))
}}}
```

O esquema resultante será o seguinte.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- state: string
  |-- zip: int
}}}
```

Você também pode usar `applyMapping` para aninhar novamente as colunas. Por exemplo, o seguinte inverte a transformação anterior e cria uma estrutura chamada `address` no destino.

```
{{{
  df.applyMapping(
   Seq(("name", "string", "name", "string"),
       ("age", "int", "age", "int"),
```

```
        ("state", "string", "address.state", "string"),
        ("zip", "int", "address.zip", "int")))
 }}}
```

Os nomes de campo que contêm caracteres '`.`' (período) pode ser cotado usando acentos graves (``).

> **Note**
>
> Atualmente, você não pode usar o método `applyMapping` para mapear colunas que estão aninhadas sob arrays.

Def assertErrorThreshold

```
def assertErrorThreshold : Unit
```

Uma ação que força a computação e verifica se o número de registros de erros está abaixo de `stageThreshold` e de `totalThreshold`. Lança uma exceção se a condição falhar.

Def count

```
lazy
def count
```

Retorna o número de elementos neste `DynamicFrame`.

Def dropField

```
def dropField( path : String,
               transformationContext : String = "",
               callSite : CallSite = CallSite("Not provided", ""),
               stageThreshold : Long = 0,
               totalThreshold : Long = 0
             ) : DynamicFrame
```

Retorna um novo `DynamicFrame` com a coluna especificada removida.

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
```

Retorna um novo `DynamicFrame` com as colunas especificadas removidas.

Esse método pode ser usado para excluir colunas aninhadas, incluindo aquelas dentro de matrizes, mas não pode ser usado para descartar elementos de matriz específicos.

Def dropNulls

```
def dropNulls( transformationContext : String = "",
               callSite : CallSite = CallSite("Not provided", ""),
               stageThreshold : Long = 0,
               totalThreshold : Long = 0 )
```

Retorna um novo `DynamicFrame` com todas as colunas nulas removidas.

> **Note**
>
> Isso remove apenas colunas do tipo `NullType`. Valores nulos individuais em outras colunas não são removidos ou modificados.

Def errorsAsDynamicFrame

```
def errorsAsDynamicFrame
```

Retorna um novo `DynamicFrame` contendo os registros de erro deste `DynamicFrame`.

Def filter

```
def filter( f : DynamicRecord => Boolean,
            errorMsg : String = "",
            transformationContext : String = "",
            callSite : CallSite = CallSite("Not provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0
          ) : DynamicFrame
```

Cria um novo `DynamicFrame` que contém apenas os registros para os quais a função "`f`" retorna `true`. A função de filtro "`f`" não deve alterar o registro de entrada.

Def getName

```
def getName : String
```

Retorna o nome deste `DynamicFrame`.

Def getNumPartitions

```
def getNumPartitions
```

Retorna o número de partições neste `DynamicFrame`.

Def getSchemaIfComputed

```
def getSchemaIfComputed : Option[Schema]
```

Retorna o esquema, se ele já foi calculado. Não verifica os dados se o esquema ainda não tiver sido calculado.

Def isSchemaComputed

```
def isSchemaComputed : Boolean
```

Retorna `true` se o esquema foi calculado para este `DynamicFrame` ou `false`, se não. Se esse método retorna falso, chamar o método `schema` exige outra passagem pelos registros nesse `DynamicFrame`.

Def 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` – As colunas nesse `DynamicFrame` para usar na junção.
- `keys2`: as colunas no `frame2` a serem usadas na junção. Deve ter o mesmo tamanho que `keys1`.
- `frame2` — O `DynamicFrame` para usar na junção.

Retorna o resultado da execução de uma junção equivalente com `frame2` usando as chaves especificadas.

Def map

```
def map( f : DynamicRecord => DynamicRecord,
         errorMsg : String = "",
         transformationContext : String = "",
         callSite : CallSite = CallSite("Not provided", ""),
         stageThreshold : Long = 0,
         totalThreshold : Long = 0
       ) : DynamicFrame
```

Retorna um novo `DynamicFrame` criado aplicando a função especificada "f" para cada registro nesse `DynamicFrame`.

Este método copia cada registro antes de aplicar a função especificada, portanto, é seguro alterar os registros. Se a função de mapeamento lançar uma exceção em um determinado registro, esse registro é marcado como um erro e o rastreamento de pilha é salvo como uma coluna no registro de erros.

Def 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`: o `DynamicFrame` de preparação para mesclar.

- `primaryKeys`: a lista de campos de chave primária para corresponder aos registros da fonte e `DynamicFrames` de preparação.
- `transformationContext`: uma string exclusiva usada para recuperar os metadados sobre a transformação atual (opcional).
- `options`: uma string de pares nome-valor JSON que fornecem informações adicionais para essa transformação.
- `callSite`: usado para fornecer informações de contexto para o relatório de erros.
- `stageThreshold`: uma `Long`. O número de erros na transformação para a qual o processamento precisa apresentar falhas.
- `totalThreshold`: uma `Long`. O número total de erros nessa transformação para os quais o processamento precisa apresentar falhas.

Mescla esse `DynamicFrame` com uma preparação `DynamicFrame` de acordo com as chaves primárias especificadas para identificar registros. Registros duplicados (com as mesmas chaves primárias) não são eliminados. Se não houver nenhum registro correspondente no quadro de preparação, todos os registros (incluindo os duplicados) serão retidos da origem. Se o quadro de preparação tiver registros correspondentes, os do quadro de preparação substituirão os da origem no AWS Glue.

O `DynamicFrame` retornado contém registro A nos seguintes casos:

1. Se `A` existir no quadro de origem e no quadro de preparação, o `A` do quadro de preparação será retornado.
2. Se `A` estiver na tabela de origem e `A.primaryKeys` não estiver no `stagingDynamicFrame` (isso significa que `A` não é atualizado na tabela de preparação).

O quadro de origem e o quadro de preparação não precisam ter o mesmo esquema.

Example

```
val mergedFrame: DynamicFrame = srcFrame.mergeDynamicFrames(stageFrame, Seq("id1",
 "id2"))
```

Def printSchema

```
def printSchema : Unit
```

Imprime o esquema deste `DynamicFrame` para `stdout` em um formato legível.

Def recomputeSchema

```
def recomputeSchema : Schema
```

Força um recálculo do esquema. Isso requer uma verificação nos dados, mas pode "restringir" o esquema se houver alguns campos no esquema atual que não estejam presentes nos dados.

Retorna o esquema recalculado.

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`: o nome a ser usado para o `DynamicFrame` base na saída. `DynamicFrames` criados pelo deslocamento de matrizes começam com isso como um prefixo.
- `stagingPath`: o caminho do Amazon Simple Storage Service (Amazon S3) para gravação de dados intermediários.
- `options`: opções e a configuração da função Relationalize. Não utilizado no momento.

Nivela todas as estruturas aninhadas e matrizes dinâmicas em tabelas separadas.

Você pode usar essa operação para preparar dados extremamente aninhados para adição em um banco de dados relacional. As estruturas aninhadas são niveladas da mesma maneira que a transformação Unnest. Além disso, as matrizes são dinamizadas em tabelas separadas, com cada elemento da matriz se tornando uma linha. Por exemplo, digamos que você tenha um `DynamicFrame` com os seguintes dados.

```
{"name": "Nancy", "age": 47, "friends": ["Fred", "Lakshmi"]}
{"name": "Stephanie", "age": 28, "friends": ["Yao", "Phil", "Alvin"]}
```

```
 {"name": "Nathan", "age": 54, "friends": ["Nicolai", "Karen"]}
```

Execute o código a seguir.

```
{{{
  df.relationalize("people", "s3:/my_bucket/my_path", JsonOptions.empty)
}}}
```

Isso produz duas tabelas. A primeira tabela é chamada "pessoas" e contém o seguinte.

```
{{{
  {"name": "Nancy", "age": 47, "friends": 1}
  {"name": "Stephanie", "age": 28, "friends": 2}
  {"name": "Nathan", "age": 54, "friends": 3)
}}}
```

Aqui, a matriz de amigos foi substituída por uma chave de junção gerada automaticamente. Uma tabela separada chamada `people.friends` é criada com o seguinte conteúdo.

```
{{{
  {"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"}
}}}
```

Nessa tabela, '`id`' é uma chave de junção que identifica de qual registro o elemento da matriz é proveniente, '`index`' refere-se à posição na matriz original e '`val`' é a entrada real da matriz.

O método `relationalize` retorna a sequência de `DynamicFrame` criada aplicando esse processo recursivamente a todas as matrizes.

> **Note**
>
> A biblioteca do AWS Glue gera automaticamente chaves de junção para novas tabelas. Para garantir que as chaves de junção sejam exclusivas nas execuções do trabalho, você deve ativar as marcações de trabalho.

Def renameField

```
def renameField( oldName : String,
                 newName : String,
                 transformationContext : String = "",
                 callSite : CallSite = CallSite("Not provided", ""),
                 stageThreshold : Long = 0,
                 totalThreshold : Long = 0
               ) : DynamicFrame
```

- `oldName` – O nome original da coluna.
- `newName` – O novo nome da coluna.

Retorna um novo `DynamicFrame` com campo especificado renomeado.

Você pode usar esse método para renomear campos aninhados. Por exemplo, o código a seguir renomearia `state` como `state_code` na estrutura de endereço.

```
{{{
  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
```

Retorna um novo `DynamicFrame` com partições `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` — Uma ação a ser aplicada a todas as colunas `ChoiceType` não listadas na sequência de especificações.
- `database`: o banco de dados do Data Catalog a ser usado com a ação `match_catalog`.
- `tableName`: a tabela do Data Catalog a ser usada com a ação `match_catalog`.

Retorna um novo `DynamicFrame` substituindo um ou mais `ChoiceType` por um tipo mais específico.

Há duas maneiras de usar `resolveChoice`. A primeira é especificar uma sequência de colunas específicas e como resolvê-las. Elas são especificadas como tuplas compostas de pares (coluna, ação).

A seguir estão as ações possíveis:

- `cast:type` – Tenta converter todos os valores para o tipo especificado.
- `make_cols` – Converte cada tipo distinto em uma coluna com o nome `columnName_type`.
- `make_struct` – Converte uma coluna em uma estrutura com chaves para cada tipo distinto.
- `project:type` — Mantém apenas valores do tipo especificado.

O outro modo para `resolveChoice` é especificar uma única resolução para todos os `ChoiceTypes`. Você pode usar isso em casos em que a lista completa de `ChoiceTypes` for desconhecida antes da execução. Além das ações listadas anteriormente, esse modo também aceita a seguinte ação:

- `match_catalogChoiceType` – Tenta converter cada para o tipo correspondente na tabela de catálogo especificada.

Exemplos:

Corrija a coluna `user.id` convertendo para um inteiro e faça o campo `address` reter apenas as estruturas.

```
{{{
  df.resolveChoice(specs = Seq(("user.id", "cast:int"), ("address", "project:struct")))
}}}
```

Resolva todos os `ChoiceTypes` convertendo cada opção em uma coluna separada.

```
{{{
  df.resolveChoice(choiceOption = Some(ChoiceOption("make_cols")))
}}}
```

Resolva todos os `ChoiceTypes` convertendo para os tipos na tabela de catálogo especificada.

```
{{{
  df.resolveChoice(choiceOption = Some(ChoiceOption("match_catalog")),
                   database = Some("my_database"),
                   tableName = Some("my_table"))
}}}
```

Def schema

```
def schema : Schema
```

Retorna o esquema deste `DynamicFrame`.

O esquema retornado é garantido para conter todos os domínios que estão presentes nesse registro `DynamicFrame`. Mas em um pequeno número de casos, ele também pode conter campos adicionais. Você pode usar o método Unnest para "restringir" o esquema com base nos registros deste `DynamicFrame`.

Def selectField

```
def selectField( fieldName : String,
                 transformationContext : String = "",
                 callSite : CallSite = CallSite("Not provided", ""),
                 stageThreshold : Long = 0,
                 totalThreshold : Long = 0
               ) : DynamicFrame
```

Retorna um único campo como um `DynamicFrame`.

Def selectFields

```
def selectFields( paths : Seq[String],
                  transformationContext : String = "",
                  callSite : CallSite = CallSite("Not provided", ""),
                  stageThreshold : Long = 0,
                  totalThreshold : Long = 0
                ) : DynamicFrame
```

- `paths` — A sequência de nomes de coluna para selecionar.

Retorna um novo `DynamicFrame` contendo as colunas especificadas.

> **Note**
>
> O método `selectFields` só pode ser usado para selecionar as colunas de nível superior. O método applyMapping pode ser usado para selecionar as colunas aninhadas.

Def show

```
def show( numRows : Int = 20 ) : Unit
```

- `numRows` – O número de linhas a serem impressas.

Imprime linhas desse `DynamicFrame` no formato JSON.

Def simplifyDDBJson

As exportações do DynamoDB feitas com o conector de exportação para DynamoDB do AWS Glue resultam em arquivos JSON de estruturas aninhadas específicas. Para obter mais informações, consulte Objetos de dados. `simplifyDDBJson` Simplifica as colunas aninhadas em um DynamicFrame desse tipo de dados e retorna um novo DynamicFrame simplificado. Se houver vários tipos ou um tipo de mapa contidos em um tipo de lista, os elementos na lista não serão simplificados. Esse método oferece suporte somente a dados no for mato JSON de exportação do DynamoDB. Considere o `unnest` para realizar alterações semelhantes em outros tipos de dados.

```
def simplifyDDBJson() : DynamicFrame
```

Esse método não aceita parâmetros.

Exemplo de entrada

Considere o seguinte esquema gerado por uma exportação do 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
```

Código de exemplo

```
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()
  }

}
```

Exemplo de saída

A transformação `simplifyDDBJson` simplificará isso para:

```
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
```

Transformação de passagem que retorna os mesmos registros, mas grava um subconjunto de registros como um efeito secundário.

- `path`: o caminho no Amazon S3 no qual gravar a saída, no formato `s3://bucket//path`.
- `options` — Um mapa opcional `JsonOptions` que descreve o comportamento de amostragem.

Retorna um `DynamicFrame` que contém os mesmos registros deste.

Por padrão, grava 100 registros arbitrários no local especificado por `path`. Você pode personalizar esse comportamento usando o mapa `options`. Chaves válidas incluem o seguinte:

- `topk`: especifica o número total de registros gravados. O padrão é 100.
- `prob`: especifica a probabilidade (como um número decimal) de incluir um registro individual. O padrão é 1.

Por exemplo, a chamada a seguir seria um exemplo do conjunto de dados, selecionando cada registro com uma probabilidade de 20% e interrompendo após a gravação de 200 registros.

```
{{{
  df.spigot("s3://my_bucket/my_path", JsonOptions(Map("topk" -&gt; 200, "prob" -&gt;
 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` — Os caminhos a serem incluídos no primeiro `DynamicFrame`.

Retorna uma sequência de dois `DynamicFrames`. O primeiro `DynamicFrame` contém os caminhos especificados e o segundo, todas as outras colunas.

Exemplo

Este exemplo usa um DynamicFrame criado a partir da tabela `persons` no banco de dados `legislators` no catálogo de dados do Glue da AWS e divide o DynamicFrame em dois, com os campos especificados entrando no primeiro DynamicFrame e os campos restantes entrando em um segundo DynamicFrame. O exemplo então escolhe o primeiro DynamicFrame do resultado.

```
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]
```

Divide linhas com base em predicados que comparam colunas com constantes.

- `paths` — As colunas a serem usadas para comparação.
- `values` — Os valores constantes a serem usados para comparação.
- `operators` — Os operadores a serem usados para comparação.

Retorna uma sequência de dois `DynamicFrames`. O primeiro contém linhas para as quais o predicado é verdadeiro, e o segundo contém linhas para as quais ele é falso.

Os predicados são especificados usando três sequências: "`paths`" contém os nomes de coluna (possivelmente aninhados), "`values`" contém os valores constantes para comparar e "`operators`" contém os operadores a serem usados para comparação. Todas as três sequências devem ter o mesmo tamanho: o operador n é usado para comparar a coluna n com o valor n.

Cada operador deve ser um de "!=", "=", "<=", "<", ">=" ou ">".

Como exemplo, a chamada a seguir dividiria um `DynamicFrame` para que o primeiro quadro de saída contivesse registros de pessoas dos Estados Unidos com mais de 65 anos, e o segundo contivesse todos os outros registros.

```
{{{
  df.splitRows(Seq("age", "address.country"), Seq(65, "USA"), Seq("&gt;=", "="))
}}}
```

Def stageErrorsCount

```
def stageErrorsCount
```

Retorna o número de registros de erros criados durante o cálculo desse `DynamicFrame`. Isso exclui erros de operações anteriores que foram passadas para este `DynamicFrame` como entrada.

Def toDF

```
def toDF( specs : Seq[ResolveSpec] = Seq.empty[ResolveSpec] ) : DataFrame
```

Converte isso `DynamicFrame` para um Apache Spark SQL `DataFrame` com o mesmo esquema e registros.

> **Note**
>
> Como `DataFrames` não oferecem suporte para `ChoiceTypes`, esse método converte automaticamente colunas `ChoiceType` em `StructTypes`. Para obter mais informações e opções para opções de resolução, consulte 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`: a coluna a ser analisada. Deve ser uma string ou binária.
- `format` – O formato a ser usado para a análise.
- `optionString` – Opções para passar para o formato, como o separador CSV.

Analisa uma coluna de string ou binária incorporada de acordo com o formato especificado. Colunas analisadas são aninhadas sob uma estrutura com o nome da coluna original.

Por exemplo, suponha que há um arquivo CSV com uma coluna JSON incorporada,

```
name, age, address
Sally, 36, {"state": "NE", "city": "Omaha"}
...
```

Após uma análise inicial, seria obtido um `DynamicFrame` com o seguinte esquema.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: string
}}}
```

É possível chamar `unbox` na coluna de endereço para analisar os componentes específicos.

```
{{{
  df.unbox("address", "json")
}}}
```

Isso nos dá um `DynamicFrame` com o seguinte esquema.

```
{{{
  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
```

Retorna um novo `DynamicFrame` com todas as estruturas aninhadas niveladas. Os nomes são criados usando o caractere `'.'` (ponto).

Por exemplo, digamos que você tem um `DynamicFrame` com o seguinte esquema.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address: struct
  |    |-- state: string
  |    |-- city: string
}}}
```

A chamada a seguir desaninha a estrutura do endereço.

```
{{{
  df.unnest()
}}}
```

O esquema resultante será o seguinte.

```
{{{
  root
  |-- name: string
  |-- age: int
  |-- address.state: string
  |-- address.city: string
}}}
```

Esse método também desaninha estruturas aninhados dentro de matrizes. No entanto, por razões históricas, os nomes dos campos são prefixados com o nome do array de fechamento e "`.val`".

Def unnestDDBJson

```
unnestDDBJson(transformationContext : String = "",
            callSite : CallSite = CallSite("Not Provided"),
            stageThreshold : Long = 0,
            totalThreshold : Long = 0): DynamicFrame
```

Desaninha colunas aninhadas em um `DynamicFrame` que estão especificamente na estrutura JSON do DynamoDB e retorna um novo `DynamicFrame` não aninhado. Colunas que pertençam a uma matriz de tipos de estrutura não serão desaninhadas. Observe que esse é um tipo específico de transformação de desaninhamento que se comporta diferentemente da transformação `unnest` comum e requer que os dados já estejam na estrutura JSON do DynamoDB. Para mais informações, consulte JSON do DynamoDB.

Por exemplo, o esquema de uma leitura de uma exportação com a estrutura JSON do DynamoDB pode se parecer com o seguinte:

```
root
|-- Item: struct
|    |-- ColA: struct
|    |    |-- S: string
|    |-- ColB: struct
|    |    |-- S: string
|    |-- ColC: struct
```

```
|    |    |-- N: string
|    |-- ColD: struct
|    |    |-- L: array
|    |    |    |-- element: null
```

A transformação `unnestDDBJson()` converteria isso em:

```
root
|-- ColA: string
|-- ColB: string
|-- ColC: string
|-- ColD: array
|    |-- element: null
```

O exemplo de código a seguir mostra como usar o conector de exportação para DynamoDB do AWS Glue, invocar um desaninhamento de JSON do DynamoDB e imprimir o número de partições:

```
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()
  }

}
```

Def withFrameSchema

```
def withFrameSchema( getSchema : () => Schema ) : DynamicFrame
```

- `getSchema`: uma função que retorna o esquema a ser usado. Especificado como uma função de parâmetro zero para adiar a computação potencialmente dispendiosa.

Define o esquema desse `DynamicFrame` com o valor especificado. Isso é usado principalmente de maneira interna para evitar a recomputação dispendiosa do esquema. O esquema transmitido deve conter todas as colunas presentes nos dados.

Def withName

```
def withName( name : String ) : DynamicFrame
```

- `name` — O novo nome a ser usado.

Retorna uma cópia desse `DynamicFrame` com um novo nome.

Def withTransformationContext

```
def withTransformationContext( ctx : String ) : DynamicFrame
```

Retorna uma cópia desse `DynamicFrame` com o contexto de transformação especificado.

O objeto DynamicFrame

Pacote: com.amazonaws.services.glue

```
object DynamicFrame
```

Def apply

```
def apply( df : DataFrame,
           glueContext : GlueContext
         ) : DynamicFrame
```

Def 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)
```

Def newFrameWithErrors

```
def newFrameWithErrors( prevFrame : DynamicFrame,
                        rdd : RDD[DynamicRecord],
                        name : String = "",
                        transformationContext : String = "",
                        callSite : CallSite,
                        stageThreshold : Long,
                        totalThreshold : Long
                      ) : DynamicFrame
```

Classe DynamicRecord em Scala do AWS Glue

Tópicos

- Def addField
- Def dropField
- Def setError
- Def isError
- Def getError
- Def clearError
- Def write
- Def readFields
- Def clone
- Def schema
- Def getRoot
- Def toJson
- Def getFieldNode
- Def getField
- Def hashCode
- Def equals
- Objeto DynamicRecord
- Característica RecordTraverser

Pacote: com.amazonaws.services.glue

```
class DynamicRecord extends Serializable with Writable with Cloneable
```

Um `DynamicRecord` é uma estrutura de dados autodescritiva que representa uma linha de conjunto de dados que está sendo processado. É autodescritiva, no sentido de que você pode obter o esquema da linha representada pelo `DynamicRecord`, inspecionando o próprio registro. Um `DynamicRecord` é semelhante a uma `Row` no Apache Spark

Def addField

```
def addField( path : String,
```

```
              dynamicNode : DynamicNode
            ) : Unit
```

Adiciona um DynamicNode ao caminho especificado.

- `path` – O caminho para o campo a ser adicionado.
- `dynamicNode` — O DynamicNode a ser adicionado no caminho especificado.

Def dropField

```
def dropField(path: String, underRename: Boolean = false): Option[DynamicNode]
```

Remove um DynamicNode do caminho especificado e retorna o nó removido se não houver uma matriz no caminho especificado.

- `path` — O caminho para o campo a ser removido.
- `underRenamedropField` – Verdadeiro se for chamado como parte de uma transformação de renomeação ou falso, caso contrário (falso por padrão).

Retorna um `scala.Option Option` (DynamicNode).

Def setError

```
def setError( error : Error )
```

Define esse registro como um registro de erro, conforme especificado pelo parâmetro `error`.

Retorna um `DynamicRecord`.

Def isError

```
def isError
```

Verifica se esse registro é um registro de erro.

Def getError

```
def getError
```

Obtém o `Error` se o registro for um registro de erro. Retorna `scala.Some` Some (Erro) se esse registro for um registro de erro ou `scala.None`, caso contrário.

Def clearError

```
def clearError
```

Defina `Error` como `scala.None.None` .

Def write

```
override def write( out : DataOutput ) : Unit
```

Def readFields

```
override def readFields( in : DataInput ) : Unit
```

Def clone

```
override def clone : DynamicRecord
```

Clona esse registro para um novo `DynamicRecord` e o retorna.

Def schema

```
def schema
```

Obtém o `Schema` ao inspecionar o registro.

Def getRoot

```
def getRoot : ObjectNode
```

Obtém a raiz `ObjectNode` do registro.

Def toJson

```
def toJson : String
```

Obtém a string JSON para o registro.

Def getFieldNode

```
def getFieldNode( path : String ) : Option[DynamicNode]
```

Obtém o valor do campo no `path` especificado como uma opção de `DynamicNode`.

Retorna `scala.Some` Some (DynamicNode) se o campo existir ou `scala.None.None`, caso contrário.

Def getField

```
def getField( path : String ) : Option[Any]
```

Obtém o valor do campo no `path` especificado como uma opção de `DynamicNode`.

Retorna `scala.Some` Some (valor).

Def hashCode

```
override def hashCode : Int
```

Def equals

```
override def equals( other : Any )
```

Objeto DynamicRecord

```
object DynamicRecord
```

Def apply

```
def apply( row : Row,
           schema : SparkStructType )
```

Aplique o método para converter um Apache Spark SQL `Row` em um DynamicRecord.

- `row` – Um Spark SQL Row.
- `schema` – O Schema dessa linha.

Retorna um `DynamicRecord`.

Característica RecordTraverser

```
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
}
```

APIs GlueContext em Scala do AWS Glue

Pacote: com.amazonaws.services.glue

```
class GlueContext extends SQLContext(sc) (
           @transient val sc : SparkContext,
           val defaultSourcePartitioner : PartitioningStrategy )
```

`GlueContext` é o ponto de entrada para leitura e gravação de um DynamicFrame de e para o Amazon Simple Storage Service (Amazon S3), AWS Glue Data Catalog, JDBC e assim por diante.

Essa classe fornece funções de utilitário para criar objetos Característica do DataSource e DataSink que, por sua vez, podem ser usados para ler e gravar `DynamicFrames`.

`GlueContext` também pode ser usado para definir um número de partições de destino (o padrão é 20) no `DynamicFrame` se o número de partições criado da origem é menor do que um limite mínimo para as partições (o padrão é 10).

def addIngestionTimeColumns

```
def addIngestionTimeColumns(
         df : DataFrame,
         timeGranularity : String = "") : dataFrame
```

Acrescenta colunas de tempo de ingestão, como `ingest_year`, `ingest_month`, `ingest_day`, `ingest_hour`, `ingest_minute`, para o `DataFrame` de entrada. Essa função é gerada automaticamente no script gerado pelo AWS Glue, quando você especifica uma tabela do catálogo de dados com o Amazon S3 como destino. Essa função atualiza automaticamente a partição com colunas de tempo de ingestão na tabela de saída. Isso permite que os dados de saída sejam particionados automaticamente no tempo de ingestão sem exigir colunas de tempo de ingestão explícitas nos dados de entrada.

- `dataFrame`: o `dataFrame` ao qual anexar as colunas de tempo de ingestão.
- `timeGranularity`: o detalhamento das colunas de tempo. Os valores válidos são “`day`”, “`hour`” e “`minute`”. Por exemplo, se “`hour`” é transmitido para a função, o `dataFrame` original terá as colunas de tempo “`ingest_year`”, “`ingest_month`”, “`ingest_day`” e “`ingest_hour`” anexadas.

Retorna o quadro de dados após anexar as colunas de detealhamento de tempo.

Exemplo:

```
glueContext.addIngestionTimeColumns(dataFrame, "hour")
```

def createDataFrameFromOptions

```
def createDataFrameFromOptions( connectionType : String,
                        connectionOptions : JsonOptions,
                        transformationContext : String = "",
```

```
                        format : String = null,
                        formatOptions : JsonOptions = JsonOptions.empty
                      ) : DataSource
```

Retorna um `DataFrame` criado com a conexão e o formato especificados. Use essa função apenas com fontes de transmissão do AWS Glue.

- `connectionType`: o tipo de conexão de transmissão. Os valores válidos são `kinesis` e `kafka`.
- `connectionOptions`: opções de conexão, a quais são diferentes para Kinesis e Kafka. Você pode encontrar a lista de todas as opções de conexão para cada origem dos dados de transmissão em Tipos e opções de conexão para ETL no AWS Glue para Spark. Observe as seguintes diferenças nas opções de conexão de transmissão:
  - As fontes de transmissão do Kinesis exigem `streamARN`, `startingPosition`, `inferSchema` e `classification`.
  - As fontes de transmissão do Kafka exigem `connectionName`, `topicName`, `startingOffsets`, `inferSchema` e `classification`.
- `transformationContext`: o contexto de transformação a ser usado (opcional).
- `format`: uma especificação de formato (opcional). É usado para uma conexão do Amazon S3 ou do AWS Glue com suporte para vários formatos. Para obter informações sobre os formatos compatíveis, consulte Opções de formato de dados para entradas e saídas no AWS Glue para Spark.
- `formatOptions`: as opções de formato para o formato especificado. Para obter informações sobre as opções de formato compatíveis, consulte Opções de formato de dados.

Exemplo para fonte de transmissão do Amazon Kinesis:

```
val data_frame_datasource0 =
glueContext.createDataFrameFromOptions(transformationContext = "datasource0",
 connectionType = "kinesis",
connectionOptions = JsonOptions("""{"streamName": "example_stream", "startingPosition":
 "TRIM_HORIZON", "inferSchema": "true", "classification": "json"}}""" ))
```

Exemplo para fonte de transmissão do 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)`

Aplica a `batch_function` transmitida para cada microlote lido a partir da fonte de transmissão.

- `frame`: o DataFrame que contém o microlote atual.
- `batch_function`: uma função que será aplicada para cada microlote.
- `options`: uma coleção de pares de chave-valor que contém informações sobre como processar microlotes. São necessárias as seguintes opções:
  - `windowSize`: a quantidade de tempo gasto no processamento de cada lote.
  - `checkpointLocation`: o local onde os pontos de verificação são armazenados para o trabalho de ETL de transmissão.
  - `batchMaxRetries`: o número máximo de novas tentativas deste lote em caso de falha. O valor padrão é 3. Essa opção só pode ser configurada para o Glue versão 2.0 e posterior.

Exemplo:

```
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
```

Cria um DataSink que grava em um local especificado de uma tabela definida no Data Catalog.

- `database`: o nome do banco de dados no Data Catalog.
- `tableName`: o nome da tabela no Data Catalog.
- `redshiftTmpDir`: o diretório de preparação temporário a ser usado com determinados coletores de dados. Definido como vazio por padrão.
- `transformationContext`: o contexto de transformação associado ao coletor a ser usado pelos marcadores de trabalho. Definido como vazio por padrão.
- `additionalOptions`: opções adicionais fornecidas ao AWS Glue.
- `catalogId`: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando nulo, o ID da conta do chamador padrão é usado.

Retorna o `DataSink`.

def getCatalogSource

```
def getCatalogSource( database : String,
```

```
                    tableName : String,
                    redshiftTmpDir : String = "",
                    transformationContext : String = ""
                    pushDownPredicate : String = " "
                    additionalOptions: JsonOptions = JsonOptions.empty,
                    catalogId: String = null
                  ) : DataSource
```

Cria um Característica do DataSource que lê dados em uma definição de tabela do Data Catalog.

- `database`: o nome do banco de dados no Data Catalog.
- `tableName`: o nome da tabela no Data Catalog.
- `redshiftTmpDir`: o diretório de preparação temporário a ser usado com determinados coletores de dados. Definido como vazio por padrão.
- `transformationContext`: o contexto de transformação associado ao coletor a ser usado pelos marcadores de trabalho. Definido como vazio por padrão.
- `pushDownPredicate`: filtra partições sem a necessidade de listar e ler todos os arquivos no seu conjunto de dados. Para ter mais informações, consulte Pré-filtragem usando a aplicação de predicados.
- `additionalOptions` – Uma coleção de pares nome-valor opcionais. As opções possíveis incluem as listadas em Tipos e opções de conexão para ETL no AWS Glue para Spark, exceto para `endpointUrl`, `streamName`, `bootstrap.servers`, `security.protocol`, `topicName`, `classification` e `delimiter`. Outra opção suportada é `catalogPartitionPredicate`:

  `catalogPartitionPredicate`: você pode transmitir uma expressão de catálogo para filtrar com base nas colunas de índice. Isso leva a filtragem para o lado do servidor. Para obter mais informações, consulte Índices de partição do AWS Glue. Observe que `push_down_predicate` e `catalogPartitionPredicate` usam sintaxes diferentes. O primeiro usa a sintaxe padrão do Spark SQL e o outro usa o analisador JSQL.
- `catalogId`: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando nulo, o ID da conta do chamador padrão é usado.

Retorna o `DataSource`.

Exemplo de fonte de transmissão

```
val data_frame_datasource0 = glueContext.getCatalogSource(
```

```
    database = "tempdb",
    tableName = "test-stream-input",
    redshiftTmpDir = "",
    transformationContext = "datasource0",
    additionalOptions = JsonOptions("""{
        "startingPosition": "TRIM_HORIZON", "inferSchema": "false"}""")
    ).getDataFrame()
```

def getJDBCSink

```
def getJDBCSink( catalogConnection : String,
                 options : JsonOptions,
                 redshiftTmpDir : String = "",
                 transformationContext : String = "",
                 catalogId: String = null
               ) : DataSink
```

Cria um DataSink que grava em um banco de dados JDBC especificado em um objeto `Connection` no Data Catalog. O objeto `Connection` tem informações para se conectar a um depósito JDBC, incluindo URL, nome de usuário, senha, VPC, sub-rede e grupos de segurança.

- `catalogConnection`: o nome da conexão no Data Catalog que contém o URL do JDBC onde gravar.
- `options`: uma string de pares de nome-valor JSON que fornecem as informações adicionais necessárias para gravar em um datastore do JDBC. Isso inclui:
  - dbtable (obrigatório) — O nome da tabela JDBC. Para armazenamentos de dados JDBC que oferecem suporte a esquemas dentro de um banco de dados, especifique `schema.table-name`. Se um esquema não for fornecido, o esquema "público" padrão será usado. O exemplo a seguir mostra um parâmetro de opções que aponta para um esquema chamado `test` e uma tabela chamada `test_table` no banco de dados `test_db`.

    ```
    options = JsonOptions("""{"dbtable": "test.test_table", "database": "test_db"}""")
    ```

  - database (obrigatório) — O nome do banco de dados do JDBC.
  - Todas as opções adicionais transmitidas diretamente para gravador do JDBC de SparkSQL. Para obter mais informações, consulte Fonte de dados Redshift para Spark.
- `redshiftTmpDir`: um diretório de preparação temporário a ser usado com determinados coletores de dados. Definido como vazio por padrão.

- `transformationContext`: o contexto de transformação associado ao coletor a ser usado pelos marcadores de trabalho. Definido como vazio por padrão.
- `catalogId`: o ID do catálogo (ID da conta) do Data Catalog que está sendo acessado. Quando nulo, o ID da conta do chamador padrão é usado.

Código de exemplo:

```
getJDBCSink(catalogConnection = "my-connection-name", options =
 JsonOptions("""{"dbtable": "my-jdbc-table", "database": "my-jdbc-db"}"""),
 redshiftTmpDir = "", transformationContext = "datasink4")
```

Retorna o `DataSink`.

def getSink

```
def getSink( connectionType : String,
             connectionOptions : JsonOptions,
             transformationContext : String = ""
           ) : DataSink
```

Cria um DataSink que grava dados em um destino como Amazon Simple Storage Service (Amazon S3), JDBC, Catálogo de Dados do AWS Glue ou um fluxo de dados do Amazon Kinesis ou do Apache Kafka.

- `connectionType` — O tipo da conexão. Consulte the section called “Parâmetros de conexão”.
- `connectionOptions` – uma string de pares de nome/valor JSON que fornecem as informações adicionais para estabelecer a conexão com o depósito de dados. Consulte the section called “Parâmetros de conexão”.
- `transformationContext`: o contexto de transformação associado ao coletor a ser usado pelos marcadores de trabalho. Definido como vazio por padrão.

Retorna o `DataSink`.

def getSinkWithFormat

```
def getSinkWithFormat( connectionType : String,
                       options : JsonOptions,
```

```
                        transformationContext : String = "",
                        format : String = null,
                        formatOptions : JsonOptions = JsonOptions.empty
                      ) : DataSink
```

Cria um DataSink que grava dados em um destino como Amazon S3, JDBC, Catálogo de Dados ou um fluxo de dados do Amazon Kinesis ou do Apache Kafka. Também define o formato dos dados que serão gravados no destino.

- `connectionType` — O tipo da conexão. Consulte the section called “Parâmetros de conexão”.
- `options` — Uma string de pares de nome/valor JSON que fornecem as informações adicionais para estabelecer a conexão com o depósito de dados. Consulte the section called “Parâmetros de conexão”.
- `transformationContext`: o contexto de transformação associado ao coletor a ser usado pelos marcadores de trabalho. Definido como vazio por padrão.
- `format` — O formato dos dados a serem gravados no destino.
- `formatOptions`: uma string de pares de nome-valor JSON que fornecem opções adicionais para a formatação de dados no destino. Consulte Opções de formato de dados.

Retorna o `DataSink`.

def getSource

```
def getSource( connectionType : String,
               connectionOptions : JsonOptions,
               transformationContext : String = ""
               pushDownPredicate
             ) : DataSource
```

Cria um Característica do DataSource que lê dados em uma fonte, como o Amazon S3, JDBC ou AWS Glue Data Catalog. Também oferece suporte a origens de dados de transmissão do Kafka e Kinesis.

- `connectionType`: o tipo da origem dos dados. Consulte the section called “Parâmetros de conexão”.
- `connectionOptions` – uma string de pares de nome/valor JSON que fornecem as informações adicionais para estabelecer uma conexão com a origem de dados. Para ter mais informações, consulte the section called “Parâmetros de conexão”.

Uma fonte de transmissão do Kinesis requer as seguintes opções de conexão: `streamARN`, `startingPosition`, `inferSchema` e `classification`.

Uma fonte de transmissão do Kafka requer as seguintes opções de conexão: `connectionName`, `topicName`, `startingOffsets`, `inferSchema` e `classification`.

- `transformationContext`: o contexto de transformação associado ao coletor a ser usado pelos marcadores de trabalho. Definido como vazio por padrão.
- `pushDownPredicate`: predicado em colunas de partição.

Retorna o `DataSource`.

Exemplo para fonte de transmissão do 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)
}
```

Exemplo para fonte de transmissão do 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)
 }
```

def getSourceWithFormat

```
def getSourceWithFormat( connectionType : String,
                         options : JsonOptions,
                         transformationContext : String = "",
                         format : String = null,
                         formatOptions : JsonOptions = JsonOptions.empty
                       ) : DataSource
```

Cria um Característica do DataSource que lê dados em uma fonte, como o Amazon S3, JDBC ou AWS Glue Data Catalog, e também define o formato dos dados armazenados na fonte.

- `connectionType`: o tipo da origem dos dados. Consulte the section called “Parâmetros de conexão”.
- `options`: uma string de pares de nome-valor JSON que fornecem as informações adicionais para estabelecer uma conexão com a origem dos dados. Consulte the section called “Parâmetros de conexão”.
- `transformationContext`: o contexto de transformação associado ao coletor a ser usado pelos marcadores de trabalho. Definido como vazio por padrão.
- `format`: o formato dos dados armazenados na fonte. Quando o `connectionType` é "s3", você também pode especificar `format`. Pode ser um de “avro”, “csv”, “grokLog”, “ion”, “json”, “xml”, “parquet” ou “orc”.
- `formatOptions`: uma string de pares de nome-valor JSON que fornecem opções adicionais para a análise dos dados na fonte. Consulte Opções de formato de dados.

Retorna o `DataSource`.

Exemplos

Crie um DynamicFrame a partir de uma origem de dados que seja um arquivo com valores separados por vírgula (CSV) no 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()
```

Crie um DynamicFrame a partir de uma origem de dados que seja um PostgreSQL usando uma conexão 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()
```

Crie um DynamicFrame a partir de uma origem de dados que seja um MySQL usando uma conexão 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
```

Obtém o objeto `SparkSession` associado a este GlueContext. Use este objeto SparkSession para registrar tabelas e UDFs a serem usados com `DataFrame` criado dos DynamicFrames.

Retorna o SparkSession.

def startTransaction

```
def startTransaction(readOnly: Boolean):String
```

Iniciar uma nova transação. Chama internamente a API startTransaction do Lake Formation.

- `readOnly`: (booleano) indica se esta transação deve ser somente de leitura ou de leitura e gravação. As gravações feitas usando um ID de transação somente de leitura serão rejeitadas. As transações somente de leitura não precisam ser confirmadas.

Retorna o ID da transação.

def commitTransaction

```
def commitTransaction(transactionId: String, waitForCommit: Boolean): Boolean
```

Tenta confirmar a transação especificada. `commitTransaction` pode retornar antes que a transação tenha terminado de confirmar. Chama internamente a API commitTransaction do Lake Formation.

- `transactionId`: (string) a transação a ser confirmada.
- `waitForCommit`: (booleano) Determina se `commitTransaction` retorna imediatamente. O valor padrão é true. Se for falso, `commitTransaction` sonda e aguarda até que a transação seja confirmada. A quantidade de tempo de espera é restrita a 1 minuto usando recuo exponencial com um máximo de 6 tentativas.

Retorna um booleano para indicar se a confirmação foi feita ou não.

def cancelTransaction

```
def cancelTransaction(transactionId: String): Unit
```

Tenta cancelar a transação especificada. Chama internamente a API cancelTransaction do Lake Formation.

- `transactionId`: (string) a transação a ser cancelada.

Retorna uma exceção `TransactionCommittedException` se a transação tiver sido confirmada anteriormente.

def this

```
def this( sc : SparkContext,
          minPartitions : Int,
          targetPartitions : Int )
```

Cria um objeto `GlueContext` usando o `SparkContext` especificado, um mínimo de partições e partições de destino.

- `sc` — A ferramenta `SparkContext`.
- `minPartitions` – O número mínimo de partições.
- `targetPartitions` — O número destino de partições.

Retorna o `GlueContext`.

def this

```
def this( sc : SparkContext )
```

Cria um objeto `GlueContext` com o `SparkContext` fornecido. Define o mínimo de partições como 10 e as partições de destino como 20.

- `sc` — A ferramenta `SparkContext`.

Retorna o `GlueContext`.

def this

```
def this( sparkContext : JavaSparkContext )
```

Cria um objeto `GlueContext` com o `JavaSparkContext` fornecido. Define o mínimo de partições como 10 e as partições de destino como 20.

- `sparkContext` — A ferramenta `JavaSparkContext`.

Retorna o `GlueContext`.

MappingSpec

Pacote: com.amazonaws.services.glue

Classe do caso MappingSpec

```
case class MappingSpec( sourcePath: SchemaPath,
                        sourceType: DataType,
                        targetPath: SchemaPath,
                        targetType: DataTyp
                       ) 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` – O `SchemaPath` do campo de origem.
- `sourceType` – O `DataType` do campo de origem.
- `targetPath` – O `SchemaPath` do campo de destino.
- `targetType` – O `DataType` do campo de destino.

Um `MappingSpec` especifica um mapeamento de um caminho de origem e um tipo de dados de origem para um caminho de destino e um tipo de dados de destino. O valor no caminho de origem no quadro de origem aparece no quadro de destino no caminho de destino. O tipo de dados de origem é convertido no tipo de dados de destino.

Ele se estende a partir de `Product4` para que você possa lidar com qualquer `Product4` em sua interface do `applyMapping`.

Objeto MappingSpec

```
object MappingSpec
```

O objeto `MappingSpec` tem os seguintes membros:

Val orderingByTarget

```
val orderingByTarget: Ordering[MappingSpec]
```

Def apply

```
def apply( sourcePath : String,
           sourceType : DataType,
           targetPath : String,
           targetType : DataType
         ) : MappingSpec
```

Cria um `MappingSpec`.

- `sourcePath` – Uma representação de string do caminho de origem.
- `sourceType` — O `DataType` de origem.
- `targetPath` – Uma representação de string do caminho de destino.
- `targetType` - O `DataType` de destino.

Retorna um `MappingSpec`.

Def apply

```
def apply( sourcePath : String,
           sourceTypeString : String,
           targetPath : String,
           targetTypeString : String
         ) : MappingSpec
```

Cria um `MappingSpec`.

- `sourcePath` – Uma representação de string do caminho de origem.
- `sourceType` – Uma representação de string do tipo de dados de origem.
- `targetPath` – Uma representação de string do caminho de destino.
- `targetType` – Uma representação de string do tipo de dados de destino.

Retorna um MappingSpec.

Def apply

```
def apply( product : Product4[String, String, String, String] ) : MappingSpec
```

Cria um `MappingSpec`.

- `product` — O `Product4` do caminho de origem, do tipo de dados de origem, do caminho de destino e do tipo de dados de destino.

Retorna um `MappingSpec`.

APIs ResolveSpec no Scala do AWS Glue

Tópicos

- Objeto ResolveSpec
- Classe do caso ResolveSpec

Pacote: com.amazonaws.services.glue

Objeto ResolveSpec

ResolveSpec

```
object ResolveSpec
```

Def

```
def apply( path : String,
           action : String
         ) : ResolveSpec
```

Cria um `ResolveSpec`.

- `path` – Uma representação da string do campo de escolha que precisa ser resolvido.
- `action`: uma ação de resolução. A ação pode ser uma das seguintes: `Project`, `KeepAsStruct` ou `Cast`.

Retorna o `ResolveSpec`.

Def

```
def apply( product : Product2[String, String] ) : ResolveSpec
```

Cria um `ResolveSpec`.

- `product` — `Product2` de: caminho de origem, ação de resolução.

Retorna o `ResolveSpec`.

Classe do caso ResolveSpec

```
case class ResolveSpec extends Product2[String, String]  (
           path : SchemaPath,
           action : String )
```

Cria um `ResolveSpec`.

- `path` – O `SchemaPath` do campo de escolha que precisa ser resolvido.
- `action`: uma ação de resolução. A ação pode ser uma das seguintes: `Project`, `KeepAsStruct` ou `Cast`.

Métodos def ResolveSpec

```
def _1 : String
```

```
def _2 : String
```

APIs ArrayNode em Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso ArrayNode

ArrayNode

```
case class ArrayNode extends DynamicNode  (
           value : ArrayBuffer[DynamicNode] )
```

Métodos def de ArrayNode

```
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 )
```

APIs BinaryNode em Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso BinaryNode

BinaryNode

```
case class BinaryNode extends ScalarNode(value, TypeCode.BINARY)  (
           value : Array[Byte] )
```

Campos val BinaryNode

- `ordering`

Métodos def BinaryNode

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

APIs BooleanNode em Scala no AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso BooleanNode

BooleanNode

```
case class BooleanNode extends ScalarNode(value, TypeCode.BOOLEAN)  (
           value : Boolean )
```

Campos val BooleanNode

- `ordering`

Métodos def BooleanNode

```
def equals( other : Any )
```

APIs de ByteNode de Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso ByteNode

ByteNode

```
case class ByteNode extends ScalarNode(value, TypeCode.BYTE)  (
```

```
            value : Byte )
```

Campos val ByteNode

- `ordering`

Métodos def ByteNode

```
def equals( other : Any )
```

APIs de DateNode de Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso DateNode

DateNode

```
case class DateNode extends ScalarNode(value, TypeCode.DATE)  (
            value : Date )
```

Campos val DateNode

- `ordering`

Métodos def DateNode

```
def equals( other : Any )
```

```
def this( value : Int )
```

APIs DecimalNode em Scala no AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso DecimalNode

DecimalNode

```
case class DecimalNode extends ScalarNode(value, TypeCode.DECIMAL)  (
```

```
            value : BigDecimal )
```

Campos val DecimalNode

- `ordering`

Métodos def DecimalNode

```
def equals( other : Any )
```

```
def this( value : Decimal )
```

APIs DoubleNode em Scala no AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso DoubleNode

DoubleNode

```
case class DoubleNode extends ScalarNode(value, TypeCode.DOUBLE)  (
            value : Double )
```

Campos val DoubleNode

- `ordering`

Métodos def DoubleNode

```
def equals( other : Any )
```

APIs DynamicNode em Scala no AWS Glue

Tópicos

- Classe DynamicNode
- Objeto DynamicNode

Pacote: com.amazonaws.services.glue.types

Classe DynamicNode

DynamicNode

```
class DynamicNode extends Serializable with Cloneable
```

Métodos def DynamicNode

```
def getValue : Any
```

Obter um valor simples e vinculado ao registro atual:

```
def nodeType : TypeCode
```

```
def toJson : String
```

Método para depuração:

```
def toRow( schema : Schema,
           options : Map[String, ResolveOption]
         ) : Row
```

```
def typeName : String
```

Objeto DynamicNode

DynamicNode

```
object DynamicNode
```

Métodos def DynamicNode

```
def quote( field : String,
           useQuotes : Boolean
         ) : String
```

```
def quote( node : DynamicNode,
           useQuotes : Boolean
         ) : String
```

Classe EvaluateDataQuality

O AWS Glue Data Quality está em uma versão pré-lançamento do AWS Glue e está sujeito a alterações.

Pacote: com.amazonaws.services.glue.dq

```
object EvaluateDataQuality
```

Def apply

```
def apply(frame: DynamicFrame,
            ruleset: String,
            publishingOptions: JsonOptions = JsonOptions.empty): DynamicFrame
```

Avalia um conjunto de regras de qualidade de dados em relação a um `DynamicFrame` e retorna um novo `DynamicFrame` com os resultados da avaliação. Para saber mais sobre o AWS Glue Data Quality, consulte AWS Glue Data Quality.

- `frame`: o `DynamicFrame` cuja qualidade de dados você deseja avaliar.
- `ruleset`: um conjunto de regras em Data Quality Definition Language (DQDL) no formato de string. Para saber mais sobre DQDL, consulte o guia de Referência de Data Quality Definition Language (DQDL).
- `publishingOptions`: um dicionário que especifica as seguintes opções para publicar resultados e métricas de avaliação:
  - `dataQualityEvaluationContext`: uma string que especifica o namespace com o qual o AWS Glue deve publicar as métricas e os resultados de qualidade dos dados do Amazon CloudWatch. As métricas agregadas aparecem no CloudWatch, enquanto os resultados completos aparecem na interface do AWS Glue Studio.
    - Obrigatório: Não
    - Valor padrão: `default_context`
  - `enableDataQualityCloudWatchMetrics`: especifica se os resultados da avaliação de qualidade dos dados devem ser publicados no CloudWatch. Você especifica um namespace para as métricas usando a opção `dataQualityEvaluationContext`.
    - Obrigatório: Não

  - Valor padrão: False
- `enableDataQualityResultsPublishing`: especifica se os resultados de qualidade dos dados devem estar visíveis na guia Data Quality (Qualidade de dados) na interface do AWS Glue Studio.
  - Obrigatório: Não
  - Valor padrão: true
- `resultsS3Prefix`: especifica o local no Amazon S3 em que o AWS Glue pode gravar os resultados da avaliação de qualidade dos dados.
  - Obrigatório: Não
  - Valor padrão: "" (string vazia)

Exemplo

O código de exemplo a seguir demonstra como avaliar a qualidade dos dados de um `DynamicFrame` antes de realizar uma transformação `SelectFields`. O script verifica se todas as regras de qualidade de dados são aprovadas antes de tentar a transformação.

```
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",
 tableName="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()
  }
}
```

APIs FloatNode em Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso FloatNode

FloatNode

```
case class FloatNode extends ScalarNode(value, TypeCode.FLOAT)  (
           value : Float )
```

Campos val FloatNode

- `ordering`

Métodos def FloatNode

```
def equals( other : Any )
```

Classe FillMissingValues

Pacote: 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
```

Preenche os valores ausentes de um quadro dinâmico em uma coluna especificada e retorna um novo quadro com estimativas em uma nova coluna. Para linhas sem valores ausentes, o valor da coluna especificada é duplicado para a nova coluna.

- `frame`: o DynamicFrame no qual preencher valores ausentes. Obrigatório.
- `missingValuesColumn`: a coluna que contém valores ausentes (valores `null` e strings vazias). Obrigatório.
- `outputColumn`: o nome da nova coluna que conterá valores estimados para todas as linhas cujo valor estava ausente. Opcional. O padrão é o valor da `missingValuesColumn` seguida do sufixo `"_filled"`.
- `transformationContext`: uma string única que é usada para identificar informações de estado (opcional).
- `callSite`: usado para fornecer informações de contexto para o relatório de erros (opcional).
- `stageThreshold`: o número máximo de erros que podem ocorrer na transformação antes que ela falhe (opcional, o padrão é zero).
- `totalThreshold`: o número máximo de erros que podem ocorrer antes que o processamento falhe (opcional, o padrão é zero).

Retorna um novo quadro dinâmico com uma coluna adicional que contém estimativas para linhas com valores ausentes e o valor presente para outras linhas.

Classe FindMatches

Pacote: 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
```

Localize correspondências em um quadro de entrada e retorne um novo quadro com uma nova coluna contendo um ID exclusivo por grupo de correspondência.

- `frame`: o DynamicFrame no qual encontrar correspondências. Obrigatório.
- `transformId`: o ID exclusivo associado à transformação FindMatches a ser aplicado em registros no quadro de entrada. Obrigatório.
- `transformationContext`: o identificador para esse `DynamicFrame`. O `transformationContext` é usado como uma chave para o estado do marcador de trabalho que é mantido nas execuções. Opcional.
- `callSite`: usado para fornecer informações de contexto para o relatório de erros. Esses valores são definidos automaticamente quando chamados do Python. Opcional.
- `stageThreshold`: o número máximo de registros de erros permitidos a partir da computação desse `DynamicFrame` antes de lançar uma exceção, excluindo os registros presentes no `DynamicFrame` anterior. Opcional. O padrão é zero.
- `totalThreshold`: o número máximo de registros de erros totais antes que uma exceção seja lançada, incluindo os de quadros anteriores. Opcional. O padrão é zero.
- `enforcedMatches`: o quadro para correspondências impostas. Opcional. O padrão é `null`.
- `computeMatchConfidenceScores`: um valor booleano que indica se é preciso calcular uma pontuação de confiança para cada grupo de registros correspondentes. Opcional. O padrão é falso.

Retorna um novo quadro dinâmico com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

Classe FindIncrementalMatches

Pacote: 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
```

Encontre correspondências entre os quadros existentes e incrementais e retorne um novo quadro com uma coluna contendo um ID exclusivo por grupo de correspondência.

- `existingframe`: um quadro existente ao qual foi atribuído um ID correspondente para cada grupo. Obrigatório.
- `incrementalframe`: um quadro incremental usado para encontrar correspondências no quadro existente. Obrigatório.
- `transformId`: o ID exclusivo associado à transformação FindIncrementalMatches a ser aplicado em registros no quadro de entrada. Obrigatório.
- `transformationContext`: o identificador para esse `DynamicFrame`. O `transformationContext` é usado como uma chave para o estado do marcador de trabalho que é mantido nas execuções. Opcional.
- `callSite`: usado para fornecer informações de contexto para o relatório de erros. Esses valores são definidos automaticamente quando chamados do Python. Opcional.
- `stageThreshold`: o número máximo de registros de erros permitidos a partir da computação desse `DynamicFrame` antes de lançar uma exceção, excluindo os registros presentes no `DynamicFrame` anterior. Opcional. O padrão é zero.

- `totalThreshold`: o número máximo de registros de erros totais antes que uma exceção seja lançada, incluindo os de quadros anteriores. Opcional. O padrão é zero.
- `enforcedMatches`: o quadro para correspondências impostas. Opcional. O padrão é `null`.
- `computeMatchConfidenceScores`: um valor booleano que indica se é preciso calcular uma pontuação de confiança para cada grupo de registros correspondentes. Opcional. O padrão é falso.

Retorna um novo quadro dinâmico com um identificador exclusivo atribuído a cada grupo de registros correspondentes.

APIs de IntegerNode de Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso IntegerNode

IntegerNode

```
case class IntegerNode extends ScalarNode(value, TypeCode.INT)  (
           value : Int )
```

Campos val IntegerNode

- `ordering`

Métodos def IntegerNode

```
def equals( other : Any )
```

APIs LongNode em Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso LongNode

LongNode

```
case class LongNode extends ScalarNode(value, TypeCode.LONG)  (
           value : Long )
```

Campos val LongNode

- `ordering`

Métodos def LongNode

```
def equals( other : Any )
```

APIs MapLikeNode no Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe MapLikeNode

MapLikeNode

```
class MapLikeNode extends DynamicNode  (
           value : mutable.Map[String, DynamicNode] )
```

Métodos def MapLikeNode

```
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
```

Exemplo: Dado esse JSON:

```
{"foo": "bar"}
```

Se `useQuotes == true`, `toJson` gera `{"foo": "bar"}`. Se `useQuotes == false`, `toJson` gera `{foo: bar}` @return.

APIs MapNode no Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso MapNode

MapNode

```
case class MapNode extends MapLikeNode(value)  (
           value : mutable.Map[String, DynamicNode] )
```

Métodos def MapNode

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

```
def nodeType
```

```
def this
```

APIs NullNode no Scala do AWS Glue

Tópicos

- Classe NullNode
- Objeto do caso NullNode

Pacote: com.amazonaws.services.glue.types

Classe NullNode

NullNode

```
class NullNode
```

Objeto do caso NullNode

NullNode

```
case object NullNode extends NullNode
```

APIs ObjectNode no Scala do AWS Glue

Tópicos

- Objeto ObjectNode
- Classe do caso ObjectNode

Pacote: com.amazonaws.services.glue.types

Objeto ObjectNode

ObjectNode

```
object ObjectNode
```

Métodos def ObjectNode

```
def apply( frameKeys : Set[String],
           v1 : mutable.Map[String, DynamicNode],
           v2 : mutable.Map[String, DynamicNode],
```

```
            resolveWith : String
          ) : ObjectNode
```

Classe do caso ObjectNode

ObjectNode

```
case class ObjectNode extends MapLikeNode(value)  (
            val value : mutable.Map[String, DynamicNode] )
```

Métodos def ObjectNode

```
def clone
```

```
def equals( other : Any )
```

```
def hashCode : Int
```

```
def nodeType
```

```
def this
```

APIs ScalarNode no Scala do AWS Glue

Tópicos

- Classe ScalarNode
- Objeto ScalarNode

Pacote: com.amazonaws.services.glue.types

Classe ScalarNode

ScalarNode

```
class ScalarNode extends DynamicNode  (
            value : Any,
            scalarType : TypeCode )
```

Métodos def ScalarNode

```
def compare( other : Any,
             operator : String
           ) : Boolean
```

```
def getValue
```

```
def hashCode : Int
```

```
def nodeType
```

```
def toJson
```

Objeto ScalarNode

ScalarNode

```
object ScalarNode
```

Métodos def ScalarNode

```
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
```

APIs ShortNode no Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso ShortNode

ShortNode

```
case class ShortNode extends ScalarNode(value, TypeCode.SHORT)  (
           value : Short )
```

Campos val ShortNode

- `ordering`

Métodos def ShortNode

```
def equals( other : Any )
```

APIs StringNode no Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso StringNode

StringNode

```
case class StringNode extends ScalarNode(value, TypeCode.STRING)  (
           value : String )
```

Campos val StringNode

- `ordering`

Métodos def StringNode

```
def equals( other : Any )
```

```
def this( value : UTF8String )
```

APIs TimestampNode no Scala do AWS Glue

Pacote: com.amazonaws.services.glue.types

Classe do caso TimestampNode

TimestampNode

```
case class TimestampNode extends ScalarNode(value, TypeCode.TIMESTAMP)  (
           value : Timestamp )
```

Campos val TimestampNode

- `ordering`

Métodos def TimestampNode

```
def equals( other : Any )
```

```
def this( value : Long )
```

APIs GlueArgParser em Scala no AWS Glue

Pacote: com.amazonaws.services.glue.util

Objeto GlueArgParser

GlueArgParser

```
object GlueArgParser
```

Isso é estritamente consistente com a versão do Python de `utils.getResolvedOptions` no pacote `AWSGlueDataplanePython`.

Métodos def GlueArgParser

```
def getResolvedOptions( args : Array[String],
                        options : Array[String]
                      ) : Map[String, String]
```

```
def initParser( userOptionsSet : mutable.Set[String] ) : ArgumentParser
```

Example Recuperar argumentos passados para um trabalho

Para recuperar os argumentos do trabalho, você pode usar o método `getResolvedOptions`. Considere o exemplo a seguir, que recupera um argumento de trabalho denominado `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)
```

APIs de trabalho em Scala do AWS Glue

Pacote: com.amazonaws.services.glue.util

Objeto Job

Trabalho

```
object Job
```

Métodos def Job

```
def commit
```

```
def init( jobName : String,
          glueContext : GlueContext,
          args : java.util.Map[String, String] = Map[String, String]().asJava
        ) : this.type
```

```
def init( jobName : String,
          glueContext : GlueContext,
          endpoint : String,
          args : java.util.Map[String, String]
        ) : this.type
```

```
def isInitialized
```

```
def reset
```

```
def runId
```

Recursos e otimizações para programação de scripts de ETL do AWS Glue para Spark

As seções a seguir descrevem técnicas e valores que se aplicam geralmente à programação de ETL (extração, transformação e carregamento) do AWS Glue para Spark em qualquer linguagem.

Tópicos

- Tipos e opções de conexão para ETL no AWS Glue para Spark
- Opções de formato de dados para entradas e saídas no AWS Glue para Spark
- Compatibilidade do AWS Glue Data Catalog com trabalhos do Spark SQL
- Usar marcadores de trabalho
- Usar detecção de dados confidenciais fora do AWS Glue Studio
- API Visual Job do AWS Glue

Tipos e opções de conexão para ETL no AWS Glue para Spark

No AWS Glue Glue, vários métodos e transformações do PySpark e do Scala especificam o tipo de conexão usando um parâmetro `connectionType`. Eles especificam opções de conexão usando um parâmetro `connectionOptions` ou `options`.

O parâmetro `connectionType` pode usar os valores mostrados na tabela a seguir. Os valores do parâmetro `connectionOptions` (ou `options`) associados para cada tipo estão documentados nas seções a seguir. Salvo indicação em contrário, os parâmetros se aplicam quando a conexão é usada como fonte ou coletor.

Para obter um código de exemplo que demonstra a configuração e o uso de opções de conexão, consulte a página inicial de cada tipo de conexão.

`connectionType`	Conecta-se a
dynamodb	Banco de dados do Amazon DynamoDB
kinesis	Amazon Kinesis Data Streams

`connectionType`	Conecta-se a
s3	Amazon S3
documentdb	banco de dados do Amazon DocumentDB (compatível com MongoDB)
opensearch	Amazon OpenSearch Service.
redshift	Banco de dados do Amazon Redshift
kafka	Kafka ou Amazon Managed Streaming for Apache Kafka
azurecosmos	Azure Cosmos para NoSQL.
azuresql	Azure SQL.
bigquery	Google BigQuery.
mongodb	Banco de dados MongoDB, incluindo MongoDB Atlas.
sqlserver	Banco de dados do Microsoft SQL Server (consulte Conexões JDBC)
mysql	Banco de dados MySQL (consulte Conexões JDBC)
oracle	Banco de dados Oracle (consulte Conexões JDBC)
postgresql	Banco de dados PostgreSQL (consulte Conexões JDBC)
saphana	SAP HANA.
snowflake	Data lake do Snowflake
teradata	Teradata Vantage.
vertica	Vertica.
custom.*	Armazenamentos de dados do Spark, Athena ou JDBC (consulte Valores de connectionType personalizados e AWS Marketplace
marketplace.*	Armazenamentos de dados do Spark, Athena ou JDBC (consulte Valores de connectionType personalizados e AWS Marketplace)

Conexões do DynamoDB

É possível usar o AWS Glue para Spark para ler e gravar em tabelas no DynamoDB no AWS Glue. Conecte-se ao DynamoDB usando as permissões do IAM anexadas ao seu trabalho do AWS Glue. O AWS Glueoferece suporte à gravação de dados em uma tabela do DynamoDB em uma conta da AWS diferente. Para ter mais informações, consulte the section called “Acesso a tabelas do DynamoDB entre contas e entre regiões”.

Além do conector de ETL para AWS Glue DynamoDB, é possível ler do DynamoDB usando o conector de exportação para DynamoDB. Esse conector invoca uma solicitação `ExportTableToPointInTime` do DynamoDB e a armazena no formato DynamoDB JSON em um local do Amazon S3 fornecido por você. Em seguida, o AWS Glue cria um objeto DynamicFrame ao ler os dados do local de exportação do Amazon S3.

O gravador do DynamoDB é compatível com o AWS Glue versão 1.0 ou posterior. O conector de exportação do AWS Glue DynamoDB é compatível com o AWS Glue versão 2.0 ou posterior.

Para obter mais informações sobre o DynamoDB, consulte a documentação do Amazon DynamoDB.

> **Note**
>
> O leitor de ETL do DynamoDB não é compatível com filtros ou predicados de aplicação.

Configurar conexões do DynamoDB

Para se conectar ao DynamoDB via AWS Glue, conceda ao perfil do IAM associado ao seu trabalho do AWS Glue permissão para interagir com o DynamoDB. Para obter mais informações sobre as permissões necessárias para ler ou gravar no DynamoDB, consulte Ações, recursos e chaves de condição para DynamoDB na documentação do IAM.

Nas seguintes situações, configurações adicionais podem ser necessárias:

- Ao usar o conector de exportação do DynamoDB, você precisará configurar o IAM para que seu trabalho possa solicitar exportações de tabelas do DynamoDB. Além disso, você precisará identificar um bucket do Amazon S3 para a exportação e fornecer as permissões apropriadas no IAM para que o DynamoDB grave nele e para que seu trabalho do AWS Glue possa ler dele. Para obter mais informações, consulte Solicitar uma exportação de tabela no DynamoDB.
- Se sua tarefa do AWS Glue tiver requisitos específicos de conectividade da Amazon VPC, use o tipo de conexão `NETWORK` do AWS Glue para fornecer opções de rede. Como o acesso

ao DynamoDB é autorizado pelo IAM, não há necessidade de um tipo de conexão AWS Glue DynamoDB.

Ler e gravar no DynamoDB

Os exemplos de código a seguir mostram como fazer a leitura (via conector ETL) e gravação de tabelas do DynamoDB. Eles demonstram a leitura de uma tabela e a gravação em uma outra tabela.

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()
  }

}
```

Usar o conector de exportação do DynamoDB

O conector de exportação apresenta um melhor desempenho do que o conector de ETL quando o tamanho da tabela do DynamoDB é superior a 80 GB. Além disso, como a solicitação de exportação é conduzida fora dos processos do Spark em um trabalho do AWS Glue, você pode habilitar a autoescalabilidade de trabalhos do AWS Glue para poupar o uso de DPU durante a solicitação de exportação. Com o conector de exportação, você também não precisa configurar o número de divisões para o paralelismo do executor do Spark ou o percentual de leitura de throughput do DynamoDB.

> **Note**
>
> O DynamoDB tem requisitos específicos para invocar as solicitações `ExportTableToPointInTime`. Para mais informações, consulte Solicitação de uma exportação de tabela no DynamoDB. Por exemplo, para usar esse conector, é necessário que a Point-in-Time-Recovery (PITR – Recuperação em um ponto anterior no tempo) esteja habilitada na tabela. O conector do DynamoDB também é compatível com criptografia do AWS KMS para exportações do DynamoDB para o Amazon S3. O fornecimento de sua configuração de segurança na configuração do trabalho do AWS Glue habilita a criptografia do AWS KMS para uma exportação do DynamoDB. A chave do KMS precisa estar na mesma região do bucket do Amazon S3.
> Observe que há cobranças adicionais para exportação do DynamoDB e custos de armazenamento do Amazon S3. Os dados exportados no Amazon S3 persistem após a conclusão de uma execução de trabalho, de modo que você possa reutilizá-los sem exportações adicionais do DynamoDB. Um requisito para o uso desse conector é que a recuperação a um ponto anterior no tempo (PITR) esteja habilitada para a tabela.
> O conector de ETL e o conector de exportação do DynamoDB não são compatíveis com a aplicação de filtros ou predicados de aplicação na fonte do DynamoDB.

Os exemplos de código a seguir mostram como fazer a leitura (usando o conector de exportação) e imprimir o número de partições.

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()
  }

}
```

Estes exemplos mostram como fazer a leitura (usando o conector de exportação) e imprimir o número de partições de uma tabela do AWS Glue Data Catalog que tenha uma classificação dynamodb:

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())
)
```

Simplificar o uso do JSON de exportação do DynamoDB

As exportações do DynamoDB feitas com o conector de exportação para DynamoDB do AWS Glue resultam em arquivos JSON de estruturas aninhadas específicas. Para mais informações, consulte Objetos de dados. O AWS Glue fornece uma transformação DynamicFrame, que pode desaninhar essas estruturas em uma forma mais fácil de usar para aplicações downstream.

A transformação pode ser invocada de duas formas. É possível definir a opção de conexão `"dynamodb.simplifyDDBJson"` com o valor `"true"` ao chamar um método para ler do

DynamoDB. Você também pode chamar a transformação como um método disponível de forma independente na biblioteca do AWS Glue.

Considere o seguinte esquema gerado por uma exportação do 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
```

A transformação `simplifyDDBJson` simplificará isso para:

```
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` só está disponível no AWS Glue 3.0 e versões posteriores. A transformação `unnestDDBJson` também está disponível para simplificar o JSON de exportação do DynamoDB. Incentivamos os usuários a fazer a transição de `unnestDDBJson` para `simplifyDDBJson`.

Configurar o paralelismo nas operações do DynamoDB

Para aumentar a performance, é possível ajustar alguns parâmetros disponíveis para o conector do DynamoDB. Seu objetivo ao ajustar os parâmetros de paralelismo é maximizar o uso dos operadores do AWS Glue provisionados. Assim, se você precisar de mais performance, recomendamos aumentar a escala do seu trabalho horizontalmente aumentando o número de DPUs.

Você pode alterar o paralelismo em uma operação de leitura do DynamoDB usando o parâmetro `dynamodb.splits` ao utilizar o conector ETL. Ao ler com o conector de exportação, não é necessário configurar o número de divisões para o paralelismo do executor do Spark. Você pode alterar o paralelismo em uma operação de gravação do DynamoDB com `dynamodb.output.numParallelTasks`.

Ler com o conector ETL do DynamoDB

Recomendamos calcular `dynamodb.splits` com base no número máximo de trabalhadores definido em sua configuração de trabalho e no cálculo `numSlots` a seguir. Em caso de escalonamento automático, o número real de operadores disponíveis pode cair abaixo desse limite. Para obter mais informações sobre como definir o número máximo de trabalhadores, consulte Número de trabalhadores (`NumberOfWorkers`) em the section called “Configurar propriedades de trabalho para trabalhos do Spark”.

- `numExecutors = NumberOfWorkers - 1`

  Para contextualizar, um executor é reservado para o driver do Spark, outros executores são usados para processar dados.

- `numSlotsPerExecutor =`

  AWS Glue 3.0 and later versions

  - 4 se `WorkerType` for `G.1X`
  - 8 se `WorkerType` for `G.2X`
  - 16 se `WorkerType` for `G.4X`
  - 32 se `WorkerType` for `G.8X`

  AWS Glue 2.0 and legacy versions

  - 8 se `WorkerType` for `G.1X`
  - 16 se `WorkerType` for `G.2X`
- `numSlots = numSlotsPerExecutor * numExecutors`

Recomendamos definir `dynamodb.splits` como o número de slots disponíveis, `numSlots`.

Gravar no DynamoDB

O parâmetro `dynamodb.output.numParallelTasks` é usado para determinar a WCU por tarefa do Spark, usando o seguinte cálculo:

```
permittedWcuPerTask = ( TableWCU * dynamodb.throughput.write.percent ) / 
dynamodb.output.numParallelTasks
```

O gravador do DynamoDB funcionará melhor se a configuração representar com precisão o número de tarefas do Spark gravadas no DynamoDB. Em alguns casos, talvez seja necessário substituir o cálculo padrão para aumentar o desempenho de gravação. Se você não especificar esse parâmetro, as WCU permitidas por tarefa do Spark serão calculadas automaticamente pela seguinte fórmula:

-
  - `numPartitions = dynamicframe.getNumPartitions()`
  - `numSlots` (conforme definido anteriormente nesta seção)
  - `numParallelTasks = min(numPartitions, numSlots)`
- Exemplo 1. DPU=10, WorkerType=Standard. DynamicFrame de entrada tem 100 partições RDD.
  - `numPartitions = 100`
  - `numExecutors = (10 - 1) * 2 - 1 = 17`
  - `numSlots = 4 * 17 = 68`
  - `numParallelTasks = min(100, 68) = 68`
- Exemplo 2. DPU=10, WorkerType=Standard. DynamicFrame de entrada tem 20 partições RDD.

- `numPartitions = 20`
- `numExecutors = (10 - 1) * 2 - 1 = 17`
- `numSlots = 4 * 17 = 68`
- `numParallelTasks = min(20, 68) = 20`

> **Note**
>
> Trabalhos em versões antigas do AWS Glue e aqueles que usam operadores Standard exigem métodos diferentes para calcular o número de slots. Se você precisar ajustar a performance desses trabalhos, recomendamos fazer a transição para as versões compatíveis do AWS Glue.

Referência de opções de conexão do DynamoDB

Designa uma conexão com o Amazon DynamoDB.

As opções de conexão diferem para uma conexão da fonte e uma conexão do coletor.

“connectionType”: “dynamodb” com o conector de ETL como fonte

Ao usar o conector de ETL para DynamoDB do AWS Glue, use as seguintes opções de conexão com `"connectionType": "dynamodb"` como fonte:

- `"dynamodb.input.tableName"`: (obrigatório) a tabela do DynamoDB da qual fazer a leitura.
- `"dynamodb.throughput.read.percent"`: (opcional) a porcentagem de unidades de capacidade de leitura (RCU) para usar. O padrão é definido como "0,5". Os valores aceitáveis são de "0,1" a "1,5", inclusive.
  - `0.5` representa a taxa de leitura padrão, o que significa que o AWS Glue tentará consumir metade da capacidade de leitura da tabela. Se você aumentar o valor acima de `0.5`, o AWS Glue aumentará a taxa de solicitação. Diminuir o valor abaixo de `0.5` reduz a taxa de solicitação de leitura. (A taxa de leitura real poderá variar, dependendo de fatores como se há uma distribuição de chaves uniformes na tabela do DynamoDB.)
  - Quando a tabela do DynamoDB está no modo sob demanda, o AWS Glue lida com a capacidade de leitura da tabela como 40.000. Para exportar uma tabela grande, recomendamos alternar sua tabela do DynamoDB para o modo sob demanda.

- `"dynamodb.splits"`: (opcional) define em quantas divisões essa tabela do DynamoDB deve ser particionada ao fazer a leitura. O padrão é definido como "1". Os valores aceitáveis são de "1" a "1,000,000", inclusive.

  1 indica que não há paralelismo. É altamente recomendável que você especifique um valor maior para uma performance melhor usando a fórmula abaixo. Para obter mais informações sobre como definir adequadamente um valor, consulte the section called “Paralelismo dinâmico”.
- `"dynamodb.sts.roleArn"`: (opcional) o ARN da função do IAM a ser assumida para acesso entre contas. Esse parâmetro está disponível no AWS Glue 1.0 ou posterior.
- `"dynamodb.sts.roleSessionName"`: (opcional) nome da sessão STS. O padrão é definido como “glue-dynamodb-read-sts-session”. Esse parâmetro está disponível no AWS Glue 1.0 ou posterior.

“connectionType”: “dynamodb” com o conector de exportação para DynamoDB do AWS Glue como fonte

Use as seguintes opções de conexão com "connectionType": "dynamodb" como fonte ao usar o conector de exportação para DynamoDB do AWS Glue, que está disponível apenas para o AWS Glue versão 2.0 em diante:

- `"dynamodb.export"`: (obrigatório) um valor de string:
  - Se definido como `ddb`, habilita o conector de exportação para DynamoDB do AWS Glue. Um novo `ExportTableToPointInTimeRequest` será invocado durante o trabalho do AWS Glue. Uma nova exportação será gerada com o local repassado de `dynamodb.s3.bucket` e `dynamodb.s3.prefix`.
  - Se definido como `s3`, habilita o conector de exportação para DynamoDB do AWS Glue, mas ignora a criação de uma nova exportação do DynamoDB. Em vez disso, usa o `dynamodb.s3.bucket` e `dynamodb.s3.prefix` como o local do Amazon S3 de uma exportação anterior dessa tabela.
- `"dynamodb.tableArn"`: (obrigatório) a tabela do DynamoDB da qual fazer a leitura.
- `"dynamodb.unnestDDBJson"`: (Opcional) Padrão: false. Valores válidos: booleano. Se definido como “true” (verdadeiro), executa uma transformação de desaninhamento da estrutura JSON do DynamoDB que está presente nas exportações. É um erro definir `"dynamodb.unnestDDBJson"` e `"dynamodb.simplifyDDBJson"` como verdadeiro ao mesmo tempo. No AWS Glue 3.0 e versões posteriores, recomendamos usar `"dynamodb.simplifyDDBJson"` para melhorar

o comportamento ao simplificar os tipos de mapas do DynamoDB. Para ter mais informações, consulte the section called “Simplificar o uso do JSON de exportação do DynamoDB”.

- `"dynamodb.simplifyDDBJson"`: (Opcional) Padrão: false. Valores válidos: booleano. Se definido como “true” (verdadeiro), executa uma transformação para simplificar o esquema da estrutura JSON do DynamoDB que está presente nas exportações. Isso tem a mesma finalidade que a opção `"dynamodb.unnestDDBJson"`, mas fornece melhor suporte a tipos de mapas do DynamoDB ou até mesmo tipos de mapas aninhados em sua tabela do DynamoDB. Esse atributo só está disponível no AWS Glue 3.0 e versões posteriores. É um erro definir `"dynamodb.unnestDDBJson"` e `"dynamodb.simplifyDDBJson"` como verdadeiro ao mesmo tempo. Para ter mais informações, consulte the section called “Simplificar o uso do JSON de exportação do DynamoDB”.
- `"dynamodb.s3.bucket"`: (opcional) indica o local do bucket do Amazon S3 no qual o processo `ExportTableToPointInTime` do DynamoDB deve ser executado. O formato de arquivo para a exportação é DynamoDB JSON.
  - `"dynamodb.s3.prefix"`: (Opcional) indica o local do prefixo do Amazon S3 dentro do bucket do Amazon S3 no qual as cargas `ExportTableToPointInTime` do DynamoDB devem ser armazenadas. Se não houver a especificação de `dynamodb.s3.prefix` e `dynamodb.s3.bucket`, esses valores serão definidos por padrão para o local do diretório temporário especificado na configuração de trabalho do AWS Glue. Para mais informações, consulte Parâmetros especiais usados pelo AWS Glue.
  - `"dynamodb.s3.bucketOwner"`: indica o proprietário do bucket necessário para acesso entre contas do Amazon S3.
- `"dynamodb.sts.roleArn"`: (opcional) o ARN do perfil do IAM a ser assumido para acesso entre contas e/ou acesso entre regiões para a tabela do DynamoDB. Observação: o mesmo ARN de função do IAM será usado para acessar o local do Amazon S3 especificado para a solicitação `ExportTableToPointInTime`.
- `"dynamodb.sts.roleSessionName"`: (opcional) nome da sessão STS. O padrão é definido como “glue-dynamodb-read-sts-session”.
- `"dynamodb.exportTime"` (Opcional) Valores válidos: strings representando instantes ISO-8601. Um momento no qual a exportação deve ser feita.
- `"dynamodb.sts.region"`: (obrigatório se estiver fazendo uma chamada entre regiões usando um endpoint regional) a região que hospeda a tabela do DynamoDB que você deseja ler.

“connectionType”: “dynamodb” com o conector de ETL como coletor

Use as seguintes opções de conexão com `"connectionType": "dynamodb"` como coletor:

- `"dynamodb.output.tableName"`: (obrigatório) a tabela do DynamoDB na qual fazer a gravação.
- `"dynamodb.throughput.write.percent"`: (opcional) a porcentagem de unidades de capacidade de gravação (WCU) para usar. O padrão é definido como "0,5". Os valores aceitáveis são de "0,1" a "1,5", inclusive.
  - `0.5` representa a taxa de gravação padrão, o que significa que o AWS Glue tentará consumir metade da capacidade de gravação da tabela. Se você aumentar o valor acima de 0,5, o AWS Glue aumentará a taxa de solicitação. Diminuir o valor abaixo de 0,5 reduz a taxa de solicitação de gravação. (A taxa de gravação real pode variar, dependendo de fatores como a existência de uma distribuição de chaves uniforme na tabela do DynamoDB.)
  - Quando a tabela do DynamoDB está no modo sob demanda, o AWS Glue lida com a capacidade de gravação da tabela como `40000`. Para importar uma tabela grande, recomendamos mudar sua tabela do DynamoDB para o modo sob demanda.
- `"dynamodb.output.numParallelTasks"`: (opcional) define quantas tarefas simultâneas gravam no DynamoDB ao mesmo tempo. Usado para calcular as WCU permissivas por tarefa do Spark. Na maioria dos casos, o AWS Glue calculará um valor padrão razoável para esse valor. Para ter mais informações, consulte the section called “Paralelismo dinâmico”.
- `"dynamodb.output.retry"`: (opcional) define quantas novas tentativas realizamos quando há uma `ProvisionedThroughputExceededException` do DynamoDB. O padrão é definido como “10”.
- `"dynamodb.sts.roleArn"`: (opcional) o ARN da função do IAM a ser assumida para acesso entre contas.
- `"dynamodb.sts.roleSessionName"`: (opcional) nome da sessão STS. O padrão é definido como “glue-dynamodb-write-sts-session”.

Acesso a tabelas do DynamoDB entre contas e entre regiões

Os trabalhos de ETL do AWS Glue oferecem suporte a acesso a tabelas do DynamoDB tanto entre regiões quanto entre contas. Os trabalhos de ETL do AWS Glue suportam tanto a leitura de dados de uma tabela do DynamoDB de outra conta da AWS quanto a gravação de dados em uma tabela do DynamoDB de outra conta da AWS. O AWS Glue também suporta leitura de uma tabela do

DynamoDB em outra região e gravação em uma tabela do DynamoDB em outra região. Esta seção fornece instruções sobre como configurar o acesso e fornece um script de exemplo.

Os procedimentos nesta seção fazem referência a um tutorial do IAM para criar uma função do IAM e conceder acesso à função. O tutorial também discute sobre como assumir uma função, mas aqui, em vez disso, você usará um script de trabalho para assumir a função no AWS Glue. Este tutorial também contém informações sobre práticas gerais entre contas. Para ver um exemplo, consulte o Tutorial: Delegar acesso entre contas da AWS usando funções do IAM no Manual do usuário do IAM.

Criar um perfil

Siga o passo 1 no tutorial para criar uma função do IAM na conta A. Ao definir as permissões da função, você pode optar por anexar políticas existentes, como `AmazonDynamoDBReadOnlyAccess` ou `AmazonDynamoDBFullAccess`, para permitir que a função leia/grave do DynamoDB. O exemplo a seguir mostra a criação de uma função chamada `DynamoDBCrossAccessRole` com a política de permissão `AmazonDynamoDBFullAccess`.

Conceder acesso ao perfil

Siga o passo 2 no tutorial no Guia do usuário do IAM para permitir que a conta B alterne para a função recém-criada. O exemplo a seguir cria uma nova política com a seguinte instrução:

```
{
    "Version": "2012-10-17",
    "Statement": {
        "Effect": "Allow",
        "Action": "sts:AssumeRole",
        "Resource": "<DynamoDBCrossAccessRole's ARN>"
    }
}
```

Em seguida, você pode anexar essa política ao grupo/função/usuário que deseja usar para acessar o DynamoDB.

Assumir o perfil no script de trabalho do AWS Glue

Agora, você pode fazer login na conta B e criar um trabalho do AWS Glue. Para criar um trabalho, consulte as instruções em Configurar propriedades de trabalho para trabalhos do Spark no AWS Glue.

No script de trabalho, você precisa usar o parâmetro `dynamodb.sts.roleArn` para assumir a função `DynamoDBCrossAccessRole`. Assumir essa função permite que você obtenha as

credenciais temporárias, que precisam ser usadas para acessar o DynamoDB na conta B. Revise estes scripts de exemplo.

Para uma leitura entre contas entre regiões (conector 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()
```

Para uma leitura entre contas entre regiões (conector ELT):

```
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()
```

Para uma leitura e gravação entre contas entre regiões:

```
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()
```

Conexões do Kinesis

É possível usar uma conexão do Kinesis para ler e gravar o Amazon Kinesis Data Streams usando informações armazenadas em uma tabela do Data Catalog ou fornecendo informações para acessar diretamente o fluxo de dados. Você pode ler informações do Kinesis em um Spark DataFrame e depois convertê-las em um Glue DynamicFrame AWS. Você pode gravar DynamicFrames no Kinesis em um formato JSON. Se você acessar diretamente o fluxo de dados, use essas opções para fornecer as informações sobre como acessar o fluxo de dados.

Se você usar `getCatalogSource` ou `create_data_frame_from_catalog` para consumir registros de uma fonte de transmissão do Kinesis, o trabalho tem o banco de dados do catálogo de dados e as informações de nome da tabela, e pode usá-los para obter alguns parâmetros básicos para leitura da fonte de transmissão do Kinesis. Se você usar `getSource`, `getSourceWithFormat`, `createDataFrameFromOptions` ou `create_data_frame_from_options`, será necessário especificar esses parâmetros básicos usando as opções de conexão descritas aqui.

Você pode especificar as opções de conexão para o Kinesis usando os seguintes argumentos para os métodos especificados na classe `GlueContext`.

- Scala
  - `connectionOptions`: usar com `getSource`, `createDataFrameFromOptions`, `getSink`
  - `additionalOptions`: usar com `getCatalogSource`, `getCatalogSink`
  - `options`: usar com `getSourceWithFormat`, `getSinkWithFormat`
- Python
  - `connection_options`: usar com `create_data_frame_from_options`, `write_dynamic_frame_from_options`
  - `additional_options`: usar com `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
  - `options`: usar com `getSource`, `getSink`

Para notas e restrições sobre trabalhos de ETL de streaming, consulte the section called “Notas e restrições sobre ETL de transmissão”.

Configurar o Kinesis

Para ler um fluxo de dados do Kinesis em uma trabalho do AWS Glue Spark, você precisará de alguns pré-requisitos:

- Se for leitura, o trabalho do AWS Glue deve ter permissões IAM do nível de acesso de leitura ao fluxo de dados do Kinesis.
- Se for gravação, o trabalho do AWS Glue deve ter permissões IAM do nível de acesso de gravação ao fluxo de dados do Kinesis.

Em certos casos, você precisará configurar pré-requisitos adicionais:

- Se o trabalho do AWS Glue estiver configurado com conexões de rede adicionais (normalmente para se conectar a outros conjuntos de dados) e uma dessas conexões fornecer opções de rede da Amazon VPC, isso direcionará o trabalho para se comunicar pela Amazon VPC. Nesse caso, você também precisará configurar o fluxo de dados do Kinesis para se comunicar pela Amazon VPC. É possível fazer isso criando um endpoint da VPC de interface entre a Amazon VPC e o fluxo de dados do Kinesis. Para obter mais informações, consulte Using Kinesis Data Streams with Interface VPC Endpoints.
- Ao especificar Amazon Kinesis Data Streams em outra conta, você deve configurar os perfis e políticas para permitir o acesso entre contas. Para obter mais informações, consulte Exemplo: Ler de uma transmissão do Kinesis em outra conta.

Para obter mais informações sobre pré-requisitos de trabalho de ETL de streaming, consulte the section called “Trabalhos de transmissão de ETL”.

Exemplo: ler de fluxos do Kinesis

Exemplo: ler de fluxos do Kinesis

Usado em conjunto com the section called “forEachBatch”.

Exemplo para fonte de transmissão do 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)
```

Exemplo: gravação em streams do Kinesis

Exemplo: ler de fluxos do Kinesis

Usado em conjunto com the section called “forEachBatch”.

Exemplo para fonte de transmissão do 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)
```

Referência de opções de conexão do Kinesis

Designa opções de conexão para o Amazon Kinesis Data Streams.

Use as seguintes opções de conexão para fontes de dados de transmissão do Kinesis:

- `"streamARN"` (obrigatório) usado para leitura/gravação. O ARN do fluxo de dados do Kinesis.
- `"classification"` (Obrigatório para leitura) Usado para leitura. O formato de arquivo usado pelos dados no registro. Obrigatório, a menos que fornecido por meio do catálogo de dados.
- `"streamName"` (opcional) usado para leitura. O nome de um fluxo de dados do Kinesis de onde ler. Usado com `endpointUrl`.
- `"endpointUrl"` (opcional) usado para leitura. Padrão: “https://kinesis.us-east-1.amazonaws.com” O endpoint AWS do stream do Kinesis. Você não precisa alterar isso, a menos que esteja se conectando a uma região especial.
- `"partitionKey"` (opcional) usado para gravação. A chave de partição do Kinesis usada na produção de registros.
- `"delimiter"` (opcional) usado para leitura. O separador de valores usado quando a `classification` é CSV. O padrão é `","`.
- `"startingPosition"`: (opcional) usado para leitura. A posição inicial no fluxo de dados do Kinesis de onde ler os dados. Os valores possíveis são `"latest"`, `"trim_horizon"`, `"earliest"` ou uma string de timestamp no formato UTC no padrão `yyyy-mm-`

ddTHH:MM:SSZ (onde Z representa um desvio do fuso horário UTC com +/-). Por exemplo: "2023-04-04T08:00:00-04:00"). O valor padrão é "latest". Observação: a string de timestamp no formato UTC para "startingPosition" é compatível somente com a versão 4.0 ou posterior do AWS Glue.

- "failOnDataLoss": (Opcional) Falha na tarefa se algum fragmento ativo estiver ausente ou expirado. O valor padrão é "false".
- "awsSTSRoleARN": (opcional) usado para leitura/gravação. O nome de recurso da Amazon (ARN) da função a ser assumida com o uso do AWS Security Token Service (AWS STS). Essa função deve ter permissões para descrever ou ler operações de registro para o fluxo de dados do Kinesis. Você deve usar esse parâmetro ao acessar um fluxo de dados em uma conta diferente. Usado em conjunto com "awsSTSSessionName".
- "awsSTSSessionName": (opcional) usado para leitura/gravação. Um identificador para a sessão que assume a função usando o AWS STS. Você deve usar esse parâmetro ao acessar um fluxo de dados em uma conta diferente. Usado em conjunto com "awsSTSRoleARN".
- "awsSTSEndpoint": (Opcional) O AWS STS endpoint a ser usado ao se conectar ao Kinesis com uma função assumida. Isso permite usar o AWS STS endpoint regional em uma VPC, o que não é possível com o endpoint global padrão.
- "maxFetchTimeInMs": (opcional) usado para leitura. O tempo máximo para o executor do trabalho ler registros referentes ao lote atual do fluxo de dados do Kinesis especificado em milissegundos (ms). Várias chamadas de API GetRecords podem ser feitas nesse período. O valor padrão é 1000.
- "maxFetchRecordsPerShard": (opcional) usado para leitura. O número máximo de registros a serem obtidos por fragmento no fluxo de dados do Kinesis por microlote. Observação: o cliente poderá exceder esse limite se o trabalho de streaming já tiver lido registros extras do Kinesis (na mesma chamada get-records). Se maxFetchRecordsPerShard precisa ser rigoroso, então precisa ser um múltiplo de maxRecordPerRead. O valor padrão é 100000.
- "maxRecordPerRead": (opcional) usado para leitura. O número máximo de registros a serem obtidos por fragmento no fluxo de dados do Kinesis em cada operação getRecords. O valor padrão é 10000.
- "addIdleTimeBetweenReads": (opcional) usado para leitura. Adiciona um atraso de tempo entre duas operações getRecords. O valor padrão é "False". Essa opção só pode ser configurada para o Glue versão 2.0 e posterior.

- `"idleTimeBetweenReadsInMs"`: (opcional) usado para leitura. O atraso mínimo entre duas operações , especificado em ms. O valor padrão é `1000`. Essa opção só pode ser configurada para o Glue versão 2.0 e posterior.
- `"describeShardInterval"`: (opcional) usado para leitura. O intervalo de tempo mínimo entre duas chamadas de API `ListShards` para que seu script considere a refragmentação. Para obter mais informações, consulte Estratégias para refragmentação no Guia do desenvolvedor do Amazon Kinesis Data Streams. O valor padrão é `1s`.
- `"numRetries"`: (opcional) usado para leitura. O número máximo de novas tentativas para solicitações de API do Kinesis Data Streams. O valor padrão é `3`.
- `"retryIntervalMs"`: (opcional) usado para leitura. O período de espera (especificado em ms) antes de repetir a chamada da API Kinesis Data Streams. O valor padrão é `1000`.
- `"maxRetryIntervalMs"`: (opcional) usado para leitura. O período de espera máximo (especificado em ms) entre duas tentativas de uma chamada de API Kinesis Data Streams. O valor padrão é `10000`.
- `"avoidEmptyBatches"`: (opcional) usado para leitura. Evita a criação de um trabalho de micro lote vazio verificando se há dados não lidos no fluxo de dados do Kinesis antes de o lote ser iniciado. O valor padrão é `"False"`.
- `"schema"`: (Obrigatório quando inferSchema é definido como false): usado para leitura. O esquema a ser usado para processar a carga. Se a classificação for `avro`, o esquema fornecido deverá estar no formato de esquema Avro. Se a classificação não for `avro`, o esquema fornecido deverá estar no formato de esquema DDL.

  Veja a seguir alguns exemplos de esquema.

  Example 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"`: (opcional) usado para leitura. O valor padrão é "false". Se definido como “true”, o esquema será detectado em runtime com base na carga útil em `foreachbatch`.
- `"avroSchema"`: (Obsoleto) Usado para leitura. Parâmetro usado para especificar um esquema de dados Avro quando o formato Avro é usado. Esse parâmetro foi descontinuado. Use o parâmetro `schema`.
- `"addRecordTimestamp"`: (opcional) usado para leitura. Quando essa opção for definida como "true", a saída de dados conterá uma coluna adicional denominada "__src_timestamp" que indica a hora que o registro correspondente é recebido pelo fluxo. O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.
- `"emitConsumerLagMetrics"`: (opcional) usado para leitura. Quando a opção for definida como "true" (verdadeira), para cada lote, serão emitidas métricas durante o período entre a hora que o registro mais antigo é recebido pelo tópico e a hora que ele chega ao AWS Glue para o CloudWatch. O nome da métrica é "glue.driver.streaming.maxConsumerLagInMs". O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.
- `"fanoutConsumerARN"`: (opcional) usado para leitura. O ARN de um consumidor de fluxo do Kinesis para o fluxo especificado em `streamARN`. Usado para habilitar o modo de distribuição avançada para a conexão do Kinesis. Para obter mais informações sobre como consumir um fluxo do Kinesis com distribuição avançada, consulte the section called “Usar distribuição avançada nas tarefas de streaming do Kinesis”.
- `"recordMaxBufferedTime"` (opcional) usado para gravação. Padrão: 1000 (ms). Tempo máximo em que um registro é armazenado em buffer enquanto espera para ser gravado.

- `"aggregationEnabled"` (opcional) usado para gravação. Padrão: true. Especifica se os registros devem ser agregados antes de serem enviados para o Kinesis.
- `"aggregationMaxSize"` (opcional) usado para gravação. Padrão: 51200 (bytes) Se um registro for maior que esse limite, ele ignorará o agregador. Nota: O Kinesis impõe um limite de 50 KB no tamanho do registro. Se você definir isso além de 50 KB, registros grandes serão rejeitados pelo Kinesis.
- `"aggregationMaxCount"` (opcional) usado para gravação. Padrão: 4294967295. O número máximo de itens a serem retornados em um registro agregado.
- `"producerRateLimit"` (opcional) usado para gravação. Padrão: 150 (%). Limita o throughput por fragmento enviado por um único produtor (como seu trabalho), como uma porcentagem do limite de back-end.
- `"collectionMaxCount"` (opcional) usado para gravação. Padrão: 500. Número máximo de itens a serem compactados em uma solicitação PutRecords.
- `"collectionMaxSize"` (opcional) usado para gravação. Padrão: 5242880 (bytes) Quantidade máxima de dados a serem enviados com uma solicitação PutRecords.

Usar distribuição avançada nas tarefas de streaming do Kinesis

Um consumidor de distribuição avançada pode receber registros de um fluxo do Kinesis com um throughput dedicado que pode ser maior que o dos consumidores comuns. Isso é feito otimizando o protocolo de transferência usado para fornecer dados a um consumidor do Kinesis, como o seu trabalho. Para obter mais informações sobre distribuição avançada do Kinesis, consulte a documentação do Kinesis.

No modo de distribuição avançada, as opções de conexão `maxRecordPerRead` e `idleTimeBetweenReadsInMs` não se aplicam mais, pois esses parâmetros não são configuráveis quando se usa o fan-out aprimorado. As opções de configuração para novas tentativas funcionam conforme descrito.

Use os procedimentos a seguir para habilitar e desabilitar a distribuição avançada para seu trabalho de streaming. Você deve registrar um consumidor de fluxo para cada trabalho que consuma dados do fluxo.

Para permitir um maior consumo de distribuição avançada no trabalho:

1. Registre um consumidor de fluxo para o trabalho usando a API do Kinesis. Siga as instruções para register a consumer with enhanced fan-out using the Kinesis Data Streams

API na documentação do Kinesis. Você só precisará seguir a primeira etapa: chamar RegisterStreamConsumer. Sua solicitação deve retornar um ARN, *consumerARN*.

2. Defina a opção de conexão `fanoutConsumerARN` como *consumerARN* nos argumentos do método de conexão.
3. Reinicie seu trabalho.

Para desabilitar o consumo de distribuição avançada no trabalho:

1. Remova a opção de conexão `fanoutConsumerARN` da sua chamada de método.
2. Reinicie seu trabalho.
3. Siga as instruções para deregister a consumer na documentação do Kinesis. Essas instruções se aplicam ao console, mas também podem ser obtidas por meio da API Kinesis. Para obter mais informações sobre o cancelamento do registro de consumidores de fluxo por meio da API do Kinesis, consulte DeregisterStreamConsumer na documentação do Kinesis.

Conexões do Amazon S3

Você pode usar o AWS Glue para Spark para ler e gravar arquivos no Amazon S3. O AWS Glue para Spark é compatível com muitos formatos de dados comuns armazenados no Amazon S3 prontos para uso, incluindo CSV, Avro, JSON, Orc e Parquet. Para obter mais informações sobre os formatos de dados compatíveis, consulte the section called “Opções de formato de dados”. Cada formato de dados pode ser compatível um conjunto diferente de atributos do AWS Glue. Consulte a página do seu formato de dados para obter os detalhes específicos da compatibilidade com atributos. Além disso, você pode ler e gravar arquivos versionados armazenados nas estruturas de data lake do Hudi, Iceberg e do Delta Lake. Para obter mais informações sobre estruturas de data lake, consulte the section called “Estruturas de data lake”.

Com o AWS Glue, você pode particionar os objetos do Amazon S3 em uma estrutura de pastas durante a gravação e depois recuperá-los por partição para melhorar a performance usando uma configuração simples. Você também pode definir a configuração para agrupar arquivos pequenos ao transformar seus dados, para melhorar a performance. Você pode ler e gravar arquivos `bzip2` e `gzip` no Amazon S3.

Tópicos

- Configurar conexões do S3
- Referência de opções de conexão do Amazon S3

- Sintaxes de conexão obsoletas para formatos de dados
- Excluir classes de armazenamento do Amazon S3
- Gerenciar partições para saída de ETL no AWS Glue
- Ler arquivos de entrada em grupos maiores
- Endpoints da Amazon VPC para o Amazon S3

Configurar conexões do S3

Para se conectar ao Amazon S3 em um trabalho do AWS Glue com Spark, você precisará de alguns pré-requisitos:

- O trabalho do AWS Glue deve ter permissões do IAM para buckets relevantes do Amazon S3.

Em certos casos, você precisará configurar pré-requisitos adicionais:

- Ao configurar o acesso entre contas, os controles de acesso apropriados no bucket do Amazon S3.
- Por motivos de segurança, você pode optar por rotear suas solicitações do Amazon S3 por meio de uma Amazon VPC. Essa abordagem pode introduzir desafios de largura de banda e disponibilidade. Para ter mais informações, consulte the section called “Endpoints da Amazon VPC para o Amazon S3”.

Referência de opções de conexão do Amazon S3

Designa uma conexão com o Amazon S3.

Como o Amazon S3 gerencia arquivos em vez de tabelas, além de especificar as propriedades de conexão fornecidas neste documento, você precisará especificar configurações adicionais sobre seu tipo de arquivo. Você especifica essas informações por meio de opções de formato de dados. Para obter mais informações sobre essas opções de formato, consulte the section called “Opções de formato de dados”. Você também pode especificar essas informações fazendo a integração com o catálogo de dados do AWS Glue.

Para obter um exemplo da distinção entre opções de conexão e opções de formato, considere como o método the section called “create_dynamic_frame_from_options” usa `connection_type`, `connection_options`, `format` e `format_options`. Esta seção discute especificamente os parâmetros fornecidos às `connection_options`.

Use as seguintes opções de conexão com `"connectionType": "s3"`:

- `"paths"`: (obrigatório) uma lista de caminhos do Amazon S3 dos quais fazer a leitura.
- `"exclusions"`: (Opcional) Uma string contendo uma lista JSON de padrões glob de estilo Unix padrões para excluir. Por exemplo, `"[\"**.pdf\"]"` exclui todos os arquivos PDF. Para obter mais informações sobre a sintaxe glob compatível com o AWS Glue, consulte Incluir e excluir padrões.
- `"compressionType"`: ou `"compression"`: (opcional) especifica como os dados são compactados. Use `"compressionType"` para fontes do Amazon S3 e `"compression"` para destinos do Amazon S3. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip2"`). Formatos de compactação adicionais podem ser compatíveis com formatos específicos. Para obter os detalhes específicos da compatibilidade com atributos, consulte a página do seu formato de dados.
- `"groupFiles"`: (opcional) o agrupamento de arquivos é ativado por padrão quando a entrada contiver mais de 50.000 arquivos. Para habilitar o agrupamento com menos de 50.000 arquivos, defina esse parâmetro como `"inPartition"`. Para desabilitar o agrupamento quando houver mais de 50.000 arquivos, defina esse parâmetro como `"none"`.
- `"groupSize"`: (Opcional) O tamanho do grupo de destino em bytes. O padrão é calculado com base no tamanho de dados de entrada e o tamanho de seu cluster. Quando há menos de 50.000 arquivos de entrada, `"groupFiles"` deve ser definido como `"inPartition"` para poder entrar em vigor.
- `"recurse"`: (Opcional) Se definido como verdadeiro, recursivamente lê arquivos em todos os subdiretórios de acordo com os caminhos especificados.
- `"maxBand"`: (opcional, avançado) essa opção controla a duração, em milissegundos, após a qual a listagem `s3` provavelmente será consistente. Os arquivos com carimbos de data e hora de modificação que estão dentro dos últimos `maxBand` milissegundos são rastreados principalmente ao usar `JobBookmarks` para considerar a consistência final do Amazon S3. A maioria dos usuários não precisa definir essa opção. O valor padrão é 900.000 milissegundos, ou 15 minutos.
- `"maxFilesInBand"`: (opcional, avançado) essa opção especifica o número máximo de arquivos que devem ser salvos dos últimos `maxBand` segundos. Se esse número for excedido, os arquivos extras são ignorados e apenas processados na próxima execução do trabalho. A maioria dos usuários não precisa definir essa opção.
- `"isFailFast"`: (opcional) essa opção determina se um trabalho de ETL do AWS Glue lança exceções de análise do leitor. Se definido como `true`, os trabalhos falham rapidamente se quatro tentativas da tarefa do Spark falharem em analisar os dados corretamente.

- `"catalogPartitionPredicate"`: (opcional) usado para leitura. O conteúdo de uma cláusula SQL `WHERE`. Usado ao ler tabelas do catálogo de dados com uma quantidade muito grande de partições. Recupera partições correspondentes dos índices do catálogo de dados. Usado com `push_down_predicate`, uma opção do método the section called “create_dynamic_frame_from_catalog” (e outros métodos similares). Para ter mais informações, consulte the section called “Predicados de partição de catálogo”.
- `"partitionKeys"`: (opcional) usado para gravação. Uma matriz de strings de rótulo da coluna. O AWS Glue particionará os dados conforme especificado por essa configuração. Para ter mais informações, consulte the section called “Gravar partições”.
- `"excludeStorageClasses"`: (opcional) usado para leitura. Uma matriz de strings especificando as classes de armazenamento do Amazon S3. O AWS Glue excluirá objetos do Amazon S3 com base nessa configuração. Para ter mais informações, consulte the section called “Excluir classes de armazenamento do Amazon S3”.

Sintaxes de conexão obsoletas para formatos de dados

Certos formatos de dados podem ser acessados usando a sintaxe de um tipo de conexão específico. Essa sintaxe está obsoleta. Em seu lugar, recomendamos que você especifique os formatos usando o tipo de conexão `s3` e as opções de formato fornecidas em the section called “Opções de formato de dados”.

“connectionType”: “orc”

Designa uma conexão para arquivos armazenados no Amazon S3 no formato de arquivo Apache Hive Optimized Row Columnar (ORC).

Use as seguintes opções de conexão com `"connectionType": "orc"`:

- `paths`: (obrigatório) uma lista de caminhos do Amazon S3 dos quais fazer a leitura.
- (Outras opções de pares de nome/valor): qualquer opção adicional, incluindo opções de formatação, são transmitidas diretamente à `DataSource` do SparkSQL.

"connectionType": "parquet"

Designa uma conexão com arquivos armazenados no Amazon S3 no formato de arquivo Apache Parquet.

Use as seguintes opções de conexão com `"connectionType": "parquet"`:

- `paths`: (obrigatório) uma lista de caminhos do Amazon S3 dos quais fazer a leitura.
- (Outras opções de pares de nome/valor): qualquer opção adicional, incluindo opções de formatação, são transmitidas diretamente à `DataSource` do SparkSQL.

Excluir classes de armazenamento do Amazon S3

Se você estiver executando trabalhos de ETL do AWS Glue que leiam arquivos ou partições do Amazon Simple Storage Service (Amazon S3), poderá excluir alguns tipos de classe de armazenamento do Amazon S3.

As seguintes classes de armazenamento estão disponíveis no Amazon S3:

- `STANDARD`: para armazenamento de uso geral de dados acessados com frequência.
- `INTELLIGENT_TIERING`: para dados com padrões de acesso desconhecidos ou inconstantes.
- `STANDARD_IA` e `ONEZONE_IA`: para dados de longa duração, mas acessados com menos frequência.
- `GLACIER`, `DEEP_ARCHIVE` e `REDUCED_REDUNDANCY`: para arquivamento de longo prazo e preservação digital.

Para obter mais informações, consulte Classes de armazenamento do Amazon S3 no Guia do desenvolvedor do Amazon S3.

Os exemplos nesta seção mostram como excluir as classes de armazenamento `GLACIER` e `DEEP_ARCHIVE`. Essas classes permitem que você liste arquivos, mas elas não permitem que você leia os arquivos, a menos que sejam restaurados. (Para obter mais informações, consulte Restaurar objetos arquivados no Guia do desenvolvedor do Amazon S3).

Ao usar exclusões de classe de armazenamento, você pode garantir que seus trabalhos do AWS Glue funcionarão em tabelas com partições entre esses níveis de classe de armazenamento. Sem exclusões, os trabalhos que leem dados desses níveis falham com o seguinte erro: AmazonS3Exception: The operation is not valid for the object's storage class (AmazonS3Exception: a operação não é válida para a classe de armazenamento do objeto).

Há diferentes maneiras de filtrar classes de armazenamento do Amazon S3 no AWS Glue.

Tópicos

- Excluir classes de armazenamento do Amazon S3 ao criar um quadro dinâmico

- Excluir classes de armazenamento do Amazon S3 em uma tabela do Data Catalog

Excluir classes de armazenamento do Amazon S3 ao criar um quadro dinâmico

Para excluir classes de armazenamento do Amazon S3 ao criar um quadro dinâmico, use `excludeStorageClasses` em `additionalOptions`. O AWS Glue usa automaticamente sua própria implementação do `Lister` do Amazon S3 para listar e excluir arquivos correspondentes às classes de armazenamento especificadas.

Os exemplos de Python e Scala a seguir mostram como excluir as classes de armazenamento `GLACIER` e `DEEP_ARCHIVE` ao criar um quadro dinâmico.

Exemplo do 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"]
    }
)
```

Exemplo do Scala:

```
val* *df = glueContext.getCatalogSource(
    nameSpace, tableName, "", "my_transformation_context",
    additionalOptions = JsonOptions(
        Map("excludeStorageClasses" -> List("GLACIER", "DEEP_ARCHIVE"))
    )
).getDynamicFrame()
```

Excluir classes de armazenamento do Amazon S3 em uma tabela do Data Catalog

É possível especificar exclusões de classe de armazenamento a serem usadas por um trabalho de ETL do AWS Glue como um parâmetro de tabela no catálogo de dados do Glue da AWS. Você pode incluir esse parâmetro na operação `CreateTable` usando a AWS Command Line Interface (AWS CLI) ou de forma programática com a API. Para obter mais informações, consulte Estrutura de tabelas e CreateTable.

Você também pode especificar classes de armazenamento excluídas no console do AWS Glue.

Como excluir classes de armazenamento do Amazon S3 (console)

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. No painel de navegação à esquerda, escolha Tables (Tabelas).
3. Escolha o nome da tabela na lista e, depois, escolha Edit table (Editar tabela).
4. Em Table properties (Propriedades da tabela), adicione **`excludeStorageClasses`** como uma chave e **`[\"GLACIER\",\"DEEP_ARCHIVE\"]`** como um valor.
5. Escolha Aplicar.

Gerenciar partições para saída de ETL no AWS Glue

O particionamento é uma técnica importante para organizar os conjuntos de dados para que possam ser consultados com eficiência. Ele organiza dados em uma estrutura hierárquica de diretórios com base nos valores distintos de uma ou mais colunas.

Por exemplo, você pode decidir particionar os logs da sua aplicação no Amazon Simple Storage Service (Amazon S3) por data, divididos em ano, mês e dia. Os arquivos que correspondem a um único dia de dados são colocados com um prefixo, como `s3://my_bucket/logs/year=2018/month=01/day=23/`. Sistemas como o Amazon Athena, o Amazon Redshift Spectrum e agora o AWS Glue podem usar essas partições para filtrar dados por valor de partição sem precisar ler todos os dados subjacentes do Amazon S3.

Os crawlers não apenas inferem tipos de arquivo e esquemas, como também identificam automaticamente a estrutura da partição do seu conjunto de dados quando eles preenchem o AWS Glue Data Catalog. As colunas resultantes da partição ficam disponíveis para consulta em trabalhos de ETL do AWS Glue ou em mecanismos de consulta, como o Amazon Athena.

Após rastrear uma tabela, você pode visualizar as partições que o crawler criou. No console do AWS Glue, escolha Tables (Tabelas) no painel de navegação esquerdo. Escolha a tabela criada pelo crawler e, em seguida, selecione View Partitions (Exibir partições).

Para os caminhos particionados do Apache Hive no estilo `key=val`, os crawlers preenchem automaticamente o nome da coluna usando o nome da chave padrão. Caso contrário, ele usa nomes padrão, como `partition_0`, `partition_1` e assim por diante. Você pode alterar os

nomes padrão no console. Para fazer isso, navegue até a tabela. Verifique se os índices existem na guia Índices. Se for esse o caso, você precisa excluí-las para continuar (você poderá recriá-las posteriormente usando os novos nomes das colunas). Em seguida, escolha Editar esquema e modifique os nomes das colunas de partição.

Nos scripts de ETL, você pode filtrar as colunas da partição. Uma vez que as informações de partição são armazenadas no Data Catalog, utilize as chamadas de API `from_catalog` para incluir as colunas de partição no `DynamicFrame`. Por exemplo, use `create_dynamic_frame.from_catalog` em vez de `create_dynamic_frame.from_options`.

Particionamento é uma técnica de otimização que reduz as varreduras de dados. Para obter mais informações sobre o processo para identificar quando essa técnica é adequada, consulte Reduce the amount of data scan no guia Best practices for performance tuning AWS Glue for Apache Spark jobs em AWS Prescriptive Guidance.

Pré-filtragem usando a aplicação de predicados

Em muitos casos, você pode usar uma aplicação de predicado para filtrar partições sem precisar listar e ler todos os arquivos do seu conjunto de dados. Em vez de ler todo o conjunto de dados e, em seguida, filtrá-lo em um DynamicFrame, você pode aplicar o filtro diretamente nos metadados da partição no Data Catalog. Em seguida, você lista e lê somente o que você realmente precisa em um DynamicFrame.

Por exemplo, em Python, você pode gravar o seguinte.

```
glue_context.create_dynamic_frame.from_catalog(
    database = "my_S3_data_set",
    table_name = "catalog_data_table",
    push_down_predicate = my_partition_predicate)
```

Isso cria um DynamicFrame que carrega somente as partições do Data Catalog que satisfazem a expressão do predicado. Dependendo do tamanho do subconjunto dos dados que você está carregando, isso pode economizar muito tempo de processamento.

A expressão do predicado pode ser qualquer expressão booleana compatível com Spark SQL. Tudo que você pode colocar em uma cláusula `WHERE` de uma consulta do SQL Spark funcionará. Por exemplo, a expressão de predicado `pushDownPredicate = "(year=='2017' and month=='04')"` carrega apenas as partições no Data Catalog que tiverem tanto `year` igual a 2017

quanto `month` igual a 04. Para obter mais informações, consulte a Documentação do Apache Spark SQL e, em especial, a Referência das funções SQL em Scala.

Filtragem do lado do servidor usando predicados de partição de catálogo

A opção `push_down_predicate` é aplicada depois de listar todas as partições do catálogo e antes de listar arquivos do Amazon S3 para essas partições. Se você tiver muitas partições para uma tabela, a listagem de partições de catálogo ainda poderá incorrer em sobrecarga de tempo adicional. Para resolver essa sobrecarga, você pode usar a remoção de partição do lado do servidor com a opção `catalogPartitionPredicate`, que usaíndices de partição no AWS Glue Data Catalog. Isso torna a filtragem de partição muito mais rápida quando você tem milhões de partições em uma tabela. Você pode usar `push_down_predicate` e `catalogPartitionPredicate` em `additional_options` juntos, se seu `catalogPartitionPredicate` exigir sintaxe de predicado que ainda não é suportada com os índices de partição de catálogo.

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` e `catalogPartitionPredicate` usam sintaxes diferentes. O primeiro usa a sintaxe padrão do Spark SQL e o outro usa o analisador JSQL.

Gravar partições

Por padrão, um DynamicFrame não é particionado quando é gravado. Todos os arquivos de saída são gravados no nível superior do caminho de saída especificado. Até recentemente, a única maneira de gravar um DynamicFrame em partições era convertê-lo em um DataFrame Spark SQL antes da gravação.

No entanto, DynamicFrames agora oferecem suporte ao particionamento nativo usando uma sequência de chaves, usando a opção `partitionKeys` ao criar um depósito. Por exemplo, o seguinte código Python grava um conjunto de dados no Amazon S3 no formato Parquet em diretórios particionados, de acordo com o tipo de campo. A partir daí, você pode processar essas partições usando outros sistemas, como o Amazon Athena.

```
glue_context.write_dynamic_frame.from_options(
    frame = projectedEvents,
    connection_type = "s3",
    connection_options = {"path": "$outpath", "partitionKeys": ["type"]},
    format = "parquet")
```

Ler arquivos de entrada em grupos maiores

Você pode definir as propriedades das tabelas para habilitar um trabalho de ETL do AWS Glue a fim de agrupar arquivos quando eles são lidos em um armazenamento de dados do Amazon S3. Essas propriedades permitem que cada tarefa de ETL leia um grupo de arquivos de entrada em uma única partição na memória. Isso é especialmente útil quando há um grande número de arquivos pequenos no armazenamento de dados do Amazon S3. Ao definir determinadas propriedades, você instrui o AWS Glue a agrupar arquivos em uma partição de dados do Amazon S3 e a definir o tamanho dos grupos a serem lidos. Você também pode definir essas opções durante a leitura em um armazenamento de dados do Amazon S3 com o método `create_dynamic_frame.from_options`.

Para habilitar o agrupamento de arquivos para uma tabela, defina pares de chave/valor no campo de parâmetros da estrutura da tabela. Use a notação JSON para definir um valor para o campo de parâmetro da tabela. Para obter mais informações sobre como editar as propriedades de uma tabela, consulte Exibir e gerenciar detalhes da tabela.

Você pode usar esse método para habilitar o agrupamento de tabelas no Data Catalog com armazenamentos de dados do Amazon S3.

groupFiles

Defina groupFiles (agrupar arquivos) como `inPartition` para habilitar o agrupamento de arquivos em uma partição de dados do Amazon S3. O AWS Glue habilitará automaticamente o agrupamento se houver mais de 50.000 arquivos de entrada, como no exemplo a seguir.

```
'groupFiles': 'inPartition'
```

groupSize

Defina groupSize como o tamanho de destino de grupos em bytes. A propriedade groupSize é opcional. Se não for fornecida, o AWS Glue calculará um tamanho para usar todos os núcleos de CPU no cluster e, ao mesmo tempo, ainda reduzindo o número total de tarefas de ETL e partições na memória.

Por exemplo, o seguinte define o tamanho do grupo como 1 MB.

```
'groupSize': '1048576'
```

Observe que o `groupsize` deve ser definido com o resultado de um cálculo. Por exemplo 1024 * 1024 = 1048576.

recurse

Defina recursivo para `True` recursivamente ler arquivos em todos os subdiretórios ao especificar `paths` uma matriz de caminhos. Você não precisará definir recurse (recursivo) se `paths` for uma matriz de chaves de objeto no Amazon S3 ou se o formato de entrada for parquet/orc, como no exemplo a seguir.

```
'recurse':True
```

Se você estiver lendo no Amazon S3 diretamente usando o método `create_dynamic_frame.from_options`, adicione estas opções de conexão. Por exemplo, as seguintes tentativas de agrupar arquivos em grupos de 1 MB.

```
df = glueContext.create_dynamic_frame.from_options("s3", {'paths': ["s3://s3path/"],
 'recurse':True, 'groupFiles': 'inPartition', 'groupSize': '1048576'}, format="json")
```

> **Note**
>
> Há suporte para `groupFiles` para DynamicFrames criados a partir dos seguintes formatos de dados: csv, ion, grokLog, json e xml. Não há suporte dessa opção para avro, parquet e orc.

Endpoints da Amazon VPC para o Amazon S3

Por motivos de segurança, muitos clientes da AWS executam suas aplicações em um ambiente da Amazon Virtual Private Cloud (Amazon VPC). Com a Amazon VPC, você pode executar instâncias do Amazon EC2 em uma nuvem privada virtual, a qual é isolada logicamente de outras redes, incluindo a Internet pública. Com uma Amazon VPC, você tem controle sobre o intervalo de endereços IP, sub-redes, tabelas de roteamento, gateways de rede e configurações de segurança.

> **Note**
>
> Caso tenha criado sua conta da AWS após 4/12/2013, você já tem uma VPC padrão em cada região da AWS. Você pode começar a usar sua VPC padrão imediatamente sem qualquer configuração adicional.
> Para obter mais informações, consulte Suas sub-redes e VPC padrão no Manual do usuário da Amazon VPC.

Muitos clientes têm preocupações legítimas com a segurança e a privacidade sobre o envio e o recebimento de dados pela Internet pública. Os clientes podem resolver essas preocupações usando uma rede privada virtual (VPN) para rotear todo o tráfego de rede do Amazon S3 por meio da infraestrutura de rede corporativa deles. No entanto, essa abordagem pode introduzir desafios de largura de banda e disponibilidade.

Os endpoints da VPC para o Amazon S3 podem reduzir esses desafios. Um endpoint da VPC para o Amazon S3 permite ao AWS Glue usar endereços IP privados para acessar o Amazon S3 sem exposição à Internet pública. O AWS Glue não precisa de endereços IP públicos e você não precisa de um gateway da Internet, de um dispositivo NAT ou de um gateway privado virtual na sua VPC.

Use as políticas de endpoint para controlar o acesso ao Amazon S3. O tráfego entre sua VPC e o produto da AWS não sai da rede da Amazon.

Ao criar um endpoint da VPC para o Amazon S3, quaisquer solicitações para um endpoint do Amazon S3 dentro da região (por exemplo: s3.us-west-2.amazonaws.com) são encaminhadas para um endpoint privado do Amazon S3 dentro da rede da Amazon. Você não precisa modificar suas aplicações em execução em instâncias do Amazon EC2 na VPC. O nome do endpoint permanece o mesmo, mas a rota para o Amazon S3 permanece inteiramente dentro da rede da Amazon e não acessa a Internet pública.

Para obter mais informações sobre o endpoints da VPC, consulte Endpoints da VPC no Manual do usuário da Amazon VPC.

O diagrama a seguir mostra como o AWS Glue pode usar um endpoint da VPC para acessar o Amazon S3.

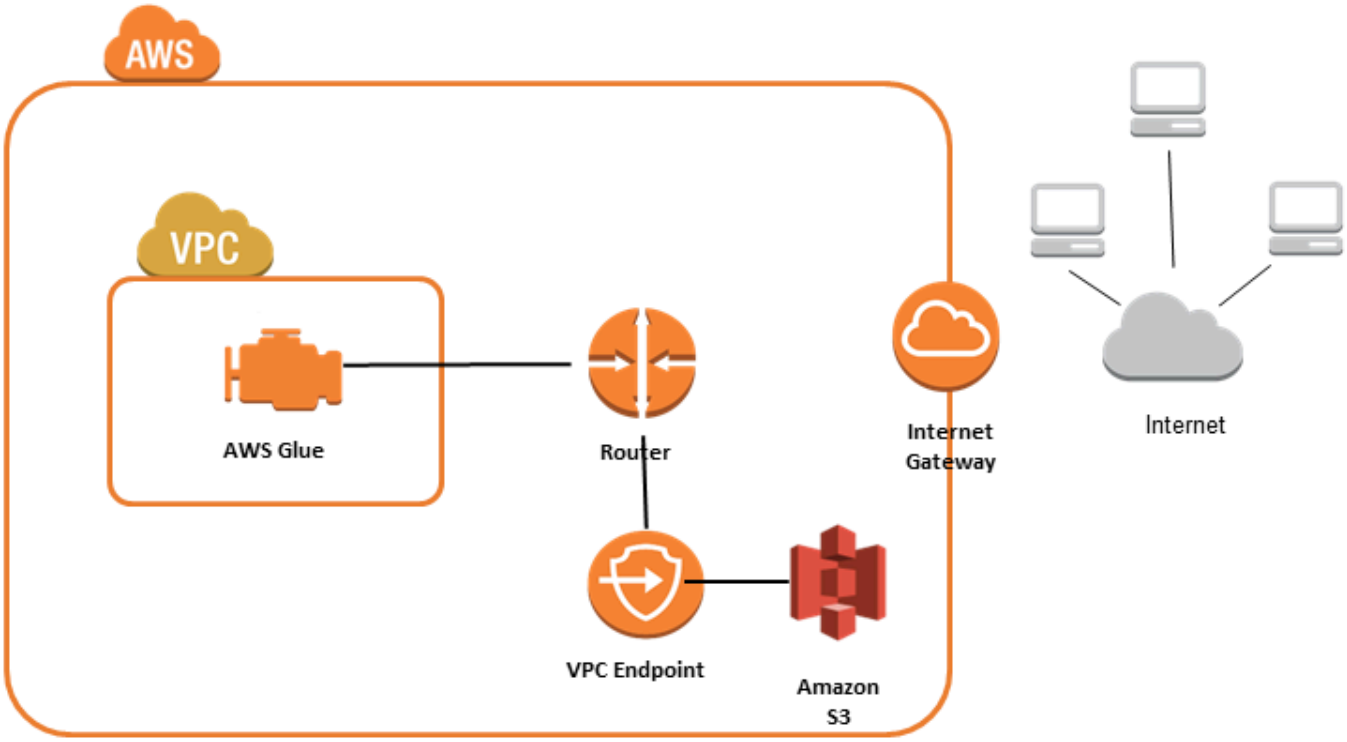

Para configurar o acesso ao Amazon S3

1. Faça login no AWS Management Console e abra o console da Amazon VPC em https://console.aws.amazon.com/vpc/.
2. No painel de navegação à esquerda, escolha Endpoints.
3. Escolha Create Endpoint (Criar endpoint) e siga as etapas para criar um endpoint da VPC do Amazon S3 do tipo Gateway.

Conexões do Amazon DocumentDB

É possível usar o AWS Glue para Spark para ler e gravar em tabelas no Amazon DocumentDB. Você pode se conectar ao Amazon DocumentDB usando credenciais armazenadas no AWS Secrets Manager por meio de uma conexão do AWS Glue.

Para obter mais informações sobre o Amazon DocumentDB, consulte a Documentação do Amazon DocumentDB.

> **Note**
>
> No momento, os clusters elásticos do Amazon DocumentDB não são compatíveis com o uso do conector do AWS Glue. Para obter mais informações sobre clusters elásticos, consulte Using Amazon DocumentDB elastic clusters.

Ler e gravar em coleções do Amazon DocumentDB

> **Note**
>
> Ao criar um trabalho de ETL que se conecta ao Amazon DocumentDB, para a propriedade de trabalho `Connections`, é necessário designar um objeto de conexão que especifica a nuvem privada virtual (VPC) em que o Amazon DocumentDB é executado. Para o objeto de conexão, o tipo de conexão deve ser `JDBC`, e o `JDBC URL` deve ser `mongo://<DocumentDB_host>:27017`.

> **Note**
>
> Estes exemplos de código foram desenvolvidos para o AWS Glue 3.0. Para migrar para o AWS Glue 4.0, consulte the section called “MongoDB”. O parâmetro `uri` foi alterado.

> **Note**
>
> Ao usar o Amazon DocumentDB, `retryWrites` deve ser definido como falso em determinadas situações, como quando o documento escrito especifica `_id`. Para obter mais informações, consulte Diferenças funcionais com o MongoDB na documentação do Amazon DocumentDB.

O script Python a seguir demonstra como usar tipos e opções de conexão para ler e gravar no 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()
```

O script Scala a seguir demonstra como usar tipos e opções de conexão para ler e gravar no 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)
  }
}
```

Referência de opções de conexão do Amazon DocumentDB

Designa uma conexão com o Amazon DocumentDB (compatível com MongoDB).

As opções de conexão diferem para uma conexão da fonte e uma conexão do coletor.

“connectionType”: “documentdb” como fonte

Use as seguintes opções de conexão com `"connectionType": "documentdb"` como fonte:

- `"uri"`: (obrigatório) o host do Amazon DocumentDB do qual fazer a leitura, formatado como `mongodb://<host>:<port>`.
- `"database"`: (obrigatório) o banco de dados do Amazon DocumentDB do qual fazer a leitura.
- `"collection"`: (obrigatório) a coleção do Amazon DocumentDB da qual fazer a leitura.
- `"username"`: (obrigatório) o nome de usuário do Amazon DocumentDB.
- `"password"`: (obrigatório) a senha do Amazon DocumentDB.
- `"ssl"`: (obrigatório se estiver usando SSL) se sua conexão usar SSL, você deve incluir essa opção com o valor `"true"`.
- `"ssl.domain_match"`: (obrigatório se estiver usando SSL) se sua conexão usar SSL, você deve incluir essa opção com o valor `"false"`.
- `"batchSize"`: (opcional) o número de documentos que devem ser retornados por lote, usado no cursor de lotes internos.
- `"partitioner"`: (opcional) o nome da classe do particionador do qual deve ser feita a leitura dos dados de entrada do Amazon DocumentDB. O conector fornece os seguintes particionadores:
  - `MongoDefaultPartitioner` (padrão) (sem suporte no AWS Glue 4.0)
  - `MongoSamplePartitioner` (sem suporte no AWS Glue 4.0)
  - `MongoShardedPartitioner`
  - `MongoSplitVectorPartitioner`
  - `MongoPaginateByCountPartitioner`
  - `MongoPaginateBySizePartitioner` (sem suporte no AWS Glue 4.0)
- `"partitionerOptions"`: (opcional) opções para o particionador designado. As seguintes opções são compatíveis com cada particionador:
  - `MongoSamplePartitioner`: `partitionKey`, `partitionSizeMB`, `samplesPerPartition`
  - `MongoShardedPartitioner`: `shardkey`
  - `MongoSplitVectorPartitioner`: `partitionKey`, partitionSizeMB
  - `MongoPaginateByCountPartitioner`: `partitionKey`, `numberOfPartitions`
  - `MongoPaginateBySizePartitioner`: `partitionKey`, partitionSizeMB

Para obter mais informações sobre essas opções, consulte Partitioner Configuration na documentação do MongoDB.

“connectionType”: “documentdb” como coletor

Use as seguintes opções de conexão com `"connectionType": "documentdb"` como coletor:

- `"uri"`: (obrigatório) o host do Amazon DocumentDB no qual fazer a gravação, formatado como `mongodb://<host>:<port>`.
- `"database"`: (obrigatório) o banco de dados do Amazon DocumentDB no qual fazer a gravação.
- `"collection"`: (obrigatório) a coleção do Amazon DocumentDB na qual fazer a gravação.
- `"username"`: (obrigatório) o nome de usuário do Amazon DocumentDB.
- `"password"`: (obrigatório) a senha do Amazon DocumentDB.
- `"extendedBsonTypes"`: (opcional) se `true`, permite tipos BSON estendidos ao gravar dados no Amazon DocumentDB. O padrão é `true`.
- `"replaceDocument"`: (opcional) se for `true`, substituirá todo o documento ao salvar conjuntos de dados que contêm um campo `_id`. Se for `false`, serão atualizados somente os campos do documento que correspondam aos campos do conjunto de dados. O padrão é `true`.
- `"maxBatchSize"`: (opcional) o tamanho máximo do lote para operações em massa ao salvar dados. O padrão é 512.
- `"retryWrites"`: (Opcional): repita automaticamente determinadas operações de escrita uma única vez se o AWS Glue encontrar um erro de rede.

Conexões do OpenSearch Service

O AWS Glue para Spark pode ser usado para ler e escrever em tabelas no OpenSearch Service no AWS Glue 4.0 e versões posteriores. Você pode definir o que deseja ler do OpenSearch Service com uma consulta do OpenSearch. Conecte-se ao OpenSearch Service usando credenciais de autenticação básica HTTP armazenadas no AWS Secrets Manager via conexão do AWS Glue. Esse recurso não é compatível com o OpenSearch Service com tecnologia sem servidor.

Para obter mais informações sobre o serviço Amazon OpenSearch Service, consulte a Documentação do Amazon OpenSearch Service.

Configurar conexões do OpenSearch Service

Para se conectar ao OpenSearch Service via AWS Glue, você precisará criar e armazenar suas credenciais do OpenSearch Service em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão AWS Glue OpenSearch Service.

Pré-requisitos:

- Identifique o endpoint do domínio, *aosEndpoint* e porta, *aosPort* do qual gostaria de ler, ou crie o recurso seguindo as instruções na documentação do Amazon OpenSearch Service. Para obter mais informações sobre a criação de domínios, consulte Criar e gerenciar domínios do Amazon OpenSearch Service na documentação do Amazon OpenSearch Service.

  Um endpoint de domínio do Amazon OpenSearch Service terá o seguinte formato padrão, https://search-*domainName*-*unstructuredIdContent*.*region*.es.amazonaws.com. Para obter mais informações sobre a identificação do endpoint do domínio, consulte Criar e gerenciar domínios do Amazon OpenSearch Service na documentação do Amazon OpenSearch Service.

  Identifique ou gere credenciais de autenticação básica HTTP, *aosUser* e *aosPassword* para seu domínio.

Para configurar uma conexão com o OpenSearch Service:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do OpenSearch Service. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

   - Ao selecionar Pares chave/valor, crie um par para a chave `USERNAME` com o valor *aosUser*.
   - Ao selecionar Pares chave/valor, crie um par para a chave `PASSWORD` com o valor *aosPassword*.
2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para uso futuro no AWS Glue.

   - Ao selecionar um Tipo de conexão, escolha OpenSearch Service.
   - Ao selecionar um endpoint de domínio, forneça *aosEndpoint*.
   - Ao selecionar uma porta, forneça *aosPort*.

- Ao selecionar um Segredo da AWS, forneça o *secretName*.

Depois de criar uma conexão AWS Glue OpenSearch Service, siga estas etapas antes de executar seu trabalho do AWS Glue:

- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *secretName*.
- Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional.

Ler dos índices do OpenSearch Service

Pré-requisitos:

- Um índice do OpenSearch Service do qual você gostaria de ler, *aosIndex*.
- Uma conexão do AWS Glue OpenSearch Service configurada para fornecer informações de autenticação e localização da rede. Para fazer isso, conclua as etapas do procedimento anterior, Para configurar uma conexão com o OpenSearch Service. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Este exemplo lê um índice do Amazon OpenSearch Service. Será necessário fornecer o parâmetro `pushdown`.

Por exemplo:

```
opensearch_read = glueContext.create_dynamic_frame.from_options(
    connection_type="opensearch",
    connection_options={
        "connectionName": "connectionName",
        "opensearch.resource": "aosIndex",
        "pushdown": "true",
    }
)
```

Você também pode fornecer uma srting de consulta para filtrar os resultados retornados em seu DynamicFrame. Você precisará configurar `opensearch.query`.

O `opensearch.query` pode usar uma string de parâmetros de consulta de URL *`queryString`* ou um objeto *`queryObject`* de consulta JSON DSL. Para obter mais informações sobre a consulta DSL, consulte Consulta DSL na documentação do OpenSearch. Para fornecer uma string de parâmetros de consulta de URL, adicione o prefixo `?q=` à sua consulta, como você faria em um URL totalmente qualificado. Para fornecer um objeto DSL de consulta, faça o escape de string do objeto JSON antes de fornecê-lo.

Por exemplo:

```
            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",
    }
)
```

Para obter mais informações sobre como criar uma consulta fora de sua sintaxe específica, consulte Sintaxe da string de consulta na documentação do OpenSearch.

Ao ler as coleções do OpenSearch que contêm dados do tipo de matriz, você deve especificar quais campos são do tipo de matriz em sua chamada de método usando o parâmetro `opensearch.read.field.as.array.include`.

Por exemplo, ao ler o documento abaixo, você encontrará os campos `genre` e `actor` de matriz:

```
{
    "_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"
    }
}
```

Nesse caso, você incluiria esses nomes de campo na chamada do método. Por exemplo:

```
"opensearch.read.field.as.array.include": "genre,actor"
```

Se o campo de matriz estiver aninhado dentro da estrutura do documento, consulte-o usando a notação de pontos: `"genre,actor,foo.bar.baz"`. Isso especificaria uma matriz `baz` incluída em seu documento de origem por meio do documento incorporado `foo` que contém o documento incorporado `bar`.

Escrever em tabelas do OpenSearch Service

Este exemplo escreve informações de um DynamicFrame existente, *dynamicFrame*, no OpenSearch Service. Se o índice já tiver informações, o AWS Glue anexará dados do seu DynamicFrame. Será necessário fornecer o parâmetro `pushdown`.

Pré-requisitos:

- Uma tabela do OpenSearch Service na qual você gostaria de escrever. Você precisará de informações de identificação para a tabela. Vamos chamar isso de *tableName*.
- Uma conexão do AWS Glue OpenSearch Service configurada para fornecer informações de autenticação e localização da rede. Para fazer isso, conclua as etapas do procedimento anterior, Para configurar uma conexão com o OpenSearch Service. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="opensearch",
    connection_options={
      "connectionName": "connectionName",
      "opensearch.resource": "aosIndex",
    },
)
```

Referência de opções de conexão do OpenSearch Service

- `connectionName` — Obrigatório. Usado para leitura/gravação. O nome de uma conexão do AWS Glue OpenSearch Service configurada para fornecer informações de autenticação e localização da rede ao seu método de conexão.
- `opensearch.resource` — Obrigatório. Usado para leitura/gravação. Valores válidos: nomes de índice do OpenSearch. O nome do índice com o qual seu método de conexão interagirá.
- `opensearch.query` - Usado para leitura. Valores válidos: JSON com escape de string ou, quando essa string começa com ?, a parte de pesquisa de um URL. Uma consulta do OpenSearch que filtra o que deve ser recuperado durante a leitura. Para obter mais informações sobre como usar esse parâmetro, consulte a seção the section called “Ler do OpenSearch Service” anterior.

- `pushdown`: exigido se. Usado para leitura. Valores válidos: booleano. Instrui o Spark a passar consultas de leitura para o OpenSearch para que o banco de dados retorne apenas documentos relevantes.
- `opensearch.read.field.as.array.include`: obrigatório ao ler dados do tipo matriz. Usado para leitura. Valores válidos: listas separadas por vírgulas de nomes de campo. Especifica os campos a serem lidos como matrizes de documentos do OpenSearch. Para obter mais informações sobre como usar esse parâmetro, consulte a seção the section called “Ler do OpenSearch Service” anterior.

Conexões do Redshift

Você pode usar o AWS Glue para Spark para ler e gravar tabelas nos bancos de dados do Amazon Redshift. Ao se conectar aos bancos de dados do Amazon Redshift, o AWS Glue move dados pelo Amazon S3 para obter o throughput máximo usando os comandos `COPY` e `UNLOAD` do Amazon Redshift SQL. No AWS Glue 4.0 e posteriores, você pode usar a integração do Amazon Redshift para Apache Spark para ler e gravar com otimizações e atributos específicos do Amazon Redshift além dos disponíveis ao fazer a conexão por meio das versões anteriores.

Saiba como o AWS Glue está tornando mais fácil do que nunca para os usuários do Amazon Redshift migrar para o AWS Glue para integração de dados e ETL com tecnologia sem servidor.

Configurar conexões do Redshift

Para usar clusters do Amazon Redshift no AWS Glue, você precisará de alguns pré-requisitos:

- Um diretório do Amazon S3 a ser usado para armazenamento temporário ao ler e gravar no banco de dados.
- Uma Amazon VPC que permita a comunicação entre o cluster do Amazon Redshift, o trabalho do AWS Glue e o diretório do Amazon S3.
- Permissões apropriadas do IAM no trabalho do AWS Glue e no cluster do Amazon Redshift.

Configurar perfis do IAM

Configurar o perfil para o cluster do Amazon Redshift

O cluster do Amazon Redshift precisa poder ler e gravar no Amazon S3 para se integrar com os trabalhos do AWS Glue. Para permitir isso, você pode associar perfis do IAM ao cluster do Amazon Redshift ao qual você deseja se conectar. Seu perfil deve ter uma política que permita ler e gravar

no diretório temporário do Amazon S3. Seu perfil deve ter uma relação de confiança que permita ao serviço `redshift.amazonaws.com` `AssumeRole`.

Para associar um perfil do IAM ao Amazon Redshift

1. Pré-requisitos: um bucket ou diretório do Amazon S3 usado para o armazenamento temporário de arquivos.
2. Identifique quais permissões do Amazon S3 o cluster do Amazon Redshift precisará ter. Ao mover dados entre um cluster do Amazon Redshift, os trabalhos do AWS Glue emitem instruções COPY e UNLOAD no Amazon Redshift. Se o trabalho modificar uma tabela no Amazon Redshift, o AWS Glue também emitirá instruções CREATE LIBRARY. Para obter informações sobre as permissões específicas do Amazon S3 necessárias para o Amazon Redshift executar essas instruções, consulte a documentação do Amazon Redshift: Amazon Redshift: Permissões para acessar outros recursos da AWS.
3. No console do IAM, crie uma política do IAM com as permissões necessárias. Para obter informações sobre a criação de uma política, consulte Criação de políticas do IAM.
4. No console do IAM, crie um perfil e uma relação de confiança que permita ao Amazon Redshift assumir o perfil. Siga as instruções na documentação do IAM Para criar um perfil para um serviço da AWS (console)

   - Quando solicitado a escolher um caso de uso de um serviço da AWS, escolha "Redshift: personalizável".
   - Quando solicitado a anexar uma política, escolha a política que você definiu anteriormente.

   > **Note**
   >
   > Para obter mais informações sobre a configuração de perfis para o Amazon Redshift, consulte Autorizar o Amazon Redshift a acessar outros serviços da AWS em seu nome na documentação do Amazon Redshift.

5. No console do Amazon Redshift, associe o perfil ao seu cluster do Amazon Redshift. Siga as instruções na documentação do Amazon Redshift.

   Selecione a opção realçada no console do Amazon Redshift para definir esta configuração:

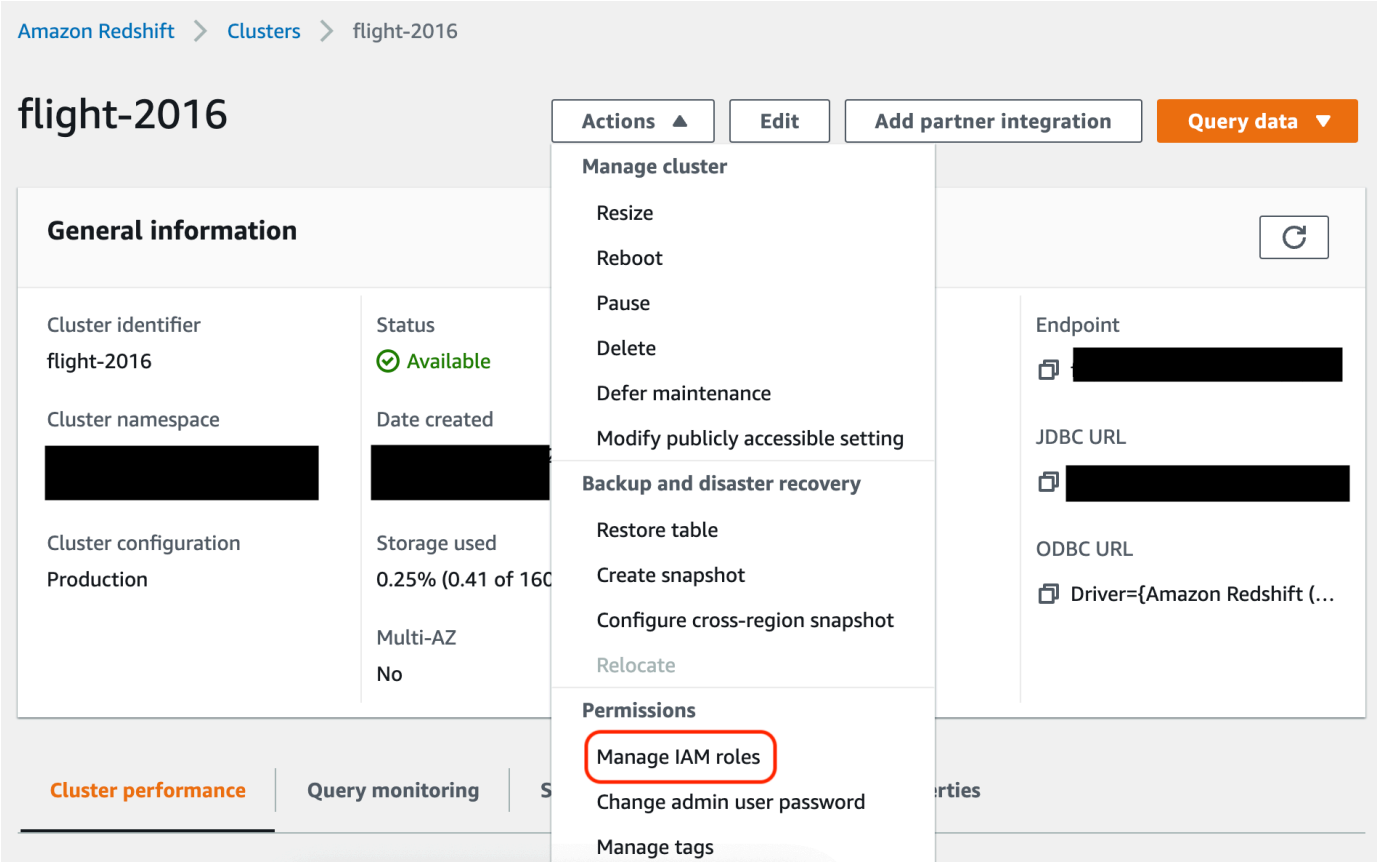

> **Note**
>
> Por padrão, o AWS Glue transmite credenciais temporárias do Amazon Redshift que são criadas usando o perfil que você especificou para executar o trabalho. Não recomendamos usar esses parâmetros para especificar credenciais. Por motivos de segurança, essas credenciais expiram após 1 hora.

Configurar o perfil para o trabalho do AWS Glue

O trabalho do AWS Glue precisa de um perfil para acessar o bucket do Amazon S3. Você não precisa de permissões do IAM para o cluster do Amazon Redshift, seu acesso é controlado pela conectividade no Amazon VPC e por suas credenciais do banco de dados.

Configurar a Amazon VCP

Para configurar o acesso aos armazenamentos de dados do Amazon Redshift

1. Faça login no AWS Management Console e abra o console do Amazon Redshift em https://console.aws.amazon.com/redshiftv2/.
2. No painel de navegação à esquerda, escolha Clusters.
3. Escolha o nome de cluster que você deseja acessar no AWS Glue.
4. Na seção Cluster Properties (Propriedades do cluster), escolha um grupo de segurança em VPC security groups (Grupos de segurança da VPC) para permitir que o AWS Glue o utilize. Anote o nome do security group que você escolheu para referência futura. Escolher o grupo de segurança abre a lista Security Groups (Grupos de segurança) do console do Amazon EC2.
5. Escolha o security group a ser modificado e navegue até a guia Inbound.
6. Adicione uma regra de autorreferência para permitir que os componentes do AWS Glue se comuniquem. Especificamente, adicione ou confirme que existe uma regra de Type `All TCP`, que Protocol é `TCP`, Port Range inclui todas as portas e Source e Group ID apresentam o mesmo nome de security group.

   O regra de entrada tem aparência semelhante a esta:

Tipo	Protocolo	Intervalo de portas	Origem
Todos os TCP	TCP	0–65535	database-security-group

   Por exemplo:

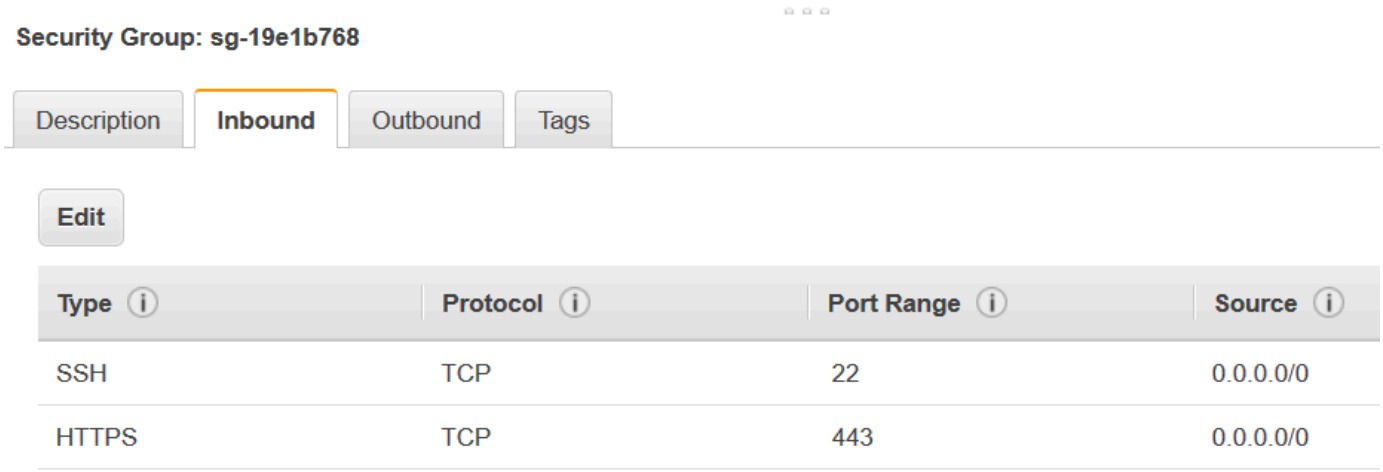

7. Adicione também uma regra para o tráfego de saída. Abra o tráfego de saída a todas as portas, por exemplo:

Tipo	Protocolo	Intervalo de portas	Destino
Todo o tráfego	ALL	ALL	0.0.0.0/0

Ou crie uma regra de autorreferência em que Type (Tipo) é `All TCP`, Protocol (Protocolo) é `TCP`, Port Range (Intervalo de portas) inclui todas as portas e cujo Destination (Destino) é o mesmo nome de security group de Group ID (ID de grupo). Se você estiver usando um endpoint da VPC do Amazon S3, adicione também uma regra HTTPS para acesso ao Amazon S3. O *`s3-prefix-list-id`* é necessário na regra do grupo de segurança para permitir o tráfego da VPC para o endpoint da VPC do Amazon S3.

Por exemplo:

Tipo	Protocolo	Intervalo de portas	Destino
Todos os TCP	TCP	0–65535	*`security-group`*
HTTPS	TCP	443	*`s3-prefix-list-id`*

Configurar o AWS Glue

Você precisará criar uma conexão do catálogo de dados do AWS Glue que forneça informações de conexão com a Amazon VPC.

Para configurar a conectividade da Amazon VPC do Amazon Redshift com o AWS Glue no console

1. Crie uma conexão do catálogo de dados seguindo as etapas em:the section called “Adicionar uma conexão do AWS Glue”. Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para a próxima etapa.

   - Ao selecionar um tipo de conexão, selecione Amazon Redshift.
   - Ao selecionar um cluster do Redshift, selecione seu cluster pelo nome.
   - Forneça informações de conexão padrão para um usuário do Amazon Redshift em seu cluster.
   - As configurações do Amazon VPC serão definidas automaticamente.

   > **Note**
   >
   > Você precisará fornecer `PhysicalConnectionRequirements` manualmente para a Amazon VPC ao criar uma conexão do Amazon Redshift por meio do SDK da AWS.

2. Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional.

Exemplo: leitura de tabelas do Amazon Redshift

Você pode ler nos clusters do Amazon Redshift e ambientes do Amazon Redshift sem servidor.

Pré-requisitos: uma tabela do Amazon Redshift que você deseja ler. *Siga as etapas da seção anterior the section called “Configurar o Redshift” e, depois disso, você deverá ter o URI do Amazon S3 para um diretório temporário, temp-s3-dir, e um perfil do IAM, rs-role-name, (na conta role-account-id*).

Using the Data Catalog

Pré-requisitos adicionais: um banco de dados e uma tabela do catálogo de dados para a tabela do Amazon Redshift que você deseja ler. Para obter mais informações sobre o catálogo de

dados, consulte Descoberta e catalogação de dados. *Depois de criar uma entrada para a tabela do Amazon Redshift, você identificará sua conexão com um redshift-dc-database-name e redshift-table-name.*

Configuração: nas opções de função, você identificará a tabela do catálogo de dados com os parâmetros `database` e `table_name`. Você identificará seu diretório temporário do Amazon S3 com `redshift_tmp_dir`. Você também fornecerá *rs-role-name* usando a chave `aws_iam_role` no parâmetro `additional_options`.

```
 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

Pré-requisitos adicionais: *você precisará do nome da sua tabela do Amazon Redshift (redshift-table-name*). Você precisará das informações da conexão JDBC para o cluster do Amazon Redshift que armazena essa tabela. Você fornecerá suas informações de conexão com *host*, *porta*, *redshift-database-name*, *nome de usuário* e *senha*.

Você pode recuperar suas informações de conexão no console do Amazon Redshift ao trabalhar com clusters do Amazon Redshift. Ao usar o Amazon Redshift sem servidor, consulte Conectar-se ao Amazon Redshift Serverless na documentação do Amazon Redshift.

Configuração: nas opções de função, você identificará os parâmetros `url`, `dbtable`, `user` e `password`. Você identificará seu diretório temporário do Amazon S3 com `redshift_tmp_dir`. Você pode especificar seu perfil do IAM usando `aws_iam_role` quando você usa `from_options`. A sintaxe é semelhante à conexão por meio do catálogo de dados, mas você coloca os parâmetros no mapa de `connection_options`.

Não é um prática recomendável codificar senhas em scripts do AWS Glue. Considere armazenar suas senhas do AWS Secrets Manager e recuperá-las no seu script com o 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)
```

Exemplo: gravaçr em tabelas do Amazon Redshift

Você pode ler dos clusters do Amazon Redshift e em ambientes do Amazon Redshift sem servidor.

Pré-requisitos: um cluster do Amazon Redshift e siga as etapas da seção anterior. the section called “Configurar o Redshift”. Depois disso, você deverá ter o URI do Amazon S3 para um diretório temporário, *temp-s3-dir* e um perfil do IAM, *rs-role-name*, (na conta *role-account-id*). Você também precisará de um `DynamicFrame` cujo conteúdo você deseja gravar no banco de dados.

Using the Data Catalog

Pré-requisitos adicionais: um banco de dados do catálogo de dados para o cluster do Amazon Redshift no qual que você deseja gravar. Para obter mais informações sobre o catálogo de dados, consulte Descoberta e catalogação de dados. *Você identificará sua conexão com redshift-dc-database-name e a tabela de destino com redshift-table-name*.

Configuração: nas opções de função, você identificará o banco de dados do catálogo de dados com o parâmetros `database` e depois fornecerá a tabela com `table_name`. Você identificará seu diretório temporário do Amazon S3 com `redshift_tmp_dir`. Você também fornecerá *rs-role-name* usando a chave `aws_iam_role` no parâmetro `additional_options`.

```
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

Você pode se conectar ao Amazon Redshift diretamente usando o método `write_dynamic_frame.from_options`. Porém, em vez de inserir os detalhes da conexão diretamente no script, você pode referenciar os detalhes da conexão armazenados em uma conexão do catálogo de dados com o método `from_jdbc_conf`. Você pode fazer isso sem fazer crawling ou criar tabelas do catálogo de dados para o banco de dados. Para obter mais informações sobre as conexões do catálogo de dados, consulte Conectar a dados.

Pré-requisitos adicionais: uma conexão do catálogo de dados para seu banco de dados, uma tabela do Amazon Redshift que você deseja ler

Configuração: você identificará sua conexão do catálogo de dados com *dc-connection-name*. *Você identificará seu banco de dados e tabela do Amazon Redshift com redshift-table-name e redshift-database-name*. Você fornecerá as informações de conexão do catálogo de dados com `catalog_connection` e as informações do Amazon Redshift com `dbtable` e `database`. A sintaxe é semelhante à conexão por meio do catálogo de dados, mas você coloca os parâmetros no mapa de `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"])
```

Referência da opções de conexão do Amazon Redshift

As opções básicas de conexão usadas em todas as conexões JDBC do AWS Glue para configurar informações como `url`, `user` e `password` são consistentes em todos os tipos de JDBC. Para obter mais informações sobre os parâmetros padrão de JDBC consulte the section called “Parâmetros de conexão JDBC”.

O tipo de conexão do Amazon Redshift tem algumas opções adicionais de conexão:

- `"redshiftTmpDir"`: (obrigatório) o caminho do Amazon S3 onde dados temporários podem ser preparados ao serem copiados para fora do banco de dados.
- `"aws_iam_role"`: (opcional) o ARN de um perfil do IAM. O trabalho AWS Glue passará esse perfil para o cluster do Amazon Redshift para conceder ao cluster as permissões necessárias para concluir as instruções do trabalho.

Opções adicionais de conexão disponíveis no AWS Glue 4.0+

Você também pode transmitir opções para o novo conector do Amazon Redshift por meio das opções de conexão do AWS Glue. Para obter uma lista completa das opções de conectores compatíveis, consulte a seção de Parâmetros do Spark SQL em Amazon Redshift integration for Apache Spark (Integração do Amazon Redshift for Apache Spark).

Para sua conveniência, reiteramos algumas novas opções aqui:

Name	Obrigatório	Padrão	Descrição
autopushdown	Não	VERDADEIRO	Aplica pushdown de predicados e consultas capturando e analisando os planos lógicos do Spark para operações SQL. As operações são traduzidas em uma consulta SQL e executadas no Amazon Redshift para

Name	Obrigatório	Padrão	Descrição
			melhorar a performance.
autopushdown.s3_result_cache	Não	FALSE	Armazena a consulta SQL para descarregar dados do mapeamento de caminhos do Amazon S3 na memória para que a mesma consulta não precise ser executada novamente na mesma sessão do Spark. Só é possível quando o `autopushdown` está habilitado.
unload_s3_format	Não	PARQUET	PARQUET - descarrega os resultados da consulta no formato Parquet. TEXT - descarrega os resultados da consulta em formato de texto delimitado por barras.

Name	Obrigatório	Padrão	Descrição
sse_kms_key	Não	N/D	A chave do AWS SSE-KMS a ser usada para criptografia durante as operações, de `UNLOAD` em vez da criptografia padrão para AWS.
extracopyoptions	Não	N/D	Uma lista de opções extras para anexar ao comando `COPY` do Amazon Redshift ao carregar dados, como `TRUNCATECOLUMNS` ou `MAXERROR n` (para outras opções, consulte COPY: parâmetros opcionais). Observe que, como essas opções são anexadas ao fim do comando `COPY`, apenas opções que façam sentido no final do comando podem ser usadas. Isso deve abranger a maioria dos casos de uso possíveis.

Name	Obrigatório	Padrão	Descrição
csvnullstring (experimental)	Não	NULL	O valor da string a ser gravado para nulos ao usar o `tempformat` CSV. Esse deve ser um valor que não apareça nos dados reais.

Esses novos parâmetros podem ser usados como se segue.

Novas opções para melhoria de performance

O novo conector introduz algumas novas opções de melhoria de performance:

- `autopushdown`: habilitado por padrão.
- `autopushdown.s3_result_cache`: desabilitado por padrão.
- `unload_s3_format`: `PARQUET` por padrão.

Para obter informações sobre como usar essas opções, consulte Amazon Redshift integration for Apache Spark (Integração do Amazon Redshift for Apache Spark). Recomendamos que você não ative o `autopushdown.s3_result_cache` quando tiver operações mistas de leitura e gravação, pois os resultados em cache podem conter informações obsoletas. A opção `unload_s3_format` é definida como `PARQUET` por padrão para o comando `UNLOAD`, para melhorar a performance e reduzir o custo de armazenamento. Para usar o comportamento padrão do comando `UNLOAD`, redefina a opção como `TEXT`.

Nova opção de criptografia para leitura

Por padrão, os dados na pasta temporária usada pelo AWS Glue ao ler dados da tabela do Amazon Redshift são criptografados usando a criptografia `SSE-S3`. Para usar as chaves gerenciadas pelo cliente do AWS Key Management Service (AWS KMS) para criptografar dados, você pode configurar `("sse_kms_key" # kmsKey)` em que ksmKey é a ID da chave do AWS KMS, em vez da opção de configuração antiga `("extraunloadoptions" # s"ENCRYPTED KMS_KEY_ID '$kmsKey'")` no AWS Glue versão 3.0.

```
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"
)
```

Compatibilidade com a URL JDBC baseada no IAM

O novo conector é compatível com uma URL JDBC baseada no IAM para que você não precise passar um usuário/senha ou um segredo. Com uma URL JDBC baseada no IAM, o conector usa o perfil de runtime de trabalho para acessar a fonte de dados do Amazon Redshift.

Etapa 1: anexar a seguinte política mínima exigida ao perfil de runtime 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": "*"
        }
    ]
}
```

Etapa 2: usar a URL do JDBC baseado em IAM como se segue. Especifique uma nova opção `DbUser` com o nome de usuário do Amazon Redshift com o qual você está se conectando.

```
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**
>
> Atualmente, um `DynamicFrame` é compatível apenas com uma URL JDBC baseada no IAM com um `DbUser` no fluxo de trabalho `GlueContext.create_dynamic_frame.from_options`.

Migrar do AWS Glue versão 3.0 para a versão 4.0

No AWS Glue 4.0, trabalhos de ETL têm acesso a um novo conector do Amazon Redshift Spark e um novo driver JDBC com opções e configurações diferentes. O novo conector e o novo driver do Amazon Redshift foram criados pensando em performance e mantêm a consistência transacional dos dados. Esses produtos estão documentados na documentação do Amazon Redshift. Para obter mais informações, consulte:

- Integração do Amazon Redshift for Apache Spark
- Driver JDBC do Amazon Redshift, versão 2.1

Restrição de nomes e identificadores de tabelas/colunas

O novo conector e driver do Amazon Redshift Spark têm um requisito mais restrito para o nome da tabela do Redshift. Para obter mais informações, consulte Nomes e identificadores para definir o nome da tabela do Amazon Redshift. O fluxo de trabalho de marcadores de trabalho pode não funcionar com um nome de tabela que não corresponda às regras e com determinados caracteres, como espaço.

Se você tiver tabelas antigas com nomes que não estão em conformidade com as regras de nomes e identificadores e tiver problemas com marcadores (trabalhos que reprocessam dados de tabelas antigas do Amazon Redshift), recomendamos que você renomeie as tabelas. Para obter mais informações, consulte Exemplos de ALTER TABLE.

Alteração de tempformat padrão no Dataframe

O conector Spark versão 3.0 da AWS Glue usa como padrão o `tempformat` para CSV ao gravar no Amazon Redshift. Para ser consistente, no AWS Glue versão 3.0, o `DynamicFrame` ainda tem como padrão que o `tempformat` use `CSV`. Se você já usou APIs de Dataframe do Spark diretamente com o conector do Amazon Redshift Spark, você pode definir explicitamente o `tempformat` como CSV nas opções `DataframeReader/Writer`. Caso contrário, o padrão para `tempformat` é `AVRO` no novo conector Spark.

Alteração de comportamento: mapeie o tipo de dados REAL do Amazon Redshift para o tipo de dados do FLOAT do Spark, em vez de DOUBLE

No AWS Glue versão 3.0, o Amazon Redshift `REAL` é convertido em um tipo `DOUBLE` do Spark. O novo conector do Amazon Redshift Spark atualizou o comportamento para que o tipo `REAL` do Amazon Redshift seja convertido para o tipo `FLOAT` do Spark e vice-versa. Se você tiver um caso de uso antigo em que ainda desejar que o tipo `REAL` do Amazon Redshift seja mapeado para um tipo `DOUBLE` do Spark, poderá usar a seguinte solução alternativa:

- Para um `DynamicFrame`, mapeie o tipo `Float` para um tipo `Double` com `DynamicFrame.ApplyMapping`. Para um `Dataframe`, você precisa usar `cast`.

Exemplo de código:

```
dyf_cast = dyf.apply_mapping([('a', 'long', 'a', 'long'), ('b', 'float', 'b',
 'double')])
```

Manipular o tipo de dados VARBYTE

Ao trabalhar com tipos de dados do AWS Glue 3.0 e do Amazon Redshift, o AWS Glue 3.0 converte o `VARBYTE` Redshift para o tipo Spark `STRING`. No entanto, o conector Spark mais recente do Amazon Redshift não é compatível com o tipo de dados `VARBYTE`. Para contornar essa limitação, você pode criar uma visualização do Redshift que transforma colunas `VARBYTE` em um tipo de dados compatível. Em seguida, use o novo conector para carregar dados dessa visualização em vez da tabela original, o que garante a compatibilidade e mantém o acesso aos seus dados `VARBYTE`.

Exemplo de consulta do Redshift:

```
CREATE VIEW view_name AS SELECT FROM_VARBYTE(varbyte_column, 'hex') FROM table_name
```

Conexões do Kafka

É possível usar uma conexão do Kafka para ler e gravar fluxos de dados do Kafka usando informações armazenadas em uma tabela do Catálogo de Dados ou fornecendo informações para acessar diretamente o fluxo de dados. A conexão é compatível com um cluster do Kafka ou um cluster do Amazon Managed Streaming for Apache Kafka. Você pode ler informações do Kafka em um Spark DataFrame e depois convertê-las em um AWS Glue DynamicFrame. É possível gravar DynamicFrames no Kafka em um formato JSON. Se você acessar diretamente o fluxo de dados, use essas opções para fornecer as informações sobre como acessar o fluxo de dados.

Se você usar `getCatalogSource` ou `create_data_frame_from_catalog` para consumir registros de uma fonte de streaming do Kafka, ou `getCatalogSink` ou `write_dynamic_frame_from_catalog` para gravar registros no Kafka, e o trabalho tiver o banco de dados do catálogo de dados e as informações de nome da tabela, e poderá usá-los para obter alguns parâmetros básicos para leitura da fonte de streaming do Kafka. Se você usar `getSource`, `getCatalogSink`, `getSourceWithFormat`, `getSinkWithFormat`, `createDataFrameFromOptions`, `create_data_frame_from_options` ou `write_dynamic_frame_from_catalog`, será necessário especificar esses parâmetros básicos usando as opções de conexão descritas aqui.

Você pode especificar as opções de conexão para o Kafka usando os seguintes argumentos para os métodos especificados na classe `GlueContext`.

- Scala
  - `connectionOptions`: usar com `getSource`, `createDataFrameFromOptions`, `getSink`
  - `additionalOptions`: usar com `getCatalogSource`, `getCatalogSink`
  - `options`: usar com `getSourceWithFormat`, `getSinkWithFormat`

- Python
  - `connection_options`: usar com `create_data_frame_from_options`, `write_dynamic_frame_from_options`
  - `additional_options`: usar com `create_data_frame_from_catalog`, `write_dynamic_frame_from_catalog`
  - `options`: usar com `getSource`, `getSink`

Para notas e restrições sobre trabalhos de ETL de streaming, consulte the section called “Notas e restrições sobre ETL de transmissão”.

Configurar o Kafka

Não há pré-requisitos da AWS para se conectar aos fluxos do Kafka disponíveis pela Internet.

Você pode criar uma conexão do AWS Glue Kafka para gerenciar suas credenciais de conexão. Para ter mais informações, consulte the section called “Criar uma conexão para um fluxo de dados do Kafka”. Na configuração do trabalho do AWS Glue, forneça *`connectionName`* como uma conexão de rede adicional e depois na chamada do método, forneça *`connectionName`* para o parâmetro `connectionName`.

Em certos casos, você precisará configurar pré-requisitos adicionais:

- Se estiver usando o Amazon Managed Streaming for Apache Kafka com autenticação do IAM, você precisará da configuração apropriada do IAM.
- Se estiver usando o Amazon Managed Streaming for Apache Kafka com uma Amazon VPC, você precisará da configuração apropriada do Amazon VPC. Você precisará criar uma conexão do AWS Glue que forneça informações de conexão com o Amazon VPC. Você precisará que a configuração do trabalho inclua a conexão do AWS Glue como uma conexão de rede adicional.

Para obter mais informações sobre pré-requisitos de trabalho de ETL de streaming, consulte the section called “Trabalhos de transmissão de ETL”.

Exemplo: leitura de fluxos do Kafka

Usado em conjunto com the section called “forEachBatch”.

Exemplo para fonte de transmissão do 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)
```

Exemplo: gravação em fluxos do Kafka

Exemplos de gravação no Kafka:

Exemplo com o método `getSink`:

```
data_frame_datasource0 =
glueContext.getSink(
 connectionType="kafka",
 connectionOptions={
  JsonOptions("""{
   "connectionName": "ConfluentKafka",
   "classification": "json",
   "topic": "kafka-auth-topic",
   "typeOfData": "kafka"}
  """)},
 transformationContext="dataframe_ApacheKafka_node1711729173428")
 .getDataFrame()
```

Exemplo com o método `write_dynamic_frame.from_options`:

```
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)
```

Referência de opções de conexão do Kafka

Ao ler, use as seguintes opções de conexão com `"connectionType": "kafka"`:

- `"bootstrap.servers"` (obrigatório) uma lista de URLs do servidor de bootstrap, por exemplo, como `b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Essa opção deve ser especificada na chamada de API ou definida nos metadados da tabela no Data Catalog.
- `"security.protocol"` (obrigatório) O protocolo usado para se comunicar com os agentes. Os valores possíveis são `"SSL"` ou `"PLAINTEXT"`.
- `"topicName"` (Obrigatório): uma lista separada por vírgulas de tópicos para assinar. É necessário especificar um e apenas um de `"topicName"`, `"assign"` ou `"subscribePattern"`.
- `"assign"` (Obrigatório): uma string JSON para especificar o `TopicPartitions` a ser consumido. É necessário especificar um e apenas um de `"topicName"`, `"assign"` ou `"subscribePattern"`.

  Exemplo: '{"topicA":[0,1],"topicB":[2,4]}'
- `"subscribePattern"`: (obrigatório) uma string regex Java que identifica a lista de tópicos para assinar. É necessário especificar um e apenas um de `"topicName"`, `"assign"` ou `"subscribePattern"`.

  Exemplo: 'topic.*'
- `"classification"` (Obrigatório) O formato de arquivo usado pelos dados no registro. Obrigatório, a menos que fornecido por meio do catálogo de dados.
- `"delimiter"` (Opcional) O separador de valores usado quando a `classification` é CSV. O padrão é `","`.
- `"startingOffsets"`: (opcional) a posição inicial no tópico do Kafka de onde ler os dados. Os valores possíveis são `"earliest"` ou `"latest"`. O valor padrão é `"latest"`.
- `"startingTimestamp"`: (opcional, compatível somente com o AWS Glue versão 4.0 ou posterior) O timestamp do registro no tópico do Kafka do qual ler os dados. O valor possível é uma string de timestamp no formato UTC no padrão `yyyy-mm-ddTHH:MM:SSZ` (onde `Z` representa um desvio do fuso horário UTC com +/-). Por exemplo: "2023-04-04T08:00:00-04:00").

  Observação: somente um dos 'startingOffsets' ou 'startingTimestamp' pode estar presente na lista de opções de conexão do script de streaming do AWS Glue. A inclusão de ambas as propriedades resultará em falha no trabalho.
- `"endingOffsets"`: (opcional) o ponto final quando uma consulta em lote é encerrada. Os valores possíveis são `"latest"` ou uma string JSON que especifica um deslocamento final para cada `TopicPartition`.

Para a string JSON, o formato é `{"topicA":{"0":23,"1":-1},"topicB":{"0":-1}}`. O valor `-1` como um deslocamento representa `"latest"`.

- `"pollTimeoutMs"`: (opcional) o tempo limite em milissegundos para sondar dados do Kafka em executores de trabalho do Spark. O valor padrão é `600000`.
- `"numRetries"`: (opcional) o número de novas tentativas antes de falhar em obter os deslocamentos do Kafka. O valor padrão é `3`.
- `"retryIntervalMs"`: (opcional) o tempo em milissegundos a se esperar antes de tentar novamente buscar os deslocamentos do Kafka. O valor padrão é `10`.
- `"maxOffsetsPerTrigger"`: (opcional) o limite de taxa no número máximo de deslocamentos que são processados por intervalo do acionador. O número total especificado de deslocamentos é dividido proporcionalmente entre `topicPartitions` de diferentes volumes. O valor padrão é nulo, o que significa que o consumidor lê todos os deslocamentos até o deslocamento mais recente conhecido.
- `"minPartitions"`: (opcional) o número mínimo desejado de partições a serem lidas do Kafka. O valor padrão é nulo, o que significa que o número de partições do Spark é igual ao número de partições do Kafka.
- `"includeHeaders"`: (opcional) informa se deve incluir os cabeçalhos do Kafka. Quando a opção estiver definida como "true", a saída de dados conterá uma coluna adicional chamada "glue_streaming_kafka_headers" com o tipo `Array[Struct(key: String, value: String)]`. O valor padrão é “false”. Essa opção está disponível no AWS Glue versão 3.0 ou posterior.
- `"schema"` (Obrigatório quando inferSchema é definido como false): o esquema a ser usado para processar a carga útil. Se a classificação for `avro`, o esquema fornecido deverá estar no formato de esquema Avro. Se a classificação não for `avro`, o esquema fornecido deverá estar no formato de esquema DDL.

  Veja a seguir alguns exemplos de esquema.

  Example 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"` (Opcional): o valor padrão é "false". Se definido como “true”, o esquema será detectado em runtime com base na carga útil em `foreachbatch`.
- `"avroSchema"` (Descontinuado): parâmetro usado para especificar um esquema de dados Avro quando o formato Avro é usado. Esse parâmetro foi descontinuado. Use o parâmetro `schema`.
- `"addRecordTimestamp"`: (opcional) quando essa opção for definida como “true“, a saída de dados conterá uma coluna adicional denominada “__src_timestamp” que indica a hora em que o registro correspondente foi recebido pelo tópico. O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.
- `"emitConsumerLagMetrics"`: (opcional) quando a opção for definida como "true", para cada lote, serão emitidas métricas durante o período entre a hora que o registro mais antigo é recebido pelo tópico e a hora que ele chega ao AWS Glue para o CloudWatch. O nome da métrica é "glue.driver.streaming.maxConsumerLagInMs". O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.

Ao gravar, use as seguintes opções de conexão com o `"connectionType": "kafka"`:

- `"connectionName"` (Obrigatório) Nome da conexão do AWS Glue usada para se conectar ao cluster do Kafka (semelhante à origem do Kafka).
- `"topic"` (Obrigatório) Se uma coluna de tópico existir, seu valor será usado como tópico ao gravar a linha especificada no Kafka, a menos que a opção de configuração do tópico esteja definida. Ou seja, a opção de configuração `topic` substitui a coluna do tópico.
- `"partition"` (Opcional) Se um número de partição válido for especificado, essa `partition` será usada no envio do registro.

  Se nenhuma partição for especificada, mas uma `key` estiver presente, uma partição será escolhida usando um hash da chave.

  Se nem `key` nem `partition` estiverem presentes, uma partição será escolhida com base no particionamento fixo dessas alterações quando pelo menos bytes batch.size forem produzidos na partição.
- `"key"` (Opcional) Usado para particionar se `partition` for nulo.
- `"classification"` (Opcional) O formato de arquivo usado pelos dados no registro. Só oferecemos suporte a JSON, CSV e Avro.

  Com o formato Avro, podemos fornecer um avroSchema personalizado para serializar, mas observe que isso também precisa ser fornecido na fonte para desserialização. Caso contrário, por padrão, ele usa o Apache AvroSchema para serializar.

Além disso, você pode ajustar o coletor Kafka conforme necessário atualizando os parâmetros de configuração do produtor Kafka. Observe que não há nenhuma lista de permissões nas opções de conexão. Todos os pares de chave-valor são mantidos no coletor como estão.

No entanto, há uma pequena lista de opções negadas que não entrarão em vigor. Para obter mais informações, consulte Configurações específicas do Kafka.

Conexões do Azure Cosmos DB

O AWS Glue para Spark pode ser usado para ler e escrever em contêineres existentes no Azure Cosmos DB usando a API NoSQL no AWS Glue 4.0 e versões posteriores. Você pode definir o que ler no Azure Cosmos DB com uma consulta SQL. Conecte-se ao Azure Cosmos DB usando uma chave do Azure Cosmos DB armazenada no AWS Secrets Manager via conexão do AWS Glue.

Para obter mais informações sobre o Azure Cosmos DB para NoSQL, consulte a Documentação do Azure.

Configurar conexões do Azure Cosmos DB

Para se conectar ao Azure Cosmos DB via AWS Glue, será necessário criar e armazenar sua chave do Azure Cosmos DB em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão do Azure Cosmos DB AWS Glue.

Pré-requisitos:

- No Azure, será necessário identificar ou gerar uma chave do Azure Cosmos DB para uso pelo AWS Glue, `cosmosKey`. Para obter mais informações, consulte Acesso seguro a dados no Azure Cosmos DB na documentação do Azure.

Para configurar uma conexão com o Azure Cosmos DB:

1. No AWS Secrets Manager, crie um segredo usando sua chave do Azure Cosmos DB. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.
   - Ao selecionar Pares chave/valor, crie um par para a chave `spark.cosmos.accountKey` com o valor *`cosmosKey`*.
2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *`connectionName`*, para uso futuro no AWS Glue.
   - Ao selecionar um Tipo de conexão, selecione Azure Cosmos DB.
   - Ao selecionar um Segredo da AWS, forneça o *`secretName`*.

Depois de criar uma conexão AWS Glue Azure Cosmos DB, siga estas etapas antes de executar seu trabalho do AWS Glue:

- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *`secretName`*.
- Na configuração do trabalho do AWS Glue, forneça *`connectionName`* como uma conexão de rede adicional.

Ler de contêineres do Azure Cosmos DB para NoSQL

Pré-requisitos:

- Um contêiner do Azure Cosmos DB para NoSQL do qual você gostaria de ler. Você precisará de informações de identificação para o contêiner.

  Um contêiner do Azure Cosmos para NoSQL é identificado por seu banco de dados e contêiner. É necessário fornecer os nomes do banco de dados, *cosmosDBName* e do contêiner, *cosmosContainerName*, ao se conectar à API do Azure Cosmos para NoSQL.
- Uma conexão do AWS Glue Azure Cosmos DB configurada para fornecer informações de autenticação e localização da rede. Para fazer isso, conclua as etapas do procedimento anterior, Para configurar uma conexão com o Azure Cosmos DB. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
azurecosmos_read = glueContext.create_dynamic_frame.from_options(
    connection_type="azurecosmos",
    connection_options={
    "connectionName": connectionName,
    "spark.cosmos.database": cosmosDBName,
    "spark.cosmos.container": cosmosContainerName,
    }
)
```

Você também pode fornecer uma consulta SQL SELECT para filtrar os resultados retornados ao seu DynamicFrame. Você precisará configurar `query`.

Por exemplo:

```
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"
    }
)
```

Escrever em contêineres do Azure Cosmos DB para NoSQL

Este exemplo escreve informações de um DynamicFrame existente, *dynamicFrame*, no Azure Cosmos DB. Se o contêiner já contiver informações, o AWS Glue anexará dados do seu DynamicFrame. Se as informações no contêiner tiverem um esquema diferente das informações que você escrever, haverá erros.

Pré-requisitos:

- Uma tabela do Azure Cosmos DB em que você deseja escrever. Você precisará de informações de identificação para o contêiner. É necessário criar o contêiner antes de chamar o método de conexão.

  Um contêiner do Azure Cosmos para NoSQL é identificado por seu banco de dados e contêiner. É necessário fornecer os nomes do banco de dados, *cosmosDBName* e do contêiner, *cosmosContainerName*, ao se conectar à API do Azure Cosmos para NoSQL.
- Uma conexão do AWS Glue Azure Cosmos DB configurada para fornecer informações de autenticação e localização da rede. Para fazer isso, conclua as etapas do procedimento anterior, Para configurar uma conexão com o Azure Cosmos DB. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
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
)
```

Referência de opções de conexão do Azure Cosmos DB

- `connectionName` — Obrigatório. Usado para leitura/gravação. O nome de uma conexão AWS Glue Azure Cosmos DB configurada para fornecer informações de autenticação e localização da rede ao seu método de conexão.
- `spark.cosmos.database` — Obrigatório. Usado para leitura/gravação. Valores válidos: nomes de bancos de dados. Nome do banco de dados do Azure Cosmos DB para NoSQL.

- `spark.cosmos.container` — Obrigatório. Usado para leitura/gravação. Valores válidos: nomes de contêineres. Nome do contêiner do Azure Cosmos DB para NoSQL.
- `spark.cosmos.read.customQuery` - Usado para leitura. Valores válidos: consultas SQL SELECT. Consulta personalizada para selecionar documentos a serem lidos.

Conexões do Azure SQL

O AWS Glue para Spark pode ser usado para ler e gravar em tabelas em instâncias gerenciadas do Azure SQL no AWS Glue 4.0 e versões posteriores. Você pode definir o que ler no Azure SQL com uma consulta SQL. Conecte-se ao Azure SQL usando credenciais de usuário e senha armazenadas no AWS Secrets Manager via conexão do AWS Glue.

Para obter mais informações sobre o Azure SQL, consulte a Documentação do Azure SQL.

Configurar conexões do Azure SQL

Para se conectar ao Azure SQL via AWS Glue, será necessário criar e armazenar sua credenciais do Azure SQL em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão do Azure SQL AWS Glue.

Para configurar uma conexão com o Azure SQL:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do Azure SQL. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.
   - Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *`azuresqlUsername`*.
   - Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *`azuresqlPassword`*.
2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *`connectionName`*, para uso futuro no AWS Glue.
   - Ao selecionar um Tipo de conexão, selecione Azure SQL.
   - Ao fornecer o URL do Azure SQL, forneça um URL de endpoint do JDBC.

Essa lista deve estar no seguinte formato:
`jdbc:sqlserver://databaseServerName:databasePort;databaseName=azuresqlDBnam`

O AWS Glue requer as seguintes propriedades de URL:

- `databaseName`: um banco de dados padrão no Azure SQL ao qual se conectar.

Para obter mais informações sobre URLs de JDBC para instâncias gerenciadas Azure SQL, consulte a Documentação da Microsoft.

- Ao selecionar um Segredo da AWS, forneça o *secretName*.

Depois de criar uma conexão AWS Glue Azure SQL, siga estas etapas antes de executar seu trabalho do AWS Glue:

- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *secretName*.
- Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional.

Ler de tabelas SQL do Azure

Pré-requisitos:

- Uma tabela do Azure SQL da qual você deseja ler. Você precisará de informações de identificação para a tabela, *databaseName* e *tableIdentifier*.

  Uma tabela do Azure SQL é identificada por seu banco de dados, esquema e nome da tabela. É necessário fornecer o nome do banco de dados e o nome da tabela ao se conectar ao Azure SQL. Você também deverá fornecer o esquema se ele não for o padrão, "public". O banco de dados é fornecido por meio de uma propriedade de URL em *connectionName*, esquema e nome da tabela via `dbtable`.
- Uma conexão AWS Glue Azure SQL configurada para fornecer informações de autenticação. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o Azure SQL para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
azuresql_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type="azuresql",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableIdentifier"
    }
)
```

Você também pode fornecer uma consulta SQL SELECT para filtrar os resultados retornados ao seu DynamicFrame. Você precisará configurar `query`.

Por exemplo:

```
azuresql_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="azuresql",
    connection_options={
        "connectionName": "connectionName",
        "query": "query"
    }
)
```

Escrevendo em tabelas do Azure SQL

Este exemplo escreve informações de um DynamicFrame existente, *`dynamicFrame`*, no Azure SQL. Se a tabela já contiver informações, o AWS Glue anexará dados do seu DynamicFrame.

Pré-requisitos:

- Uma tabela do Azure SQL em que você deseja escrever. Você precisará de informações de identificação para a tabela, *`databaseName`* e *`tableIdentifier`*.

  Uma tabela do Azure SQL é identificada por seu banco de dados, esquema e nome da tabela. É necessário fornecer o nome do banco de dados e o nome da tabela ao se conectar ao Azure SQL. Você também deverá fornecer o esquema se ele não for o padrão, "public". O banco de dados é fornecido por meio de uma propriedade de URL em *`connectionName`*, esquema e nome da tabela via `dbtable`.
- Informações de autenticação do Azure SQL. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o Azure SQL para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *`ConnectionName`*.

Por exemplo:

```
azuresql_write = glueContext.write_dynamic_frame.from_options(
    connection_type="azuresql",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableIdentifier"
    }
)
```

Referência de opções de conexão do Azure SQL

- `connectionName` — Obrigatório. Usado para leitura/gravação. O nome de uma conexão AWS Glue Azure SQL configurada para fornecer informações de autenticação e localização da rede ao seu método de conexão.
- `databaseName`: usado para leitura/gravação. Valores válidos: nomes de bancos de dados do Azure SQL. O nome do banco de dados do Azure SQL ao qual conectar.
- `dbtable`: necessário para escrever, obrigatório para leitura, a menos que `query` seja fornecido. Usado para leitura/gravação. Valores válidos: nomes de tabelas do Azure SQL ou combinações de nomes de esquema/tabela separados por pontos. Usado para especificar a tabela e o esquema que identificam a tabela à qual conectar. O esquema padrão é "public". Se sua tabela estiver em um esquema não padrão, forneça essas informações no formulário *`schemaName`*`.`*`tableName`*.
- `query` - Usado para leitura. Uma consulta SQL SELECT que define o que deve ser recuperado na leitura do Azure SQL. Para obter mais informações, consulte a Documentação da Microsoft.

Conexões BigQuery

Você pode usar o AWS Glue for Spark para ler e gravar tabelas no Google BigQuery no AWS Glue 4.0 e versões posteriores. Você pode ler no BigQuery com uma consulta do Google SQL. Você se conecta ao BigQuery usando credenciais armazenadas AWS Secrets Manager por meio de uma conexão AWS Glue.

Para obter mais informações sobre o Google BigQuery, consulte o site do Google Cloud BigQuery.

Configurar conexões BigQuery

Para se conectar ao Google BigQuery a partir do AWS Glue, você precisará criar e armazenar suas credenciais do Google Cloud Platform em um segredo e, em seguida, associar esse AWS Secrets Manager segredo a uma conexão do Google BigQuery AWS Glue.

Para configurar uma conexão com o BigQuery:

1. No Google Cloud Platform, crie e identifique recursos relevantes:

   - Crie ou identifique um projeto do GCP contendo tabelas do BigQuery às quais você gostaria de se conectar.
   - Ative a API BigQuery. Para obter mais informações, consulte Use the BigQuery Storage Read API to read na tabela.

2. No Google Cloud Platform, crie e exporte as credenciais da conta de serviço:

   Você pode usar o assistente de credenciais do BigQuery para acelerar essa etapa: criar credenciais.

   Para criar uma conta de serviço no GCP, siga o tutorial disponível em Criar contas de serviço.

   - Ao selecionar o projeto, selecione o projeto que contém sua tabela do BigQuery.
   - Ao selecionar perfis do IAM do GCP para sua conta de serviço, adicione ou crie um papel que conceda permissões apropriadas para executar jobs do BigQuery para ler, gravar ou criar tabelas do BigQuery.

   Para criar credenciais para a sua conta de serviço, siga o tutorial disponível em Criar uma chave da conta de serviço.

   - Ao selecionar o tipo de chave, selecione JSON.

   Agora você deve ter baixado um arquivo JSON com credenciais para sua conta de serviço. A aparência deve ser semelhante à seguinte:

```
{
  "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. base64 codifica seu arquivo de credenciais baixado. Em uma AWS CloudShell sessão ou similar, você pode fazer isso na linha de comando executando `cat` *`credentialsFile.json`* `| base64 -w 0`. Mantenha a saída desse comando, *`credentialString`*.
4. Nos AWS Secrets Manager, crie um segredo usando suas credenciais do Google Cloud Platform. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.
   - *Ao selecionar* ***pares de chave/valor****, crie um par para a chave* *`credentials`* *com o valor* *`credentialString`*.
5. No catálogo de dados do AWS Glue, crie uma conexão seguindo as etapas em the section called “Adicionar uma conexão do AWS Glue”. Depois de criar a conexão, guarde o nome da conexão, *`connectionName`*, para a próxima etapa.
   - Ao selecionar um tipo de conexão, selecione Google BigQuery.
   - Ao selecionar um Segredo da AWS, forneça o *`secretName`*.
6. Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *`secretName`*.
7. Na configuração do trabalho do AWS Glue, forneça *`connectionName`* como uma conexão de rede adicional.

Ler das tabelas do BigQuery

Pré-requisitos:

- Uma tabela do BigQuery que você deseja ler. Você precisará dos nomes da tabela e do conjunto de dados do BigQuery no formulário `[dataset].[table]`. Vamos chamar isso de *`tableName`*.
- O projeto de faturamento da tabela do BigQuery. Você precisará do nome do projeto, *`ParentProject`*. Se não houver um projeto principal de cobrança, use o projeto que contém a tabela.
- Informações de autenticação do BigQuery. Conclua as etapas para gerenciar suas credenciais de conexão com o AWS Glue para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *`ConnectionName`*.

Por exemplo:

```
bigquery_read = glueContext.create_dynamic_frame.from_options(
    connection_type="bigquery",
    connection_options={
        "connectionName": "connectionName",
        "parentProject": "parentProject",
        "sourceType": "table",
        "table": "tableName",
    }
```

Você também pode fornecer uma consulta para filtrar os resultados retornados ao seu DynamicFrame. Você precisará configurar `query`, `sourceType`, `viewsEnabled` e `materializationDataset`.

Por exemplo:

Pré-requisitos adicionais

Você precisará criar ou identificar um conjunto de dados do BigQuery, *`MaterializationDataset, em que o BigQuery possa escrever visualizações materializadas`* para suas consultas.

Você precisará conceder as permissões apropriadas do GCP IAM à sua conta de serviço para criar tabelas no *`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"
            }
        )
```

Gravar em tabelas do BigQuery

Este exemplo grava diretamente no serviço BigQuery. O BigQuery também é compatível com o método de escrita “indireto”. Para obter mais informações sobre como configurar gravações indiretas, consulte the section called “Usar gravação indireta com o Google BigQuery”.

Pré-requisitos:

- Uma tabela do BigQuery na qual você gravar. Você precisará dos nomes da tabela e do conjunto de dados do BigQuery no formulário `[dataset].[table]`. Você também pode fornecer um novo nome de tabela que será criado automaticamente. Vamos chamar isso de *`tableName`*.
- O projeto de faturamento da tabela do BigQuery. Você precisará do nome do projeto, *`ParentProject`*. Se não houver um projeto principal de cobrança, use o projeto que contém a tabela.
- Informações de autenticação do BigQuery. Conclua as etapas para gerenciar suas credenciais de conexão com o AWS Glue para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *`ConnectionName`*.

Por exemplo:

```
bigquery_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="bigquery",
    connection_options={
        "connectionName": "connectionName",
        "parentProject": "parentProject",
        "writeMethod": "direct",
        "table": "tableName",
    }
)
```

Referência de opções de conexão BigQuery

- `project` — Padrão: conta de serviço padrão do Google Cloud. Usado para leitura/gravação. O nome de um projeto do Google Cloud associado à sua tabela.
- `table`: (obrigatório) usado para leitura/gravação. O nome da sua tabela do BigQuery no formato `[[project:]dataset.]`.

- `dataset` — Obrigatório quando não definido por meio da `table` opção. Usado para leitura/gravação. O nome do conjunto de dados que contém sua tabela do BigQuery.
- `parentProject` — Padrão: conta de serviço padrão do Google Cloud. Usado para leitura/gravação. O nome de um projeto do Google Cloud associado ao `project` usado para faturamento.
- `sourceType` - Usado para leitura. Obrigatório ao ler. Valores válidos: `table`, `query` informa ao AWS Glue se você lerá por tabela ou por consulta.
- `materializationDataset` - Usado para leitura. Valores válidos: strings. O nome de um conjunto de dados do BigQuery usado para armazenar materializações para visualizações.
- `viewsEnabled` - Usado para leitura. Padrão: falso. Valores válidos: true, false Configura se o BigQuery usará visualizações.
- `query` - Usado para leitura. Usado quando `viewsEnabled` for verdadeiro. Uma consulta DQL do GoogleSQL.
- `temporaryGcsBucket` — Usado para escrever. Obrigatório quando `writeMethod` estiver definido como padrão (`indirect`). Nome de um bucket do Google Cloud Storage usado para armazenar uma forma intermediária dos seus dados ao gravar no BigQuery.
- `writeMethod`: padrão: `indirect`. Valores válidos: `direct`, `indirect`. Usado para gravação. Especifica o método usado para gravar seus dados.
  - Se definido como `direct`, seu conector gravará usando a API BigQuery Storage Write.
  - Se definido como `indirect`, seu conector gravará no Google Cloud Storage e o transferirá para o BigQuery usando uma operação de carregamento. Sua conta de serviço do Google Cloud precisará das permissões apropriadas do GCS.

Usar gravação indireta com o Google BigQuery

Este exemplo usa gravação indireta, que grava dados no Google Cloud Storage e os copia para o Google BigQuery.

Pré-requisitos:

Você precisará de um bucket temporário do Google Cloud Storage, *`TemporaryBucket`*.

`O papel do GCP IAM para a conta de serviço do GCP do AWS Glue precisará das permissões apropriadas do GCS para acessar o TemporaryBucket.`

Configuração adicional

Para configurar a gravação indireta com o BigQuery:

1. Avalie the section called “Configurando o BigQuery” e localize ou baixe novamente seu arquivo JSON de credenciais do GCP. Identifique *secretName*, o AWS Secrets Manager segredo da conexão do Google BigQuery AWS Glue usada em seu trabalho.
2. Carregue seu arquivo JSON de credenciais em um local do Amazon S3 adequadamente seguro. Guarde o caminho para o arquivo, *s3secretpath, para futuras etapas*.
3. Edite *SecretName*, adicionando a `spark.hadoop.google.cloud.auth.service.account.json.keyfile` chave. Defina o valor como *s3secretpath*.
4. *Conceda ao seu trabalho do AWS Glue permissões do Amazon S3 IAM para acessar s3secretpath.*

Agora você pode fornecer a localização temporária do bucket do GCS ao seu método de gravação. Você não precisa fornecer `writeMethod`, pois historicamente `indirect` é o padrão.

```
bigquery_write = glueContext.write_dynamic_frame.from_options(
    frame=frameToWrite,
    connection_type="bigquery",
    connection_options={
        "connectionName": "connectionName",
        "parentProject": "parentProject",
        "temporaryGcsBucket": "temporaryBucket",
        "table": "tableName",
    }
)
```

Conexões JDBC

Certos tipos de banco de dados, geralmente relacionais, são compatíveis com conexão por meio do padrão JDBC. Para obter mais informações sobre o JDBC, consulte a documentação da Java JDBC API. O AWS Glue oferece suporte nativo à conexão a determinados bancos de dados por meio de conectores JDBC; as bibliotecas JDBC são fornecidas nos trabalhos do AWS Glue Spark. Ao se conectar a esses tipos de banco de dados usando as bibliotecas do AWS Glue, você tem acesso a um conjunto padrão de opções.

Os valores JDBCConnectionType incluem o seguinte:

- `"connectionType": "sqlserver"`: Designa uma conexão a um banco de dados do Microsoft SQL Server.
- `"connectionType": "mysql"`: designa uma conexão com um banco de dados MySQL.
- `"connectionType": "oracle"`: designa uma conexão com um banco de dados Oracle.
- `"connectionType": "postgresql"`: designa uma conexão com um banco de dados PostgreSQL.
- `"connectionType": "redshift"`: designa uma conexão com um banco de dados do Amazon Redshift. Para obter mais informações, consulte the section called “Conexões do Redshift”.

A tabela a seguir lista as versões de driver do JDBC compatíveis com o AWS Glue.

Produto	Versões do driver JDBC para o Glue 5.0	Versões do driver JDBC para o Glue 4.0	Versões do driver JDBC para o Glue 3.0	Versões do driver JDBC para o 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

* Para o tipo de conexão do Amazon Redshift, todas as outras opções de pares nome/valor que estão incluídas nas opções de conexão para uma conexão JDBC, incluindo opções de formatação, são passadas diretamente para a fonte de dados SparkSQL subjacente. Nos trabalhos do AWS Glue com Spark no AWS Glue 4.0 e versões posteriores, o conector nativo do AWS Glue para o Amazon Redshift usa a integração do Amazon Redshift para o Apache Spark. Para obter informações sobre como usar essas opções, consulte Integração do Amazon Redshift para o Apache Spark. Nas versões anteriores, consulte a fonte de dados do Amazon Redshift para Spark.

Para configurar a Amazon VPC para se conectar aos armazenamentos de dados do Amazon RDS usando JDBC, consulte the section called “Configurar um Amazon VPC para conectar aos armazenamentos de dados do Amazon RDS”.

> **Note**
>
> Os trabalhos do AWS são associados apenas a uma sub-rede durante uma execução. Isso pode afetar sua capacidade de se conectar a várias fontes de dados por meio do mesmo trabalho. Esse comportamento não se limita às fontes JDBC.

Tópicos

- Referência de opções de conexão JDBC
- Usar sampleQuery
- Usar o driver JDBC personalizado
- Leitura de tabelas JDBC em paralelo
- Configurar um Amazon VPC para conexões JDBC aos armazenamentos de dados do Amazon RDS desde o AWS Glue

Referência de opções de conexão JDBC

Se você já tiver uma conexão JDBC do AWS Glue definida, poderá reutilizar as propriedades de configuração nela definidas, como: url, usuário e senha, para não precisar especificá-las no código como opções de conexão. Esse atributo só está disponível no AWS Glue 3.0 e versões posteriores. Para fazer isso, use as seguintes propriedades de conexão:

- `"useConnectionProperties"`: defina como "true" para indicar que você deseja usar a configuração de uma conexão.
- `"connectionName"`: insira o nome da conexão da qual recuperar a configuração; a conexão deve ser definida na mesma região da tarefa.

Use estas opções de conexão com conexões JDBC:

- `"url"`: (Obrigatório) O URL do JDBC para o banco de dados.

- `"dbtable"`: (obrigatório) o banco de dados a ser lido. Para armazenamentos de dados JDBC que oferecem suporte a esquemas dentro de um banco de dados, especifique `schema.table-name`. Se um esquema não for fornecido, o esquema "público" padrão será usado.
- `"user"`: (obrigatório) o nome de usuário a ser usado ao se conectar.
- `"password"`: (Obrigatório) A senha a ser usada ao se conectar.
- (Opcional) As opções a seguir permitem que você forneça um driver do JDBC personalizado. Use estas opções se for necessário usar um driver que não seja compatível nativamente com o AWS Glue.

  Os trabalhos de ETL podem usar diferentes versões de driver JDBC para o destino e a fonte de dados, mesmo que o destino e a origem sejam o mesmo produto de banco de dados. Isso permite migrar dados entre bancos de dados de fonte e de destino com versões diferentes. Para usar estas opções, é necessário primeiro fazer upload do arquivo JAR do driver do JDBC para o Amazon S3.

  - `"customJdbcDriverS3Path"`: o caminho no Amazon S3 do driver JDBC personalizado.
  - `"customJdbcDriverClassName"`: o nome da classe do driver JDBC.
- `"bulkSize"`: (opcional) usado para configurar inserções paralelas para acelerar cargas em massa em destinos de JDBC. Especifique um valor inteiro para o grau de paralelismo a ser usado ao gravar ou inserir dados. Essa opção é útil para melhorar a performance de gravações em bancos de dados, como o Arch User Repository (AUR).
- `"hashfield"` (Opcional) Uma string, usada para especificar o nome de uma coluna na tabela JDBC a ser usada para dividir os dados em partições ao ler tabelas JDBC em paralelo. Forneça "hashfield" OU "hashexpression". Para obter mais informações, consulte the section called “Leitura do JDBC em paralelo”.
- `"hashexpression"` (Opcional) Uma cláusula de seleção SQL retornando um número inteiro. Usada para dividir os dados em uma tabela JDBC em partições ao ler tabelas JDBC em paralelo. Forneça "hashfield" OU "hashexpression". Para obter mais informações, consulte the section called “Leitura do JDBC em paralelo”.
- `"hashpartitions"` (Opcional) Um número inteiro positivo. Usado para especificar o número de leituras paralelas da tabela JDBC ao ler tabelas JDBC em paralelo. Padrão: 7. Para obter mais informações, consulte the section called “Leitura do JDBC em paralelo”.
- `"sampleQuery"`: (opcional) uma instrução de consulta SQL personalizada. Usada para especificar um subconjunto de informações em uma tabela para recuperar uma amostra do conteúdo da tabela. Quando configurada sem considerar os dados, pode ser menos eficiente do

que os métodos DynamicFrame, causando timeouts ou erros de falta de memória. Para obter mais informações, consulte the section called “Usar sampleQuery”.

- `"enablePartitioningForSampleQuery"`: (opcional) um booleano. Padrão: falso. Usado para permitir a leitura de tabelas JDBC em paralelo ao especificar `sampleQuery`. Se definido como verdadeiro, **`sampleQuery`** deve terminar com "where" ou "and" para o AWS Glue para anexar condições de particionamento. Para obter mais informações, consulte the section called “Usar sampleQuery”.
- `"sampleSize"`: (opcional) um número inteiro positivo. Limita o número de linhas retornado pela consulta de amostra. Funciona somente quando `enablePartitioningForSampleQuery` é verdadeiro. Se o particionamento não estiver habilitado, você deverá adicionar diretamente `"limit x"` à `sampleQuery` para limitar o tamanho. Para obter mais informações, consulte the section called “Usar sampleQuery”.

Usar sampleQuery

Esta seção explica como usar `sampleQuery`, `sampleSize` e `enablePartitioningForSampleQuery`.

`sampleQuery` pode ser uma forma eficiente de amostrar algumas linhas do conjunto de dados. Por padrão, a consulta é executada por um único executor. Quando configurada sem considerar os dados, pode ser menos eficiente do que os métodos DynamicFrame, causando timeouts ou erros de falta de memória. A execução de SQL no banco de dados subjacente como parte do pipeline de ETL geralmente só é necessária para fins de performance. Se você estiver tentando visualizar algumas linhas do conjunto de dados, considere usar the section called “show”. Se você estiver tentando transformar o conjunto de dados usando SQL, considere usar the section called “toDF” para definir uma transformação de SparkSQL para os dados no formato DataFrame.

Embora sua consulta possa manipular uma variedade de tabelas, a `dbtable` continua sendo obrigatória.

Usar sampleQuery para recuperar uma amostra da tabela

Ao usar o comportamento padrão de sampleQuery para recuperar uma amostra dos dados, o AWS Glue não espera um throughput substancial, assim ele executa a consulta em um único executor. Para limitar os dados que você fornece e não causar problemas de performance, sugerimos que você inclua uma cláusula `LIMIT` no SQL.

Example Usar SampleQuery sem particionamento

O exemplo de código a seguir mostra como usar `sampleQuery` sem particionamento.

```
//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()
```

Usar sampleQuery em conjuntos de dados maiores

Se você estiver lendo um conjunto de dados grande, talvez seja necessário ativar o particionamento JDBC para consultar uma tabela em paralelo. Para obter mais informações, consulte the section called “Leitura do JDBC em paralelo”. Para usar `sampleQuery` com particionamento JDBC, defina `enablePartitioningForSampleQuery` como verdadeiro. A ativação desse atributo exige que você faça algumas alterações na `sampleQuery`.

Ao usar particionamento JDBC com `sampleQuery`, a consulta deve terminar com "where" ou "and" para o AWS Glue para anexar condições de particionamento.

Se você quiser limitar os resultados da sampleQuery ao ler tabelas JDBC em paralelo, defina o parâmetro `"sampleSize"` em vez de especificar uma cláusula `LIMIT`.

Example Usar SampleQuery com particionamento JDBC

O exemplo de código a seguir mostra como usar `sampleQuery` com particionamento 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()
```

Regras e restrições:

Consultas de amostra não podem ser usadas junto com marcadores de trabalho. O estado do marcador será ignorado quando a configuração de ambos for fornecida.

Usar o driver JDBC personalizado

Os exemplos de código a seguir mostram como fazer a leitura e gravação de bancos de dados JDBC com drivers JDBC personalizados. Eles demonstram a leitura de uma versão de um produto de banco de dados e a gravação em uma versão posterior do mesmo produto.

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)
  }
}
```

Leitura de tabelas JDBC em paralelo

Você pode definir propriedades da sua tabela JDBC para permitir que o AWS Glue leia dados em paralelo. Ao definir determinadas propriedades, você instrui o AWS Glue a executar consultas SQL paralelas em partições lógicas dos seus dados. Você pode controlar o particionamento definindo um campo de hash ou uma expressão de hash. Você também pode controlar o número de leituras paralelas que são usadas para acessar seus dados.

Ler as tabelas JDBC em paralelo é uma técnica de otimização que pode melhorar a performance. Para obter mais informações sobre o processo para identificar quando essa técnica é adequada, consulte Reduce the amount of data scan no guia Best practices for performance tuning AWS Glue for Apache Spark jobs em AWS Prescriptive Guidance.

Para habilitar leituras paralelas, você pode definir pares de chave e valor no campo de parâmetros da estrutura da tabela. Use a notação JSON para definir um valor para o campo de parâmetro da tabela. Para obter mais informações sobre como editar as propriedades de uma tabela, consulte Exibir e gerenciar detalhes da tabela. Você também pode habilitar leituras paralelas ao chamar os métodos de ETL (extração, transformação e carregamento) `create_dynamic_frame_from_options` e `create_dynamic_frame_from_catalog`. Para obter mais informações sobre como especificar opções nesses métodos, consulte from_options e from_catalog.

Você pode usar esse método para tabelas JDBC, ou seja, a maioria das tabelas cujos dados de base são um armazenamento de dados JDBC. Essas propriedades são ignoradas durante a leitura de tabelas do Amazon RedShift e Amazon S3.

hashfield

Defina `hashfield` como o nome de uma coluna na tabela JDBC a ser usada para dividir os dados em partições. Para obter os melhores resultados, essa coluna deve ter uma distribuição uniforme de valores para distribuir os dados entre partições. Essa coluna pode ser de qualquer tipo de dados. O AWS Glue gera consultas não sobrepostas que são executadas em paralelo para ler os dados particionados por essa coluna. Por exemplo, se os dados estiverem distribuídos uniformemente por mês, você poderá usar a coluna `month` para ler cada mês de dados em paralelo.

```
'hashfield': 'month'
```

O AWS Glue cria uma consulta para definir o hash do valor do campo como um número de partição e executa essa consulta para todas as partições em paralelo. Para usar sua própria consulta para particionar uma leitura de tabela, forneça uma tabela `hashexpression` em vez de um `hashfield`.

hashexpression

Defina `hashexpression` como uma expressão SQL (de acordo com a gramática do mecanismo de banco de dados JDBC) que retorne um número inteiro. Uma expressão simples é o nome de qualquer coluna numérica na tabela. O AWS Glue gera consultas SQL para ler os dados JDBC em paralelo usando o `hashexpression` na cláusula `WHERE` para particionar os dados.

Por exemplo, use a coluna numérica `customerID` para ler dados particionados por um número de cliente.

```
'hashexpression': 'customerID'
```

Para que o AWS Glue controle o particionamento, forneça um `hashfield` em vez de um `hashexpression`.

hashpartitions

Defina `hashpartitions` como o número de leituras paralelas da tabela JDBC. Se essa propriedade não for definida, o valor padrão será 7.

Por exemplo, defina o número de leituras em paralelo como 5 para que o AWS Glue lê os dados com cinco consultas (ou menos).

```
'hashpartitions': '5'
```

Configurar um Amazon VPC para conexões JDBC aos armazenamentos de dados do Amazon RDS desde o AWS Glue

Ao usar o JDBC para conectar a bancos de dados no Amazon RDS, você precisará realizar configurações adicionais. Para permitir que os componentes do AWS Glue se comuniquem com o Amazon RDS, é necessário configurar o acesso aos seus armazenamentos de dados do Amazon RDS no Amazon VPC. Para permitir que o AWS Glue se comunique entre seus componentes, especifique um grupo de segurança com uma regra de entrada de autorreferência para todas as portas TCP. Ao criar uma regra de autorreferência, você pode restringir a origem ao mesmo security group na VPC. Uma regra de autorreferência não abrirá a VPC para todas as redes. O security group padrão para sua VPC pode já conter uma regra de entrada de autorreferenciada para ALL Traffic.

Para configurar o acesso entre o AWS Glue e os armazenamentos de dados do Amazon RDS

1. Faça login no AWS Management Console e abra o console do Amazon RDS em https://console.aws.amazon.com/rds/.
2. No console do Amazon RDS, identifique os grupos de segurança usados para controlar o acesso ao banco de dados do Amazon RDS.

No painel de navegação esquerdo, escolha Bancos de dados e, em seguida, selecione a instância à qual você gostaria de se conectar na lista no painel principal.

Na página de detalhes do banco de dados, encontre Grupos de segurança da VPC na guia Conectividade e segurança.

3. Com base na sua arquitetura de rede, identifique qual grupo de segurança associado é melhor modificar para permitir o acesso ao serviço AWS Glue. Salve seu nome, *database-security-group*, para referência futura. Se não houver um grupo de segurança apropriado, siga as instruções para Fornecer acesso à instância de banco de dados na VPC criando um grupo de segurança na documentação do Amazon RDS.
4. Faça login no AWS Management Console e abra o console da Amazon VPC em https://console.aws.amazon.com/vpc/.
5. No console do Amazon VPC, identifique como atualizar *database-security-group*.

   No painel de navegação esquerdo, escolha Grupos de segurança e, em seguida, selecione *database-security-group* na lista no painel principal.
6. Identifique o ID do grupo de segurança para *database-security-group*, *database-sg-id*. Guarde-o para uso posterior.

   Na página de detalhes do grupo de segurança, encontre ID do grupo de segurança.
7. Altere as regras de entrada para *database-security-group* e adicione uma regra de autorreferência para permitir que os componentes do AWS Glue se comuniquem. Especificamente, adicione ou confirme que existe uma regra em que Tipo é `All TCP`, Protocolo é `TCP`, Intervalo de portas inclui todas as portas e Origem é *database-sg-id*. Verifique se o grupo de segurança que você inseriu para Origem é o mesmo que o grupo de segurança que você está editando.

   Na página de detalhes do grupo de segurança, selecione Editar regras de entrada.

   A regra de entrada é semelhante a esta:

Tipo	Protocolo	Intervalo de portas	Origem
Todos os TCP	TCP	0–65535	*database-sg-id*

8. Adicione regras para o tráfego de saída.

Na página de detalhes do grupo de segurança, selecione Editar regras de saída.

Se o grupo de segurança permitir todo o tráfego de saída, você não precisará de regras separadas. Por exemplo:

Tipo	Protocolo	Intervalo de portas	Destination (Destino)
Todo o tráfego	ALL	ALL	0.0.0.0/0

Se sua arquitetura de rede foi desenvolvida para que você restrinja o tráfego de saída, crie as seguintes regras de saída:

Crie uma regra de autorreferência em que Tipo é `All TCP`, Protocolo é `TCP`, Intervalo de portas inclui todas as portas e Destino é *`database-sg-id`*. Verifique se o grupo de segurança que você inseriu para Destino é o mesmo que o grupo de segurança que você está editando.

Se você estiver usando um endpoint da VPC do Amazon S3, adicione uma regra de HTTPS para permitir o tráfego da VPC para o Amazon S3. Crie uma regra em que Tipo é `HTTPS`, Protocolo é `TCP`, Intervalo de portas é `443` e Destino é o ID da lista de prefixos gerenciados para o endpoint do gateway Amazon S3, *`s3-prefix-list-id`*. Para obter mais informações sobre listas de prefixos e endpoints de gateway do Amazon S3, consulte Endpoints de gateway para Amazon S3 na documentação do Amazon VPC.

Por exemplo:

Tipo	Protocolo	Intervalo de portas	Destination (Destino)
Todos os TCP	TCP	0–65535	*`database-sg-id`*
HTTPS	TCP	443	*`s3-prefix-list-id`*

Conexões do MongoDB

O AWS Glue para Spark pode ser usado para ler e gravar em tabelas no MongoDB e MongoDB Atlas no AWS Glue 4.0 e versões posteriores. Conecte-se ao MongoDB usando credenciais de nome de usuário e senha armazenadas no AWS Secrets Manager via conexão do AWS Glue.

Para obter mais informações sobre o MongoDB, consulte a Documentação do MongoDB.

Configurar conexões do MongoDB

Para se conectar ao MongoDB via AWS Glue, você precisará de suas credenciais do MongoDB, *mongodbUser* e *mongodbPass*.

Para se conectar ao MongoDB via AWS Glue, talvez seja necessário atender a alguns pré-requisitos:

- Se a sua instância do MongoDB estiver em uma Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com a instância do MongoDB sem que o tráfego passe pela Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre sua instância do MongoDB e esse local. Com base no layout da rede, isso pode exigir alterações em regras do grupo de segurança, ACLs de rede, gateways de NAT e conexões de emparelhamento.

Em seguida, você pode continuar com a configuração do AWS Glue para usá-lo com o MongoDB.

Para configurar uma conexão com o MongoDB:

1. Opcionalmente, no AWS Secrets Manager, crie um segredo usando suas credenciais do MongoDB. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

   - Ao selecionar Pares chave/valor, crie um par para a chave `username` com o valor *mongodbUser*.

     Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *mongodbPass*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para uso futuro no AWS Glue.

   - Ao selecionar um Tipo de conexão, selecione MongoDB ou MongoDB Atlas.
   - Ao selecionar o URL do MongoDB ou o URL do MongoDB Atlas, forneça o nome de host da sua instância do MongoDB.

     Um URL do MongoDB é fornecido no formato `mongodb://`*mongoHost*`:`*mongoPort*`/`*mongoDBname*.

     Um URL do MongoDB Atlas é fornecido no formato `mongodb+srv://`*mongoHost*`:`*mongoPort*`/`*mongoDBname*.

     Fornecer o banco de dados padrão *mongoDBname* para a conexão é opcional.
   - Se você optar por criar um segredo do Secrets Manager, escolha o Tipo de credencial do AWS Secrets Manager.

     Em seguida, em Segredo do AWS, forneça o *secretName*.
   - *Se você optar por fornecer* ***Nome de usuário e senha****, forneça também o mongodbUser e o mongodbPass*.

3. Nas seguintes situações, configurações adicionais podem ser necessárias:

   - Para instâncias do MongoDB hospedadas na AWS em uma Amazon VPC
     - Será necessário fornecer informações de conexão da Amazon VPC à conexão do AWS Glue que define suas credenciais de segurança do MongoDB. Ao criar ou atualizar sua conexão, defina VPC, Sub-rede e Grupos de segurança em Opções de rede.

Depois de criar uma conexão AWS Glue MongoDB, siga estas etapas a seguir antes de chamar seu método de conexão.

- Se você optar por criar um segredo do Secrets Manager, conceda ao perfil do IAM associado ao seu trabalho do AWS Glue permissão para ler *secretName*.
- Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional.

Para usar sua conexão AWS Glue MongoDB no AWS Glue para Spark, forneça a opção `connectionName` na chamada ao método de conexão. Como alternativa, você pode seguir as etapas the section called “Integração com MongoDB” para usar a conexão em conjunto com o AWS Glue Data Catalog.

Ler do MongoDB usando uma conexão do AWS Glue

Pré-requisitos:

- Uma coleção do MongoDB da qual você gostaria de ler. Você precisará de informações de identificação para a coleção.

  Uma coleção do MongoDB é identificada por um nome de banco de dados e um nome de coleção, *`mongodbName`* e *`mongodbCollection`*.
- Uma conexão AWS Glue MongoDB configurada para fornecer informações de autenticação. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o MongoDB para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *`ConnectionName`*.

Por exemplo:

```
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.partitioner.SinglePartitionPartitioner",
        "partitionerOptions.partitionSizeMB": "10",
        "partitionerOptions.partitionKey": "_id",
        "disableUpdateUri": "false",
    }
)
```

Escrever em tabelas do MongoDB

Este exemplo escreve informações de um DynamicFrame existente, *`dynamicFrame`*, no MongoDB.

Pré-requisitos:

- Uma coleção do MongoDB na qual você gostaria de escrever. Você precisará de informações de identificação para a coleção.

  Uma coleção do MongoDB é identificada por um nome de banco de dados e um nome de coleção, *mongodbName* e *mongodbCollection*.

- Uma conexão AWS Glue MongoDB configurada para fornecer informações de autenticação. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o MongoDB para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="mongodb",
    connection_options={
        "connectionName": "connectionName",
        "database": "mongodbName",
        "collection": "mongodbCollection",
        "disableUpdateUri": "false",
        "retryWrites": "false",
    },
)
```

Leitura e escrita em tabelas no MongoDB

Este exemplo escreve informações de um DynamicFrame existente, *dynamicFrame*, no MongoDB.

Pré-requisitos:

- Uma coleção do MongoDB da qual você gostaria de ler. Você precisará de informações de identificação para a coleção.

  Uma coleção do MongoDB na qual você gostaria de escrever. Você precisará de informações de identificação para a coleção.

  Uma coleção do MongoDB é identificada por um nome de banco de dados e um nome de coleção, *mongodbName* e *mongodbCollection*.

- Informações de autenticação do MongoDB, *mongodbUser* e *mongodbPassword*.

Por exemplo:

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)
  }
}
```

Referência de opções de conexão do MongoDB

Designa uma conexão com o MongoDB. As opções de conexão diferem para uma conexão da fonte e uma conexão do coletor.

Essas propriedades de conexão são compartilhadas entre as conexões de origem e coletor:

- `connectionName`: usado para leitura/gravação. O nome de uma conexão do AWS Glue MongoDB configurada para fornecer informações de autenticação e rede ao seu método de conexão. Quando uma conexão do AWS Glue é configurada conforme descrito na seção the section called “Configurar o MongoDB” anterior, fornecer `connectionName` substituirá a necessidade de fornecer as opções de conexão `"uri"`, `"username"` e `"password"`.
- `"uri"`: (obrigatório) o host do MongoDB do qual fazer a leitura, formatado como `mongodb://<host>:<port>`. Usado nas versões do AWS Glue anteriores ao AWS Glue 4.0.

- "connection.uri": (obrigatório) o host do MongoDB do qual fazer a leitura, formatado como mongodb://<host>:<port>. Usado no AWS Glue 4.0 e versões posteriores.
- "username": (obrigatório) o nome de usuário do MongoDB.
- "password": (obrigatório) a senha do MongoDB.
- "database": (obrigatório) o banco de dados MongoDB do qual fazer a leitura. Essa opção também pode ser passada em additional_options ao chamar glue_context.create_dynamic_frame_from_catalog em seu script de trabalho.
- "collection": (obrigatório) a coleção do MongoDB da qual fazer a leitura. Essa opção também pode ser passada em additional_options ao chamar glue_context.create_dynamic_frame_from_catalog em seu script de trabalho.

“connectionType”: “mongodb” como fonte

Use as seguintes opções de conexão com "connectionType": "mongodb" como fonte:

- "ssl": (opcional) se for true, iniciará uma conexão SSL. O padrão é false.
- "ssl.domain_match": (opcional) se for true e se ssl for true, será realizada a verificação de correspondência do domínio. O padrão é true.
- "batchSize": (opcional) o número de documentos que devem ser retornados por lote, usado no cursor de lotes internos.
- "partitioner": (opcional) o nome da classe do particionador do qual fazer a leitura de dados de entrada do MongoDB. O conector fornece os seguintes particionadores:
  - MongoDefaultPartitioner (padrão) (sem suporte no AWS Glue 4.0)
  - MongoSamplePartitioner (requer o MongoDB 3.2 ou posterior) (Sem suporte no AWS Glue 4.0)
  - MongoShardedPartitioner (sem suporte no AWS Glue 4.0)
  - MongoSplitVectorPartitioner (sem suporte no AWS Glue 4.0)
  - MongoPaginateByCountPartitioner (sem suporte no AWS Glue 4.0)
  - MongoPaginateBySizePartitioner (sem suporte no AWS Glue 4.0)
  - com.mongodb.spark.sql.connector.read.partitioner.SinglePartitionPartitioner
  - com.mongodb.spark.sql.connector.read.partitioner.ShardedPartitioner
  - com.mongodb.spark.sql.connector.read.partitioner.PaginateIntoPartitionsPartit

- `"partitionerOptions"`: (opcional) opções para o particionador designado. As seguintes opções são compatíveis com cada particionador:
  - `MongoSamplePartitioner`: `partitionKey`, `partitionSizeMB`, `samplesPerPartition`
  - `MongoShardedPartitioner`: `shardkey`
  - `MongoSplitVectorPartitioner`: `partitionKey`, `partitionSizeMB`
  - `MongoPaginateByCountPartitioner`: `partitionKey`, `numberOfPartitions`
  - `MongoPaginateBySizePartitioner`: `partitionKey`, `partitionSizeMB`

  Para obter mais informações sobre essas opções, consulte Partitioner Configuration na documentação do MongoDB.

“connectionType”: “mongodb” como coletor

Use as seguintes opções de conexão com `"connectionType": "mongodb"` como coletor:

- `"ssl"`: (opcional) se for `true`, iniciará uma conexão SSL. O padrão é `false`.
- `"ssl.domain_match"`: (opcional) se for `true` e se `ssl` for `true`, será realizada a verificação de correspondência do domínio. O padrão é `true`.
- `"extendedBsonTypes"`: (opcional) se for `true`, permite tipos de BSON estendidos ao gravar dados no MongoDB. O padrão é `true`.
- `"replaceDocument"`: (opcional) se for `true`, substituirá todo o documento ao salvar conjuntos de dados que contêm um campo `_id`. Se for `false`, serão atualizados somente os campos do documento que correspondam aos campos do conjunto de dados. O padrão é `true`.
- `"maxBatchSize"`: (opcional) o tamanho máximo do lote para operações em massa ao salvar dados. O padrão é 512.
- `"retryWrites"`: (Opcional): repita automaticamente determinadas operações de escrita uma única vez se o AWS Glue encontrar um erro de rede.

Conexões do SAP HANA

O AWS Glue para Spark pode ser usado para ler e escrever em tabelas no SAP HANA no AWS Glue 4.0 e versões posteriores. Você pode definir o que ler no SAP HANA com uma consulta SQL. Conecte-se ao SAP HANA usando credenciais JDBC armazenadas no AWS Secrets Manager via conexão AWS Glue SAP HANA.

Para obter mais informações sobre o JDBC do SAP HANA, consulte a Documentação do SAP HANA.

Configurar conexões do SAP HANA

Para se conectar ao SAP HANA via AWS Glue, será necessário criar e armazenar suas credenciais do SAP HANA em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão ao AWS Glue do SAP HANA. Você precisará configurar a conectividade de rede entre seu serviço SAP HANA e o AWS Glue.

Para se conectar ao SAP HANA, talvez seja necessário atender a alguns pré-requisitos:

- Se o seu serviço SAP HANA estiver em uma Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com o serviço SAP HANA sem que o tráfego passe pela Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre seu endpoint SAP HANA e esse local. Seu trabalho precisará estabelecer uma conexão TCP com a porta JDBC do SAP HANA. Para obter mais informações sobre as portas do SAP HANA, consulte a Documentação do SAP HANA. Com base no layout da rede, isso pode exigir alterações em regras do grupo de segurança, ACLs de rede, gateways de NAT e conexões de emparelhamento.
- Não há pré-requisitos adicionais quando seu endpoint do SAP HANA está acessível pela Internet.

Para configurar uma conexão com o SAP HANA:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do SAP HANA. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.

   - Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *`saphanaUsername`*.
   - Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *`saphanaPassword`*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para uso futuro no AWS Glue.

   - Ao selecionar um Tipo de conexão, selecione SAP HANA.
   - Ao fornecer o URL do SAP HANA, forneça o URL da sua instância.

     Os URLs JDBC do SAP HANA estão no formato `jdbc:sap://`*saphanaHostname*`:`*saphanaPort*`/?`*databaseName*`=`*saphanaDBname*`,`*Paramete*

     O AWS Glue requer os seguintes parâmetros de URL do JDBC:

     - `databaseName`: um banco de dados padrão no SAP HANA ao qual se conectar.
   - Ao selecionar um Segredo da AWS, forneça o *secretName*.

Depois de criar uma conexão AWS Glue SAP HANA, siga estas etapas antes de executar seu trabalho do AWS Glue:

- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *secretName*.
- Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional.

Ler de tabelas do SAP HANA

Pré-requisitos:

- Uma tabela do SAP HANA da qual você deseja ler. Você precisará de informações de identificação para a tabela.

  Uma tabela pode ser especificada com um nome de tabela e um nome de esquema do SAP HANA, no formulário *schemaName*`.`*tableName*. O nome do esquema e o separador "." não serão necessários se a tabela estiver no esquema padrão, "público". Chame isso de *tableIdentifier*. Observe que o banco de dados é fornecido como um parâmetro de URL do JDBC em `connectionName`.
- Uma conexão AWS Glue SAP HANA configurada para fornecer informações de autenticação. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o SAP HANA para

configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
saphana_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type="saphana",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableIdentifier",
    }
)
```

Você também pode fornecer uma consulta SQL SELECT para filtrar os resultados retornados ao seu DynamicFrame. Você precisará configurar `query`.

Por exemplo:

```
saphana_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="saphana",
    connection_options={
        "connectionName": "connectionName",
        "query": "query"
    }
)
```

Escrever em tabelas do SAP HANA

Este exemplo escreve informações de um DynamicFrame existente, *dynamicFrame*, no SAP HANA. Se a tabela já contiver informações, o AWS Glue irá gerar um erro.

Pré-requisitos:

- Uma tabela do SAP HANA na qual você gostaria de escrever.

  Uma tabela pode ser especificada com um nome de tabela e um nome de esquema do SAP HANA, no formulário *schemaName*.*tableName*. O nome do esquema e o separador "." não serão necessários se a tabela estiver no esquema padrão, "público". Chame isso de *tableIdentifier*. Observe que o banco de dados é fornecido como um parâmetro de URL do JDBC em `connectionName`.

- Informações de autenticação do SAP HANA. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o SAP HANA para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
options = {
    "connectionName": "connectionName",
    "dbtable": 'tableIdentifier'
}

    saphana_write = glueContext.write_dynamic_frame.from_options(
        frame=dynamicFrame,
        connection_type="saphana",
        connection_options=options
)
```

Referência de opções de conexão do SAP HANA

- `connectionName` — Obrigatório. Usado para leitura/gravação. O nome de uma conexão do AWS Glue SAP HANA configurada para fornecer informações de autenticação e rede ao seu método de conexão.
- `databaseName`: usado para leitura/gravação. Valores válidos: nomes de bancos de dados no SAP HANA. O nome do banco de dados ao qual se conectar.
- `dbtable`: necessário para escrever, obrigatório para leitura, a menos que `query` seja fornecido. Usado para leitura/gravação. Valores válidos: conteúdo de uma cláusula SQL FROM do SAP HANA. Identifica uma tabela no SAP HANA à qual se conectar. Você também pode fornecer outro SQL além do nome de uma tabela, como uma subconsulta. Para obter mais informações, consulte a cláusula From na documentação do SAP HANA.
- `query` - Usado para leitura. Uma consulta SQL SELECT do SAP HANA que define o que deve ser recuperado na leitura do SAP HANA.

Conexões do Snowflake

Você pode usar o AWS Glue para Spark para ler e gravar em tabelas no Snowflake no AWS Glue 4.0 e versões posteriores. Você pode ler no Snowflake com uma consulta SQL. Você pode se conectar ao Snowflake usando um usuário e uma senha. Você pode consultar as credenciais do Snowflake armazenadas no AWS Secrets Manager por meio do catálogo de dados do AWS Glue .

As credenciais do Snowflake do catálogo de dados do AWS Glue para Spark são armazenadas separadamente das credenciais do Snowflake do catálogo de dados para crawlers. Você deve escolher um tipo de conexão do `SNOWFLAKE` e não um tipo de conexão `JDBC` configurada para se conectar ao Snowflake.

Para obter mais informações sobre o Snowflake, consulte o site do Snowflake. Para obter mais informações sobre o Snowflake na AWS, consulte Snowflake Data Warehouse na Amazon Web Services.

Configurar conexões do Snowflake

Não há pré-requisitos da AWS para se conectar aos fluxos do Snowflake disponíveis pela Internet.

Opcionalmente, você pode realizar a seguinte configuração para gerenciar suas credenciais de conexão com o AWS Glue.

Para gerenciar suas credenciais de conexão com AWS o Glue

1. No Snowflake, gere um usuário, *`SnowflakeUser`* e senha, *`snowflakePassword`*.
2. Nos AWS Secrets Manager, crie um segredo usando suas credenciais do Snowflake. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criação de um segredo do AWS Secrets Manager na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.
   - Ao selecionar pares de chave/valor, crie um par para *`snowflakeUser`* com a chave `USERNAME`.
   - Ao selecionar pares de chave/valor, crie um par para *`snowflakePassword`* com a chave `PASSWORD`.
   - Ao selecionar pares de chave/valor, você pode fornecer a chave ao seu armazém do Snowflake `sfWarehouse`.
3. No AWS Glue Data Catalog, crie uma conexão escolhendo Conexões e depois selecionando Criar conexão. Acompanhe as etapas do assistente de conexão para concluir o processo:
   - Ao selecionar uma Fonte de dados, escolha Snowflake e depois Avançar.
   - Insira os detalhes da conexão, como o host e a porta. Ao inserir o URL do Snowflake do host, forneça o URL da sua instância do Snowflake. Em geral, o URL usará um nome de host no formato *`account_identifier`*`.snowflakecomputing.com`. Porém, o formato do URL pode variar dependendo do tipo de conta do Snowflake (como AWS, Azure ou hospedada no Snowflake).

- Ao selecionar o perfil de serviço do IAM, escolha no menu suspenso. Esse é o perfil do IAM da sua conta que será usado para acessar o AWS Secrets Manager e atribuir o IP se a VPC for especificada.
- Ao selecionar um Segredo da AWS, forneça o *secretName*.

4. Na etapa seguinte do assistente, defina as propriedades da conexão do Snowflake.
5. Na etapa final do assistente, reveja as configurações e conclua o processo para criar a conexão.

Nas seguintes situações, você pode precisar do seguinte:

- Para Snowflake hospedado na AWS em uma Amazon VPC
  - Você precisará da configuração apropriada da Amazon VPC para o Snowflake. Para obter mais informações sobre como configurar a Amazon VPC, consulte AWS PrivateLink & Snowflake na documentação do Snowflake.
  - Você precisará da configuração apropriada da Amazon VPC para o AWS Glue. the section called “Configurar VPC endpoints de interface (AWS PrivateLink) para AWS Glue ”.
  - Você precisará criar uma conexão do catálogo de dados do AWS Glue que forneça informações de conexão do Amazon VPC (além da identificação de um AWS Secrets Manager segredo que define suas credenciais de segurança do Snowflake). A URL mudará quando o AWS PrivateLink estiver sendo usado, conforme descrito na documentação do Snowflake associada a um item anterior.
  - Você precisará que a configuração do trabalho inclua a conexão do catálogo de dados como uma Conexão de rede adicional.

Ler das tabelas do Snowflake

Pré-requisitos: uma tabela do Snowflake que você gostaria de ler. *Você precisará do nome da tabela Snowflake, tableName*. Você precisará da URL do Snowflake, *snowflakeUrl*, do nome de usuário *snowflakeUser* e da senha *snowflakePassword*. *Se o usuário do Snowflake não tiver um namespace padrão definido, você precisará do nome do banco de dados do Snowflake databaseName e do nome do esquema schemaName*. *Além disso, se o usuário do Snowflake não tiver um armazém padrão definido, você precisará de um nome de armazém warehouseName*.

Por exemplo:

Pré-requisitos adicionais: conclua as etapas de Para gerenciar suas credenciais de conexão com o AWS Glue para configurar *snowflakeURL*, *snowflakeUsername* e *snowflakePassword*. Para revisar essas etapas, consulte the section called “Configurar o Snowflake” na seção anterior. Para selecionar com qual conexão de rede adicional se conectar, usaremos o parâmetro `connectionName`.

```
snowflake_read = glueContext.create_dynamic_frame.from_options(
  connection_type="snowflake",
  connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "sfDatabase": "databaseName",
        "sfSchema": "schemaName",
        "sfWarehouse": "warehouseName",
    }
)
```

Além disso, você pode usar os parâmetros `autopushdown` e `query` para ler uma parte de uma tabela do Snowflake. Isso pode ser substancialmente mais eficiente do que filtrar os resultados depois de serem carregados no Spark. Considere um exemplo em que todas as vendas são armazenadas na mesma tabela, mas você só precisa analisar as vendas de uma determinada loja nos feriados. Se essas informações estiverem armazenadas na tabela, você poderá usar pushdown de predicado para recuperar os resultados da seguinte forma:

```
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",
    }
)
```

Gravar em tabelas do Snowflake

Pré-requisitos: um banco de dados do Snowflake no qual você deseja gravar. Você precisará de um nome de tabela atual ou desejado, *tableName*. Você precisará da URL do Snowflake, *snowflakeUrl*, do nome de usuário *snowflakeUser* e da senha *snowflakePassword*. *Se o*

usuário do Snowflake não tiver um namespace padrão definido, você precisará do nome do banco de dados do Snowflake databaseName e do nome do esquema schemaName. Além disso, se o usuário do Snowflake não tiver um armazém padrão definido, você precisará de um nome de armazém warehouseName.

Por exemplo:

Pré-requisitos adicionais: conclua as etapas de Para gerenciar suas credenciais de conexão com o AWS Glue para configurar *snowflakeURL*, *snowflakeUsername* e *snowflakePassword*. Para revisar essas etapas, consulte the section called “Configurar o Snowflake” na seção anterior. Para selecionar com qual conexão de rede adicional se conectar, usaremos o parâmetro `connectionName`.

```
glueContext.write_dynamic_frame.from_options(
    connection_type="snowflake",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "sfDatabase": "databaseName",
        "sfSchema": "schemaName",
        "sfWarehouse": "warehouseName",
    },
)
```

Referência de opções de conexão do Snowflake

O tipo de conexão do Snowflake usa as seguintes opções de conexão:

Você pode recuperar alguns dos parâmetros desta seção de uma conexão do catálogo de dados (`sfUrl`, `sfUser`, `sfPassword`) e, nesse caso, não será necessário fornecê-los. É possível fazer isso fornecendo o parâmetro `connectionName`.

Você pode recuperar alguns dos parâmetros desta seção de um segredo dos AWS Secrets Manager (`sfUser`, `sfPassword`) e, nesse caso, não será necessário fornecê-los. O segredo deve fornecer o conteúdo protegido com as chaves `sfUser` e `sfPassword`. É possível fazer isso fornecendo o parâmetro `secretId`.

Os parâmetros a seguir geralmente são usados ao se conectar com o Snowflake.

- `sfDatabase`: obrigatório se o padrão do usuário não estiver definido no Snowflake. Usado para leitura/gravação. O banco de dados a ser usado na sessão após a conexão.

- `sfSchema`: obrigatório se o padrão do usuário não estiver definido no Snowflake. Usado para leitura/gravação. O esquema a ser usado na sessão após a conexão.
- `sfWarehouse`: obrigatório se o padrão do usuário não estiver definido no Snowflake. Usado para leitura/gravação. O armazém virtual padrão a ser usado na sessão após a conexão.
- `sfRole`: obrigatório se o padrão do usuário não estiver definido no Snowflake. Usado para leitura/gravação. O perfil de segurança padrão a ser usado na sessão após a conexão.
- `sfUrl`: (obrigatório) usado para leitura/gravação. Especifica o nome do host da sua conta no seguinte formato: *`account_identifier`*`.snowflakecomputing.com`. Para obter mais informações sobre identificadores de conta, consulte Account Identifiers na documentação do Snowflake.
- `sfUser`: (obrigatório) usado para leitura/gravação. Nome de login do usuário do Snowflake.
- `sfPassword`: (obrigatório, exceto se `pem_private_key` for fornecido) usado para leitura/gravação. Senha do usuário do Snowflake.
- `dbtable`: obrigatório ao trabalhar com tabelas completas. Usado para leitura/gravação. O nome da tabela a ser lida ou da tabela na qual os dados serão gravados. Durante a leitura, todas as colunas e registros são recuperados.
- `pem_private_key`: usado para leitura/gravação. Uma string de chave privada codificada em b64 não criptografada. A chave privada do usuário do Snowflake. É comum copiá-la de um arquivo PEM. Para obter mais informações, consulte Autenticação e rotação de pares de chaves na documentação do Snowflake.
- `query`: obrigatório ao ler com uma consulta. Usado para leitura. A consulta exata (instrução `SELECT`) a ser executada

As opções a seguir são usadas para configurar comportamentos específicos durante o processo de conexão com o Snowflake.

- `preactions`: usado para leitura/gravação. Valores válidos: lista separada por ponto e vírgula de instruções SQL como string. As instruções SQL são executadas antes que os dados sejam transferidos entre o AWS Glue e o Snowflake. Se uma instrução contiver `%s`, `%s` será substituído pelo nome da tabela referenciada para a operação.
- `postactions`: usado para leitura/gravação. As instruções SQL são executadas após os dados serem transferidos entre o AWS Glue e o Snowflake. Se uma instrução contiver `%s`, `%s` será substituído pelo nome da tabela referenciada para a operação.

- `autopushdown`: padrão: `"on"`. Valores válidos: `"on"`, `"off"`. Esse parâmetro controla se o pushdown automática de consultas está habilitado. Se o pushdown estiver habilitado, quando uma consulta for executada no Spark, se for possível fazer pushdown de parte da consulta para o servidor do Snowflake, isso ocorrerá. Isso melhora a performance de algumas consultas. Para obter informações sobre se é possível fazer pushdown da consulta, consulte Pushdown na documentação do Snowflake.

Além disso, algumas das opções disponíveis no conector do Snowflake Spark podem ser compatíveis com o AWS Glue. Para obter mais informações sobre as opções disponíveis no conector do Snowflake Spark, consulte Setting Configuration Options for the Connector no Snowflake.

Limitações do conector do Snowflake

A conexão com o Snowflake com o AWS Glue para Spark está sujeita às limitações a seguir.

- Esse conector não é compatível com marcadores de trabalho. Para obter mais informações sobre marcadores de trabalho, consulte the section called “Rastrear dados processados usando marcadores de trabalho”.
- Esse conector não é compatível com leituras e gravações do Snowflake por meio de tabelas no catálogo de dados do AWS Glue usando os métodos `create_dynamic_frame.from_catalog` e `write_dynamic_frame.from_catalog`.
- Esse conector não é compatível com a conexão com o Snowflake usando outras credenciais que não sejam usuário e senha.
- Esse conector não é compatível com trabalhos de streaming.
- Esse conector é compatível com consultas baseadas em instrução `SELECT` ao recuperar informações (como com o parâmetro `query`). Outros tipos de consultas (como `SHOW`, `DESC` ou instruções DML) não são compatíveis.
- O Snowflake limita o tamanho do texto da consulta (ou seja, instruções SQL) enviado pelos clientes do Snowflake a 1 MB por instrução. Para obter mais detalhes, consulte Limits on Query Text Size.

Conexões do Teradata Vantage

O AWS Glue para Spark pode ser usado para ler e escrever em tabelas no Teradata Vantage no AWS Glue 4.0 e versões posteriores. Você pode definir o que ler no Teradata com uma consulta

SQL. Conecte-se ao Teradata usando credenciais de nome de usuário e senha armazenadas no AWS Secrets Manager via conexão do AWS Glue.

Para obter mais informações sobre o Teradata, consulte a Documentação do Teradata.

Configurar conexões do Teradata

Para se conectar ao Teradata via AWS, será necessário criar e armazenar suas credenciais do Teradata em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão ao AWS Glue do Teradata. Se sua instância do Teradata estiver em uma Amazon VPC, você também precisará fornecer opções de rede para sua conexão AWS Glue Teradata.

Para se conectar ao Teradata via AWS Glue, talvez seja necessário atender a alguns pré-requisitos:

- Se você estiver acessando seu ambiente Teradata via Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com o ambiente Teradata. Recomendamos não acessar o ambiente Teradata via Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre sua instância do Teradata e esse local. Seu trabalho precisará estabelecer uma conexão TCP com a porta cliente do Teradata. Para obter mais informações sobre portas do Teradata, consulte a Documentação do Teradata.

  Com base no layout da sua rede, a conectividade segura da VPC pode exigir alterações na Amazon VPC e em outros serviços de rede. Para obter mais informações sobre conectividade com a AWS, consulte Opções de conectividade da AWS na documentação da Teradata.

Para configurar uma conexão AWS Teradata:

1. Em sua configuração do Teradata, identifique ou crie um usuário e a senha com os quais o AWS Glue se conectará, *`teradataUser`* e *`teradataPassword`*. Para obter mais informações, consulte Visão geral da segurança do Vantage na documentação do Teradata.
2. No AWS Secrets Manager, crie um segredo usando suas credenciais do Teradata. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *`SecretName`*, para a próxima etapa.

- Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *`teradataUsername`*.
- Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *`teradataPassword`*.

3. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *`connectionName`*, para a próxima etapa.

   - Ao selecionar um Tipo de conexão, selecione Teradata.
   - Ao fornecer o URL do JDBC, forneça o URL da sua instância. Você também pode codificar certos parâmetros de conexão separados por vírgula no URL do JDBC. O URL deve estar de acordo com o seguinte formato: `jdbc:teradata://`*`teradataHostname`*`/`*`ParameterName`*`=`*`ParameterValue`*`,`*`ParameterName`*

     Os parâmetros de URL compatíveis incluem:

     - `DATABASE`: o nome do banco de dados no host a ser acessado por padrão.
     - `DBS_PORT`: a porta do banco de dados usada para execução em uma porta não padrão.
   - Ao selecionar um Tipo de credencial, selecione AWS Secrets Manager e defina Segredo da AWS como *`secretName`*.

4. Nas seguintes situações, configurações adicionais podem ser necessárias:

   - Para instâncias do Teradata hospedadas na AWS em uma Amazon VPC
     - Será necessário fornecer informações de conexão da Amazon VPC à conexão do AWS Glue que define suas credenciais de segurança do Teradata. Ao criar ou atualizar sua conexão, defina VPC, Sub-rede e Grupos de segurança em Opções de rede.

Depois de criar uma conexão AWS Glue Teradata, será necessário executar as etapas a seguir antes de chamar seu método de conexão.

- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *`secretName`*.
- Na configuração do trabalho do AWS Glue, forneça *`connectionName`* como uma conexão de rede adicional.

Ler do Teradata

Pré-requisitos:

- Uma tabela do Teradata da qual você deseja ler. Você precisará do nome da tabela, *tableName*.
- Uma conexão AWS Glue Teradata configurada para fornecer informações de autenticação. Conclua as etapas Para configurar uma conexão com o Teradata para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

Por exemplo:

```
teradata_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type="teradata",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName"
    }
)
```

Você também pode fornecer uma consulta SQL SELECT para filtrar os resultados retornados ao seu DynamicFrame. Você precisará configurar `query`.

Por exemplo:

```
teradata_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="teradata",
    connection_options={
        "connectionName": "connectionName",
        "query": "query"
    }
)
```

Escrever em tabelas do Teradata

Pré-requisitos: uma tabela do Teradata na qual você gostaria de escrever, *tableName*. É necessário criar a tabela antes de chamar o método de conexão.

Por exemplo:

```
teradata_write = glueContext.write_dynamic_frame.from_options(
```

```
    connection_type="teradata",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName"
    }
)
```

Referência de opções de conexão do Teradata

- `connectionName` — Obrigatório. Usado para leitura/gravação. O nome de uma conexão do AWS Glue Teradata configurada para fornecer informações de autenticação e rede ao seu método de conexão.
- `dbtable`: necessário para escrever, obrigatório para leitura, a menos que `query` seja fornecido. Usado para leitura/gravação. O nome de uma tabela com a qual seu método de conexão interagirá.
- `query` - Usado para leitura. Uma consulta SQL SELECT que define o que deve ser recuperado na leitura do Teradata.

Conexões do Teradata Vantage NOS

A conexão do Teradata NOS (Native Object Store) é uma nova conexão para o Teradata Vantage que utiliza a consulta Teradata WRITE_NOS para ler tabelas existentes e a consulta READ_NOS para gravar em tabelas. Essas consultas usam o Amazon S3 como um diretório de preparação e, portanto, o conector Teradata NOS é mais rápido do que o conector Teradata existente (baseado em JDBC), especialmente ao lidar com grandes quantidades de dados.

É possível usar a conexão do Teradata NOS no AWS Glue para ler e escrever em tabelas no Teradata Vantage no AWS Glue Glue 5.0 e versões posteriores. Você pode definir o que ler no Teradata com uma consulta SQL. É possível se conectar ao Teradata usando credenciais de nome de usuário e senha armazenadas no AWS Secrets Manager via conexão do AWS Glue.

Para obter mais informações sobre o Teradata, consulte a Documentação do Teradata.

Tópicos

- Criar uma conexão do Teradata NOS
- Ler de tabelas do Teradata
- Escrever em tabelas do Teradata
- Referência de opções de conexão do Teradata

- Fornecer opções na interface de usuário de ETL visual do AWS Glue

Criar uma conexão do Teradata NOS

Para se conectar ao Teradata NOS via AWS Glue, será necessário criar e armazenar suas credenciais do Teradata em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão ao AWS Glue do Teradata NOS. Se sua instância do Teradata estiver em uma Amazon VPC, você também precisará fornecer opções de rede para sua conexão do AWS Glue Teradata NOS.

Pré-requisitos:

- Se você estiver acessando seu ambiente Teradata via Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com o ambiente Teradata. Recomendamos não acessar o ambiente Teradata via Internet pública.
- Na Amazon VPC, identifique ou crie uma VPC, uma sub-rede e um grupo de segurança para o AWS Glue usar durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre sua instância do Teradata e esse local. Seu trabalho precisará estabelecer uma conexão TCP com a porta cliente do Teradata. Para obter mais informações sobre portas do Teradata, consulte Grupos de Segurança do Teradata Vantage.
- Com base no layout da sua rede, a conectividade segura da VPC pode exigir alterações na Amazon VPC e em outros serviços de rede. Para obter mais informações sobre conectividade com a AWS, consulte Opções de conectividade da AWS na documentação do Teradata.

Para configurar uma conexão do AWS Glue Teradata NOS:

1. Em sua configuração do Teradata, identifique ou crie um usuário *teradataUsername* e uma senha *teradataPassword* que serão usados pelo AWS Glue para conectar. Para obter mais informações, consulte Visão geral da segurança do Vantage na documentação do Teradata.
2. No AWS Secrets Manager, crie um segredo usando suas credenciais do Teradata. Para criar um segredo no AWS Secrets Manager, siga o tutorial disponível em Criar um segredo do AWS Secrets Manager na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.
   - Ao selecionar pares de chave/valor, crie um par para a chave USERNAME com o valor *teradataUsername*.

- Ao selecionar pares de chave/valor, crie um par para a chave PASSWORD com o valor *teradataPassword*.

3. No console do AWS Glue, crie uma conexão de acordo com as etapas em Adicionar uma conexão do AWS Glue. Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para a próxima etapa.

   - Ao selecionar um Tipo de conexão, selecione Teradata Vantage NOS.
   - Ao fornecer o URL do JDBC, forneça o URL da sua instância. Você também pode codificar certos parâmetros de conexão separados por vírgula no URL do JDBC. O URL deve estar de acordo com o seguinte formato: `jdbc:teradata://teradataHostname/ParameterName=ParameterValue,ParameterName=ParameterValue` .
   - Os parâmetros de URL compatíveis incluem:
     - `DATABASE`: o nome do banco de dados no host a ser acessado por padrão.
     - `DBS_PORT`: a porta do banco de dados usada para execução em uma porta não padrão.
   - Ao selecionar um Tipo de credencial, selecione AWS Secrets Manager e defina Segredo da AWS como *secretName*.
4. Nas seguintes situações, configurações adicionais podem ser necessárias:

   - Para instâncias do Teradata hospedas na AWS em uma Amazon VPC, será necessário fornecer informações de conexão da Amazon VPC à conexão do AWS Glue que define suas credenciais de segurança do Teradata. Ao criar ou atualizar sua conexão, defina VPC, Sub-rede e Grupos de segurança em Opções de rede.

Depois de criar uma conexão do AWS Glue Teradata Vantage NOS, será necessário executar as etapas a seguir antes de chamar seu método de conexão.

1. Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *secretName*.
2. Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional em Conexões.

Ler de tabelas do Teradata

Pré-requisitos:

- Uma tabela do Teradata da qual você deseja ler. Você precisará do nome da tabela, *tableName*.

- O ambiente Teradata tem acesso de gravação ao caminho do Amazon S3 especificado pela opção `staging_fs_url`, *`stagingFsUrl`*.
- O perfil do IAM associado ao trabalho do AWS Glue tem acesso de gravação ao local do Amazon S3 especificado pela opção `staging_fs_url`.
- Uma conexão do AWS Glue Teradata NOS configurada para fornecer informações de autenticação. Conclua as etapas Para configurar uma conexão do AWS Glue Teradata NOS: para configurar suas informações de autenticação. Você precisará do nome da conexão do AWS Glue, *`connectionName`*.

Exemplo: .

```
teradata_read_table = glueContext.create_dynamic_frame.from_options(
    connection_type= "teradatanos",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "staging_fs_url": "stagingFsUrl"
    }
)
```

Você também pode fornecer uma consulta SQL SELECT para filtrar os resultados retornados ao seu DynamicFrame. É necessário configurar a consulta. Se você configurar tanto dbTable quanto a consulta, o conector não conseguirá ler os dados. Por exemplo:

```
teradata_read_query = glueContext.create_dynamic_frame.from_options(
    connection_type="teradatanos",
    connection_options={
        "connectionName": "connectionName",
        "query": "query",
        "staging_fs_url": "stagingFsUrl"
    }
)
```

Além disso, é possível usar a API Spark DataFrame para ler tabelas do Teradata. Por exemplo:

```
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()
```

Escrever em tabelas do Teradata

Pré-requisitos

- Uma tabela do Teradata na qual você gostaria de escrever: *tableName*.
- O ambiente Teradata tem acesso de leitura à localização do Amazon S3 especificada pela opção `staging_fs_url`, *stagingFsUrl*.
- O perfil do IAM associado ao trabalho do AWS Glue tem acesso de gravação ao local do Amazon S3 especificado pela opção `staging_fs_url`.
- Uma conexão do AWS Glue Teradata configurada para fornecer informações de autenticação. Conclua as etapas em Para configurar uma conexão do AWS Glue Teradata NOS: para configurar suas informações de autenticação. Você precisará do nome da conexão do AWS Glue, *connectionName*.

  Por exemplo:

```
teradata_write = glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type= "teradatanos",
    connection_options={
        "connectionName": "connectionName",
        "dbtable": "tableName",
        "staging_fs_url": "stagingFsUrl"
    }
)
```

Referência de opções de conexão do Teradata

Opções de conexão e operação:

- `connectionName` — Obrigatório. Usado para leitura/gravação. O nome de uma conexão do AWS Glue Teradata configurada para fornecer informações de autenticação e rede ao seu método de conexão.
- `staging_fs_url` — Obrigatório. Usado para leitura/gravação. Um local gravável no Amazon S3, para ser usado para os dados descarregados ao ler do Teradata e para dados Parquet a serem

carregados no Redshift ao gravar no Teradata. O bucket do S3 deve estar na mesma região que os seus trabalhos do AWS Glue.

- `dbtable`: necessário para escrever, obrigatório para leitura, a menos que `query` seja fornecido. Usado para leitura/gravação. O nome de uma tabela com a qual seu método de conexão interagirá.
- `query` - Usado para leitura. Uma consulta SQL SELECT que define o que deve ser recuperado na leitura do Teradata. Não será possível passar se a opção `dbtable` for fornecida.
- `clean_staging_s3_dir`: opcional. Usado para leitura/gravação. Se verdadeiro, limpa os objetos de staging do Amazon S3 após uma leitura ou gravação. O valor padrão é true.
- `pre_actions`: opcional. Usado para gravação. Lista separada por ponto e vírgula de comandos SQL que são executados antes da transferência de dados entre o Spark e o Teradata Vantage.
- `post_actions`: opcional. Usado para gravação. Lista separada por ponto e vírgula de comandos SQL que são executados após a transferência de dados entre o Spark e o Teradata Vantage.
- `truncate`: opcional. Usado para gravação. Se verdadeiro, o conector trunca a tabela ao gravar no modo de sobrescrita. Se falso, o conector descarta a tabela ao gravar no modo de sobrescrita. O valor padrão é falso.
- `create_table_script`: opcional. Usado para gravação. Uma instrução SQL para criar tabela ao gravar no Teradata Vantage. Útil quando você deseja criar uma tabela com metadados personalizados (por exemplo, CREATE MULTISET ou SET table ou alterar o índice primário). Observe que o nome da tabela usado no script de criação de tabela deve corresponder ao nome da tabela especificado na opção `dbtable`.
- `partition_size_in_mb`: opcional. Usado para leitura. Tamanho máximo de uma partição do Spark em megabytes durante a leitura de objetos de preparação do Amazon S3. O valor padrão é 128.

É possível fornecer opções avançadas ao criar um nó do Teradata. Essas opções são as mesmas disponíveis ao programar AWS Glue para scripts do Spark.

Consulte the section called “Conexões do Teradata Vantage”.

Opções de autorização:

Abaixo encontram-se as opções usadas para fornecer as credenciais da conta da AWS que o conector usa para acessar o bucket de preparação do Amazon S3. Você pode optar por (1) não fornecer nenhuma opção de autorização e usar as credenciais temporárias geradas pelo perfil de

execução AWS Glue; ou (2) fornecer um objeto de autorização `auth_object` que você criou; ou (3) fornecer `aws_access_key_id and aws_secret_access_key` se estiver usando credenciais de longo prazo, ou fornecer `aws_access_key`, `aws_secret_access_key` e `aws_session_token` se estiver usando credenciais temporárias.

- `auth_object`: opcional. Usado para acessar o bucket de preparação do Amazon S3. Uma string de objeto de autorização criada na instância do Teradata. Se fornecido, o conector usará esse objeto de autorização para acessar o bucket de preparação do Amazon S3. Se não for fornecido, e `aws_access_key_id` e `aws_secret_access_key` também não forem fornecidos, uma credencial temporária será recuperada do perfil de execução AWS Glue e usada pelo conector. A conta da AWS associada a esse objeto de autorização deve estar na mesma região que os trabalhos do AWS Glue e o bucket de preparação do Amazon S3 ou estar configurada com confiança entre contas.
- `aws_access_key_id`: opcional. Usado para acessar o bucket de preparação do Amazon S3. Parte de uma credencial de segurança da conta da AWS. Se o `auth_object` não for fornecido e o `aws_access_key_id` for fornecido com a `aws_secret_access_key`, o conector os usará para acessar o bucket de preparação do Amazon S3. A conta da AWS associada a essa chave de acesso deve estar na mesma região que os trabalhos do AWS Glue e o bucket de preparação do Amazon S3 ou estar configurada com confiança entre contas.
- `aws_secret_access_key`: opcional. Usada para acessar o bucket de preparação do Amazon S3. Parte de uma credencial de segurança da conta da AWS. Se o `auth_object` não for fornecido e o `aws_secret_access_key` for fornecido com o `aws_access_key_id`, o conector os usará para acessar o bucket de preparação do Amazon S3. A conta da AWS associada a esse segredo deve estar na mesma região que os trabalhos do AWS Glue e o bucket de preparação do Amazon S3 ou estar configurada com confiança entre contas.
- `aws_session_token`: opcional. Usado para acessar o bucket de preparação do Amazon S3. Parte de uma credencial de segurança temporária da conta da AWS. Deve ser fornecido com o `aws_access_key_id` e a `aws_secret_access_key`.

Fornecer opções na interface de usuário de ETL visual do AWS Glue

Você pode fornecer todas as opções acima em sua interface de usuário de trabalho de ETL visual. Para a opção ConnectionName, você deve escolhê-la na lista suspensa de conexão do NOS Vantage do Teradata. Para todas as outras opções, você deve fornecê-las por meio das propriedades personalizadas do NOS Vantage do Teradata como pares de chave-valor.

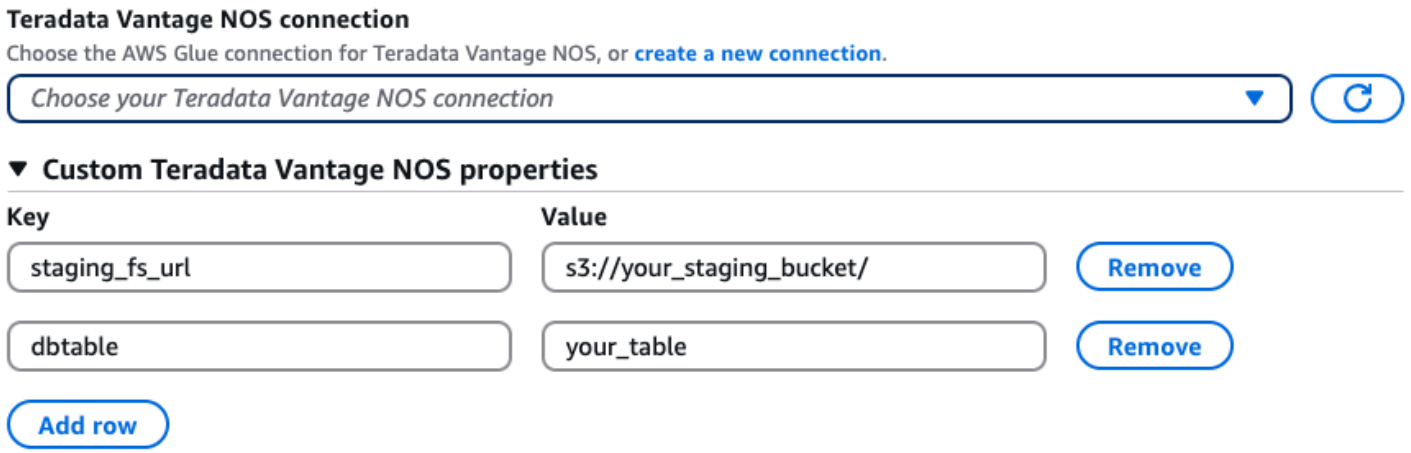

Conexões do Vertica

O AWS Glue para Spark pode ser usado para ler e escrever em tabelas no Vertica no AWS Glue 4.0 e versões posteriores. Você pode definir o que ler no Vertica com uma consulta SQL. Conecte-se ao Vertica usando credenciais de nome de usuário e senha armazenadas no AWS Secrets Manager via conexão do AWS Glue.

Para obter mais informações sobre o Vertica, consulte a Documentação do Vertica.

Configurar conexões do Vertica

Para se conectar ao Vertica via AWS Glue, será necessário criar e armazenar suas credenciais do Vertica em um segredo do AWS Secrets Manager e, em seguida, associar esse segredo a uma conexão ao AWS Glue do Vertica. Se sua instância do Vertica estiver em uma Amazon VPC, você também precisará fornecer opções de rede para sua conexão AWS Glue Vertica. É necessário um bucket ou uma pasta do Amazon S3 para usar como armazenamento temporário ao ler e gravar no banco de dados.

Para se conectar ao Vertica via AWS Glue, talvez seja necessário atender a alguns pré-requisitos:

- Um bucket ou uma pasta do Amazon S3 para usar como armazenamento temporário ao ler e escrever no banco de dados, referido por *tempS3Path*.

> **Note**
>
> Quando o Vertica é usado em pré-visualizações de dados de trabalhos do AWS Glue, os arquivos temporários podem não ser removidos automaticamente de *tempS3Path*. Para

garantir a remoção de arquivos temporários, encerre diretamente a sessão de visualização de dados escolhendo Encerrar sessão no painel Visualização de dados.
Se não for possível garantir que a sessão de visualização de dados seja encerrada diretamente, considere definir a configuração do ciclo de vida do Amazon S3 para remover dados antigos. Recomendamos remover dados com mais de 49 horas com base no runtime máximo do trabalho somado a uma margem. Para obter mais informações sobre a configuração do Amazon S3, consulte Gerenciar o ciclo de vida do armazenamento na documentação do Amazon S3.

- Uma política do IAM com permissões apropriadas para seu caminho do Amazon S3 que você pode associar ao seu perfil de trabalho do AWS Glue.
- Se a sua instância do Vertica estiver em uma Amazon VPC, configure a Amazon VPC para permitir que seu trabalho do AWS Glue se comunique com a instância do Vertica sem que o tráfego passe pela Internet pública.

  Na Amazon VPC, identifique ou crie uma VPC, uma Sub-rede e um Grupo de segurança que o AWS Glue usará durante a execução do trabalho. Além disso, você precisa garantir que a Amazon VPC esteja configurada para permitir o tráfego de rede entre sua instância do Vertica e esse local. Seu trabalho precisará estabelecer uma conexão TCP com a porta cliente do Vertica (por padrão, 5433). Com base no layout da rede, isso pode exigir alterações em regras do grupo de segurança, ACLs de rede, gateways de NAT e conexões de emparelhamento.

Em seguida, você pode continuar com a configuração do AWS Glue para usá-lo com o Vertica.

Para configurar uma conexão com o Vertica:

1. No AWS Secrets Manager, crie um segredo usando suas credenciais do Vertica, *verticaUsername* e *verticaPassword*. Para criar um segredo no Secrets Manager, siga o tutorial disponível em Criar uma AWS Secrets Manager segredo na documentação do AWS Secrets Manager. Depois de criar o segredo, guarde o nome secreto, *SecretName*, para a próxima etapa.

   - Ao selecionar Pares chave/valor, crie um par para a chave `user` com o valor *verticaUsername*.
   - Ao selecionar Pares chave/valor, crie um par para a chave `password` com o valor *verticaPassword*.

2. No console do AWS Glue, crie uma conexão seguindo as etapas em the section called "Adicionar uma conexão do AWS Glue". Depois de criar a conexão, guarde o nome da conexão, *connectionName*, para a próxima etapa.

   - Ao selecionar um Tipo de conexão, selecione Vertica.
   - Ao selecionar Host do Vertica, forneça o URL da sua instalação do Vertica.
   - Ao selecionar Porta do Vertica, a porta pela qual sua instalação do Vertica está disponível.
   - Ao selecionar um Segredo da AWS, forneça o *secretName*.

3. Nas seguintes situações, configurações adicionais podem ser necessárias:

   - Para instâncias do Teradata hospedadas na AWS em uma Amazon VPC
     - Forneça informações de conexão da Amazon VPC à conexão do AWS Glue que define suas credenciais de segurança do Vertica. Ao criar ou atualizar sua conexão, defina VPC, Sub-rede e Grupos de segurança em Opções de rede.

Depois de criar uma conexão AWS Glue Vertica, será necessário executar as etapas a seguir antes de chamar seu método de conexão.

- Conceda ao perfil do IAM associado ao seu trabalho do AWS Glue permissão para *tempS3Path*.
- Conceda ao perfil do IAM associada ao seu trabalho do AWS Glue permissão para ler *secretName*.
- Na configuração do trabalho do AWS Glue, forneça *connectionName* como uma conexão de rede adicional.

Ler no Vertica

Pré-requisitos:

- Uma tabela do Vertica que você deseja ler. Você precisará do nome do banco de dados do Vertica, *dbName* e do nome da tabela, *tableName*.
- Uma conexão AWS Glue Vertica configurada para fornecer informações de autenticação. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o Vertica para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *ConnectionName*.

- Um bucket ou pasta do Amazon S3 para usar para armazenamento temporário, mencionado anteriormente. Você precisará do nome *tempS3Path*. Você deverá se conectar a esse local usando o protocolo `s3a`.

Por exemplo:

```
dynamicFrame = glueContext.create_dynamic_frame.from_options(
    connection_type="vertica",
    connection_options={
        "connectionName": "connectionName",
        "staging_fs_url": "s3a://tempS3Path",
        "db": "dbName",
        "table": "tableName",
    }
)
```

Você também pode fornecer uma consulta SQL SELECT para filtrar os resultados retornados ao seu DynamicFrame ou para acessar um conjunto de dados de várias tabelas.

Por exemplo:

```
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",
    },
)
```

Escrever em tabelas do Vertica

Este exemplo escreve informações de um DynamicFrame existente, *dynamicFrame*, no Vertica. Se a tabela já contiver informações, o AWS Glue anexará dados do seu DynamicFrame.

Pré-requisitos:

- O nome de uma tabela atual ou desejada, *tableName*, na qual você deseja escrever. Você também precisará do nome do banco de dados Vertica correspondente, *dbName*.

- Uma conexão AWS Glue Vertica configurada para fornecer informações de autenticação. Conclua as etapas do procedimento anterior, Para configurar uma conexão com o Vertica para configurar suas informações de autenticação. Você precisará do nome da conexão AWS Glue, *`ConnectionName`*.
- Um bucket ou pasta do Amazon S3 para usar para armazenamento temporário, mencionado anteriormente. Você precisará do nome *`tempS3Path`*. Você deverá se conectar a esse local usando o protocolo `s3a`.

Por exemplo:

```
glueContext.write_dynamic_frame.from_options(
    frame=dynamicFrame,
    connection_type="vertica",
    connection_options={
        "connectionName": "connectionName",
        "staging_fs_url": "s3a://tempS3Path",
        "db": "dbName",
        "table": "tableName",
    }
)
```

Referência de opções de conexão do Vertica

- `connectionName` — Obrigatório. Usado para leitura/gravação. O nome de uma conexão do AWS Glue Vertica configurada para fornecer informações de autenticação e rede ao seu método de conexão.
- db — Obrigatório. Usado para leitura/gravação. O nome de um banco de dados no Vertica com o qual seu método de conexão interagirá.
- `dbSchema`: exigido se necessário para identificar sua tabela. Usado para leitura/gravação. Padrão: `public`. O nome de um esquema com o qual seu método de conexão interagirá.
- `table`: necessário para escrever, obrigatório para leitura, a menos que `query` seja fornecido. Usado para leitura/gravação. O nome de uma tabela com a qual seu método de conexão interagirá.
- `query` - Usado para leitura. Uma consulta SQL SELECT que define o que deve ser recuperado na leitura do Teradata.
- `staging_fs_url` — Obrigatório. Usado para leitura/gravação. Valores válidos: URLs do `s3a`. O URL de um bucket ou pasta do Amazon S3 a ser usado para armazenamento temporário.

Opções de DataFrame para ETL no AWS Glue 5.0 para Spark

Um DataFrame é um conjunto de dados organizados em colunas nomeadas semelhante a uma tabela e é compatível com operações de estilo funcional (mapear/reduzir/filtrar etc.) e operações SQL (select, project, aggregate).

Para criar um DataFrame para uma fonte de dados compatível com o Glue os seguintes requisitos devem ser atendidos:

- conector da fonte de dados `ClassName`
- conexão da fonte de dados `Options`

Da mesma forma, para gravar um DataFrame em um coletor de dados suportado pelo Glue, o mesmo é necessário:

- conector do coletor de dados `ClassName`
- conexão do coletor de dados `Options`

Observe que recursos do AWS Glue, como marcadores de tarefas, e opções de DynamicFrame, como `connectionName`, não são compatíveis com o DataFrame. Para obter mais detalhes sobre o DataFrame e as operações válidas, consulte a documentação do Spark para o DataFrame.

Especificar o ClassName do conector

Para especificar o `ClassName` de um coletor/fonte de dados, use a opção `.format` para fornecer o conector `ClassName` correspondente que define o coletor/fonte de dados.

Conectores JDBC

Para conectores JDBC, especifique `jdbc` como o valor da opção `.format` e forneça o driver JDBC `ClassName` na opção `driver`.

```
df = spark.read.format("jdbc").option("driver", "<DATA SOURCE JDBC DRIVER
 CLASSNAME>")...

df.write.format("jdbc").option("driver", "<DATA SINK JDBC DRIVER CLASSNAME>")...
```

A tabela a seguir lista o driver JDBC `ClassName` da fonte de dados compatível no AWS Glue para DataFrames.

Fonte de dados	Driver 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

Conectores do Spark

Para conectores do Spark, especifique o `ClassName` do conector como o valor da opção `.format`.

```
df = spark.read.format("<DATA SOURCE CONNECTOR CLASSNAME>")...

df.write.format("<DATA SINK CONNECTOR CLASSNAME>")...
```

A tabela a seguir lista o conector Spark `ClassName` da fonte de dados compatível no AWS Glue para DataFrames.

Fonte de dados	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

Especificar as opções de conexão

Para especificar as `Options` da conexão com um coletor/fonte de dados, use o `.option(<KEY>, <VALUE>)` para fornecer opções individuais ou `.options(<MAP>)` para fornecer várias opções como um mapa de chave-valor.

Cada coletor/fonte de dados oferece suporte ao seu próprio conjunto de conexão `Options`. Para obter detalhes sobre as `Options` disponíveis, consulte a documentação pública do conector Spark do coletor/fonte de dados específico listado na tabela a seguir.

- JDBC
- MongoDB/DocumentDB
- Redshift
- AzureCosmos
- AzureSQL
- BigQuery
- OpenSearch
- Snowflake
- Vertica

Exemplos

Os seguintes exemplos leem do PostgreSQL e gravam no SnowFlake:

Python

Exemplo: .

```
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

Exemplo: .

```
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()
```

Valores de connectionType personalizados e AWS Marketplace

Incluindo o seguinte:

- `"connectionType": "marketplace.athena"`: designa uma conexão com um armazenamento de dados do Amazon Athena. A conexão usa um conector de AWS Marketplace.
- `"connectionType": "marketplace.spark"`: designa uma conexão com um armazenamento de dados do Apache Spark. A conexão usa um conector de AWS Marketplace.
- `"connectionType": "marketplace.jdbc"`: designa uma conexão com um armazenamento de dados do JDBC. A conexão usa um conector de AWS Marketplace.
- `"connectionType": "custom.athena"`: designa uma conexão com um armazenamento de dados do Amazon Athena. A conexão usa um conector personalizado que você carrega no AWS Glue Studio.
- `"connectionType": "custom.spark"`: designa uma conexão com um armazenamento de dados do Apache Spark. A conexão usa um conector personalizado que você carrega no AWS Glue Studio.
- `"connectionType": "custom.jdbc"`: designa uma conexão com um armazenamento de dados do JDBC. A conexão usa um conector personalizado que você carrega no AWS Glue Studio.

Opções de conexão para o tipo custom.jdbc ou marketplace.jdbc

- `className`: string, obrigatório, nome da classe do driver.
- `connectionName`: string, obrigatório, nome da conexão associada ao conector.
- `url`: string, obrigatório, URL do JDBC com espaços reservados (`${}`) que são usados para construir a conexão com a origem dos dados. O espaço reservado `${secretKey}` é substituído

pelo segredo do mesmo nome em AWS Secrets Manager. Consulte a documentação do armazenamento de dados para obter mais informações sobre como construir o URL.

- `secretId` ou `user/password`: string, obrigatório, usado para recuperar credenciais para o URL.
- `dbTable` ou `query`: string, obrigatório, a tabela ou consulta SQL da qual obter os dados. Você pode especificar `dbTable` ou `query`, mas não os dois.
- `partitionColumn`: string, opcional, o nome de uma coluna de inteiros usada para o particionamento. Essa opção só funciona quando está incluída em `lowerBound`, `upperBound` e `numPartitions`. Essa opção funciona da mesma maneira que no leitor JDBC Spark SQL. Para obter mais informações, consulte JDBC para outros bancos de dados no Guia do Apache Spark SQL, DataFrames e conjuntos de dados.

  Os valores de `lowerBound` e `upperBound` são usados para decidir o passo de partição, não para filtrar as linhas na tabela. Todas as linhas na tabela são particionadas e retornadas.

  > **Note**
  >
  > Ao usar uma consulta em vez de um nome de tabela, você deve validar se a consulta funciona com a condição de particionamento especificada. Por exemplo:
  >
  > - Se o seu formato de consulta for `"SELECT col1 FROM table1"`, teste a consulta anexando uma cláusula `WHERE` no final da consulta que usa a coluna de partição.
  > - Se o seu formato de consulta for `"SELECT col1 FROM table1 WHERE col2=val"`, teste a consulta estendendo a cláusula `WHERE` com `AND` e uma expressão que usa a coluna de partição.

- `lowerBound`: inteiro, opcional, o valor mínimo de `partitionColumn` que é usado para decidir o passo de partição.
- `upperBound`: inteiro, opcional, o valor máximo de `partitionColumn` que é usado para decidir o passo de partição.
- `numPartitions`: inteiro, opcional, o número de partições. Esse valor, juntamente com `lowerBound` (inclusive) e `upperBound` (exclusive), forma os passos de partição para as expressões de cláusula `WHERE` geradas que são usadas para dividir a `partitionColumn`.

> **Important**
>
> Tenha cuidado com a quantidade, pois muitas partições podem causar problemas em seus sistemas de banco de dados externo.

- `filterPredicate`: string, opcional, cláusula de condição extra para filtrar dados da fonte. Por exemplo:

```
BillingCity='Mountain View'
```

  Ao usar uma consulta em vez de um nome de tabela, você deve validar que a consulta funciona com o `filterPredicate` especificado. Por exemplo:

  - Se o seu formato de consulta for `"SELECT col1 FROM table1"`, teste a consulta anexando uma cláusula `WHERE` no final da consulta que usa o predicado do filtro.
  - Se o seu formato de consulta for `"SELECT col1 FROM table1 WHERE col2=val"`, teste a consulta estendendo a cláusula `WHERE` com `AND` e uma expressão que usa o predicado do filtro.

- `dataTypeMapping`: dicionário, opcional, mapeamento de tipo de dados personalizado que constrói um mapeamento a partir de um tipo de dados JDBC para um tipo de dados Glue. Por exemplo, a opção `"dataTypeMapping":{"FLOAT":"STRING"}` mapeia campos de dados JDBC do tipo `FLOAT` para o tipo `String` do Java chamando o método `ResultSet.getString()` do driver e o usa para complilar registros do AWS Glue. O objeto `ResultSet` é implantado por cada driver, portanto, o comportamento é específico para o driver que você usa. Consulte a documentação do driver do JDBC para entender como ele executa as conversões.
- Os tipos de dados do AWS Glue compatíveis atualmente são:
  - DATE
  - STRING
  - TIMESTAMP
  - INT
  - FLOAT
  - LONG
  - BIGDECIMAL
  - BYTE

- SHORT
- DOUBLE

Os tipos de dados JDBC compatíveis são Java8 java.sql.types.

Os mapeamentos de tipos de dados padrão (de JDBC para o AWS Glue) são:

- 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

Se você usar um mapeamento de tipo de dados personalizado com a opção `dataTypeMapping`, poderá substituir um mapeamento de tipo de dados padrão. Somente os tipos de dados JDBC listados na opção `dataTypeMapping` são afetados. O mapeamento padrão é usado para todos os outros tipos de dados JDBC. Você pode adicionar mapeamentos para tipos de dados JDBC adicionais, se necessário. Se um tipo de dados JDBC não estiver incluído no mapeamento padrão ou em um mapeamento personalizado, o tipo de dados será convertido para o tipo de dados `STRING` do AWS Glue por padrão.

Os exemplos de código Python a seguir mostram como fazer a leitura de bancos de dados JDBC com drivers JDBC AWS Marketplace. Ele demonstra a leitura de um banco de dados e a gravação em um local 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()
```

Opções de conexão para o tipo custom.athena ou marketplace.athena

- `className`: string, obrigatório, nome da classe do driver. Quando você estiver usando o conector Athena-CloudWatch, esse valor de parâmetro será o prefixo da classe Name (Nome) (por exemplo, `"com.amazonaws.athena.connectors"`). O conector Athena-CloudWatch é composto por duas classes: um manipulador de metadados e um manipulador de registros. Se você fornecer o prefixo comum aqui, a API carregará as classes corretas com base nesse prefixo.
- `tableName`: string, obrigatório, o nome do fluxo de log do CloudWatch a ser lido. Esse trecho de código usa o nome de exibição especial `all_log_streams`, o que significa que o quadro de dados dinâmicos retornada conterá dados de todos os fluxos de log no grupo de logs.
- `schemaName`: string, obrigatório, o nome do grupo de logs do CloudWatch a ser lido. Por exemplo, `/aws-glue/jobs/output`.
- `connectionName`: string, obrigatório, nome da conexão associada ao conector.

Para obter opções adicionais para esse conector, consulte o arquivo Amazon Athena CloudWatch Connector README (LEIAME do conector Amazon Athena CloudWatch) no GitHub.

O exemplo de código Python a seguir mostra como fazer a leitura de um armazenamento de dados do Athena usando um conector AWS Marketplace. Ele demonstra a leitura do Athena e a gravação em um local 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()
```

Opções de conexão para o tipo custom.spark ou marketplace.spark

- `className`: string, obrigatório, nome da classe do conector.
- `secretId`: string, opcional, usado para recuperar credenciais para a conexão do conector.
- `connectionName`: string, obrigatório, nome da conexão associada ao conector.

- Outras opções dependem do armazenamento de dados. Por exemplo, as opções de configuração do OpenSearch começam com o prefixo `es`, conforme descrito na documentação Elasticsearch for Apache Hadoop (Elasticsearch para Apache Hadoop). Conexões do Spark com o Snowflake usam opções como `sfUser` e `sfPassword`, conforme descrito em Usar o conector do Spark no guia Conexão com o Snowflake.

O exemplo de código Python a seguir mostra como fazer a leitura de um armazenamento de dados do OpenSearch usando um conector `marketplace.spark`.

```
    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()
```

Opções gerais

As opções nesta seção são fornecidas como `connection_options`, mas não se aplicam especificamente a um determinado conector.

Os parâmetros a seguir geralmente são usados ao configurar marcadores. Eles podem se aplicar aos fluxos de trabalho do Amazon S3 ou JDBC. Para ter mais informações, consulte the section called “Usar marcadores de trabalho”.

- `jobBookmarkKeys`: uma matriz de nomes de coluna.
- `jobBookmarkKeysSortOrder`: string que define como comparar valores com base na ordem de classificação. Valores válidos: `"asc"`, `"desc"`.
- `useS3ListImplementation`: usado para gerenciar a performance da memória ao listar o conteúdo dos buckets do Amazon S3. Para obter mais informações, consulte Optimize memory management in AWS Glue.

Opções de formato de dados para entradas e saídas no AWS Glue para Spark

Essas páginas oferecem informações sobre suporte a atributos e parâmetros de configuração para formatos de dados compatíveis com o AWS Glue para Spark. Consulte a seguir uma descrição do uso e da aplicabilidade destas informações.

Suporte de recursos em todos os formatos de dados no AWS Glue

Cada formato de dados pode ser compatível com diferentes recursos do AWS Glue. Os recursos comuns a seguir podem ou não ser compatíveis, de acordo com o tipo de formato. Consulte a documentação do formato de dados para entender como utilizar nossos recursos para atender a suas necessidades.

Leitura	O AWS Glue pode reconhecer e interpretar esse formato de dados sem recursos adicionais, como conectores.
Escrever	O AWS Glue pode gravar dados nesse formato sem recursos adicionais. É possível incluir

	bibliotecas de terceiros em seu trabalho e usar as funções padrão do Apache Spark para gravar dados, como faria em outros ambientes Spark. Para mais informações sobre como incluir bibliotecas, consulte the section called “Bibliotecas Python”.
Leitura de transmissão	O AWS Glue pode reconhecer e interpretar esse formato de dados a partir de um fluxo de mensagens do Apache Kafka, do Amazon Managed Streaming para Apache Kafka ou do Amazon Kinesis. Esperamos que os fluxos apresentem os dados em um formato consistente, para que sejam lidos como `DataFrames` .
Agrupar arquivos pequeno	O AWS Glue pode agrupar arquivos para trabalhos em lote enviados para cada nó durante a execução de transformações do AWS Glue. Isso pode melhorar consideravelmente a performance de workloads que envolvam grandes quantidades de arquivos pequenos. Para ter mais informações, consulte the section called “Agrupar arquivos de entrada”.
Marcadores de trabalho	O AWS Glue pode acompanhar o progresso das transformações que realizam o mesmo trabalho no mesmo conjunto de dados em todas as execuções de tarefas com indicadores de tarefas. Isso pode melhorar a performance de workloads que envolvem conjuntos de dados em que o trabalho só precisa ser feito com novos dados desde a última execução do trabalho. Para ter mais informações, consulte the section called “Rastrear dados processados usando marcadores de trabalho”.

Parâmetros usados para interagir com formatos de dados no AWSGlue

Certos tipos de conexão do AWS Glue são compatíveis com vários tipos de `format`, fazendo com que seja necessário especificar informações sobre o formato de dados com um objeto `format_options` ao usar métodos como `GlueContext.write_dynamic_frame.from_options`.

- `s3`: para obter mais informações, consulte Tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do S3. Também é possível visualizar a documentação para os métodos que facilitam esse tipo de conexão: the section called “create_dynamic_frame_from_options” e the section called “write_dynamic_frame_from_options” em Python e os métodos Scala correspondentes the section called “getSourceWithFormat” e the section called “getSinkWithFormat”.

- `kinesis`: para obter mais informações, consulte Tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do Kinesis. Também é possível visualizar a documentação para o método que facilita esse tipo de conexão: the section called “create_data_frame_from_options” em Python e o método Scala correspondente the section called “createDataFrameFromOptions”.
- `kafka`: para obter mais informações, consulte Tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do Kafka. Também é possível visualizar a documentação para o método que facilita esse tipo de conexão: the section called “create_data_frame_from_options” em Python e o método Scala correspondente the section called “createDataFrameFromOptions”.

Alguns tipos de conexão não exigem `format_options`. Por exemplo, em uso normal, uma conexão JDBC com um banco de dados relacional recupera dados em formato de dados tabular consistente. Portanto, a leitura de uma conexão JDBC não exigiria `format_options`.

Alguns métodos para ler e gravar dados no Glue não exigem `format_options`. Por exemplo, usar `GlueContext.create_dynamic_frame.from_catalog` com crawlers do AWS Glue. Os crawlers determinam a forma dos dados. Ao usar crawlers, um classificador do AWS Glue examinará seus dados para tomar decisões inteligentes sobre como representar o formato de dados. Em seguida, armazenará uma representação de seus dados no Catálogo de Dados do AWS Glue, que pode ser usado em um script ETL do AWS Glue para recuperar dados com o método `GlueContext.create_dynamic_frame.from_catalog`. Os crawlers eliminam a necessidade de especificar manualmente as informações sobre o formato dos dados.

Para trabalhos que acessam tabelas governadas pelo AWS Lake Formation, o AWS Glue oferece suporte para a leitura e a escrita de todos os formatos com suporte pelas tabelas governadas pelo

Lake Formation. Para obter a lista atual de formatos com suporte para tabelas governadas pelo AWS Lake Formation, consulte Notas e restrições para tabelas controladas no Guia do desenvolvedor do AWS Lake Formation.

> **Note**
>
> Para gravar Apache Parquet, o ETL do AWS Glue só oferece suporte para gravação em uma tabela controlada especificando uma opção para um tipo de gravador Parquet personalizado otimizado para quadros dinâmicos. Ao gravar em uma tabela governada com o formato `parquet`, você deve adicionar a chave `useGlueParquetWriter` com um valor de `true` nos parâmetros da tabela.

Tópicos

- Uso do formato CSV no AWS Glue
- Uso do formato Parquet no AWS Glue
- Uso do formato XML no AWS Glue
- Uso do formato Avro no AWS Glue
- Uso do formato grokLog no AWS Glue
- Uso do formato Ion no AWS Glue
- Uso do formato JSON no AWS Glue
- Usar o formato ORC no AWS Glue
- Usar estruturas de data lake com trabalhos do AWS Glue ETL
- Referência de configuração compartilhada

Uso do formato CSV no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se seus dados forem armazenados ou transportados no formato de dados CSV, este documento apresenta os recursos disponíveis para usar seus dados no AWS Glue.

O AWS Glue é compatível com o uso do formato de arquivo de valores separados por vírgulas (CSV). Esse formato é um formato de dados baseado em linha. Em geral, os CSVs não estão em conformidade estrita com um padrão, mas você pode consultar RFC 4180 e RFC 7111 para obter mais informações.

Você pode usar o AWS Glue para ler CSVs do Amazon S3 e de fontes de transmissão, bem como para gravar CSVs no Amazon S3. Você pode ler e gravar arquivos `bzip` e `gzip` do S3 que contenham arquivos CSV. Você configura o comportamento de compactação no Parâmetros de conexão do S3 e não na configuração apresentada nesta página.

A tabela a seguir mostra quais são os recursos comuns do AWS Glue compatíveis com a opção de formato CSV.

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho
Compatível	Compatível	Compatível	Compatível	Compatível

Exemplo: ler arquivos ou pastas CSV do S3

Pré-requisitos: você precisará dos caminhos do S3 (`s3path`) para os arquivos ou pastas CSV que deseja ler.

Configuração: nas opções da sua função, especifique `format="csv"`. Em seu `connection_options`, use a chave `paths` para especificar `s3path`. Você pode configurar como o leitor interage com o S3 no `connection_options`. Para mais detalhes, consulte os tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do S3. Você pode configurar como o leitor interpreta os arquivos CSV em seu `format_options`. Para obter mais detalhes, consulte CSV Configuration Reference (Referência de configuração de CSV).

O seguinte script de ETL do AWS Glue mostra o processo de leitura de arquivos ou pastas CSV provenientes do S3.

Fornecemos um leitor personalizado de CSV com otimizações de desempenho para fluxos de trabalho comuns por meio da chave de configuração `optimizePerformance`. Para determinar se esse leitor é adequado para sua workload, consulte the section called “Usar o leitor CSV otimizado”.

Python

Neste exemplo, use o método 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,
    },
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .format("csv")\
    .option("header", "true")\
    .load("s3://s3path")
```

Scala

Neste exemplo, use a operação 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()
  }
}
```

Você também pode usar DataFrames em um script (`org.apache.spark.sql.DataFrame`).

```
val dataFrame = spark.read
  .option("header","true")
  .format("csv")
  .load("s3://s3path“)
```

Exemplo: gravar arquivos e pastas CSV no S3

Pré-requisitos: você precisará de um DataFrame (`dataFrame`) ou de um DynamicFrame (`dynamicFrame`) inicializado. Você também precisará do caminho de saída esperado do S3, `s3path`.

Configuração: nas opções da sua função, especifique `format="csv"`. Em seu `connection_options`, use a chave `paths` para especificar `s3path`. Você pode configurar como o gravador interage com o S3 no `connection_options`. Para mais detalhes, consulte os tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do S3. Você pode configurar como sua operação grava o conteúdo de seus arquivos no `format_options`. Para obter mais detalhes, consulte CSV Configuration Reference (Referência de configuração de CSV). O seguinte script de ETL do AWS Glue mostra o processo de gravação de arquivos e pastas CSV no S3.

Python

Neste exemplo, use o método 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,
    },
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
dataFrame.write\
    .format("csv")\
    .option("quote", None)\
    .mode("append")\
    .save("s3://s3path")
```

Scala

Neste exemplo, use o método 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)
  }
}
```

Você também pode usar DataFrames em um script (`org.apache.spark.sql.DataFrame`).

```
dataFrame.write
    .format("csv")
    .option("quote", null)
    .mode("Append")
    .save("s3://s3path")
```

Referência de configuração de CSV

Você pode usar o seguinte `format_options` sempre que as bibliotecas do AWS Glue especificarem `format="csv"`:

- `separator`: especifica o caractere delimitador. O padrão é uma vírgula, mas é possível especificar qualquer outro caractere.
  - Tipo: texto, padrão: `","`
- `escaper`: especifica um caractere a ser usado para escape. Essa opção é usada somente ao ler arquivos CSV, não para gravar. Se ativado, o caractere imediatamente seguinte será usado no estado em que se encontrar, exceto para um pequeno conjunto de escapes conhecidos (`\n`, `\r`, `\t` e `\0`).
  - Tipo: texto, padrão: nenhum
- `quoteChar`: especifica o caractere a ser usado para aspas. O padrão é aspas duplas. Defina como `-1` para desativar as aspas por completo.
  - Tipo: texto, padrão: `'"'`
- `multiLine`: especifica se um único registro pode abranger várias linhas. Isso pode ocorrer quando um campo contém um caractere de nova linha entre aspas. Você deve definir essa opção como `True` se algum registro ocupar várias linhas. Habilitar `multiLine` pode diminuir o desempenho, pois isso requer uma divisão de arquivos mais cautelosa durante a análise.
  - Tipo: booliano, padrão: `false`
- `withHeader`: especifica se a primeira linha deve ser tratada como um cabeçalho. Esta opção pode ser usada na classe `DynamicFrameReader`.

  - Tipo: booliano, padrão: `false`
- `writeHeader`: especifica se deve gravar o cabeçalho na saída. Esta opção pode ser usada na classe `DynamicFrameWriter`.
  - Tipo: booliano, padrão: `true`
- `skipFirst`: especifica se é necessário ignorar a primeira linha de dados.
  - Tipo: booliano, padrão: `false`
- `optimizePerformance`: especifica se deve usar o leitor de SIMD avançado para CSV junto com formatos de memória colunar baseados em Apache Arrow. Disponível apenas no AWS Glue 3.0+.
  - Tipo: booliano, padrão: `false`
- `strictCheckForQuoting`: ao escrever CSVs, o Glue pode adicionar aspas aos valores que interpreta como strings. Isso é feito para evitar ambiguidade no que é gravado. Para economizar tempo ao decidir o que gravar, o Glue pode incluir aspas em determinadas situações em que as aspas não são necessárias. Habilitar uma verificação rigorosa executará um cálculo mais intensivo e só incluirá aspas quando estritamente necessário. Disponível apenas no AWS Glue 3.0+.
  - Tipo: booliano, padrão: `false`

Otimizar o desempenho de leitura com o leitor de SIMD vetorizado para CSV

O AWS Glue versão 3.0 adiciona um leitor de CSV otimizado que pode acelerar significativamente o desempenho geral do trabalho em comparação com os leitores de CSV baseados em linhas.

O leitor otimizado:

- Usa instruções SIMD da CPU para fazer leituras do disco.
- Grava imediatamente registros na memória em um formato colunar (Apache Arrow).
- Divide os registros em lotes.

Isso economiza tempo de processamento quando os registros são colocados em lote ou convertidos em um formato colunar posteriormente. Por exemplo, ao alterar esquemas ou recuperar dados por coluna.

Para usar o leitor otimizado, defina `"optimizePerformance"` como `true` na propriedade `format_options` ou da tabela.

```
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")
```

Limitações para o leitor vetorizado de CSV

Observe as seguintes limitações do leitor vetorizado de CSV:

- Ele não oferece suporte às opções de formato `multiLine` e `escaper`. Ele usa o padrão `escaper` de caractere de aspas duplas `'"'`. Quando essas opções são definidas, o AWS Glue automaticamente volta ao uso do leitor de CSV baseado em linha.
- Ele não oferece suporte à criação de um DynamicFrame com ChoiceType.
- Ele não oferece suporte à criação de um DynamicFrame com registros de erro.
- Ele não oferece suporte à leitura de arquivos CSV com caracteres multibyte, como caracteres japoneses ou chineses.

Uso do formato Parquet no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se seus dados forem armazenados ou transportados no formato de dados Parquet, este documento apresenta os recursos disponíveis para usar seus dados no AWS Glue.

O AWS Glue é compatível com o uso do formato Parquet. Esse formato é um formato de dados orientado a desempenho e baseado em colunas. Para uma apresentação do formato feita pela autoridade padrão, consulte Apache Parquet Documentation Overview (Visão geral da documentação do Apache Parquet).

Você pode usar o AWS Glue para ler arquivos Parquet do Amazon S3 e de fontes de transmissão, bem como para gravar arquivos Parquet no Amazon S3. Você pode ler e gravar arquivos `bzip` e `gzip` do S3 que contenham arquivos Parquet. Você configura o comportamento de compactação no Parâmetros de conexão do S3 e não na configuração apresentada nesta página.

A tabela a seguir mostra quais são os recursos comuns do AWS Glue compatíveis com a opção de formato Parquet.

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho
Compatível	Compatível	Compatível	Sem suporte	Compatível*

*Compatível com o AWS Glue versão 1.0+

Exemplo: ler arquivos ou pastas Parquet do S3

Pré-requisitos: você precisará dos caminhos do S3 (`s3path`) para os arquivos ou pastas Parquet que deseja ler.

Configuração: nas opções da sua função, especifique `format="parquet"`. Em seu `connection_options`, use a chave `paths` para especificar seu `s3path`.

Você pode configurar como o leitor interage com o S3 no `connection_options`. Para mais detalhes, consulte os tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do S3.

Você pode configurar como o leitor interpreta os arquivos Parquet em seu `format_options`. Para obter mais detalhes, consulte Parquet Configuration Reference (Referência de configuração de Parquet).

O seguinte script de ETL do AWS Glue mostra o processo de leitura de arquivos ou pastas Parquet provenientes do S3:

Python

Neste exemplo, use o método 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"
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read.parquet("s3://s3path/")
```

Scala

Neste exemplo, use o método 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()
  }
}
```

Você também pode usar DataFrames em um script (`org.apache.spark.sql.DataFrame`).

```
spark.read.parquet("s3://s3path/")
```

Exemplo: gravar arquivos e pastas Parquet no S3

Pré-requisitos: você precisará de um DataFrame (`dataFrame`) ou de um DynamicFrame (`dynamicFrame`) inicializado. Você também precisará do caminho de saída esperado do S3, `s3path`.

Configuração: nas opções da sua função, especifique `format="parquet"`. Em seu `connection_options`, use a chave `paths` para especificar `s3path`.

Em `connection_options`, você pode alterar ainda mais a forma como o gravador interage com o S3. Para mais detalhes, consulte os tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do S3. Você pode configurar como sua operação grava o conteúdo de seus arquivos no `format_options`. Para obter mais detalhes, consulte Parquet Configuration Reference (Referência de configuração de Parquet).

O seguinte script de ETL do AWS Glue mostra o processo de gravação de arquivos e pastas Parquet no S3.

Fornecemos um gravador personalizado de Parquet com otimizações de desempenho para DynamicFrames, por meio da chave de configuração `useGlueParquetWriter`. Para determinar se esse gravador é adequado para sua workload, consulte Glue Parquet Writer (Gravador Parquet do Glue).

Python

Neste exemplo, use o método 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,
    },
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
df.write.parquet("s3://s3path/")
```

Scala

Neste exemplo, use o método 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)
  }
}
```

Você também pode usar DataFrames em um script (`org.apache.spark.sql.DataFrame`).

```
df.write.parquet("s3://s3path/")
```

Referência de configuração do Parquet

Você pode usar o seguinte `format_options` sempre que as bibliotecas do AWS Glue especificarem `format="parquet"`:

- `useGlueParquetWriter`: especifica o uso de um gravador de Parquet personalizado com otimizações de desempenho para fluxos de trabalho DynamicFrame. Para obter mais detalhes sobre o uso, consulte Glue Parquet Writer (Gravador Parquet do Glue).
  - Tipo: booliano, padrão:`false`

- `compression`: especifica o codec de compactação usado. Os valores são totalmente compatíveis com `org.apache.parquet.hadoop.metadata.CompressionCodecName`.
  - Tipo: texto enumerado, padrão: `"snappy"`
  - Valores: `"uncompressed"`, `"snappy"`, `"gzip"` e `"lzo"`
- `blockSize`: especifica em bytes o tamanho de um grupo de linhas que está sendo armazenado em memória. Você usa isso para ajustar o desempenho. O tamanho deve ser dividido exatamente em um número de megabytes.
  - Digite: numérico, padrão:`134217728`
  - O valor padrão é igual a 128 MB.
- `pageSize`: especifica o tamanho de uma página em bytes. Você usa isso para ajustar o desempenho. Uma página é a menor unidade que deve ser totalmente lida para acessar um único registro.
  - Digite: numérico, padrão:`1048576`
  - O valor padrão é igual a 1 MB.

> **Note**
>
> E ainda, quaisquer opções aceitas pelo código SparkSQL subjacente podem ser transmitidas para ele por meio do parâmetro de mapa `connection_options`. Por exemplo, é possível definir uma configuração do Spark, como mergeSchema, para o leitor de Spark do AWS Glue mesclar o esquema para todos os arquivos.

Otimizar o desempenho de gravação com o gravador de Parquet do AWS Glue

> **Note**
>
> Historicamente, o gravador de Parquet do AWS Glue tem sido acessado por meio do tipo de formato `glueparquet`. Esse padrão de acesso não é mais promovido. Em vez disso, use o tipo `parquet` com `useGlueParquetWriter` habilitado.

O gravador de Parquet do AWS Glue tem aprimoramentos de desempenho que permitem gravações mais rápidas de arquivos Parquet. O gravador tradicional calcula um esquema antes da gravação. O formato Parquet não armazena o esquema de uma maneira rapidamente recuperável, então

isso pode levar algum tempo. Com o gravador de Parquet do AWS Glue, não é necessário usar um esquema pré-calculado. O gravador calcula e modifica o esquema dinamicamente conforme recebe os dados.

Ao especificar `useGlueParquetWriter`, observe as seguintes limitações:

- O gravador oferece só é compatível com evolução do esquema (p. ex., adicionar ou remover colunas), mas não com a alteração de tipos de coluna, como com `ResolveChoice`.
- O gravador não oferece suporte à gravação de DataFrames vazios; por exemplo, para gravar um arquivo somente de esquema. Ao realizar a integração com o Catálogo de Dados da AWS ao configurar `enableUpdateCatalog=True`, a tentativa de gravar um DataFrame vazio não atualizará o Catálogo de Dados. Isso resultará na criação de uma tabela no Catálogo de Dados sem esquema.

Se sua transformação não exigir essas limitações, a ativação do gravador Parquet do AWS Glue deverá aumentar o desempenho.

Uso do formato XML no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se seus dados forem armazenados ou transportados no formato de dados XML, este documento apresenta os recursos disponíveis para usar seus dados no AWS Glue.

O AWS Glue é compatível com o uso do formato XML. Esse formato representa estruturas de dados altamente configuráveis e rigidamente definidas que não são baseadas em linhas ou colunas. O XML é altamente padronizado. Para uma introdução ao formato pela autoridade padrão, consulte XML Essentials (Conceitos básicos de XML).

Você pode usar o AWS Glue para ler arquivos XML do Amazon S3, bem como arquivos `bzip` e `gzip` contendo arquivos XML. Você configura o comportamento de compactação no Parâmetros de conexão do S3 e não na configuração apresentada nesta página.

A tabela a seguir mostra quais são os recursos comuns do AWS Glue compatíveis com a opção de formato XML.

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho
Compatível	Sem suporte	Sem suporte	Compatível	Compatível

Exemplo: ler XML do S3

O leitor de XML usa um nome de tag XML. Ele examina elementos com essa tag em sua entrada para inferir um esquema e preenche um DynamicFrame com valores correspondentes. A funcionalidade de XML do AWS Glue se comporta de modo semelhante a XML Data Source for Apache Spark (Fonte de dados XML para Apache Spark). Talvez você consiga obter informações sobre o comportamento básico comparando esse leitor com a documentação do projeto.

Pré-requisitos: você precisará dos caminhos do S3 (`s3path`) para os arquivos ou pastas XML que deseja ler, além de algumas informações sobre seu arquivo XML. Você também precisará da tag para o elemento XML que deseja ler, `xmlTag`.

Configuração: nas opções da sua função, especifique `format="xml"`. Em seu `connection_options`, use a chave `paths` para especificar `s3path`. Você pode configurar adicionalmente como o leitor interage com o S3 no `connection_options`. Para mais detalhes, consulte os tipos de conexão e opções para ETL no AWS Glue: Parâmetros de conexão do S3. Em seu `format_options`, use a chave `rowTag` para especificar `xmlTag`. Você pode configurar adicionalmente como o leitor interpreta os arquivos XML em seu `format_options`. Para obter mais detalhes, consulte XML Configuration Reference (Referência de configuração de XML).

O seguinte script de ETL do AWS Glue mostra o processo de leitura de arquivos ou pastas XML provenientes do S3.

Python

Neste exemplo, use o método 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"},
```

```
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .format("xml")\
    .option("rowTag", "xmlTag")\
    .load("s3://s3path")
```

Scala

Neste exemplo, use a operação 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()
}
```

Você também pode usar DataFrames em um script (`org.apache.spark.sql.DataFrame`).

```
val dataFrame = spark.read
  .option("rowTag", "xmlTag")
  .format("xml")
  .load("s3://s3path“)
```

Referência de configuração de XML

Você pode usar o seguinte `format_options` sempre que as bibliotecas do AWS Glue especificarem `format="xml"`:

- `rowTag`: especifica a tag XML no arquivo a ser tratada como uma linha. Tags de linha não podem ser de fechamento automático.
  - Tipo: texto, obrigatório
- `encoding`: especifica a codificação de caracteres. Pode ser o nome ou alias de um Charset compatível com nosso ambiente de runtime. Não oferecemos garantias específicas em relação ao suporte à codificação, mas as codificações principais devem funcionar.
  - Tipo: texto, padrão: `"UTF-8"`
- `excludeAttribute`: especifica se você deseja excluir atributos em elementos ou não.
  - Tipo: booliano, padrão: `false`
- `treatEmptyValuesAsNulls`: especifica se o espaço em branco deve ser tratado como um valor nulo.
  - Tipo: booliano, padrão: `false`
- `attributePrefix`: um prefixo para atributos a fim de diferenciá-los de elementos de texto secundários. Esse prefixo é usado para nomes de campo.
  - Tipo: texto, padrão: `"_"`
- `valueTag`: a tag usada para um valor quando há atributos no elemento que não têm secundários.
  - Tipo: texto, padrão: `"_VALUE"`
- `ignoreSurroundingSpaces`: especifica se o espaço em branco que envolve valores deve ser ignorado.
  - Tipo: booliano, padrão: `false`
- `withSchema`: contém o esquema esperado, em situações nas quais você deseja substituir o esquema inferido. Se você não usar essa opção, o AWS Glue inferirá o esquema com base nos dados XML.
  - Tipo: texto, padrão: não aplicável
  - O valor deve ser um objeto JSON que represente um `StructType`.

Especificar manualmente o esquema XML

Exemplo de esquema XML manual

Este é um exemplo de uso da opção de formato `withSchema` para especificar o esquema para dados 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 = ""
)
```

Uso do formato Avro no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se seus dados forem armazenados ou transportados no formato de dados Avro, o documento apresenta os recursos disponíveis para usar seus dados no AWS Glue.

O AWS Glue é compatível com o uso do formato Avro. Esse é um formato de dados orientado a performance e baseado em linhas. Para uma apresentação do formato feita pela autoridade padrão, consulte a documentação do Apache Avro 1.8.2.

Você pode usar o AWS Glue para ler arquivos Avro do Amazon S3 e de fontes de transmissão, bem como para gravar arquivos Avro no Amazon S3. Você pode ler e gravar arquivos `bzip2` e `gzip` do S3 que contenham arquivos Avro. Além disso, você pode gravar arquivamentos `deflate`, `snappy` e `xz` contendo arquivos Avro. Você configura o comportamento de compactação no Parâmetros de conexão do S3 e não na configuração apresentada nesta página.

A tabela a seguir mostra quais são as operações comuns do AWS Glue compatíveis com a opção de formato Avro.

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho
Compatível	Compatível	Compatível*	Sem suporte	Compatível

*Compatível, com restrições. Para ter mais informações, consulte the section called “Notas e restrições para fontes de transmissão Avro”.

Exemplo: ler arquivos ou pastas Avro do S3

Pré-requisitos: você precisará dos caminhos do S3 (`s3path`) para os arquivos ou pastas Avro que deseja ler.

Configuração: nas opções da sua função, especifique `format="avro"`. Em seu `connection_options`, use a chave `paths` para especificar `s3path`. Você pode configurar como o leitor interage com o S3 no `connection_options`. Para obter detalhes, consulte Opções de formato de dados para entradas e saídas de ETL no AWSGlue: the section called “Parâmetros de conexão do S3”. Você pode configurar como o leitor interpreta os arquivos Avro em seu `format_options`. Para obter mais detalhes, consulte Avro Configuration Reference (Referência de configuração de Avro).

O seguinte script de ETL do AWS Glue mostra o processo de leitura de arquivos ou pastas Avro provenientes do S3:

Python

Neste exemplo, use o método 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

Neste exemplo, use a operação 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()
  }
```

Exemplo: gravar arquivos e pastas Avro no S3

Pré-requisitos: você precisará de um DataFrame (`dataFrame`) ou de um DynamicFrame (`dynamicFrame`) inicializado. Você também precisará do caminho de saída esperado do S3, `s3path`.

Configuração: nas opções da sua função, especifique `format="avro"`. Em seu `connection_options`, use a chave `paths` para especificar seu `s3path`. Em `connection_options`, você pode alterar ainda mais a forma como o gravador interage com o S3. Para obter detalhes, consulte Opções de formato de dados para entradas e saídas de ETL no AWSGlue: the section called “Parâmetros de conexão do S3”. Você pode alterar a forma como o gravador interpreta os arquivos Avro em `format_options`. Para obter mais detalhes, consulte Avro Configuration Reference (Referência de configuração de Avro).

O seguinte script de ETL do AWS Glue mostra o processo de gravação de arquivos ou pastas Avro no S3.

Python

Neste exemplo, use o método 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

Neste exemplo, use o método 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)
  }
}
```

Referência de configuração de Avro

Você pode usar os seguinte valores de `format_options` sempre que as bibliotecas do AWS Glue especificarem `format="avro"`:

- `version`: especifica a versão do formato de leitor/gravador Apache Avro a ser suportada. O padrão é “1.7”. É possível especificar `format_options={"version": “1.8”}` para habilitar a leitura e gravação do tipo lógico Avro. Para obter mais informações, consulte a Especificação do Apache Avro 1.7.7 e a Especificação do Apache Avro 1.8.2.

  O conector do Apache Avro 1.8 oferece suporte para os seguintes tipos de conversão:

Para o leitor: esta tabela mostra a conversão entre o tipo de dados Avro (tipo lógico e o tipo primitivo Avro) e o tipo de dados `DynamicFrame` do AWS Glue para o leitor Avro 1.7 e 1.8.

Tipo de dados Avro: Tipo lógico	Tipo de dados Avro: Tipo primitivo Avro	Tipo de dados GlueDynamicFrame: Leitor Avro 1.7	Tipo de dados GlueDynamicFrame: Leitor Avro 1.8
Decimal	bytes	BINARY	Decimal
Decimal	fixo	BINARY	Decimal
Data	int	INT	Data
Tempo (milissegundo)	int	INT	INT
Tempo (microssegundo)	longo	LONG	LONG
Time stamp (milissegundo)	longo	LONG	Timestamp
Time stamp (microssegundo)	longo	LONG	LONG
Duração (não é um tipo lógico)	fixo de 12	BINARY	BINARY

Para o gravador: esta tabela mostra a conversão entre o tipo de dados `DynamicFrame` do AWS Glue e o tipo de dados Avro para o gravador Avro 1.7 e 1.8.

Tipo de dados do **`DynamicFrame`** do AWS Glue	Tipo de dados Avro: Gravador Avro 1.7	Tipo de dados Avro: Gravador Avro 1.8
Decimal	String	decimal
Data	String	date
Marca de data e hora	String	timestamp-micros

Suporte para Avro Spark DataFrame

Para usar o Avro da API Spark DataFrame, é necessário instalar o plugin Spark Avro para a versão correspondente do Spark. A versão do Spark disponível em seu trabalho é determinada pela versão do AWS Glue. Para obter mais informações sobre as versões do Spark, consulte the section called "Versões do AWS Glue". O plugin é mantido pelo Apache. Não oferecemos garantias específicas de suporte.

No AWS Glue 2.0: use a versão 2.4.3 do plugin do Spark Avro. Você encontra esse JAR no Maven Central. Consulte org.apache.spark:spark-avro_2.12:2.4.3.

No AWS Glue 3.0: use a versão 3.1.1 do plugin do Spark Avro. Você encontra esse JAR no Maven Central. Consulte org.apache.spark:spark-avro_2.12:3.1.1.

Para incluir JARs adicionais em um trabalho de ETL do AWS Glue, use o parâmetro de trabalho `--extra-jars`. Para obter mais informações sobre parâmetros de trabalho, consulte the section called "Parâmetros de trabalho". Também é possível configurar esse parâmetro no AWS Management Console.

Uso do formato grokLog no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se seus dados forem armazenados ou transportados em um formato de texto não criptografado fracamente estruturado, o documento apresenta os recursos disponíveis para usar seus dados no AWS Glue por meio de padrões Grok.

O AWS Glue é compatível com o uso de padrões Grok. Os padrões Grok são semelhantes aos grupos de captura de expressões regulares. Eles reconhecem padrões de sequências de caracteres em um arquivo de texto simples e fornecem um tipo e propósito. No AWS Glue, seu objetivo principal

é ler logs. Para ver uma apresentação do Grok feita pelos autores, consulte Logstash Reference: Grok filter plugin (Referência do Logstash: plugin de filtro Grok).

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho
Compatível	Não aplicável	Compatível	Compatível	Sem suporte

Referência da configuração grokLog

Você pode usar os seguintes valores de `format_options` com `format="grokLog"`:

- `logFormat`: especifica o padrão Grok que corresponde ao formato de log.
- `customPatterns`: especifica outros padrões Grok usados aqui.
- `MISSING`: especifica o sinal a ser usado na identificação de valores ausentes. O padrão é `'-'`.
- `LineCount`: especifica o número de linhas em cada registro de log. O padrão é `'1'`, e atualmente somente os registros de linha única são compatíveis.
- `StrictMode`: um valor booliano que especifica se o modo estrito está habilitado. No modo estrito, o leitor não faz conversão ou recuperação de tipo automática. O valor padrão é `"false"`.

Uso do formato Ion no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se seus dados forem armazenados ou transportados no formato de dados Ion, este documento apresenta os recursos disponíveis para usar seus dados no AWS Glue.

O AWS Glue é compatível com o uso do formato Ion. Esse formato representa estruturas de dados (que não são baseadas em linhas ou colunas) em representações intercambiáveis em binários e em texto não criptografado. Para ver uma apresentação do formato feita pelos autores, consulte Amazon Ion. (Para obter mais informações, consulte a Especificação do Amazon Ion.)

Você pode usar o AWS Glue para ler arquivos Ion do Amazon S3. Você pode ler arquivos `bzip` e `gzip` do S3 que contenham arquivos Ion. Você configura o comportamento de compactação no Parâmetros de conexão do S3 e não na configuração apresentada nesta página.

A tabela a seguir mostra quais são as operações comuns do AWS Glue compatíveis com a opção de formato Ion.

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho
Compatível	Sem suporte	Sem suporte	Compatível	Sem suporte

Exemplo: ler arquivos e pastas Ion do S3

Pré-requisitos: você precisará dos caminhos do S3 (`s3path`) para os arquivos ou pastas Ion que você deseja ler.

Configuração: nas opções da sua função, especifique `format="json"`. Em seu `connection_options`, use a chave `paths` para especificar seu `s3path`. Você pode configurar como o leitor interage com o S3 no `connection_options`. Para mais detalhes, consulte os tipos de conexão e opções para ETL no AWS Glue: the section called “Parâmetros de conexão do S3”.

O seguinte script de ETL do AWS Glue mostra o processo de leitura de arquivos ou pastas Ion provenientes do S3:

Python

Neste exemplo, use o método 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

Neste exemplo, use a operação 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()
  }
}
```

Referência de configuração de Ion

Não há valores de `format_options` para `format="ion"`.

Uso do formato JSON no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se os dados forem armazenados ou transportados no formato de dados JSON, este documento apresenta os recursos disponíveis para usar os dados no AWS Glue.

O AWS Glue é compatível com o uso do formato JSON. Esse formato representa estruturas de dados com forma consistente, mas com conteúdo flexível, que não são baseadas em linhas ou colunas. O JSON é definido por padrões paralelos emitidos por várias autoridades, e uma dela é a ECMA-404. Para ver uma apresentação do formato por uma fonte bastante referenciada, consulte Introducing JSON (Introdução ao JSON).

Você pode usar o AWS Glue para ler arquivos JSON do Amazon S3, bem como arquivos JSON `bzip` e `gzip` compactados. Você configura o comportamento de compactação no Parâmetros de conexão do S3 e não na configuração apresentada nesta página.

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho	
Compatível	Compatível	Compatível	Compatível	Compatível	

Exemplo: ler arquivos ou pastas JSON do S3

Pré-requisitos: você precisará dos caminhos do S3 (`s3path`) para os arquivos ou pastas JSON que gostaria de ler.

Configuração: nas opções da sua função, especifique `format="json"`. Em seu `connection_options`, use a chave `paths` para especificar seu `s3path`. Você pode alterar ainda mais a forma como sua operação de leitura atravessará o S3 nas opções de conexão. Consulte the section called “Parâmetros de conexão do S3” para obter mais detalhes. Você pode configurar como o leitor interpreta os arquivos JSON em seu `format_options`. Para obter mais detalhes, consulte JSON Configuration Reference (Referência de configuração de JSON).

O seguinte script de ETL do AWS Glue mostra o processo de leitura de arquivos ou pastas JSON provenientes do S3:

Python

Neste exemplo, use o método 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
    }
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .option("multiline", "true")\
    .json("s3://s3path")
```

Scala

Neste exemplo, use a operação 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()
  }
}
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
val dataFrame = spark.read
    .option("multiline", "true")
    .json("s3://s3path")
```

Exemplo: gravar arquivos e pastas JSON no S3

Pré-requisitos:você precisará de um DataFrame (`dataFrame`) ou de um DynamicFrame (`dynamicFrame`) inicializado. Você também precisará do caminho de saída esperado do S3, `s3path`.

Configuração: nas opções da sua função, especifique `format="json"`. Em seu `connection_options`, use a chave `paths` para especificar `s3path`. Em `connection_options`, você pode alterar ainda mais a forma como o gravador interage com o S3. Para obter detalhes, consulte Opções de formato de dados para entradas e saídas de ETL no AWSGlue: the section called “Parâmetros de conexão do S3”. Você pode configurar como o gravador interpreta os arquivos JSON em seu `format_options`. Para obter mais detalhes, consulte JSON Configuration Reference (Referência de configuração de JSON).

O seguinte script de ETL do AWS Glue mostra o processo de gravação de arquivos ou pastas JSON provenientes do S3:

Python

Neste exemplo, use o método 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"
```

```
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
df.write.json("s3://s3path/")
```

Scala

Neste exemplo, use o método 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)
  }
}
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
df.write.json("s3://s3path")
```

Referência de configuração de JSON

Você pode usar os seguintes valores de `format_options` com `format="json"`:

- `jsonPath`: uma expressão JsonPath que identifica um objeto a ser ler lido em registros. Isso é especialmente útil quando um arquivo contém registros aninhados dentro de uma matriz externa. Por exemplo, a expressão JsonPath a seguir visa o campo `id` de um objeto JSON.

```
format="json", format_options={"jsonPath": "$.id"}
```

- `multiline`: um valor booliano que especifica se um único registro pode gerar várias linhas. Isso pode ocorrer quando um campo contém um caractere de nova linha entre aspas. Você deve definir essa opção como `"true"` se algum registro ocupar várias linhas. O valor padrão é `"false"`, que permite uma divisão de arquivos mais radical durante a análise.
- `optimizePerformance`: um valor booleano que especifica se deve usar o leitor SIMD para JSON avançado junto com formatos de memória colunar baseados em Apache Arrow. Disponível apenas no AWS Glue 3.0. Não compatível com `multiline` ou `jsonPath`. Fornecer qualquer uma dessas opções instruirá o AWS Glue a voltar ao leitor padrão.
- `withSchema`: um valor de String que especifica um esquema de tabela no formato descrito em the section called “Especificar esquema XML”. Usado apenas com o `optimizePerformance` ao ler de conexões que não são do catálogo.

Usar o leitor vetorizado SIMD para JSON com formato colunar Apache Arrow

O AWS Glue versão 3.0 adiciona um leitor vetorizado para dados JSON. Ele executa duas vezes mais rápido sob certas condições, em comparação com o leitor padrão. Esse leitor vem com certas limitações que os usuários devem conhecer antes de usar, documentadas nesta seção.

Para usar o leitor otimizado, defina `"optimizePerformance"` como Verdadeiro no `format_options` ou propriedade de tabela. Você também precisará fornecer `withSchema` a menos que esteja lendo do catálogo. O `withSchema` espera uma entrada conforme descrito em the section called “Especificar esquema 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,
        })
```

Para obter mais informações sobre a criação de um *SchemaString* na biblioteca do AWS Glue, consulte the section called “Tipos”.

Limitações para o leitor vetorizado de CSV

Observe as seguintes limitações:

- Elementos JSON com objetos aninhados ou valores de matriz não são compatíveis. Se fornecido, o AWS Glue voltará para o leitor padrão.
- Um esquema deve ser fornecido do Catálogo ou com `withSchema`.
- Não compatível com `multiline` ou `jsonPath`. Fornecer qualquer uma dessas opções instruirá o AWS Glue a voltar ao leitor padrão.
- Fornecer registros de entrada que não correspondam ao esquema de entrada resultará em falha do leitor.
- Registros de erro não serão criados.
- Arquivos JSON com caracteres multiByte, como caracteres japoneses ou chineses, não são aceitos.

Usar o formato ORC no AWS Glue

O AWS Glue recupera dados de fontes e grava dados em destinos armazenados e transportados em vários formatos de dados. Se seus dados forem armazenados ou transportados no formato de dados ORC, este documento apresenta os recursos disponíveis para usar seus dados no AWS Glue.

O AWS Glue é compatível com o uso do formato ORC. Esse formato é um formato de dados orientado a desempenho e baseado em colunas. Para ver uma introdução ao formato pela autoridade padrão, consulte Apache Orc.

Você pode usar o AWS Glue para ler arquivos ORC do Amazon S3 e de fontes de transmissão, bem como para gravar arquivos ORC no Amazon S3. Você pode ler e gravar arquivos `bzip` e `gzip` do S3 que contenham arquivos ORC. Você configura o comportamento de compactação no Parâmetros de conexão do S3 e não na configuração apresentada nesta página.

A tabela a seguir mostra quais são as operações comuns do AWS Glue compatíveis com a opção de formato ORC.

Leitura	Escrever	Leitura de transmissão	Agrupar arquivos pequenos	Marcadores de trabalho
Compatível	Compatível	Compatível	Sem suporte	Compatível*

*Compatível com o AWS Glue versão 1.0+

Exemplo: ler arquivos ou pastas ORC do S3

Pré-requisitos: você precisará dos caminhos do S3 (`s3path`) para os arquivos ou pastas ORC que deseja ler.

Configuração: nas opções da sua função, especifique `format="orc"`. Em seu `connection_options`, use a chave `paths` para especificar seu `s3path`. Você pode configurar como o leitor interage com o S3 no `connection_options`. Para mais detalhes, consulte os tipos de conexão e opções para ETL no AWS Glue: the section called “Parâmetros de conexão do S3”.

O seguinte script de ETL do AWS Glue mostra o processo de leitura de arquivos ou pastas ORC provenientes do S3:

Python

Neste exemplo, use o método 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"
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
dataFrame = spark.read\
    .orc("s3://s3path")
```

Scala

Neste exemplo, use a operação 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()
  }
}
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
val dataFrame = spark.read
    .orc("s3://s3path")
```

Exemplo: gravar arquivos e pastas ORC no S3

Pré-requisitos: você precisará de um DataFrame (`dataFrame`) ou de um DynamicFrame (`dynamicFrame`) inicializado. Você também precisará do caminho de saída esperado do S3, `s3path`.

Configuração: nas opções da sua função, especifique `format="orc"`. Em suas opções de conexão, use a chave `paths` para especificar `s3path`. Em `connection_options`, você pode alterar ainda mais a forma como o gravador interage com o S3. Para obter detalhes, consulte Opções de formato de dados para entradas e saídas de ETL no AWSGlue: the section called “Parâmetros de conexão do S3”. O código de exemplo a seguir mostra o processo:

Python

Neste exemplo, use o método 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"
    }
)
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
df.write.orc("s3://s3path/")
```

Scala

Neste exemplo, use o método 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)
  }
```

```
}
```

Você também pode usar DataFrames em um script (`pyspark.sql.DataFrame`).

```
df.write.orc("s3://s3path/")
```

Referência de configuração de ORC

Não há valores de `format_options` para `format="orc"`. No entanto, quaisquer opções aceitas pelo código SparkSQL subjacente podem ser transmitidas para ele por meio do parâmetro de mapa `connection_options`.

Usar estruturas de data lake com trabalhos do AWS Glue ETL

As estruturas de data lake de código aberto simplificam o processamento incremental de dados para os arquivos que você armazena em data lakes criados no Amazon S3. O AWS Glue 3.0 e posteriores são compatíveis com as seguintes estruturas de data lake de código aberto:

- Apache Hudi
- Linux Foundation Delta Lake
- Apache Iceberg

Fornecemos suporte nativo para essas estruturas para que você possa ler e gravar os dados que armazenar no Amazon S3 de maneira transacionalmente consistente. Não é necessário instalar um conector separado nem realizar etapas adicionais de configuração para usar essas estruturas em trabalhos do AWS Glue ETL.

Ao gerenciar conjuntos de dados por meio do AWS Glue Data Catalog, você pode usar os métodos do AWS Glue para ler e gravar tabelas de data lake com o Spark DataFrames. Você também pode ler e gravar dados do Amazon S3 usando a API DataFrame do Spark.

Neste vídeo, você pode aprender sobre os conceitos básicos de como o Apache Hudi, o Apache Iceberg e o Delta Lake funcionam. Você verá como inserir, atualizar e excluir dados no data lake e como cada uma dessas estruturas funciona.

Tópicos

- Limitações
- Usar a estrutura Hudi no AWS Glue

- Usar a estrutura Delta Lake no AWS Glue
- Usar a estrutura Iceberg no AWS Glue

Limitações

Considere as seguintes limitações antes de usar estruturas de data lake com o AWS Glue.

- Os métodos do `GlueContext` do AWS Glue a seguir não são compatíveis com leitura e escrita em tabelas de estrutura de data lake. Em vez disso, use os métodos `GlueContext` da API do DataFrame ou Spark DataFrame.
  - `create_dynamic_frame.from_catalog`
  - `write_dynamic_frame.from_catalog`
  - `getDynamicFrame`
  - `writeDynamicFrame`
- Os métodos `GlueContext` a seguir para DataFrame são compatíveis com o controle de permissão do Lake Formation:
  - `create_data_frame.from_catalog`
  - `write_data_frame.from_catalog`
  - `getDataFrame`
  - `writeDataFrame`
- Agrupamento de arquivos pequenos não é compatível.
- Marcadores de trabalho não são compatíveis.
- O Apache Hudi 0.10.1 para AWS Glue 3.0 não é compatível com tabelas Merge on Read (MoR) do Hudi.
- `ALTER TABLE … RENAME TO` não está disponível para o Apache Iceberg 0.13.1 para o AWS Glue 3.0.

Limitações para tabelas em formato de data lake gerenciadas pelas permissões do Lake Formation

Os formatos de data lake são integrados ao AWS Glue ETL por meio das permissões do Lake Formation. Não há suporte à criação de um DynamicFrame usando `create_dynamic_frame`. Para obter mais informações, veja os exemplos a seguir:

- Exemplo: ler e escrever na tabela do Iceberg com o controle de permissão do Lake Formation

- Exemplo: ler e escrever na tabela do Hudi com o controle de permissão do Lake Formation
- Exemplo: ler e escrever na tabela do Delta Lake com o controle de permissão do Lake Formation

> **Note**
>
> A integração com o AWS Glue ETL por meio das permissões do Lake Formation para o Apache Hudi, o Apache Iceberg e o Delta Lake só é possível no AWS Glue versão 4.0.

O Apache Iceberg tem a melhor integração com o AWS Glue ETL por meio das permissões do Lake Formation. Ele é compatível com quase todas as operações e inclui suporte a SQL.

O Hudi é compatível com a maioria das operações básicas, com exceção de operações administrativas. Isso ocorre porque essas opções geralmente são feitas por meio da gravação de dataframes e especificadas via `additional_options`. Você precisa usar APIs do AWS Glue para criar DataFrames para suas operações, pois não há suporte ao SparkSQL.

O Delta Lake é compatível somente com leitura, anexação e substituição de dados da tabela. O Delta Lake exige o uso de suas próprias bibliotecas para poder realizar várias tarefas, como atualizações.

Os recursos a seguir não estão disponíveis para tabelas do Iceberg gerenciadas por permissões do Lake Formation.

- Compactação usando o AWS Glue ETL
- Suporte ao Spark SQL via AWS Glue ETL

A seguir estão as limitações das tabelas do Hudi gerenciadas por permissões do Lake Formation:

- Remoção de arquivos órfãos

A seguir estão as limitações das tabelas do Data Lake gerenciadas por permissões do Lake Formation:

- Todos os recursos, exceto inserir e ler das tabelas do Delta Lake.

Usar a estrutura Hudi no AWS Glue

O AWS Glue 3.0 e versões posteriores são compatíveis com a estrutura Apache Hudi para data lakes. Hudi é uma estrutura de armazenamento de data lake de código aberto que simplifica o processamento incremental de dados e o desenvolvimento de pipelines de dados. Este tópico aborda os recursos disponíveis para usar dados no AWS Glue ao transportar ou armazenar dados em uma tabela do Hudi. Para saber mais sobre o Hudi, consulte a documentação do Apache Hudi.

Você pode usar o AWS Glue para realizar operações de leitura e gravação em tabelas do Hudi no Amazon S3 ou trabalhar com tabelas do Hudi usando o AWS Glue Data Catalog. Operações adicionais, incluindo inserção, atualização e todas as operações do Apache Spark também são compatíveis.

> **Note**
>
> A implementação do Apache Hudi 0.15.0 no AWS Glue 5.0 reverte internamente o HUDI-7001. Ele não exibe a regressão relacionada à geração de chaves complexas quando a chave de registro consiste em um único campo. No entanto, esse comportamento difere do OSS Apache Hudi 0.15.0.
> O Apache Hudi 0.10.1 para AWS Glue 3.0 não é compatível com tabelas Merge on Read (MoR) do Hudi.

A tabela a seguir lista a versão do Hudi incluída em cada versão do AWS Glue.

Versão do AWS Glue	Versões compatíveis do Hudi
5,0	0.15.0
4,0	0.12.1
3.0	0.10.1

Para saber mais sobre as estruturas de data lake compatíveis com o AWS Glue, consulte Usar estruturas de data lake com trabalhos do AWS Glue ETL.

Habilitar o Hudi

Para habilitar o Hudi para AWS Glue, faça as seguintes tarefas:

- Especifique `hudi` como um valor para o parâmetro de trabalho `--datalake-formats`. Para obter mais informações, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.
- Crie uma chave denominada `--conf` para o trabalho do AWS Glue e defina-a com o seguinte valor. Ou então, você pode definir a configuração a seguir usando `SparkConf` no script. Essas configurações ajudam o Apache Spark a lidar corretamente com as tabelas do Hudi.

```
spark.serializer=org.apache.spark.serializer.KryoSerializer
```

- O suporte à permissão do Lake Formation para tabelas do Hudi está habilitado por padrão para o AWS Glue 4.0. Nenhuma configuração adicional é necessária para leitura/escrita em tabelas do Hudi registradas no Lake Formation. Para ler uma tabela do Hudi registrada, o perfil do IAM do trabalho do AWS Glue deve ter a permissão SELECT. Para escrever em uma tabela do Hudi registrada, o perfil do IAM do trabalho do AWS Glue deve ter a permissão SUPER. Para saber mais sobre como gerenciar as permissões do Lake Formation, consulte Conceder e revogar permissões nos recursos do Catálogo de Dados.

Usar uma versão diferente do Hudi

Para usar uma versão do Hudi que não é compatível com o AWS Glue, especifique seus próprios arquivos JAR do Hudi usando o parâmetro de trabalho `--extra-jars`. Não inclua `hudi` como um valor para o parâmetro de trabalho `--datalake-formats`. Se você usa o AWS Glue 5.0, é necessário definir o parâmetro `--user-jars-first true` do trabalho.

Exemplo: escrever uma tabela Hudi no Amazon S3 e registrá-la no AWS Glue Data Catalog

O exemplo a seguir demonstra como gravar uma tabela do Hudi no Amazon S3 e registrá-la no AWS Glue Data Catalog. O exemplo usa a ferramenta Hive Sync do Hudi para registrar a tabela.

> **Note**
>
> Este exemplo exige que você defina o parâmetro de trabalho `--enable-glue-datacatalog` para usar o AWS Glue Data Catalog como metastore do Apache Spark Hive. Para saber mais, consulte Usar parâmetros de tarefa em tarefas do 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()
```

Exemplo: ler uma tabela do Hudi do Amazon S3 usando o AWS Glue Data Catalog

Este exemplo lê a tabela Hudi que você criou no Exemplo: escrever uma tabela Hudi no Amazon S3 e registrá-la no AWS Glue Data Catalog do Amazon S3.

> **Note**
>
> Este exemplo exige que você defina o parâmetro de trabalho `--enable-glue-datacatalog` para usar o AWS Glue Data Catalog como metastore do Apache Spark Hive. Para saber mais, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.

Python

Para este exemplo, use o método `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

Neste exemplo, use o método 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()
  }
}
```

Exemplo: atualizar e inserir um **`DataFrame`** a em uma tabela do Hudi no Amazon S3

Este exemplo usa o AWS Glue Data Catalog para inserir um DataFrame na tabela do Hudi que você criou em Exemplo: escrever uma tabela Hudi no Amazon S3 e registrá-la no AWS Glue Data Catalog.

> **Note**
>
> Este exemplo exige que você defina o parâmetro de trabalho `--enable-glue-datacatalog` para usar o AWS Glue Data Catalog como metastore do Apache Spark Hive. Para saber mais, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.

Python

Para este exemplo, use o método `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

Neste exemplo, use o método 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.apacke.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.MultiPartKeysValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc" -> "false",
        "hoodie.datasource.hive_sync.mode" -> "hms"
      )))
      .writeDataFrame(dataFrame, glueContext)
  }
}
```

Exemplo: ler uma tabela do Hudi do Amazon S3 usando o Spark

Este exemplo lê uma tabela do Hudi do Amazon S3 usando a API do 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/>")
```

Exemplo: gravar uma tabela no Amazon S3 usando o Spark

Este exemplo grava uma tabela no Amazon S3 usando o 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/>")
```

Exemplo: ler e escrever na tabela do Hudi com o controle de permissão do Lake Formation

Este exemplo lê e escreve uma tabela do Hudi com o controle de permissão do Lake Formation

1. Criar uma tabela do Hudi e registrá-la no Lake Formation
   a. Para habilitar o controle de permissão do Lake Formation, primeiro será necessário registrar o caminho da tabela do Amazon S3 no Lake Formation. Para obter mais informações, consulte Registering an Amazon S3 location (Registrar um local do Amazon S3). É possível registrá-lo no console do Lake Formation ou usando a AWS CLI:

      ```
      aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-
      folder> --use-service-linked-role --region <REGION>
      ```

      Depois de registrar uma localização no Amazon S3, qualquer tabela do AWS Glue apontando para a localização (ou qualquer uma de suas localizações secundárias) retornará o valor do parâmetro `IsRegisteredWithLakeFormation` como verdadeiro na chamada `GetTable`.

b. Crie uma tabela do Hudi que aponte para o caminho registrado do Amazon S3 por meio da API de dataframe do Spark:

```
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. Conceda permissão do Lake Formation para o perfil do IAM do trabalho do AWS Glue. Você pode conceder permissões no console do Lake Formation ou usando a AWS CLI. Para obter mais informações, consulte Conceder permissões de banco de dados usando o console do Lake Formation e o método de recurso nomeado

3. Leia a tabela do Hudi registrada no Lake Formation. O código é o mesmo que o da leitura de uma tabela do Hudi não registrada. Observe que o perfil do IAM do trabalho do AWS Glue precisa ter a permissão SELECT para que a leitura seja bem-sucedida.

```
val dataFrame = glueContext.getCatalogSource(
     database = "<your_database_name>",
     tableName = "<your_table_name>"
   ).getDataFrame()
```

4. Escreva em uma tabela do Hudi registrada no Lake Formation. O código é o mesmo que o da escrita em uma tabela do Hudi não registrada. Observe que o perfil do IAM do trabalho do AWS Glue precisa ter a permissão SUPER para que a escrita seja bem-sucedida.

```
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.MultiPartKeysValueExtractor",
        "hoodie.datasource.hive_sync.use_jdbc" -> "false",
        "hoodie.datasource.hive_sync.mode" -> "hms"
      )))
      .writeDataFrame(dataFrame, glueContext)
```

Usar a estrutura Delta Lake no AWS Glue

O AWS Glue 3.0 e versões posteriores são compatíveis com a estrutura Linux Foundation Delta Lake. Delta Lake é uma estrutura de armazenamento de data lake de código aberto que ajuda você a realizar transações ACID, escalar o tratamento de metadados e unificar o streaming e o processamento de dados em lote. Este tópico aborda os recursos disponíveis para usar dados no AWS Glue ao transportar ou armazenar dados em uma tabela do Delta Lake. Para saber mais sobre o Delta Lake, consulte a documentação oficial do Delta Lake.

Você pode usar o AWS Glue para realizar operações de leitura e gravação em tabelas do Delta Lake no Amazon S3 ou trabalhar com tabelas do Delta Lake usando o AWS Glue Data Catalog. Operações adicionais, como inserção, atualização e leitura e gravação em lote de tabelas, também são compatíveis. Quando você usa tabelas do Delta Lake, também tem a opção de usar métodos da

biblioteca do Delta Lake Python, como `DeltaTable.forPath`. Para obter mais informações sobre a biblioteca de Python do Delta Lake, consulte a documentação de Python do Delta Lake.

A tabela a seguir lista a versão do Delta Lake incluída em cada versão do AWS Glue.

Versão do AWS Glue	Versão Delta Lake compatível
5,0	3.3.0
4,0	2.1.0
3.0	1.0.0

Para saber mais sobre as estruturas de data lake compatíveis com o AWS Glue, consulte Usar estruturas de data lake com trabalhos do AWS Glue ETL.

Habilitar o Delta Lake para AWS Glue

Para habilitar o Delta Lake para AWS Glue, faça as seguintes tarefas:

- Especifique `delta` como um valor para o parâmetro de trabalho `--datalake-formats`. Para obter mais informações, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.
- Crie uma chave denominada `--conf` para o trabalho do AWS Glue e defina-a com o seguinte valor. Ou então, é possível definir a configuração a seguir usando `SparkConf` no script. Essas configurações ajudam o Apache Spark a lidar corretamente com tabelas do 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
```

- O suporte à permissão do Lake Formation para tabelas do Delta está habilitado por padrão para o AWS Glue 4.0. Nenhuma configuração adicional é necessária para leitura/escrita em tabelas do Delta registradas no Lake Formation. Para ler uma tabela do Delta registrada, o perfil do IAM do trabalho do AWS Glue deve ter a permissão SELECT. Para escrever em uma tabela do Delta registrada, o perfil do IAM do trabalho do AWS Glue deve ter a permissão SUPER. Para saber mais sobre como gerenciar as permissões do Lake Formation, consulte Conceder e revogar permissões nos recursos do Catálogo de Dados.

Usar uma versão diferente do Delta Lake

Para usar uma versão do Delta Lake que não seja compatível com o AWS Glue, especifique seus próprios arquivos JAR do Delta Lake usando o parâmetro de trabalho `--extra-jars`. Não inclua `delta` como um valor para o parâmetro de trabalho `--datalake-formats`. Se você usa o AWS Glue 5.0, é necessário definir o parâmetro `--user-jars-first true` do trabalho. Para usar a biblioteca do Delta Lake Python nesse caso, você deve especificar os arquivos JAR da biblioteca usando o parâmetro de trabalho `--extra-py-files`. A biblioteca do Python vem empacotada nos arquivos JAR do Delta Lake.

Exemplo: escrever uma tabela Delta Lake no Amazon S3 e registrá-la no AWS Glue Data Catalog

O script do AWS Glue ETL a seguir demonstra como gravar uma tabela do Delta Lake no Amazon S3 e registrá-la no AWS Glue Data Catalog.

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>")
```

Exemplo: ler uma tabela do Delta Lake do Amazon S3 usando o AWS Glue Data Catalog

O script do AWS Glue ETL a seguir lê a tabela do Delta Lake que você criou em Exemplo: escrever uma tabela Delta Lake no Amazon S3 e registrá-la no AWS Glue Data Catalog.

Python

Neste exemplo, use o método 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

Neste exemplo, use o método getCatalogSource.

```
// Example: Read a Delta Lake table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apacke.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()
```

```
  }
}
```

Exemplo: inserir um **`DataFrame`** em uma tabela do Delta Lake no Amazon S3 usando o AWS Glue Data Catalog

Este exemplo insere dados na tabela do Delta Lake que você criou em Exemplo: escrever uma tabela Delta Lake no Amazon S3 e registrá-la no AWS Glue Data Catalog.

> **Note**
>
> Este exemplo exige que você defina o parâmetro de trabalho `--enable-glue-datacatalog` para usar o AWS Glue Data Catalog como metastore do Apache Spark Hive. Para saber mais, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.

Python

Neste exemplo, use o método 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

Neste exemplo, use o método getCatalogSink.

```
// Example: Insert into a Delta Lake table in S3 using Glue Data Catalog
```

```
import com.amazonaws.services.glue.GlueContext
import org.apacke.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)
  }
}
```

Exemplo: ler uma tabela do Delta Lake do Amazon S3 usando a API do Spark

Este exemplo lê uma tabela do Delta Lake do Amazon S3 usando a API do 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/>")
```

Exemplo: gravar uma tabela do Delta Lake no Amazon S3 usando o Spark

Exemplo: grava uma tabela do Delta Lake no Amazon S3 usando o 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/>")
```

Exemplo: ler e escrever na tabela do Delta Lake com o controle de permissão do Lake Formation

Este exemplo lê e escreve uma tabela do Delta Lake com o controle de permissão do Lake Formation.

1. Criar uma tabela do Delta e registrá-la no Lake Formation
   a. Para habilitar o controle de permissão do Lake Formation, primeiro será necessário registrar o caminho da tabela do Amazon S3 no Lake Formation. Para obter mais informações, consulte Registering an Amazon S3 location (Registrar um local do Amazon S3). É possível registrá-lo no console do Lake Formation ou usando a AWS CLI:

   ```
   aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-folder> --use-service-linked-role --region <REGION>
   ```

   Depois de registrar uma localização no Amazon S3, qualquer tabela do AWS Glue apontando para a localização (ou qualquer uma de suas localizações secundárias) retornará o valor do parâmetro `IsRegisteredWithLakeFormation` como verdadeiro na chamada `GetTable`.

   b. Crie uma tabela do Delta que aponte para o caminho registrado do Amazon S3 por meio do Spark:

   > **Note**
   >
   > Os exemplos a seguir foram criados em Python.

   ```
   dataFrame.write \
   ```

```
  .format("delta") \
  .mode("overwrite") \
  .partitionBy("<your_partitionkey_field>") \
  .save("s3://<the_s3_path>")
```

Depois que os dados forem gravados no Amazon S3, use o crawler do AWS Glue para criar uma nova tabela de catálogo do Delta. Para obter mais informações, consulte Introdução ao suporte a tabelas nativas do Delta Lake com crawlers do AWS Glue.

Você também pode criar a tabela manualmente por meio da API `CreateTable` do AWS Glue.

2. Conceda permissão do Lake Formation para o perfil do IAM do trabalho do AWS Glue. Você pode conceder permissões no console do Lake Formation ou usando a AWS CLI. Para obter mais informações, consulte Conceder permissões de banco de dados usando o console do Lake Formation e o método de recurso nomeado
3. Leia a tabela do Delta registrada no Lake Formation. O código é o mesmo que o da leitura de uma tabela do Delta não registrada. Observe que o perfil do IAM do trabalho do AWS Glue precisa ter a permissão SELECT para que a leitura seja bem-sucedida.

```
# 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. Escreva em uma tabela do Delta registrada no Lake Formation. O código é o mesmo que o da escrita em uma tabela do Delta não registrada. Observe que o perfil do IAM do trabalho do AWS Glue precisa ter a permissão SUPER para que a escrita seja bem-sucedida.

   Por padrão, o AWS Glue usa `Append` como saveMode. Você pode alterá-lo configurando a opção saveMode em `additional_options`. Para obter informações sobre o suporte ao saveMode em tabelas do Delta, consulte Escrever em uma tabela.

```
glueContext.write_data_frame.from_catalog(
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
```

```
)
```

Usar a estrutura Iceberg no AWS Glue

O AWS Glue 3.0 e versões posteriores são compatíveis com a estrutura Apache Iceberg para data lakes. O Iceberg fornece um formato de tabela de alta performance que funciona exatamente como uma tabela SQL. Este tópico aborda os recursos disponíveis para usar dados no AWS Glue ao transportar ou armazenar dados em uma tabela do Iceberg. Para saber mais sobre o Iceberg, consulte a documentação do Apache Iceberg.

É possível usar o AWS Glue para realizar operações de leitura e gravação em tabelas do Iceberg no Amazon S3 ou trabalhar com tabelas do Iceberg usando o AWS Glue Data Catalog. Operações adicionais, incluindo inserção e todas as consultas do Spark e gravações do Spark também são compatíveis. Não há suporte à atualização de tabelas do Iceberg.

> **Note**
>
> `ALTER TABLE … RENAME TO` não está disponível para o Apache Iceberg 0.13.1 para AWS Glue 3.0.

A tabela a seguir lista a versão do Iceberg incluída em cada versão do AWS Glue.

Versão do AWS Glue	Versão compatível do Iceberg
5,0	1.7.1
4,0	1.0.0
3.0	0.13.1

Para saber mais sobre as estruturas de data lake compatíveis com o AWS Glue, consulte Usar estruturas de data lake com trabalhos do AWS Glue ETL.

Habilitar a estrutura Iceberg

Para habilitar o Iceberg para AWS Glue, faça as seguintes tarefas:

- Especifique `iceberg` como um valor para o parâmetro de trabalho `--datalake-formats`. Para obter mais informações, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.
- Crie uma chave denominada `--conf` para o trabalho do AWS Glue e defina-a com o seguinte valor. Ou então, é possível definir a configuração a seguir usando `SparkConf` no script. Essas configurações ajudam o Apache Spark a lidar corretamente com as tabelas do 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
```

  Se você estiver lendo ou gravando em tabelas do Iceberg registradas no Lake Formation, siga as orientações em the section called “Lake Formation para o FGAC” no AWS Glue 5.0 e versões posteriores. No AWS Glue 4.0, adicione a configuração a seguir para habilitar o suporte ao Lake Formation.

```
--conf spark.sql.catalog.glue_catalog.glue.lakeformation-enabled=true
--conf spark.sql.catalog.glue_catalog.glue.id=<table-catalog-id>
```

  Se você usar o AWS Glue 3.0 com o Iceberg 0.13.1, deverá definir as seguintes configurações adicionais para usar o gerenciador de bloqueios do Amazon DynamoDB para garantir a transação atômica. AWS O Glue 4.0 usa o bloqueio positivo por padrão. Para obter mais informações, consulte Iceberg AWS Integrations na documentação oficial do 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>
```

Usar uma versão diferente do Iceberg

Para usar uma versão do Iceberg que não é compatível com o AWS Glue, especifique seus próprios arquivos JAR do Iceberg usando o parâmetro de trabalho `--extra-jars`. Não inclua `iceberg` como um valor para o parâmetro `--datalake-formats`. Se você usa o AWS Glue 5.0, é necessário definir o parâmetro `--user-jars-first true` do trabalho.

Habilitar criptografia para tabelas do Iceberg

> **Note**
>
> As tabelas do Iceberg têm seus próprios mecanismos para habilitar a criptografia no lado do servidor. Você deve habilitar essa configuração além da configuração de segurança do AWS Glue.

Para habilitar a criptografia do lado do servidor nas tabelas do Iceberg, consulte as orientações na documentação do Iceberg.

Adicionar configuração do Spark para acesso entre regiões do Iceberg

Para adicionar uma configuração adicional do Spark para acesso à tabela entre regiões do Iceberg com o Catálogo de Dados do AWS Glue e o AWS Lake Formation, siga as etapas abaixo:

1. Crie um ponto de acesso multirregional.
2. Defina as seguintes propriedades do Spark:

```
-----
    --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/<mrap-id>.mrap \
    --conf spark.sql.catalog.{CATALOG}.s3.access-points.bucket2",
 "arn:aws:s3::<account-id>:accesspoint/<mrap-id>.mrap
-----
```

Exemplo: escrever uma tabela do Iceberg no Amazon S3 e registrá-la no AWS Glue Data Catalog

Esse exemplo de script demonstra como escrever uma tabela Iceberg no Amazon S3. O exemplo usa aso integrações da AWS no Iceberg para registrar a tabela no AWS Glue Data Catalog.

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)
```

Como alternativa, é possível escrever uma tabela do Iceberg no Amazon S3 e no catálogo de dados usando os métodos do Spark.

Pré-requisitos: você precisará provisionar um catálogo para uso da biblioteca do Iceberg. Ao usar o catálogo de dados do AWS Glue, o AWS Glue simplifica essa operação. O catálogo de dados do AWS Glue é pré-configurado para ser usado pelas bibliotecas do Spark como `glue_catalog`. As tabelas do catálogo de dados são identificadas por um*`databaseName`* e um *`tableName`*. Para obter mais informações sobre o catálogo de dados do AWS Glue, consulte Descoberta e catalogação de dados.

Se você não estiver usando o catálogo de dados do AWS Glue, precisará provisionar um catálogo por meio das APIs do Spark. Para obter mais informações, consulte Configuração do Spark na documentação do Iceberg.

Este exemplo grava uma tabela Iceberg no Amazon S3 e no Data Catalog usando 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()
```

Exemplo: ler uma tabela do Iceberg do Amazon S3 usando o AWS Glue Data Catalog

Este exemplo lê a tabela do Iceberg que você criou em Exemplo: escrever uma tabela do Iceberg no Amazon S3 e registrá-la no AWS Glue Data Catalog.

Python

Para este exemplo, use o método `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

Neste exemplo, use o método getCatalogSource.

```
// Example: Read an Iceberg table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apacke.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()
  }
}
```

Exemplo: inserir um **`DataFrame`** em um tabela do Iceberg no Amazon S3 usando o AWS Glue Data Catalog

Este exemplo insere dados na tabela do Iceberg que você criou em Exemplo: escrever uma tabela do Iceberg no Amazon S3 e registrá-la no AWS Glue Data Catalog.

> **Note**
>
> Este exemplo exige que você defina o parâmetro de trabalho `--enable-glue-datacatalog` para usar o AWS Glue Data Catalog como metastore do Apache Spark Hive. Para saber mais, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.

Python

Para este exemplo, use o método `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

Neste exemplo, use o método getCatalogSink.

```
// Example: Insert into an Iceberg table from Glue Data Catalog

import com.amazonaws.services.glue.GlueContext
import org.apacke.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)
  }
}
```

Exemplo: ler uma tabela do Iceberg do Amazon S3 usando o Spark

Pré-requisitos: você precisará provisionar um catálogo para uso da biblioteca do Iceberg. Ao usar o catálogo de dados do AWS Glue, o AWS Glue simplifica essa operação. O catálogo de dados do AWS Glue é pré-configurado para ser usado pelas bibliotecas do Spark como `glue_catalog`. As tabelas do catálogo de dados são identificadas por um*databaseName* e um *tableName*. Para obter

mais informações sobre o catálogo de dados do AWS Glue, consulte Descoberta e catalogação de dados.

Se você não estiver usando o catálogo de dados do AWS Glue, precisará provisionar um catálogo por meio das APIs do Spark. Para obter mais informações, consulte Configuração do Spark na documentação do Iceberg.

Este exemplo lê uma tabela do Iceberg no Amazon S3 do catálogo de dados usando o 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")
```

Exemplo: ler e escrever na tabela do Iceberg com o controle de permissão do Lake Formation

Este exemplo lê e escreve uma tabela do Iceberg com o controle de permissão do Lake Formation.

> **Note**
>
> Este exemplo funciona apenas no AWS Glue 4.0. No AWS Glue 5.0 e versões posteriores, siga as orientações em the section called “Lake Formation para o FGAC”.

1. Crie uma tabela do Iceberg e registrá-la no Lake Formation:
   a. Para habilitar o controle de permissão do Lake Formation, primeiro será necessário registrar o caminho da tabela do Amazon S3 no Lake Formation. Para obter mais informações, consulte Registering an Amazon S3 location (Registrar um local do Amazon S3). É possível registrá-lo no console do Lake Formation ou usando a AWS CLI:

```
aws lakeformation register-resource --resource-arn arn:aws:s3:::<s3-bucket>/<s3-
folder> --use-service-linked-role --region <REGION>
```

Depois de registrar uma localização no Amazon S3, qualquer tabela do AWS Glue apontando para a localização (ou qualquer uma de suas localizações secundárias) retornará o valor do parâmetro `IsRegisteredWithLakeFormation` como verdadeiro na chamada `GetTable`.

b. Crie uma tabela do Iceberg que aponte para o caminho registrado por meio do Spark:

> **Note**
>
> Os exemplos a seguir foram criados em 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)
```

Você também pode criar a tabela manualmente por meio da API `CreateTable` do AWS Glue. Para obter mais informações, consulte Criar tabelas do Apache Iceberg.

> **Note**
>
> No momento, a API `UpdateTable` não oferece suporte ao formato de tabela do Iceberg como entrada para a operação.

2. Conceda permissão do Lake Formation para o perfil do IAM do trabalho. É possível conceder permissões no console do Lake Formation ou usando a AWS CLI. Para obter mais informações, consulte: https://docs.aws.amazon.com/lake-formation/latest/dg/granting-table-permissions.html
3. Leia uma tabela do Iceberg registrada no Lake Formation. O código é o mesmo que o da leitura de uma tabela do Iceberg não registrada. Observe que o perfil do IAM do trabalho do AWS Glue precisa ter a permissão SELECT para que a leitura seja bem-sucedida.

```
# Example: Read an Iceberg table from the AWS Glue Data Catalog
from awsglue.context import GlueContextfrom 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. Escreva em uma tabela do Iceberg registrada no Lake Formation. O código é o mesmo que o da escrita em uma tabela do Iceberg não registrada. Observe que o perfil do IAM do trabalho do AWS Glue precisa ter a permissão SUPER para que a escrita seja bem-sucedida.

```
glueContext.write_data_frame.from_catalog(
    frame=dataFrame,
    database="<your_database_name>",
    table_name="<your_table_name>",
    additional_options=additional_options
)
```

Referência de configuração compartilhada

Você pode usar os valores de `format_options` a seguir com qualquer tipo de formato.

- `attachFilename`: uma string no formato apropriado para ser usada como nome de coluna. Se você fornecer essa opção, o nome do arquivo de origem do registro será anexado ao registro. O valor do parâmetro será usado como nome da coluna.
- `attachTimestamp`: uma string no formato apropriado para ser usada como nome de coluna. Se você fornecer essa opção, a hora da modificação do arquivo de origem do registro será anexado ao registro. O valor do parâmetro será usado como nome da coluna.

Compatibilidade do AWS Glue Data Catalog com trabalhos do Spark SQL

O AWS Glue Data Catalog é um catálogo compatível com o metastore do Apache Hive. Você pode configurar seus trabalhos e endpoints de desenvolvimento do AWS Glue para usar o catálogo de

dados como um metastore externo do Apache Hive. Depois, você pode executar diretamente as consultas do Apache Spark SQL nas tabelas armazenados no catálogo de dados. Os quadros dinâmicos do AWS Glue se integram ao catálogo de dados por padrão. No entanto, com esse recurso, os trabalhos do Spark SQL podem começar a usar o Data Catalog como um metastore externo do Hive.

Este recurso requer acesso da rede ao endpoint da API do AWS Glue. Para trabalhos do AWS Glue com conexões localizadas em sub-redes privadas, você deve configurar um endpoint da VPC ou um gateway NAT para fornecer acesso à rede. Para obter mais informações sobre a configuração do endpoint da VPC, consulte Configurar o acesso de rede aos armazenamentos de dados. Para criar um gateway NAT, consulte Gateways NAT no Manual do usuário da Amazon VPC.

Você pode configurar tarefas e endpoints de desenvolvimento do AWS Glue adicionando o argumento `"--enable-glue-datacatalog": ""` aos argumentos da tarefa e do endpoint de desenvolvimento, respectivamente. Enviar esse argumento define determinadas configurações no Spark, que permitem o acesso ao Data Catalog como um metastore externo do Hive. Também habilita o suporte ao Hive no objeto `SparkSession` criado na tarefa ou no endpoint de desenvolvimento do AWS Glue.

Para habilitar o acesso ao Data Catalog, marque a caixa de seleção Usar o AWS Glue Data Catalog como o metastore Hive no grupo Opções de catálogo na página Adicionar trabalho ou Adicionar endpoint no console. Observe que a função do IAM usada para a tarefa ou o endpoint de desenvolvimento deve ter permissões `glue:CreateDatabase`. Um banco de dados chamado “`default`” (padrão) é criado no Data Catalog, caso não exista.

Vamos analisar um exemplo de como é possível usar esse recurso em suas tarefas do Spark SQL. O exemplo a seguir assume que você rastreou o conjunto de dados de legisladores dos EUA disponível em `s3://awsglue-datasets/examples/us-legislators`.

Para serializar/desserializar dados das tabelas definidas no AWS Glue Data Catalog, o Spark SQL precisa da classe Hive SerDe para o formato definido no AWS Glue Data Catalog no classpath do trabalho do Spark.

SerDes para determinados formatos comuns são distribuídos pelo AWS Glue. Veja a seguir os links do Amazon S3 para eles:

- JSON
- XML
- Grok

Adicione o JSON SerDe como um JAR adicional para o endpoint de desenvolvimento. Para tarefas, você pode adicionar o SerDe usando o argumento `--extra-jars` no campo de argumentos. Para ter mais informações, consulte Usar parâmetros de tarefa em tarefas do AWS Glue.

Veja aqui um exemplo de JSON de entrada para criar um endpoint de desenvolvimento com o Data Catalog habilitado para o 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"
}
```

Agora, consulte as tabelas criadas a partir do conjunto de dados dos legisladores dos EUA usando o 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|
+--------------------+---------+-----------------+
```

Se a classe SerDe para o formato não estiver disponível no caminho de classe da tarefa, ocorrerá um erro semelhante ao seguinte.

```
>>> 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
```

Para visualizar apenas os `organization_id`s distintos da tabela `memberships`, execute a seguinte consulta SQL.

```
>>> spark.sql("select distinct organization_id from memberships_json").show()
+--------------------+
|     organization_id|
+--------------------+
|d56acebe-8fdc-47b...|
|8fa6c3d2-71dc-478...|
+--------------------+
```

Se precisar fazer o mesmo com os quadros dinâmicos, execute o seguinte.

```
>>> 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...|
+--------------------+
```

Embora DynamicFrames sejam otimizados para operações de ETL, habilitar o Spark SQL para acessar o Data Catalog diretamente fornece uma maneira concisa para executar instruções SQL complexas ou aplicações de portas existentes.

Usar marcadores de trabalho

O AWS Glue para Spark usa marcadores de trabalho para rastrear dados que já foram processados. Para obter um resumo do atributo de marcadores de emprego e o que ele suporta, consulte the section called “Rastrear dados processados usando marcadores de trabalho”. Ao programar um trabalho do AWS Glue com marcadores, você tem acesso à flexibilidade indisponível em trabalhos visuais.

- Ao ler do JDBC, você pode especificar as colunas a serem usadas como chaves de marcadores no seu script do AWS Glue.
- Você pode escolher qual `transformation_ctx` aplicar a cada chamada de método.

Sempre chame *`job.init`* no início do script e *`job.commit`* no final do script com parâmetros configurados adequadamente. Essas duas funções inicializam o serviço de marcadores e atualizam a alteração de estado para o serviço. Marcadores não funcionarão sem chamá-las.

Especifique chaves de marcadores

Para fluxos de trabalho JDBC, o marcador acompanha quais linhas seu trabalho leu comparando os valores dos campos-chave com um valor marcado. Isso não é necessário nem aplicável aos fluxos de trabalho do Amazon S3. Ao escrever um script do AWS Glue sem o editor visual, você pode especificar qual coluna rastrear com marcadores. Você pode também especificar várias colunas. Lacunas na sequência de valores são permitidas ao especificar chaves de marcadores definidas pelo usuário.

> **Warning**
>
> Se forem usadas chaves de marcadores definidas pelo usuário, elas deverão aumentar ou diminuir estritamente de forma monotônica. Ao selecionar campos adicionais para uma chave composta, os campos para conceitos como “versões secundárias” ou “números de revisão”

não atendem a esses critérios, pois seus valores são reutilizados em todo o seu conjunto de dados.

É possível especificar `jobBookmarkKeys` e `jobBookmarkKeysSortOrder` das seguintes maneiras:

- `create_dynamic_frame.from_catalog`: use `additional_options`.
- `create_dynamic_frame.from_options`: use `connection_options`.

Contexto de transformação

Muitos dos métodos de quadros dinâmicos PySpark do AWS Glue incluem um parâmetro opcional chamado `transformation_ctx`, que é um identificador exclusivo para a instância do operador do ETL. O parâmetro `transformation_ctx` é usado para identificar informações de estado em um marcador de trabalho para o determinado operador. Especificamente, o AWS Glue usa `transformation_ctx` para indexar a chave para o marcador de estado.

⚠ Warning

`transformation_ctx` serve como a chave para pesquisar o estado do marcador para uma fonte específica em seu script. Para que o marcador funcione corretamente, você sempre deve manter a fonte e o `transformation_ctx` associado consistentes. Alterar a propriedade da fonte ou renomear `transformation_ctx` pode tornar o marcador anterior inválido e talvez a filtragem baseada em carimbo de data/hora não ofereça o resultado correto.

Para que os marcadores de trabalho funcionem corretamente, habilite o parâmetro de marcador de trabalho e defina o parâmetro `transformation_ctx`. Se você não passar o parâmetro `transformation_ctx`, os marcadores de trabalho não serão habilitados para uma tabela ou quadro dinâmico usado no método. Por exemplo, se você tiver um trabalho de ETL que lê e une duas fontes do Amazon S3, poderá optar por passar o parâmetro `transformation_ctx` somente para os métodos em que deseja habilitar marcadores. Se você redefinir o marcador de um trabalho, ele redefinirá todas as transformações associadas ao trabalho, independentemente do `transformation_ctx` usado.

Para obter mais informações sobre a classe `DynamicFrameReader`, consulte Classe DynamicFrameReader. Para obter mais informações sobre as extensões PySpark, consulte Referência de extensões PySpark do AWS Glue.

Exemplos

Example

Veja a seguir um exemplo de um script gerado para uma fonte de dados do Amazon S3. As partes do script necessárias para usar marcadores de trabalho são mostradas em itálico. Para obter mais informações sobre esses elementos, consulte a API Classe GlueContexte a API Classe DynamicFrameWriter.

```
# 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

Veja a seguir um exemplo de um script gerado para uma fonte JDBC. A tabela de origem é uma tabela de funcionário com a coluna empno como a chave primária. Embora, por padrão, o trabalho use uma chave primária sequencial como chave de marcador se nenhuma chave de marcador for especificada, já que empno não é necessariamente sequencial (pode haver lacunas nos valores), ela não estará qualificada como chave de marcador padrão. Portanto, o script designa explicitamente empno como a chave de marcador. Essa parte do código é mostrada em itálico.

```
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()
```

Usar detecção de dados confidenciais fora do AWS Glue Studio

O AWS Glue Studio permite que você detecte dados confidenciais, mas também é possível usar a funcionalidade de detecção de dados confidenciais fora do AWS Glue Studio.

Para obter uma lista completa dos tipos de dados confidenciais gerenciados, consulte Managed data types.

Detectar dados confidenciais usando os tipos de PII gerenciados pela AWS

O AWS Glue fornece duas APIs em um trabalho de ETL do AWS Glue. Essas APIs são `detect()` e `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")
```

Você pode usar a API `detect()` para identificar os tipos de PII gerenciados pela AWS e os tipos de entidades personalizadas. Uma nova coluna é criada automaticamente com o resultado da detecção. A API `classifyColumns()` retorna um mapa em que as chaves são nomes de colunas e os valores são uma lista dos tipos de entidades detectados. `SampleFraction` indica a fração dos dados que deve ser amostrada ao escanear entidades de PII, enquanto `ThresholdFraction` indica a fração de dados que deve ser atendida para que uma coluna seja identificada como dados de PII.

Detecção em nível de linha

No exemplo, o trabalho está realizando as seguintes ações usando as APIs `classifyColumns()` e `detect()`:

- ler os dados de um bucket do Amazon S3 e transformá-los em um dynamicFrame
- detectar instâncias de "e-mail" e "cartão de crédito" no dynamicFrame
- retornar um dynamicFrame com os valores originais mais uma coluna que inclui o resultado da detecção para cada linha
- gravar o dynamicFrame retornado em outro caminho do 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()
    }
 }
```

Detecção em nível de linha com ações refinadas

No exemplo, o trabalho está realizando as seguintes ações usando as APIs `detect()`:

- lendo dados de um bucket do Amazon S3 e transformando-os em um dynamicFrame;
- detectando tipos de dados confidenciais para “USA_PTIN”, “BANK_ACCOUNT”, “USA_SSN”, “USA_PASSPORT_NUMBER” e “PHONE_NUMBER” no DynamicFrame;
- retornando um dynamicFrame com os valores mascarados modificados mais uma coluna que inclui o resultado da detecção para cada linha;
- gravando o dynamicFrame retornado em outro caminho do Amazon S3

Em contraste com a API `detect()` acima, isso usa ações refinadas para detectar tipos de entidades. Para ter mais informações, consulte Parâmetros de detecção para uso 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()
  }
}
```

Detecção em nível de coluna

No exemplo, o trabalho está realizando as seguintes ações usando as APIs `classifyColumns()`:

- lendo dados de um bucket do Amazon S3 e transformando-os em um dynamicFrame;
- detectando instâncias de "Email" e "Credit Card" no dynamicFrame;
- definindo parâmetros para amostrar 100% da coluna e marcar uma entidade como detectada se ela estiver em 10% das células e apresentar sensibilidade "BAIXA";
- retornando um mapa em que as chaves são os nomes das colunas e os valores são uma lista dos tipos de entidades detectados
- gravando o dynamicFrame retornado em outro caminho do 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,
        entityTypesToDetect = 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()
  }
}
```

Detectar dados confidenciais usando tipos de PII CustomEntityType da AWS

Você pode definir as entidades personalizadas por meio do AWS Studio. Mas, para usar esse recurso fora do AWS Studio, você precisará primeiro definir os tipos de entidades personalizadas e, em seguida, adicionar os tipos de entidades personalizadas que foram definidos à lista de `entityTypesToDetect`.

Se você tiver tipos de dados confidenciais específicos em seus dados (como “ID do funcionário”), poderá criar entidades personalizadas chamando a API `CreateCustomEntityType()`.
O exemplo a seguir define o tipo de entidade personalizada 'EMPLOYEE_ID' para a API `CreateCustomEntityType()` com os parâmetros de solicitação:

```
{
    "name": "EMPLOYEE_ID",
    "regexString": "\d{4}-\d{3}",
    "contextWords": ["employee"]
}
```

Em seguida, modifique o trabalho para usar o novo tipo de dados confidenciais personalizados adicionando o tipo de entidade personalizada (EMPLOYEE_ID) à 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**
>
> Se um tipo de dados confidenciais personalizados for definido com o mesmo nome de um tipo de entidade gerenciada existente, o tipo de dados confidenciais personalizados terá precedência e substituirá a lógica do tipo de entidade gerenciada.

Parâmetros de detecção para uso de **`detect()`**

Esse método é usado para detectar entidades em um DynamicFrame. Ele retorna um novo DataFrame com valores originais e uma coluna adicional outputColumnName que contém metadados de detecção de PII. O mascaramento personalizado poderá ser feito depois que esse DynamicFrame for retornado no script AWS Glue ou a API detect() com ações refinadas pode ser usada em seu lugar.

```
detect(frame: DynamicFrame,
       entityTypesToDetect: Seq[String],
       outputColumnName: String = "DetectedEntities",
       detectionSensitivity: String = "LOW"): DynamicFrame
```

Parâmetros:

- frame (tipo:`DynamicFrame`): o DynamicFrame de entrada contendo os dados a serem processados.
- entityTypesToDetect (tipo: `[Seq[String]`): a lista de tipos de entidades a serem detectadas. Esses podem ser tipos de entidade gerenciados ou tipos de entidade personalizados.
- outputColumnName (tipo:`String`, padrão: "DetectedEntities"): o nome da coluna em que as entidades detectadas serão armazenadas. Se não for fornecido, o nome da coluna padrão será "DetectedEntities".
- detectionSensitivity (tipo:`String`, opções: "BAIXA" ou "ALTA", padrão: "BAIXA"): especifica a sensibilidade do processo de detecção. As opções válidas são "BAIXA" ou "ALTA". Se essa propriedade não for definida, a sensibilidade padrão será definida como "BAIXA".

Configurações do `outputColumnName`:

O nome da coluna em que as entidades detectadas serão armazenadas. Se não for fornecido, o nome da coluna padrão será "DetectedEntities". Para cada linha na coluna de saída, a coluna suplementar inclui um mapa do nome da coluna para os metadados da entidade detectada com os seguintes pares de chave-valor:

- entityType: o tipo da entidade detectada.
- start: a posição inicial da entidade detectada nos dados originais.
- end: a posição final da entidade detectada nos dados originais.
- actionUsed: a ação executada na entidade detectada (por exemplo, “DETECT”, “REDACT”, “PARTIAL_REDACT”, “SHA256_HASH”).

Exemplo:

```
{
   "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
         }
      ]
   }
}
```

Parâmetros de detecção para **`detect()`** com ações refinadas

Esse método é usado para detectar entidades em um DynamicFrame usando os parâmetros especificados. Ele retorna um novo DataFrame com os valores originais substituídos por dados confidenciais mascarados e uma coluna `outputColumnName` adicional com metadados de detecção de PII.

```
detect(frame: DynamicFrame,
       detectionParameters: JsonOptions,
       outputColumnName: String = "DetectedEntities",
       detectionSensitivity: String = "LOW"): DynamicFrame
```

Parâmetros:

- frame (tipo:`DynamicFrame`): o DynamicFrame de entrada contendo os dados a serem processados.
- detectionParameters (tipo:`JsonOptions`): opções JSON que especificam parâmetros para o processo de detecção.
- outputColumnName (tipo:`String`, padrão: "DetectedEntities"): o nome da coluna em que as entidades detectadas serão armazenadas. Se não for fornecido, o nome da coluna padrão será "DetectedEntities".

- detectionSensitivity (tipo:`String`, opções: "BAIXA" ou "ALTA", padrão: "BAIXA"): especifica a sensibilidade do processo de detecção. As opções válidas são "BAIXA" ou "ALTA". Se essa propriedade não for definida, a sensibilidade padrão será definida como "BAIXA".

configurações `detectionParameters`

Se nenhuma configuração for incluída, os valores padrão serão usados.

- action (tipo:`String`, opções: "DETECT", "REDACT", "PARTIAL_REDACT", "SHA256_HASH"): especifica a ação a ser executada na entidade. Obrigatório. Observe que as ações que executam o mascaramento (todas com exceção de "DETECT") só podem realizar uma ação por coluna. Essa é uma medida preventiva para mascarar entidades coalescidas.
- sourceColumns (tipo: `List[String]`, padrão: ["*"]): lista de nomes de colunas de origem para realizar a detecção da entidade. Por padrão, será ["*"] se não estiver presente. Aumentará `IllegalArgumentException` se um nome de coluna inválido for usado.
- sourceColumnsToExclude (tipo: `List[String]`): lista de nomes de colunas de origem para realizar a detecção para a entidade. Use `sourceColumns` ou `sourceColumnsToExclude`. Aumentará `IllegalArgumentException` se um nome de coluna inválido for usado.
- actionOptions: opções adicionais com base na ação especificada:
  - Para "DETECT" e "SHA256_HASH", nenhuma opção é permitida.
  - Para "REDACT":
    - redactText (tipo:`String`, padrão: "*****"): texto para substituir a entidade detectada.
  - Para "PARTIAL_REDACT":
    - redactChar (tipo:`String`, padrão: "*"): caractere para substituir cada caractere detectado na entidade.
    - matchPattern (tipo:`String`): padrão Regex para redação parcial. Não pode ser combinado com numLeftCharsToExclude ou `numRightCharsToExclude`.
    - numLeftCharsToExclude (tipo:`String, integer`): número de caracteres à esquerda a serem excluídos. Não pode ser combinado com matchPattern, mas pode ser usado com `numRightCharsToExclude`.
    - numRightCharsToExclude (tipo:`String, integer`): número de caracteres à direita a serem excluídos. Não pode ser combinado com matchPattern, mas pode ser usado com `numRightCharsToExclude`.

Configurações de `outputColumnName`

Consulte as configurações de outputColumnName

Parâmetros de detecção para **`classifyColumns()`**

Esse método é usado para detectar entidades em um DynamicFrame. Ele retorna um mapa em que as chaves são os nomes das colunas e os valores são uma lista dos tipos de entidades detectados. O mascaramento personalizado poderá ser feito depois que isso for retornado no script AWS Glue.

```
classifyColumns(frame: DynamicFrame,
                entityTypesToDetect: Seq[String],
                sampleFraction: Double = 0.1,
                thresholdFraction: Double = 0.1,
                detectionSensitivity: String = "LOW")
```

Parâmetros:

- frame (tipo:`DynamicFrame`): o DynamicFrame de entrada contendo os dados a serem processados.
- entityTypesToDetect (tipo: `Seq[String]`): a lista de tipos de entidades a serem detectadas. Esses podem ser tipos de entidade gerenciados ou tipos de entidade personalizados.
- sampleFraction (tipo:`Double`, padrão: 10%): a fração dos dados que será amostrada na verificação de entidades de PII.
- thresholdFraction (tipo:`Double`, padrão: 10%): a fração dos dados que deverá ser atendida para que uma coluna seja identificada como dados de PII.
- detectionSensitivity (tipo:`String`, opções: "BAIXA" ou "ALTA", padrão: "BAIXA"): especifica a sensibilidade do processo de detecção. As opções válidas são "BAIXA" ou "ALTA". Se essa propriedade não for definida, a sensibilidade padrão será definida como "BAIXA".

Tipos de dados confidenciais gerenciados

Entidades globais

Tipo de dado	Categoria	Descrição
PERSON_NAME	Universal	O nome da pessoa.

Tipo de dado	Categoria	Descrição
EMAIL	Pessoal	O endereço de e-mail.
IP_ADDRESS	Computador	O endereço IP
MAC_ADDRESS	Pessoal	O endereço MAC.

Tipos de dados dos EUA

Tipo de dado	Descrição
BANK_ACCOUNT	O número da conta bancária. Não específico de um país ou região, porém, apenas formatos de contas nos EUA e Canadá são detectados no momento.
CREDIT_CARD	O número do cartão de crédito.
PHONE_NUMBER	Número de telefone. Não específico de um país ou região, mas, apenas números de telefone dos EUA e Canadá são detectados no momento.
USA_ATIN	O número de identificação fiscal de adoção dos EUA emitido pela Receita Federal.
USA_CPT_CODE	O código CPT (específico dos EUA).
USA_DEA_NUMBER	O número do DEA (específico dos EUA).
USA_DRIVING_LICENSE	O número da carteira de motorista (específico dos EUA).
USA_HCPCS_CODE	O código HCPCS (específico dos EUA).
USA_HEALTH_INSURANCE_CLAIM_NUMBER	Número da reividicação do seguro de saúde (específico dos EUA).

Tipo de dado	Descrição
USA_ITIN	O ITIN (para pessoas físicas ou entidades nos EUA).
USA_MEDICARE_BENEFICIARY_IDENTIFIER	Identificação de beneficiário do Medicare (específico dos EUA).
USA_NATIONAL_DRUG_CODE	O código NDC (específico dos EUA).
USA_NATIONAL_PROVIDER_IDENTIFIER	O número identificador de prestador de serviço nacional (específico dos EUA).
USA_PASSPORT_NUMBER	O número do passaporte (para pessoas físicas dos EUA).
USA_PTIN	O número de identificação fiscal de adoção dos EUA emitido pela Receita Federal.
USA_SSN	O número da previdência social (para pessoas físicas nos EUA).

Tipos de dados da Argentina

Tipo de dado	Descrição
ARGENTINA_TAX_IDENTIFICATIO N_NUMBER	Número de identificação fiscal da Argentina. Também conhecido como CUIT ou CUIL.

Tipos de dados australianos

Tipo de dado	Descrição
AUSTRALIA_BUSINESS_NUMBER	Número de empresa australiana (ABN). Um identificador exclusivo emitido pelo Registro de

Tipo de dado	Descrição
	Empresas Australianas (ABR) para identificar empresas para o governo e a comunidade.
AUSTRALIA_COMPANY_NUMBER	Número da empresa australiana (ACN). Identificador exclusivo emitido pela Comissão Australiana de Valores Mobiliários e Investimentos.
AUSTRALIA_DRIVING_LICENSE	O número da carteira de motorista da Austrália.
AUSTRALIA_MEDICARE_NUMBER	Número do Medicare australiano. Identificador pessoal emitido pela Comissão Australiana de Seguro de Saúde.
NÚMERO DO PASSAPORTE AUSTRALIANO	Número do passaporte australiano.
AUSTRALIA_TAX_FILE_NUMBER	Número do arquivo fiscal da Austrália (TFN). Emitido pelo Escritório Australiano de Tributação (ATO) para contribuintes (pessoas físicas, jurídicas, etc.) para transações tributárias.

Tipos de dados da Áustria

Tipo de dado	Descrição
AUSTRIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Áustria).
AUSTRIA_PASSPORT_NUMBER	O número do passaporte (específico da Áustria).
AUSTRIA_SSN	O número da previdência social (para pessoas físicas da Áustria).
AUSTRIA_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Áustria).

Tipo de dado	Descrição
AUSTRIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Áustria).

Tipos de dados dos Bálcãs

Tipo de dado	Descrição
BOSNIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número de cidadão mestre exclusivo (JMBG) para cidadãos da Bósnia-Herzegovina.
KOSOVO_UNIQUE_MASTER_CITIZEN_NUMBER	Número de cidadão mestre exclusivo (JMBG) para o Kosovo.
MACEDONIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número de cidadão mestre exclusivo para a Macedônia.
MONTENEGRO_UNIQUE_MASTER_CITIZEN_NUMBER	Número de cidadão mestre exclusivo (JMBG) para Montenegro.
SERBIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número de cidadão mestre exclusivo (JMBG) para a Sérvia.
SERBIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Áustria).
VOJVODINA_UNIQUE_MASTER_CITIZEN_NUMBER	Número de cidadão mestre exclusivo (JMBG) para a Voivodina.

Tipos de dados da Bélgica

Tipo de dado	Descrição
BELGIUM_DRIVING_LICENSE	O número da carteira de motorista (específico da Bélgica).

Tipo de dado	Descrição
BELGIUM_NATIONAL_IDENTIFICATION_NUMBER	O número nacional belga (BNN).
BELGIUM_PASSPORT_NUMBER	O número do passaporte (específico da Bélgica).
BELGIUM_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Bélgica).
BELGIUM_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Bélgica).

Tipos de dados do Brasil

Tipo de dado	Descrição
BRAZIL_BANK_ACCOUNT	O número da conta bancária (específico do Brasil).
BRAZIL_NATIONAL_IDENTIFICATION_NUMBER	O identificador nacional (específico do Brasil).
BRAZIL_NATIONAL_REGISTRY_OF_LEGAL_ENTITIES_NUMBER	O número de identificação emitido para empresas (específico do Brasil), também conhecido como CNPJ.
BRAZIL_NATURAL_PERSON_REGISTRY_NUMBER	Número de registro de pessoa física, também conhecido como CPF.

Tipos de dados da Bulgária

Tipo de dado	Descrição
BULGARIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Bulgária).

Tipo de dado	Descrição
BULGARIA_UNIFORM_CIVIL_NUMBER	Número civil unificado (EGN) que serve como número de identificação nacional.
BULGARIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Bulgária).

Tipos de dados do Canadá

Tipo de dado	Descrição
CANADA_DRIVING_LICENSE	O número da carteira de motorista (específico do Canadá).
CANADA_GOVERNMENT_IDENTIFICATION_CARD_NUMBER	O identificador nacional (específico do Canadá).
CANADA_PASSPORT_NUMBER	O número do passaporte (específico do Canadá).
CANADA_PERMANENT_RESIDENCE_NUMBER	Número de residência permanente (número do cartão PR).
CANADA_PERSONAL_HEALTH_NUMBER	O identificador exclusivo para assistência médica (número PHN).
CANADA_SOCIAL_INSURANCE_NUMBER	O número do seguro social (SIN) no Canadá.

Tipos de dados do Chile

Tipo de dado	Descrição
CHILE_DRIVING_LICENSE	O número da carteira de motorista (específico do Chile).

Tipo de dado	Descrição
CHILE_NATIONAL_IDENTIFICATION_NUMBER	O identificador nacional do Chile, também conhecido como RUT ou RUN.

Tipos de dados da China, Hong Kong, Macau e Taiwan

Tipo de dado	Descrição
CHINA_IDENTIFICATION	O identificador da China.
CHINA_LICENSE_PLATE_NUMBER	O número da carteira de motorista (específico da China).
CHINA_MAINLAND_TRAVEL_PERMIT_ID_HONG_KONG_MACAU	A autorização de viagem ao continente para residentes de Hong Kong e Macau.
CHINA_MAINLAND_TRAVEL_PERMIT_ID_TAIWAN	A autorização de viagem ao continente para residentes de Taiwan emitida pelo Governo da República Popular da China (RPC).
CHINA_PASSPORT_NUMBER	O número do passaporte (específico da China).
CHINA_PHONE_NUMBER	O número de telefone (específico da China).
HONG_KONG_IDENTITY_CARD	O documento de identidade oficial emitido pelo Departamento de Imigração de Hong Kong.
MACAU_RESIDENT_IDENTITY_CARD	A carteira de identidade de residente de Macau ou BIR é uma carteira de identidade oficial emitida pelo Gabinete de Serviços de Identificação de Macau.
TAIWAN_NATIONAL_IDENTIFICATION_NUMBER	O identificador nacional (específico de Taiwan).
TAIWAN_PASSPORT_NUMBER	O número do passaporte (específico de Taiwan).

Tipos de dados da Colômbia

Tipo de dado	Descrição
COLOMBIA_PERSONAL_IDENTIFICATION_NUMBER	Identificador exclusivo atribuído aos colombianos no nascimento.
COLOMBIA_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Colômbia).

Tipos de dados da Croácia

Tipo de dado	Descrição
CROATIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Croácia).
CROATIA_IDENTITY_NUMBER	O identificador nacional (específico da Croácia).
CROATIA_PASSPORT_NUMBER	O número do passaporte (específico da Croácia).
CROATIA_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (OIB).

Tipos de dados de Chipre

Tipo de dado	Descrição
CYPRUS_DRIVING_LICENSE	O número da carteira de motorista (específico de Chipre).
CYPRUS_NATIONAL_IDENTIFICATION_NUMBER	A carteira de identidade cipriota.

Tipo de dado	Descrição
CYPRUS_PASSPORT_NUMBER	O número do passaporte (específico de Chipre).
CYPRUS_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico de Chipre).
CYPRUS_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico de Chipre).

Tipos de dados da República Tcheca

Tipo de dado	Descrição
CZECHIA_DRIVING_LICENSE	O número da carteira de motorista (específico da República Tcheca).
CZECHIA_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (específico da República Tcheca).
CZECHIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da República Tcheca).

Tipos de dados da Dinamarca

Tipo de dado	Descrição
DENMARK_DRIVING_LICENSE	O número da carteira de motorista (específico da Dinamarca).
DENMARK_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (específico da Dinamarca).
DENMARK_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Dinamarca).

Tipo de dado	Descrição
DINAMARCA_VALOR_IMPOSTO_AGR EGADO	Imposto sobre valor agregado (específico da Dinamarca).

Tipos de dados da Estônia

Tipo de dado	Descrição
ESTONIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Estônia).
ESTONIA_PASSPORT_NUMBER	O número do passaporte (específico da Estônia).
ESTONIA_PERSONAL_IDENTIFICA TION_CODE	O número de identificação pessoal (específico da Estônia).
ESTONIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Estônia).

Tipos de dados da Finlândia

Tipo de dado	Descrição
FINLAND_DRIVING_LICENSE	O número da carteira de motorista (específico da Finlândia).
FINLAND_HEALTH_INSURANCE_NUMBER	O número do seguro saúde (específico da Finlândia).
FINLAND_NATIONAL_IDENTIFICA TION_NUMBER	O número identificador de prestador de serviço nacional (específico da Finlândia).
FINLAND_PASSPORT_NUMBER	O número do passaporte (específico da Finlândia).

Tipo de dado	Descrição
FINLAND_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Finlândia).

Tipos de dados da França

Tipo de dado	Descrição
FRANCE_BANK_ACCOUNT	O número da conta bancária (específico da França).
FRANCE_DRIVING_LICENSE	O número da carteira de motorista (específico da França).
FRANCE_HEALTH_INSURANCE_NUMBER	Número do seguro saúde da França.
FRANCE_INSEE_CODE	Número da previdência social, SSN ou NIR da França.
FRANCE_NATIONAL_IDENTIFICATION_NUMBER	Número de identificação nacional (CNI) da França.
FRANCE_PASSPORT_NUMBER	O número do passaporte (específico da França).
FRANCE_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da França).
FRANCE_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da França).

Tipos de dados da Alemanha

Tipo de dado	Descrição
GERMANY_BANK_ACCOUNT	O número da conta bancária (específico da Alemanha).
GERMANY_DRIVING_LICENSE	O número da carteira de motorista (específico da Alemanha).
GERMANY_PASSPORT_NUMBER	O número do passaporte (específico da Alemanha).
GERMANY_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (específico da Alemanha).
GERMANY_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Alemanha).
GERMANY_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Alemanha).

Tipos de dados da Grécia

Tipo de dado	Descrição
GREECE_DRIVING_LICENSE	O número da carteira de motorista (específico da Grécia).
GREECE_PASSPORT_NUMBER	O número do passaporte (específico da Grécia).
GREECE_SSN	O número da previdência social (para pessoas físicas da Grécia).
GREECE_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Grécia).
GREECE_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Grécia).

Tipos de dados da Hungria

Tipo de dado	Descrição
HUNGARY_DRIVING_LICENSE	O número da carteira de motorista (específico da Hungria).
HUNGARY_PASSPORT_NUMBER	O número do passaporte (específico da Hungria).
HUNGARY_SSN	O número da previdência social (para pessoas físicas da Hungria).
HUNGARY_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Hungria).
HUNGARY_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Hungria).

Tipos de dados da Islândia

Tipo de dado	Descrição
ICELAND_NATIONAL_IDENTIFICATION_NUMBER	O identificador nacional (específico da Islândia).
ICELAND_PASSPORT_NUMBER	O número do passaporte (específico da Islândia).
ICELAND_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Islândia).

Tipos de dados da Índia

Tipo de dado	Descrição
INDIA_AADHAAR_NUMBER	Número de identificação Aadhaar emitido pela Autoridade de Identificação Única da Índia.
INDIA_PERMANENT_ACCOUNT_NUMBER	Número da conta permanente (PAN) da Índia.

Tipos de dados da Indonésia

Tipo de dado	Descrição
INDONESIA_IDENTITY_CARD_NUMBER	O identificador nacional (específico da Indonésia).

Tipos de dados da Irlanda

Tipo de dado	Descrição
IRELAND_DRIVING_LICENSE	O número da carteira de motorista (específico da Irlanda).
IRELAND_PASSPORT_NUMBER	O número do passaporte (específico da Irlanda).
IRELAND_PERSONAL_PUBLIC_SERVICE_NUMBER	Número de serviço público pessoal da Irlanda (PPS).
IRELAND_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Irlanda).
IMPOSTO SOBRE VALOR AGREGADO DA IRLANDA	Imposto sobre valor agregado (específico da Irlanda).

Tipos de dados de Israel

Tipo de dado	Descrição
ISRAEL_IDENTIFICATION_NUMBER	O identificador nacional (específico de Israel).

Tipos de dados da Itália

Tipo de dado	Descrição
ITALY_BANK_ACCOUNT	O número da conta bancária (específico da Itália).
ITALY_DRIVING_LICENSE	O número da carteira de motorista (específico da Itália).
ITALY_FISCAL_CODE	O número identificador, também conhecido como Codice Fiscale italiano.
ITALY_PASSPORT_NUMBER	O número do passaporte (específico da Itália).
ITALY_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Itália).

Tipos de dados do Japão

Tipo de dado	Descrição
JAPAN_BANK_ACCOUNT	Conta bancária no Japão.
JAPAN_DRIVING_LICENSE	Um número de carteira de motorista do Japão.
JAPAN_MY_NUMBER	O identificador exclusivo para cidadãos ou corporações do Japão, usado para administr ação tributária, administração de previdência social e resposta a desastres
JAPAN_PASSPORT_NUMBER	Número do passaporte do Japão.

Tipos de dados da Coreia

Tipo de dado	Descrição
KOREA_PASSPORT_NUMBER	O número do passaporte (específico da Coreia).
KOREA_RESIDENCE_REGISTRATION_NUMBER_FOR_CITIZENS	Número de registro de residência na Coreia para residentes.
KOREA_RESIDENCE_REGISTRATION_NUMBER_FOR_FOREIGNERS	Número de registro de residência na Coreia para estrangeiros.

Tipos de dados da Letônia

Tipo de dado	Descrição
LATVIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Letônia).
LATVIA_PASSPORT_NUMBER	O número do passaporte (específico da Letônia).
LATVIA_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (específico da Letônia).
LATVIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Letônia).

Tipos de dados de Liechtenstein

Tipo de dado	Descrição
LIECHTENSTEIN_NATIONAL_IDENTIFICATION_NUMBER	O identificador nacional (específico de Liechtenstein).

Tipo de dado	Descrição
LIECHTENSTEIN_PASSPORT_NUMBER	O número do passaporte (específico de Liechtenstein).
LIECHTENSTEIN_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico de Liechtenstein).

Tipos de dados da Lituânia

Tipo de dado	Descrição
LITHUANIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Lituânia).
LITHUANIA_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (específico da Lituânia).
LITHUANIA_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Lituânia).
LITHUANIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Lituânia).

Tipos de dados de Luxemburgo

Tipo de dado	Descrição
LUXEMBOURG_DRIVING_LICENSE	O número da carteira de motorista (específico de Luxemburgo).
LUXEMBOURG_NATIONAL_INDIVIDUAL_NUMBER	O identificador nacional (específico de Luxemburgo).
LUXEMBOURG_PASSPORT_NUMBER	O número do passaporte (específico de Luxemburgo).

Tipo de dado	Descrição
LUXEMBOURG_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico de Luxemburgo).
LUXEMBOURG_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico de Luxemburgo).

Tipos de dados da Malásia

Tipo de dado	Descrição
MALAYSIA_MYKAD_NUMBER	O identificador nacional (específico da Malásia).
MALAYSIA_PASSPORT_NUMBER	O número do passaporte (específico da Malásia).

Tipos de dados de Malta

Tipo de dado	Descrição
MALTA_DRIVING_LICENSE	O número da carteira de motorista (específico de Malta).
MALTA_NATIONAL_IDENTIFICATION_NUMBER	O identificador nacional (específico de Malta).
MALTA_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico de Malta).
MALTA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico de Malta).

Tipos de dados do México

Tipo de dado	Descrição
MEXICO_CLABE_NUMBER	México (número bancário CLABE (Clave Bancaria Estandarizada).
MEXICO_DRIVING_LICENSE	O número da carteira de motorista (específico do México).
MEXICO_PASSPORT_NUMBER	O número do passaporte (específico do México).
MEXICO_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico do México).
MEXICO_UNIQUE_POPULATION_REGISTRY_CODE	O código de identidade exclusivo Clave Única de Registro de Población (CURP) do México.

Tipos de dados da Holanda

Tipo de dado	Descrição
NETHERLANDS_CITIZEN_SERVICE_NUMBER	Número de cidadão holandês (BSN, burgerservicenummer).
NETHERLANDS_DRIVING_LICENSE	O número da carteira de motorista (específico da Holanda).
NETHERLANDS_PASSPORT_NUMBER	O número do passaporte (específico da Holanda).
NETHERLANDS_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Holanda).
NETHERLANDS_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Holanda).
NETHERLANDS_BANK_ACCOUNT	O número da conta bancária (específico da Holanda).

Tipos de dados da Nova Zelândia

Tipo de dado	Descrição
NEW_ZEALAND_DRIVING_LICENSE	O número da carteira de motorista (específico da Nova Zelândia).
NEW_ZEALAND_NATIONAL_HEALTH_INDEX_NUMBER	Número do índice nacional de saúde da Nova Zelândia.
NEW_ZEALAND_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal, também conhecido como número da Receita Federal (específico da Nova Zelândia).

Tipos de dados da Noruega

Tipo de dado	Descrição
NORWAY_BIRTH_NUMBER	Número de identidade nacional norueguês.
NORWAY_DRIVING_LICENSE	O número da carteira de motorista (específico da Noruega).
NORWAY_HEALTH_INSURANCE_NUMBER	Número do seguro saúde da Noruega.
NORWAY_NATIONAL_IDENTIFICATION_NUMBER	O número identificador de prestador de serviço nacional (específico da Noruega).
NORWAY_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Noruega).

Tipos de dados das Filipinas

Tipo de dado	Descrição
PHILIPPINES_DRIVING_LICENSE	O número da carteira de motorista (específico da Noruega).

Tipo de dado	Descrição
PHILIPPINES_PASSPORT_NUMBER	O número do passaporte (específico das Filipinas).

Tipos de dados da Polônia

Tipo de dado	Descrição
POLAND_DRIVING_LICENSE	O número da carteira de motorista (específico das Filipinas).
POLAND_IDENTIFICATION_NUMBER	O identificador da Polônia.
POLAND_PASSPORT_NUMBER	O número do passaporte (específico das Filipinas).
NÚMERO DA REGIÃO DA POLÔNIA	O número identificador REGON, também conhecido como Número de Identificação Estatística.
POLAND_SSN	O número da previdência social (para pessoas físicas da Polônia).
POLAND_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Polônia).
POLAND_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Polônia).

Tipos de dados de Portugal

Tipo de dado	Descrição
PORTUGAL_DRIVING_LICENSE	O número da carteira de motorista (específico de Portugal).

Tipo de dado	Descrição
PORTUGAL_NATIONAL_IDENTIFIC ATION_NUMBER	O número identificador de prestador de serviço nacional (específico de Portugal).
NÚMERO_PASSAPORTE_PORTUGAL_BR	O número do passaporte (específico de Portugal).
PORTUGAL_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico de Portugal).
PORTUGAL_VALUE_ADDED_TAX	Imposto sobre o valor acrescentado (específico de Portugal).

Tipos de dados da Romênia

Tipo de dado	Descrição
ROMANIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Romênia).
ROMANIA_NUMERICAL_PERSONAL_CODE	O número de identificação pessoal (específico da Romênia).
ROMANIA_PASSPORT_NUMBER	O número do passaporte (específico da Romênia).
ROMANIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Romênia).

Tipos de dados de Singapura

Tipo de dado	Descrição
SINGAPORE_DRIVING_LICENSE	O número da carteira de motorista (específico de Singapura).

Tipo de dado	Descrição
SINGAPORE_NATIONAL_REGISTRY _IDENTIFICATION_NUMBER	A carteira de identidade de registro nacional de Singapura.
SINGAPORE_PASSPORT_NUMBER	O número do passaporte (específico de Singapura).
SINGAPORE_UNIQUE_ENTITY_NUMBER	O número identificador exclusivo (UEN) de Singapura.

Tipos de dados da Eslováquia

Tipo de dado	Descrição
SLOVAKIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Eslováquia).
SLOVAKIA_NATIONAL_IDENTIFIC ATION_NUMBER	O número identificador de prestador de serviço nacional (específico da Eslováquia).
SLOVAKIA_PASSPORT_NUMBER	O número do passaporte (específico da Eslováquia).
SLOVAKIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Eslováquia).

Tipos de dados da Eslovênia

Tipo de dado	Descrição
SLOVENIA_DRIVING_LICENSE	O número da carteira de motorista (específico da Eslovênia).
SLOVENIA_PASSPORT_NUMBER	O número do passaporte (específico da Eslovênia).

Tipo de dado	Descrição
SLOVENIA_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal (específico da Eslovênia).
SLOVENIA_UNIQUE_MASTER_CITIZEN_NUMBER	Número de cidadão mestre exclusivo (JMBG) para cidadãos da Eslovênia.
SLOVENIA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Eslovênia).

Tipos de dados da África do Sul

Tipo de dado	Descrição
SOUTH_AFRICA_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (específico da África do Sul).

Tipos de dados da Espanha

Tipo de dado	Descrição
SPAIN_BANK_ACCOUNT	O número da conta bancária (específico da Espanha).
SPAIN_DNI	O cartão de identidade nacional (Documento Nacional de Identidad) da Espanha.
SPAIN_DRIVING_LICENSE	O número da carteira de motorista (específico da Espanha).
SPAIN_NIE	O número de identidade de estrangeiro (específico da Espanha), também conhecido como NIE.
SPAIN_NIF	Número de identificação fiscal (específico da Espanha), também conhecido como NIF.

Tipo de dado	Descrição
SPAIN_PASSPORT_NUMBER	O número do passaporte (específico da Espanha).
SPAIN_SSN	O número da previdência social (para pessoas físicas da Espanha).
SPAIN_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Espanha).

Tipos de dados do Sri Lanka

Tipo de dado	Descrição
SRI_LANKA_NATIONAL_IDENTIFICATION_NUMBER	O identificador nacional (específico do Sri Lanka).

Tipos de dados da Suécia

Tipo de dado	Descrição
CARTEIRA DE HABILITAÇÃO SUECA	O número da carteira de motorista (específico da Suécia).
SWEDEN_PASSPORT_NUMBER	O número do passaporte (específico da Suécia).
SWEDEN_PERSONAL_IDENTIFICATION_NUMBER	O número identificador de prestador de serviço nacional (específico da Suécia).
SWEDEN_TAX_IDENTIFICATION_NUMBER	Número de identificação fiscal da Suécia (personnummer).
SWEDEN_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Suécia).

Tipos de dados da Suíça

Tipo de dado	Descrição
SWITZERLAND_AHV	O número da previdência social (para pessoas físicas da Suíça).
SWITZERLAND_HEALTH_INSURANCE_NUMBER	Número do seguro saúde suíço.
SWITZERLAND_PASSPORT_NUMBER	O número do passaporte (específico da Suíça).
SWITZERLAND_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Suíça).

Tipos de dados da Tailândia

Tipo de dado	Descrição
THAILAND_PASSPORT_NUMBER	O número do passaporte (específico da Tailândia).
THAILAND_PERSONAL_IDENTIFICATION_NUMBER	O número de identificação pessoal (específico da Tailândia).

Tipos de dados da Turquia

Tipo de dado	Descrição
TURKEY_NATIONAL_IDENTIFICATION_NUMBER	O número didentificador de prestador de serviço nacional (específico da Turquia).
TURKEY_PASSPORT_NUMBER	O número do passaporte (específico da Turquia).
TURKEY_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Turquia).

Tipos de dados da Ucrânia

Tipo de dado	Descrição
UKRAINE_INDIVIDUAL_IDENTIFICATION_NUMBER	O identificador exclusivo (específico da Ucrânia).
UKRAINE_PASSPORT_NUMBER_DOMESTIC	O número do passaporte nacional (específico da Ucrânia).
UKRAINE_PASSPORT_NUMBER_INTERNATIONAL	O número do passaporte internacional (específico da Ucrânia).

Tipos de dados dos Emirados Árabes Unidos (EAU)

Tipo de dado	Descrição
UNITED_ARAB_EMIRATES_PERSONAL_NUMBER	O número de identificação pessoal (específico dos Emirados Árabes Unidos).

Tipos de dados do Reino Unido

Tipo de dado	Descrição
UK_BANK_ACCOUNT	Conta bancária do Reino Unido (Reino Unido).
UK_BANK_SORT_CODE	Código de classificação bancária do Reino Unido (Reino Unido). Os códigos Sore são códigos bancários usados para rotear transferências de dinheiro entre bancos em seus respectivos países por meio de suas respectivas organizações de compensação.
UK_DRIVING_LICENSE	O número da carteira de motorista do Reino Unido da Grã-Bretanha e Irlanda do Norte (específico do Reino Unido)

Tipo de dado	Descrição
UK_ELECTORAL_ROLL_NUMBER	O Electoral Roll Number (ERN) é o número de identificação emitido para um indivíduo para registro eleitoral no Reino Unido. O formato desse número é especificado pelas Normas do Governo do Reino Unido do Gabinete do Reino Unido.
UK_NATIONAL_HEALTH_SERVICE_NUMBER	O número do Serviço de Saúde Nacional (NHS) é o número exclusivo atribuído a um usuário registrado dos serviços públicos de saúde no Reino Unido.
UK_NATIONAL_INSURANCE_NUMBER	O National Insurance Number (NINO) é um número usado no Reino Unido (Reino Unido) para identificar um indivíduo para o programa de seguro nacional ou o sistema de previdência social. Às vezes o número é referenciado como NI No ou NINO.
UK_PASSPORT_NUMBER	Número do passaporte do Reino Unido (Reino Unido).
UK_UNIQUE_TAXPAYER_REFERENCE_NUMBER	O número de Unique Taxpayer Reference (UTR) do Reino Unido. Um identificador usado pelo governo do Reino Unido para gerenciar o sistema tributário.
UK_VALUE_ADDED_TAX	O VAT é um imposto sobre o consumo que é pago pelo consumidor final. O VAT é pago por cada transação no processo de fabricação e distribuição. Para o Reino Unido, o número do VAT é emitido pelo escritório de VAT da região em que a empresa está estabelecida.
UK_PHONE_NUMBER	Número de telefone do Reino Unido (Reino Unido).

Tipos de dados da Venezuela

Tipo de dado	Descrição
VENEZUELA_DRIVING_LICENSE	O número da carteira de motorista (específico da Venezuela).
VENEZUELA_NATIONAL_IDENTIFICATION_NUMBER	O número de identificação nacional (específico da Venezuela).
VENEZUELA_VALUE_ADDED_TAX	Imposto sobre valor agregado (específico da Venezuela).

Usar a detecção minuciosa de dados confidenciais

> **Note**
>
> As ações minuciosas só estão disponíveis no AWS Glue versões 3.0 e 4.0. Isso inclui a experiência do AWS Glue Studio. As alterações persistentes do log de auditoria também não estão disponíveis na versão 2.0.
> Todas as tarefas visuais do AWS Glue Studio 3.0 e 4.0 terão um script criado que usa automaticamente APIs de ações minuciosas.

A transformação Detectar dados confidenciais permite detectar, mascarar ou remover entidades definidas por você ou que são predefinidas pelo AWS Glue. Além disso, ações minuciosas permitem que você aplique uma ação específica por entidade. Os benefícios adicionais incluem:

- Performance aprimorada à medida que as ações são aplicadas assim que os dados são detectados.
- A opção de incluir ou excluir colunas específicas.
- A capacidade de usar mascaramento parcial. Isso permite mascarar parcialmente as entidades de dados confidenciais detectadas, em vez de mascarar a string inteira. Ambos os parâmetros simples com deslocamentos e regex são aceitos.

A seguir são mostrados trechos de código de APIs de detecção de dados confidenciais e ações minuciosas usados nos exemplos de trabalhos mencionados na próxima seção.

API de detecção: as ações minuciosas usam o novo parâmetro `detectionParameters`:

```
def detect(
    frame: DynamicFrame,
    detectionParameters: JsonOptions,
    outputColumnName: String = "DetectedEntities",
    detectionSensitivity: String = "LOW"
): DynamicFrame = {}
```

Usar APIs de detecção de dados confidenciais com ações minuciosas

As APIs de detecção de dados confidenciais que usam detect analisam os dados fornecidos, determinam se as linhas ou colunas são tipos de entidades de dados confidenciais e executam ações especificadas pelo usuário para cada tipo de entidade.

Usar a API de detecção com ações minuciosas

Use a API detect e especifique `outputColumnName` e `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()
     }
```

O script acima criará um DataFrame com base em um local no Amazon S3 e, em seguida, executará a API `detect`. Como a API `detect` exige que o campo `detectionParameters` (um mapa do nome da entidade para uma lista de todas as configurações de ação a serem usadas para essa entidade) seja representado pelo objeto `JsonOptions` do AWS Glue, ela também nos permitirá estender a funcionalidade da API.

Para cada ação especificada por entidade, insira uma lista de todos os nomes das colunas às quais deseja aplicar a combinação entidade/ação. Isso permite personalizas as entidades a serem detectadas em cada coluna em seu conjunto de dados e ignorar as entidades que você sabe que não estão em uma coluna específica. Isso também permite que seus trabalhos apresentem uma melhor performance ao não realizar chamadas de detecção desnecessárias para essas entidades e permite a você executar ações exclusivas para cada combinação de coluna e entidade.

Examinando mais de perto o `detectionParameters`, há três tipos de entidades no trabalho de exemplo. São elas: `Phone Number`, `USA_PASSPORT_NUMBER` e `USA_DRIVING_LICENSE`. Para cada um desses tipos de entidade, o AWS Glue executará ações diferentes que são `PARTIAL_REDACT`, `SHA256_HASH`, `REDACT` e `DETECT`. Cada um dos tipos de entidade também tem `sourceColumns` para ser aplicado a ele e/ou `sourceColumnsToExclude`, se detectado.

> **Note**
>
> Somente uma ação de edição no local (`PARTIAL_REDACT`, `SHA256_HASH` ou `REDACT`) pode ser usada por coluna, mas a ação `DETECT` pode ser usada com qualquer uma dessas ações.

O campo `detectionParameters` tem o layout abaixo:

```
ENTITY_NAME -> List[Actions]
{
 "ENTITY_NAME": [{
  Action, // required
```

```
      ColumnSpecs,
      ActionOptionsMap
        }],
        "ENTITY_NAME2": [{
      ...
        }]
    }
```

Os tipos de `actions` e `actionOptions` estão listados abaixo:

```
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"
```

```
    ]
}
```

Depois que o script é executado, os resultados são enviados para a localização específica do Amazon S3. Você pode visualizar seus dados no Amazon S3, mas com os tipos de entidade selecionados sendo sensibilizados com base na ação selecionada. No caso, teríamos uma linha que teria a seguinte aparência:

```
{
    "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"
}
```

No script acima, o `Phone Number` foi parcialmente redigido com #. O `Passport No` foi transformado em um hash SHA256. O `DL NO#` foi detectado como um número da carteira de motorista dos EUA e foi redigido como "USA_DL", assim como indicado no `detectionParameters`.

> **Note**
>
> A API classifyColumns não está disponível para uso com ações minuciosas devido à natureza da API. Essa API realiza a amostragem de colunas (ajustável pelo usuário, mas tem valores padrão) para realizar a detecção mais rapidamente. Por esse motivo, as ações minuciosas exigem a iteração de cada valor.

Log de auditoria persistente

Um novo recurso introduzido com ações minuciosas (mas também disponível ao usar as APIs normais) é a presença de um log de auditoria persistente. No momento, a execução da API de detecção acrescenta um parâmetro adicional de coluna (o padrão é `DetectedEntities`, mas ele personalizável via `outputColumnName`) com metadados de detecção de PII. Ela agora tem uma chave de metadados "actionUsed", que é uma de `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
        }
    ]
}
```

Até mesmo clientes que usam APIs sem ações minuciosas, como `detect(entityTypesToDetect, outputColumnName)`, verão esse log de auditoria persistente no dataframe resultante.

Os clientes que usam APIs com ações minuciosas verão todas as ações, independentemente de terem sido editadas ou não. Exemplo:

```
+--------------------+---------------
+-------------------------------------------------------------------------------------------------------
+
| Credit Card Number  |  Phone Number  |
                                              DetectedEntities
                                                                                    |
```

```
+--------------------+---------------
+-------------------------------------------------------------------------------------------------------
+
| 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}]}} |
+--------------------+---------------
+-------------------------------------------------------------------------------------------------------
+
```

Se você não quiser ver a coluna DetectedEntities, basta soltar a coluna adicional em um script personalizado.

API Visual Job do AWS Glue

O AWS Glue fornece uma API que permite aos clientes criar trabalhos de integração de dados usando a API do AWS Glue diretamente de um objeto JSON que representa um fluxo de trabalho de etapa visual. Em seguida, os clientes podem usar o editor visual no AWS Glue Studio para lidar com esses trabalhos.

Para mais informações sobre os tipos de dados da API Visual Job, consulte API Visual Job.

Tópicos

- Design de API e APIs CRUD
- Conceitos básicos
- Limitações de trabalho visual

Design de API e APIs CRUD

Agora as APIs CreateJob e UpdateJob oferecem suporte a um parâmetro opcional adicional, codeGenConfigurationNodes. O fornecimento de uma estrutura JSON não vazia a esse campo

resultará no registro do DAG no AWS Glue Studio para o trabalho criado e o código associado que está sendo gerado. Um valor nulo ou string vazia para este campo na criação do trabalho será ignorado.

As atualizações do campo codeGenConfigurationNodes serão feitas por meio da API UpdateJob do AWS Glue de maneira semelhante a CreateJob. Deve-se especificar o campo inteiro em UpdateJob quando o DAG tiver sido alterado conforme desejado. Um valor nulo fornecido será ignorado e nenhuma atualização para o DAG será executada. Uma estrutura ou string vazia fará com que CodeGenConfigurationNodes seja definido como vazio e qualquer DAG anterior seja removido. A API GetJob retornará um DAG, se houver. A API DeleteJob também excluirá qualquer DAG associado.

Conceitos básicos

Para criar um trabalho, use a ação CreateJob. A entrada da solicitação `CreateJob` terá um campo adicional “codeGenConfigurationNodes”, no qual é possível especificar o objeto DAG no JSON.

Tenha em mente que:

- O campo "codeGenConfigurationNodes" é um mapa de nodeId para o nó.
- Cada nó começa com uma chave que identifica o tipo do nó.
- Só pode haver uma chave especificada, pois um nó só pode ser de um tipo.
- O campo de entrada contém os nós pais do nó atual.

Veja a seguir uma representação de JSON de uma entrada CreateJob.

```
{
  "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"]
        }
      ]
    }
  }
}
```

Atualizar e receber trabalhos

Como UpdateJob também terá um campo “codeGenConfigurationNodes”, o formato de entrada será o mesmo. Consulte a ação UpdateJob.

A ação GetJob também retornará um campo “codeGenConfigurationNodes” no mesmo formato. Consulte a ação GetJob.

Limitações de trabalho visual

Como o parâmetro "codeGenConfigurationNodes" foi adicionado a APIs existentes, quaisquer limitações nessas APIs serão herdadas. Além disso, codeGenConfigurationNodes e alguns nós serão limitados em tamanho. Para mais informações, consulte Estrutura de trabalho.

Programar scripts de ETL

O AWS Glue facilita a gravação e a execução de scripts do Ray. Esta seção descreve os recursos compatíveis do Ray que estão disponíveis no AWS Glue para Ray. Programar scripts do Ray no Python.

Seu script personalizado deve ser compatível com a versão do Ray definida pelo campo `Runtime` na definição do trabalho. Para obter mais informações sobre o `Runtime` na API de trabalhos, consulte the section called “Tarefas”. Para obter mais informações sobre cada ambiente de runtime, consulte the section called “Ambientes de runtime do Ray compatíveis”.

Tópicos

- Tutorial: escrever um script de ETL no AWS Glue para Ray
- Usar o Ray Core e o Ray Data no AWS Glue para Ray
- Fornecer arquivos e bibliotecas do Python para trabalhos do Ray
- Conectar a dados em trabalhos do Ray

Tutorial: escrever um script de ETL no AWS Glue para Ray

O Ray permite escrever e escalar tarefas distribuídas de modo nativo no Python. O AWS Glue para Ray oferece ambientes do Ray sem servidor que você pode acessar tanto em trabalhos quanto em sessões interativas (as sessões interativas do Ray estão em versão prévia). O sistema de trabalhos do AWS Glue fornece uma maneira consistente de gerenciar e executar tarefas, segundo uma agenda, acionadas por um gatilho ou no console do AWS Glue.

A combinação dessas ferramentas do AWS Glue cria um poderoso conjunto de ferramentas que você pode usar para workloads de extração, transformação e carregamento (ETL), um caso de uso popular do AWS Glue. Neste tutorial, você aprenderá o básico sobre como desenvolver essa solução.

Também oferecemos compatibilidade com o uso do AWS Glue for Spark para suas workloads de ETL. Para obter um tutorial sobre escrever scripts do AWS Glue for Spark, consulte the section called "Tutorial: criar um script do Spark". Para obter mais informações sobre os mecanismos disponíveis, consulte the section called "AWS Glue para Spark e AWS Glue para Ray". O Ray é capaz de lidar com vários tipos diferentes de tarefas em análise, machine learning (ML) e desenvolvimento de aplicações.

Neste tutorial, você extrairá, transformará e carregará um conjunto de dados CSV hospedado no Amazon Simple Storage Service (Amazon S3). Você começará com o conjunto de dados de registro de viagens da Taxi and Limousine Commission (TLC) da cidade de Nova York, que está armazenado em um bucket público do Amazon S3. Para obter mais informações sobre esse conjunto de dados, consulte Dados abertos na AWS.

Você transformará os dados com transformações predefinidas que estão disponíveis na biblioteca Ray Data. Ray Data é uma biblioteca de preparação de conjuntos de dados projetada pela Ray e incluída por padrão nos ambientes do AWS Glue para Ray. Para obter mais informações sobre as bibliotecas incluídas por padrão, consulte the section called "Módulos fornecidos com trabalhos do Ray". Em seguida, você gravará os dados transformados em um bucket do Amazon S3 que você controla.

Pré-requisitos: para este tutorial, você precisará de uma conta da AWS com acesso ao AWS Glue e ao Amazon S3.

Etapa 1: criar um bucket no Amazon S3 para armazenar os dados de saída

será necessário um bucket do Amazon S3 que você controla para servir como coletor dos dados criados neste tutorial. Você pode criar esse bucket com o procedimento a seguir.

> **Note**
>
> Se quiser gravar os dados em um bucket existente que você controla, pode pular esta etapa. Anote *`yourBucketName`*, o nome do bucket existente, para usar em etapas posteriores.

Para criar um bucket para a saída do trabalho do Ray

- Crie um bucket seguindo as etapas em Criação de um bucket no Guia do usuário do Amazon S3.

- Ao escolher um nome de bucket, anote *yourBucketName*, que você vai referenciar em etapas posteriores.
- Para outras configurações, as configurações sugeridas fornecidas no console do Amazon S3 devem funcionar bem neste tutorial.

Por exemplo, a caixa de diálogo de criação do bucket pode ter essa aparência no console do Amazon S3.

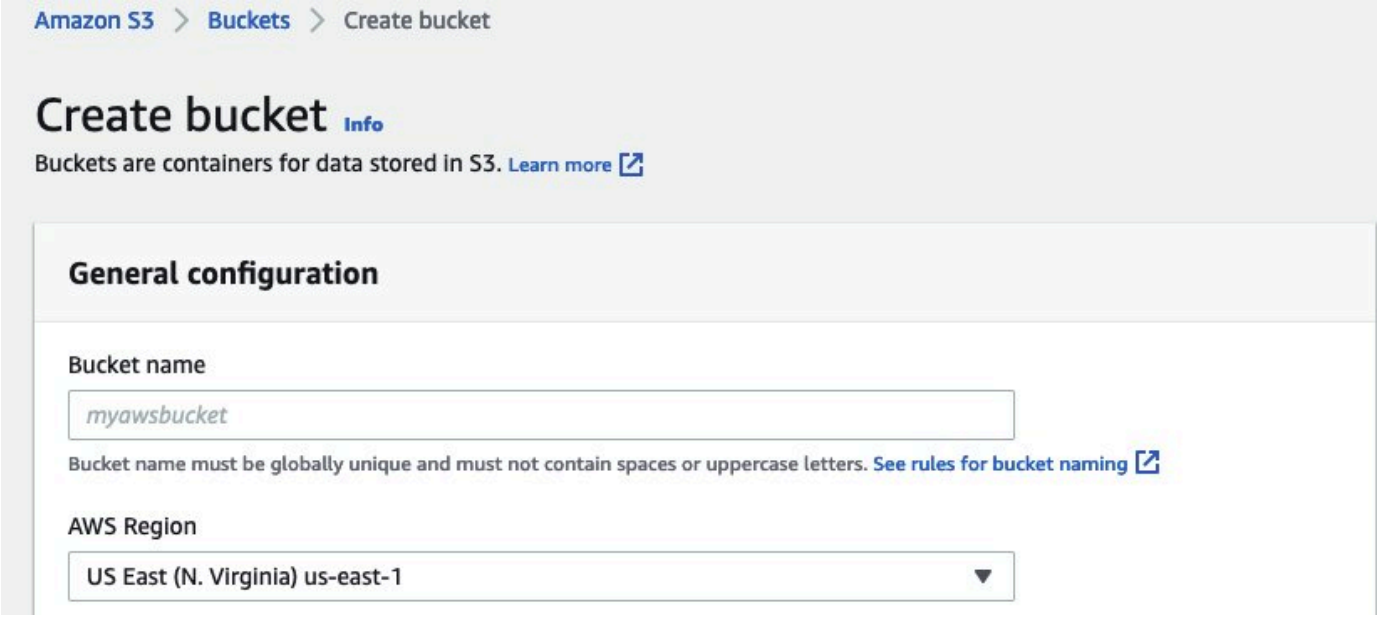

Etapa 2: criar uma política e um perfil do IAM para o trabalho do Ray

O trabalho precisará de um perfil do AWS Identity and Access Management (IAM) com o seguinte:

- Permissões concedidas pela política gerenciada pela `AWSGlueServiceRole`. Estas são as permissões básicas necessárias para executar um trabalho do AWS Glue.
- Permissões de nível de acesso de `Read` para o recurso `nyc-tlc/*` do Amazon S3.
- Permissões de nível de acesso de `Write` para o recurso *yourBucketName*`/*` do Amazon S3.
- Uma relação de confiança que permita que a entidade principal do `glue.amazonaws.com` assuma o perfil.

Você pode criar esse perfil com o procedimento a seguir.

Para criar um perfil do IAM para o trabalho do AWS Glue para Ray

> **Note**
>
> Você pode criar um perfil do IAM seguindo vários procedimentos diferentes. Para obter mais informações ou opções de como provisionar recursos do IAM, consulte a documentação do AWS Identity and Access Management.

1. Crie uma política que defina as permissões do Amazon S3 descritas anteriormente seguindo as etapas em Criar políticas do IAM (console) com o editor visual no Guia do usuário do IAM.
   - Ao selecionar um serviço, escolha Amazon S3.
   - Ao selecionar permissões para a política, anexe os seguintes conjuntos de ações para os seguintes recursos (mencionados anteriormente):
     - Permissões de nível de acesso de leitura para o recurso `nyc-tlc/*` do Amazon S3.
     - Permissões de nível de acesso de gravação para o recurso *`yourBucketName`*`/*` do Amazon S3.
   - Ao escolher um nome de bucket, anote *`YourPolicyName`*, que você vai referenciar uma etapa posterior.
2. Crie um perfil parra o trabalho do AWS Glue para Ray seguindo as etapas em Criar um perfil para um serviço da AWS (console) no Guia do usuário do IAM.
   - Ao selecionar uma entidade confiável de serviço da AWS, escolha `Glue`. Isso preencherá automaticamente a relação de confiança necessária para o trabalho.
   - Ao selecionar políticas para a política de permissões, anexe as seguintes políticas:
     - `AWSGlueServiceRole`
     - *`YourPolicyName`*
   - Ao selecionar um nome de perfil, anote *`YourRoleName`*, que você vai referenciar em etapas posteriores.

Etapa 3: criar e executar um trabalho do AWS Glue para Ray

Nesta etapa, você cria um trabalho do AWS Glue usando o AWS Management Console, fornece a ele um script de amostra e executa o trabalho. Quando você cria um trabalho, ele cria um local no

console para você armazenar, configurar e editar seu script do Ray. Para obter mais informações sobre como criar trabalhos, consulte the section called “Fazer login no console”.

Neste tutorial, abordamos o seguinte cenário de ETL: você deseja ler o conjunto de dados de registro de viagens de janeiro de 2022 da TLC da cidade de Nova York, adicionar uma nova coluna (`tip_rate`) ao conjunto de dados combinando os dados nas colunas existentes, depois remover várias colunas que não são relevantes para sua análise atual e depois deseja gravar os resultados no *`yourBucketName`*. O script Ray a seguir executa essas etapas:

```
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/")
```

Para criar e executar um trabalho do AWS Glue para Ray

1. No AWS Management Console, navegue até a página inicial do AWS Glue.
2. No painel de navegação lateral, escolha Trabalhos de ETL.
3. Em Criar trabalho, escolha Editor de scripts do Ray e depois Criar, como na ilustração a seguir.

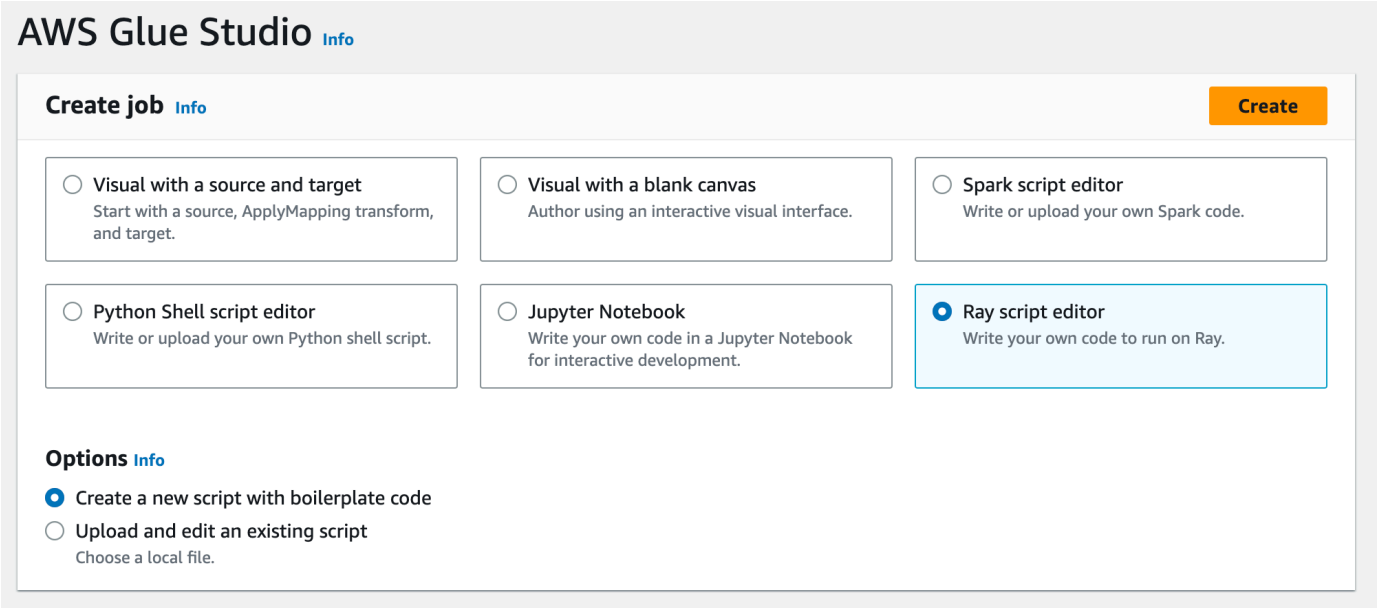

4. Cole o texto completo do script no painel Script e substitua qualquer texto existente.
5. Navegue até Detalhes do trabalho e defina a propriedade Perfil do IAM como *YourRoleName*.
6. Escolha Salvar e depois Executar.

Etapa 4: inspecionar a saída

Depois de executar o trabalho do AWS Glue, você deve validar se a saída corresponde às expectativas desse cenário. Para fazer isso, use o seguinte procedimento.

Para validar se o trabalho do Ray foi executado com êxito

1. Na página de detalhes do trabalho, navegue até Execuções.
2. Depois de alguns minutos, você verá uma execução com o Status de execução Bem-sucedida.
3. *Navegue até o console do Amazon S3 em https://console.aws.amazon.com/s3/ e inspecione yourBucketName*. Você deve ver os arquivos gravados no bucket de saída.
4. Leia os arquivos do Parquet e verifique seu conteúdo. Você pode fazer isso com as ferramentas existentes. Se você não tiver um processo para validar arquivos do Parquet, poderá fazer isso no console do AWS Glue com uma sessão interativa do AWS Glue, usando o Spark ou o Ray (em versão prévia).

   Em uma sessão interativa, você tem acesso às bibliotecas Ray Data, Spark ou pandas, que são fornecidas por padrão (com base no mecanismo de sua escolha). Para verificar o conteúdo do

arquivo, você pode usar métodos de inspeção comuns que estão disponíveis nessas bibliotecas, métodos como `count`, `schema` e `show`. Para obter mais informações sobre sessões interativas no console, consulte Using notebooks with AWS Glue Studio and AWS Glue.

Como você confirmou que os arquivos foram gravados no bucket, pode dizer com relativa certeza que, se a saída tiver problemas, eles não serão relacionados à configuração do IAM. Configure a sessão com *`yourRoleName`* para ter acesso aos arquivos relevantes.

Se você não encontrar os resultados esperados, examine o conteúdo de solução de problemas neste guia para identificar e corrigir a causa do erro. Para interpretar os estados de erro de execução do trabalho, consulte the section called “Status de execução de trabalho”. Você pode encontrar o conteúdo da solução de problemas no capítulo Solução de problemas de AWS Glue. Para erros específicos relacionados aos trabalhos do Ray, consulte the section called “Solucionar problemas de erros do Ray” no capítulo de solução de problemas.

Próximas etapas

Agora você viu e executou um processo de ETL usando o AWS Glue para Ray do início ao fim. Você pode usar os recursos a seguir para entender quais ferramentas o AWS Glue para Ray fornece para transformar e interpretar dados em grande escala.

- Para ter mais informações sobre o modelo de tarefa do Ray, consulte the section called “Usar o Ray Core e o Ray Data no AWS Glue para Ray”. Para ganhar mais experiência no uso de tarefas do Ray, siga os exemplos na documentação do Ray Core. Consulte Ray Core: Ray Tutorials and Examples (2.4.0) na documentação do Ray.
- Para obter orientação sobre as bibliotecas de gerenciamento de dados disponíveis no AWS Glue para Ray, consulte the section called “Conectar-se a dados”. Para obter mais experiência no uso do Ray Data para transformar e gravar conjuntos de dados, siga os exemplos na documentação do Ray Data. Consulte Ray Data: Examples (2.4.0).
- Para obter mais informações sobre configuração e gerenciamento de trabalhos do AWS Glue para Ray, consulte the section called “Trabalhar com trabalhos do Ray”.
- Para obter mais informações sobre escrever scripts do AWS Glue para Ray, continue lendo a documentação nesta seção.

Usar o Ray Core e o Ray Data no AWS Glue para Ray

O Ray é uma estrutura para aumentar verticalmente a escala de scripts do Python distribuindo o trabalho por um cluster. Você pode usar o Ray como uma solução para vários tipos de problemas, então o Ray fornece bibliotecas para otimizar determinadas tarefas. No AWS Glue, nos concentramos em usar o Ray para transformar grandes conjuntos de dados. O AWS Glue é compatível com o Ray Data e partes do Ray Core para facilitar essa tarefa.

O que é o Ray Core?

A primeira etapa da criação de uma aplicação distribuída é identificar e definir o trabalho que pode ser executado simultaneamente. O Ray Core contém as partes do Ray que você usa para definir tarefas que podem ser executadas simultaneamente. O Ray fornece informações de referência e de início rápido que você pode usar para aprender as ferramentas que eles fornecem. Para obter mais informações, consulte What is Ray Core? e Ray Core Quick Start. Para obter mais informações sobre a definição eficaz de tarefas simultâneas no Ray, consulte Tips for first-time users.

> **Tarefas e atores do Ray**
>
> Na documentação do AWS Glue para Ray, podemos nos referir a tarefas e atores, que são conceitos fundamentais do Ray.
>
> O Ray usa funções e classes do Python como peças de montagem de um sistema de computação distribuído. Como acontece quando as funções e as variáveis do Python se tornam "métodos" e "atributos" quando usadas em uma classe, as funções se tornam "tarefas" e as classes se tornam "atores" quando são usadas no Ray para enviar código aos operadores. Você pode identificar as funções e as classes que podem ser usadas pelo Ray por meio da anotação `@ray.remote`.
>
> As tarefas e os atores são configuráveis, têm um ciclo de vida e consomem recursos computacionais durante toda a sua existência. Um código que gera erros pode ser rastreado de volta a uma tarefa ou ator quando você descobre a causa raiz dos problemas. Assim, esses termos podem surgir quando você está aprendendo a configurar, monitorar ou depurar trabalhos do AWS Glue para Ray.
>
> Para começar a aprender como usar tarefas e atores de modo eficaz para criar uma aplicação distribuída, consulte Key Concepts na documentação do Ray.

Ray Core no AWS Glue para Ray

Os ambientes do AWS Glue para Ray gerenciam a formação e a escalação de clusters, bem como a coleta e a visualização de logs. Como gerenciamos essas preocupações, consequentemente limitamos o acesso e a compatibilidade com as APIs no Ray Core que seriam usadas para resolver essas preocupações em um cluster de código aberto.

No ambiente de runtime do `Ray2.4`, não oferecemos compatibilidade com:

- CLI do Ray Core
- CLI do Ray State
- Métodos de utilitários métricos do Prometheus `ray.util.metrics`:
  - Contador
  - Medidor
  - Histograma
- Outras ferramentas de depuração:
  - ray.util.pdb.set_trace
  - ray.util.inspect_serializability
  - ray.timeline

O que é o Ray Data?

Quando você está se conectando a fontes e destinos de dados, manipulando conjuntos de dados e iniciando transformações comuns, o Ray Data é uma metodologia simples de usar o Ray para resolver problemas de transformação de conjuntos de dados do Ray. Para obter mais informações sobre o uso do Ray Data, consulte Ray Datasets: Distributed Data Preprocessing.

Você pode usar o Ray Data ou outras ferramentas para acessar dados. Para obter mais informações sobre como acessar dados no Ray, consulte the section called “Conectar-se a dados”.

Ray Data no AWS Glue para Ray

O Ray Data é compatível e fornecido por padrão no ambiente de runtime gerenciado do `Ray2.4`. Para obter mais informações sobre os módulos fornecidos, consulte the section called “Módulos fornecidos com trabalhos do Ray”.

Fornecer arquivos e bibliotecas do Python para trabalhos do Ray

Esta seção fornece as informações de que você precisa para usar as bibliotecas do Python com trabalhos do AWS Glue Ray. Você pode usar determinadas bibliotecas comuns incluídas por padrão em todos os trabalhos do Ray. Você também pode fornecer suas próprias bibliotecas do Python para seu trabalho do Ray.

Módulos fornecidos com trabalhos do Ray

Você pode executar fluxos de trabalho de integração de dados em um trabalho do Ray com os seguintes pacotes fornecidos. Esses pacotes estão disponíveis por padrão nos trabalhos do Ray.

AWS Glue version 4.0

No AWS Glue versão 4.0, o ambiente do Ray (runtime do `Ray2.4`) fornece os seguintes pacotes:

- boto3 == 1.26.133
- ray == 2.4.0
- pyarrow == 11.0.0
- pandas== 1.5.3
- numpy == 1.24.3
- fsspec== 2023.4.0

Essa lista inclui todos os pacotes que seriam instalados com o `ray[data] == 2.4.0`. O Ray Data tem compatibilidade imediata.

Fornecer arquivos para o trabalho do Ray

Você pode fornecer arquivos para o trabalho do Ray com o parâmetro `--working-dir`. Forneça a esse parâmetro um caminho para um arquivo.zip hospedado no Amazon S3. Dentro arquivo.zip, os arquivos devem estar contidos em um único diretório de nível superior. Nenhum outro arquivo deve estar no nível superior.

Os arquivos serão distribuídos para cada nó do Ray antes que o script comece a ser executado. Considere como isso pode afetar o espaço em disco disponível para cada nó do Ray. O espaço em disco disponível é determinado pelo WorkerType definido na configuração do trabalho. Se você quiser fornecer os dados do trabalho em grande escala, esse mecanismo não é a solução certa.

Para obter mais informações sobre fornecimento de dados no trabalho, consulte the section called "Conectar-se a dados".

Os arquivos estarão acessíveis como se o diretório tivesse sido fornecido ao Ray por meio do parâmetro `working_dir`. Por exemplo, para ler um arquivo denominado `sample.txt` no diretório de nível superior do arquivo.zip, você pode chamar:

```
@ray.remote
def do_work():
    f = open("sample.txt", "r")
    print(f.read())
```

Para obter mais informações sobre o `working_dir`, consulte a documentação do Ray. Esse atributo se comporta de modo semelhante aos recursos nativos do Ray.

Módulos adicionais do Python para trabalhos do Ray

Módulos adicionais do PyPI

Os trabalhos do Ray usam o pacote de instalação do Python (pip3) para instalar módulos adicionais a serem usados por um script do Ray. Você pode usar o parâmetro `--pip-install` com uma lista de módulos do Python separados por vírgulas para adicionar um novo módulo ou alterar a versão de um módulo existente.

Por exemplo, para atualizar ou adicionar um novo módulo `scikit-learn`, use o seguinte par chave-valor:

```
"--pip-install", "scikit-learn==0.21.3"
```

Se você tiver módulos personalizados ou patches personalizados, poderá distribuir suas próprias bibliotecas do Amazon S3 com o parâmetro `--s3-py-modules`. Antes de carregar a distribuição, pode ser necessário reempacotá-la e recompilá-la. Siga as diretrizes em the section called "Incluir código do Python em trabalhos do Ray".

Distribuições personalizadas a partir do Amazon S3

As distribuições personalizadas devem seguir as diretrizes de empacotamento do Ray para dependências. Você pode descobrir como compilar essas distribuições na seção a seguir. Para obter mais informações sobre como o Ray configura dependências, consulte Environment Dependencies (Dependências de ambiente) na documentação do Ray.

Para incluir um distribuível personalizado após avaliar seu conteúdo, carregue o distribuível em um bucket disponível para o perfil do IAM do trabalho. Especifique o caminho do Amazon S3 para um arquivo zip do Python na configuração de parâmetros. Se você estiver fornecendo vários itens distribuíveis, separe-os por vírgulas. Por exemplo:

```
"--s3-py-modules", "s3://s3bucket/pythonPackage.zip"
```

Limitações

Os trabalhos do Ray não são compatíveis com a compilação de código nativo no ambiente de trabalho. Você poderá ser limitado por isso se as dependências do Python dependerem transitivamente do código nativo compilado. Os trabalhos do Ray podem executar os binários fornecidos, mas eles devem ser compilados para Linux no ARM64. Isso significa que você poderá usar o conteúdo as rodas `aarch64manylinux`. Você pode fornecer as dependências nativas em formato compilado reempacotando uma roda de acordo com os padrões do Ray. Normalmente, isso significa remover as pastas `dist-info` para que haja apenas uma pasta na raiz no arquivo compactado.

Você não pode atualizar a versão do `ray` ou do `ray[data]` usando esse parâmetro. Para usar uma nova versão do Ray, você precisará alterar o campo de runtime no trabalho, após lançarmos a compatibilidade com ele. Para obter mais informações sobre as versões compatíveis do Ray, consulte the section called “Versões do AWS Glue”.

Incluir código do Python em trabalhos do Ray

A Python Software Foundation oferece comportamentos padronizados para empacotar arquivos do Python para uso em diferentes runtimes. O Ray introduz limitações aos padrões de empacotamento que você deve conhecer. O AWS Glue não especifica padrões de empacotamento além dos especificados para o Ray. As instruções a seguir fornecem orientação padrão sobre o empacotamento de pacotes simples do Python.

Empacotar arquivos em um arquivo compactado `.zip`. Um diretório deve estar na raiz do raiz do arquivo compactado. Não deve haver outros arquivos no nível raiz do arquivo compactado, ou isso pode causar um comportamento inesperado. O diretório raiz é o pacote, e o nome dele é usado para se referir ao código do Python ao importá-lo.

Se fornecer um pacote nesse formato para um trabalho do Ray com `--s3-py-modules`, você poderá importar código do Python do pacote no script do Ray.

O pacote pode fornecer um único módulo do Python com alguns arquivos do Python, ou você pode empacotar vários módulos juntos. Ao reempacotar dependências, como bibliotecas do PyPI, verifique se há arquivos e diretórios de metadados ocultos dentro desses pacotes.

> **Warning**
>
> Certos comportamentos do sistema operacional dificultam o cumprimento adequado dessas instruções de empacotamento.
>
> - O OSX pode adicionar arquivos ocultos, como `__MACOSX` no arquivo zip no nível superior.
> - O Windows pode adicionar os arquivos em uma pasta dentro do zip automaticamente, criando involuntariamente uma pasta aninhada.

Os procedimentos a seguir pressupõem que você esteja interagindo com os arquivos no Amazon Linux 2 ou em um sistema operacional similar que forneça uma distribuição do Info-ZIP `zip` e dos utilitários `zipinfo`. Recomendamos o uso dessas ferramentas para evitar comportamentos inesperados.

Para empacotar arquivos do Python para uso no Ray

1. Crie um diretório temporário com o nome do pacote e confirme se o diretório de trabalho é o diretório principal. É possível fazer isso com os seguintes comandos:

   ```
   cd parent_directory
   mkdir temp_dir
   ```

2. Copie os arquivos no diretório temporário e confirme a estrutura de diretórios. O conteúdo desse diretório será acessado diretamente como seu módulo do Python. É possível fazer isso com o seguinte comando da :

   ```
   ls -AR temp_dir
   # my_file_1.py
   # my_file_2.py
   ```

3. Compacte a pasta temporária usando zip. É possível fazer isso com os seguintes comandos:

   ```
   zip -r zip_file.zip temp_dir
   ```

4. Confirme se o arquivo está devidamente empacotado. O *zip_file*.zip agora deve ser encontrado em seu diretório de trabalho. É possível inspecioná-lo com o seguinte comando:

```
zipinfo -1 zip_file.zip
# temp_dir/
# temp_dir/my_file_1.py
# temp_dir/my_file_2.py
```

Para reempacotar um pacote do Python para uso no Ray.

1. Crie um diretório temporário com o nome do pacote e confirme se o diretório de trabalho é o diretório principal. É possível fazer isso com os seguintes comandos:

```
cd parent_directory
mkdir temp_dir
```

2. Descompacte o pacote e copie seu conteúdo no diretório temporário. Remova arquivos relacionados ao padrão de empacotamento anterior, deixando somente o conteúdo do módulo. Confirme se a estrutura do arquivo está correta com o seguinte comando:

```
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. Compacte a pasta temporária usando zip. É possível fazer isso com os seguintes comandos:

```
zip -r zip_file.zip temp_dir
```

4. Confirme se o arquivo está devidamente empacotado. O *zip_file*.zip agora deve ser encontrado em seu diretório de trabalho. É possível inspecioná-lo com o seguinte comando:

```
zipinfo -1 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
```

Conectar a dados em trabalhos do Ray

Os trabalhos do Ray do AWS Glue podem usar uma ampla variedade de pacotes do Python criados para você integrar dados rapidamente. Fornecemos um conjunto mínimo de dependências para não encher demais seu ambiente. Para obter mais informações sobre o que está incluído por padrão, consulte the section called “Módulos fornecidos com trabalhos do Ray”.

> **Note**
>
> A extração, transformação e carregamento (ETL) do AWS Glue fornece a abstração DynamicFrame para otimizar fluxos de trabalho de ETL nos quais você resolve as diferenças de esquema entre as linhas do conjunto de dados. O ETL do AWS Glue ETL fornece recursos adicionais: marcadores de trabalhos e agrupamento de arquivos de entrada. No momento, não fornecemos recursos correspondentes em trabalhos do Ray.
> O AWS Glue para Spark permite a conexão direta com determinados formatos de dados, fontes e coletores. No Ray, o SDK da AWS para bibliotecas pandas e bibliotecas atuais de terceiros atendem substancialmente a essa necessidade. Você precisará consultar essas bibliotecas para entender quais recursos estão disponíveis.

A integração do AWS Glue para Ray com a Amazon VPC não está disponível no momento.
Os recursos da Amazon VPC não estarão acessíveis sem uma rota pública. Para obter mais informações sobre o uso do AWS Glue com a Amazon VPC, consulte the section called “Configurar VPC endpoints de interface (AWS PrivateLink) para AWS Glue ”.

Bibliotecas comuns para trabalhar com dados no Ray

Ray Data, o Ray Data fornece métodos para lidar com formatos, fontes e coletores de dados comuns. Para obter mais informações sobre formatos e fontes compatíveis com o Ray Data, consulte Entrada/saída na documentação do Ray Data. O Ray Data é uma biblioteca opinativa, não uma biblioteca de uso geral, para lidar com conjuntos de dados.

O Ray fornece algumas orientações sobre casos de uso em que o Ray Data pode ser a melhor solução para seu trabalho. Para obter mais informações, consulte Casos de uso do Ray na documentação do Ray.

AWS SDK for pandas (awswrangler): o AWS SDK for pandas é um produto da AWS que oferece soluções limpas e testadas para leitura e gravação em serviços da AWS quando as transformações gerenciam dados com DataFrames pandas. Para obter mais informações sobre formatos e fontes compatíveis no AWS SDK for pandas, consulte a API Reference na documentação do AWS SDK para pandas.

Para obter exemplos de como ler e gravar dados com o AWS SDK for pandas, consulte Quick Start na documentação do AWS SDK for pandas. O AWS SDK for pandas não fornece transformações para seus dados. Ele só é compatível com leitura e gravação a partir de fontes.

Modin: Modin é uma biblioteca do Python que implementa operações comuns do pandas de uma forma distributível. Para obter mais informações sobre o Modin, consulte a documentação do Modin. O próprio Modin não é compatível com leitura e gravação a partir de fontes. Ele fornece implementações distribuídas de transformações comuns. O Modin é compatível com o AWS SDK for pandas.

Ao executar o Modin e o AWS SDK for pandas juntos em um ambiente do Ray, você pode realizar tarefas comuns de ETL com resultados de alta performance. Para obter mais informações sobre como usar o Modin com o AWS SDK para pandas, consulte At scale no AWS SDK for pandas.

Outras estruturas: para obter mais informações sobre estruturas compatíveis com o Ray, consulte O ecossistema do Ray na documentação do Ray. Não há compatibilidade com outras estruturas no AWS Glue para Ray.

Conectar-se a dados por meio do catálogo de dados

O gerenciamento dados por meio do catálogo de dados em conjunto com os trabalhos do Ray é compatível com SDK da AWSpara pandas. Para obter mais informações, consulte Glue Catalog no site do AWS SDK for pandas.

Usar este serviço com um AWS SDK

Os kits de desenvolvimento de software (SDKs) da AWS estão disponíveis para muitas linguagens de programação populares. Cada SDK fornece uma API, exemplos de código e documentação que permitem que os desenvolvedores criem facilmente aplicações em seu idioma de preferência.

Documentação do SDK	Exemplos de código
AWS SDK para C++	Exemplos de código do AWS SDK para C++
AWS CLI	Exemplos de código do AWS CLI
AWS SDK para Go	Exemplos de código do AWS SDK para Go
AWS SDK para Java	Exemplos de código do AWS SDK para Java
AWS SDK para JavaScript	Exemplos de código do AWS SDK para JavaScript
AWS SDK para Kotlin	Exemplos de código do AWS SDK para Kotlin
AWS SDK para .NET	Exemplos de código do AWS SDK para .NET
AWS SDK para PHP	Exemplos de código do AWS SDK para PHP
Ferramentas da AWS para PowerShell	Exemplos de código do Ferramentas da AWS para PowerShell
AWS SDK para Python (Boto3)	Exemplos de código do AWS SDK para Python (Boto3)
AWS SDK para Ruby	Exemplos de código do AWS SDK para Ruby
AWS SDK para Rust	Exemplos de código do AWS SDK para Rust
SDK da AWS para SAP ABAP	Exemplos de código do SDK da AWS para SAP ABAP
AWS SDK for Swift	Exemplos de código do AWS SDK for Swift

Para obter exemplos específicos deste serviço, consulte Exemplos de código de API do AWS Glue usando os AWS SDKs.

> **Exemplo de disponibilidade**
>
> Não consegue encontrar o que precisa? Solicite um exemplo de código usando o link Fornecer feedback na parte inferior desta página.

API AWS Glue

Esta seção descreve os tipos de dados e primitivos usados por SDKs e ferramentas do AWS Glue. Existem três maneiras gerais de interagir com o AWS Glue de modo programático fora do AWS Management Console, cada uma delas com sua própria documentação:

- As bibliotecas de SDKs de linguagens permitem que você acesse recursos do AWS nas linguagens de programação comuns. Encontre mais informações em Ferramentas para criar na AWS.
- O AWS CLI permite que você acesse recursos do AWS usando a linha de comando. Encontre mais informações em Referência de comandos da AWS CLI.
- O AWS CloudFormation permite que você defina um conjunto de recursos da AWS para serem provisionados juntos de forma consistente. Encontre mais informações em AWS CloudFormation: referência de tipo de recurso da AWS Glue.

Esta seção documenta os primitivos compartilhados independentemente desses SDKs e ferramentas. As ferramentas usam a Referência de API da Web do AWS Glue para se comunicar com o AWS.

Sumário

- APIs de segurança no AWS Glue
  - Tipos de dados
  - Estrutura DataCatalogEncryptionSettings
  - Estrutura EncryptionAtRest
  - Estrutura ConnectionPasswordEncryption
  - Estrutura EncryptionConfiguration
  - Estrutura S3Encryption
  - Estrutura CloudWatchEncryption
  - Estrutura JobBookmarksEncryption
  - Estrutura SecurityConfiguration
  - Estrutura GluePolicy
  - Estrutura DataQualityEncryption
  - Operações

- Ação GetDataCatalogEncryptionSettings (Python: get_data_catalog_encryption_settings)
- Ação PutDataCatalogEncryptionSettings (Python: put_data_catalog_encryption_settings)
- Ação PutResourcePolicy (Python: put_resource_policy)
- Ação GetResourcePolicy (Python: get_resource_policy)
- Ação DeleteResourcePolicy (Python: delete_resource_policy)
- Ação CreateSecurityConfiguration (Python: create_security_configuration)
- Ação DeleteSecurityConfiguration (Python: delete_security_configuration)
- Ação GetSecurityConfiguration (Python: get_security_configuration)
- Ação GetSecurityConfigurations (Python: get_security_configurations)
- Ação GetResourcePolicies (Python: get_resource_policies)
- API Catalogar objetos
  - API de catálogos
    - Tipos de dados
    - Estrutura do catálogo
    - Estrutura CatalogInput
    - Estrutura TargetRedshiftCatalog
    - Estrutura CatalogPropriedades
    - Estrutura CatalogPropertiesOutput
    - Estrutura DataLakeAccessProperties
    - Estrutura DataLakeAccessPropertiesOutput
    - Estrutura FederatedCatalog
    - Operações
    - Ação CreateCatalog (Python: create_catalog)
    - Ação UpdateCatalog (Python: update_catalog)
    - Ação DeleteCatalog (Python: delete_catalog)
    - Ação GetCatalog (Python: get_catalog)
    - Ação GetCatalogs (Python: get_catalogs)
  - API de banco de dados
    - Tipos de dados
    - Estrutura Database

- Estrutura DatabaseInput
- Estrutura PrincipalPermissions
- Estrutura DataLakePrincipal
- Estrutura DatabaseIdentifier
- Estrutura FederatedDatabase
- Operações
- Ação CreateDatabase (Python: create_database)
- Ação UpdateDatabase (Python: update_database)
- Ação DeleteDatabase (Python: delete_database)
- Ação GetDatabase (Python: get_database)
- Ação GetDatabases (Python: get_databases)

- API de tabela
  - Tipos de dados
  - Estrutura Table
  - Estrutura TableInput
  - Estrutura FederatedTable
  - Estrutura da coluna
  - Estrutura StorageDescriptor
  - Estrutura SchemaReference
  - Estrutura SerDeInfo
  - Estrutura Order
  - Estrutura SkewedInfo
  - Estrutura TableVersion
  - Estrutura TableError
  - Estrutura TableVersionError
  - Estrutura SortCriterion
  - Estrutura TableIdentifier
  - Estrutura KeySchemaElement
  - Estrutura PartitionIndex
  - Estrutura PartitionIndexDescriptor

- Estrutura BackfillError
- Estrutura IcebergInput
- Estrutura OpenTableFormatInput
- Estrutura ViewDefinition
- Estrutura ViewDefinitionInput
- Estrutura ViewRepresentation
- Estrutura ViewRepresentationInput
- Estrutura UpdateOpenTableFormatInput
- Estrutura UpdateIcebergInput
- Estrutura CreateIcebergTableInput
- Estrutura UpdateIcebergTableInput
- Estrutura IcebergSortOrder
- Estrutura IcebergSortField
- Estrutura IcebergPartitionSpec
- Estrutura IcebergPartitionField
- Estrutura IcebergSchema
- Estrutura IcebergStructField
- Estrutura IcebergTableUpdate
- Operações
- Ação CreateTable (Python: create_table)
- Ação UpdateTable (Python: update_table)
- Ação DeleteTable (Python: delete_table)
- Ação BatchDeleteTable (Python: batch_delete_table)
- Ação GetTable (Python: get_table)
- Ação GetTables (Python: get_tables)
- Ação GetTableVersion (Python: get_table_version)
- Ação GetTableVersions (Python: get_table_versions)
- Ação DeleteTableVersion (Python: delete_table_version)
- Ação BatchDeleteTableVersion (Python: batch_delete_table_version)
- Ação SearchTables (Python: search_tables)

- Ação GetPartitionIndexes (Python: get_partitions_indexes)
- Ação CreatePartitionIndex (Python: create_partition_index)
- Ação DeletePartitionIndex (Python: delete_partition_index)
- Ação GetColumnStatisticsForTable (Python: get_column_statistics_for_table)
- Ação UpdateColumnStatisticsForTable (Python: update_column_statistics_for_table)
- Ação DeleteColumnStatisticsForTable (Python: delete_column_statistics_for_table)

- API de partição
  - Tipos de dados
  - Estrutura Partition
  - Estrutura PartitionInput
  - Estrutura PartitionSpecWithSharedStorageDescriptor
  - Estrutura PartitionListComposingSpec
  - Estrutura PartitionSpecProxy
  - Estrutura PartitionValueList
  - Estrutura Segment
  - Estrutura PartitionError
  - Estrutura BatchUpdatePartitionFailureEntry
  - Estrutura BatchUpdatePartitionRequestEntry
  - Estrutura StorageDescriptor
  - Estrutura SchemaReference
  - Estrutura SerDeInfo
  - Estrutura SkewedInfo
  - Operações
  - Ação CreatePartition (Python: create_partition)
  - Ação BatchCreatePartition (Python: batch_create_partition)
  - Ação UpdatePartition (Python: update_partition)
  - Ação DeletePartition (Python: delete_partition)
  - Ação BatchDeletePartition (Python: batch_delete_partition)
  - Ação GetPartition (Python: get_partition)
  - Ação GetPartitions (Python: get_partitions)

- Ação BatchGetPartition (Python: batch_get_partition)
- Ação BatchUpdatePartition (Python: batch_update_partition)
- Ação GetColumnStatisticsForPartition (Python: get_column_statistics_for_partition)
- Ação UpdateColumnStatisticsForPartition (Python: update_column_statistics_for_partition)
- Ação DeleteColumnStatisticsForPartition (Python: delete_column_statistics_for_partition)

- API de conexões
  - API de conexão
    - Tipos de dados
    - Estrutura Connection
    - Estrutura ConnectionInput
    - Estrutura TestConnectionInput
    - Estrutura PhysicalConnectionRequirements
    - Estrutura GetConnectionsFilter
    - Estrutura AuthenticationConfiguration
    - Estrutura AuthenticationConfigurationInput
    - Estrutura OAuth2Properties
    - Estrutura OAuth2PropertiesInput
    - Estrutura OAuth2ClientApplication
    - Estrutura AuthorizationCodeProperties
    - Estrutura BasicAuthenticationCredentials
    - Estrutura OAuth2Credentials
    - Operações
    - Ação CreateConnection (Python: create_connection)
    - Ação DeleteConnection (Python: delete_connection)
    - Ação GetConnection (Python: get_connection)
    - Ação GetConnections (Python: get_connections)
    - Ação UpdateConnection (Python: update_connection)
    - Ação TestConnection (Python: test_connection)
    - Ação BatchDeleteConnection (Python: batch_delete_connection)
  - API de tipos de conexão

        - APIs de gerenciamento de conexões
        - Ação DescribeConnectionType (Python: describe_connection_type)
        - Ação ListConnectionTypes (Python: list_connection_types)
        - Estrutura ConnectionTypeBrief
        - Estrutura de ConnectionTypeVariant
        - datatypes
        - Estrutura Validation
        - Estrutura AuthConfiguration
        - Estrutura de capacidades
        - Estrutura Property
        - Estrutura AllowedValue
        - Estrutura ComputeEnvironmentConfiguration
    - Metadados de conexão e API de visualização
        - Tipos de dados
        - Estrutura Entity
        - Estrutura Field
        - Operações
        - Ação ListEntities (Python: list_entities)
        - Ação DescribeEntity (Python: describe_entity)
        - Ação GetEntityRecords (Python: get_entity_records)
- API User-defined Function
    - Tipos de dados
    - Estrutura UserDefinedFunction
    - Estrutura UserDefinedFunctionInput
    - Operações
    - Ação CreateUserDefinedFunction (Python: create_user_defined_function)
    - Ação UpdateUserDefinedFunction (Python: update_user_defined_function)
    - Ação DeleteUserDefinedFunction (Python: delete_user_defined_function)
    - Ação GetUserDefinedFunction (Python: get_user_defined_function)
    - Ação GetUserDefinedFunctions (Python: get_user_defined_functions)

- Importar um catálogo do Athena para AWS Glue
  - Tipos de dados
  - Estrutura CatalogImportStatus
  - Operações
  - Ação ImportCatalogToGlue (Python: import_catalog_to_glue)
  - Ação GetCatalogImportStatus (Python: get_catalog_import_status)
- API do otimizador de tabelas
  - Tipos de dados
  - Estrutura do TableOptimizer
  - Estrutura do TableOptimizerConfiguration
  - Estrutura de TableOptimizerVpcConfiguration
  - Estrutura CompactionConfiguration
  - Estrutura IcebergCompactionConfiguration
  - Estrutura TableOptimizerRun
  - Estrutura BatchGetTableOptimizerEntry
  - Estrutura BatchTableTableOptimizer
  - Estrutura BatchGetTableOptimizerError
  - Estrutura RetentionConfiguration
  - Estrutura IcebergRetentionConfiguration
  - Estrutura OrphanFileDeletionConfiguration
  - Estrutura IcebergOrphanFileDeletionConfiguration
  - Estrutura CompactionMetrics
  - Estrutura RetentionMetrics
  - Estrutura OrphanFileDeletionMetrics
  - Estrutura IcebergCompactionMetrics
  - Estrutura IcebergRetentionMetrics
  - Estrutura IcebergOrphanFileDeletionMetrics
  - Estrutura RunMetrics
  - Operações
  - Ação GetTableOptimizer (Python: get_table_optimizer)

- Ação BatchGetTableOptimizer (Python: batch_get_table_optimizer)
- Ação ListTableOptimizerRuns (Python: list_table_optimizer_runs)
- Ação CreateTableOptimizer (Python: create_table_optimizer)
- Ação DeleteTableOptimizer (Python: delete_table_optimizer)
- Ação UpdateTableOptimizer (Python: update_table_optimizer)

- API de crawlers e classificadores
  - API do classificador
    - Tipos de dados
    - Estrutura Classifier
    - Estrutura GrokClassifier
    - Estrutura XMLClassifier
    - Estrutura JsonClassifier
    - Estrutura CsvClassifier
    - Estrutura CreateGrokClassifierRequest
    - Estrutura UpdateGrokClassifierRequest
    - Estrutura CreateXMLClassifierRequest
    - Estrutura UpdateXMLClassifierRequest
    - Estrutura CreateJsonClassifierRequest
    - Estrutura UpdateJsonClassifierRequest
    - Estrutura CreateCsvClassifierRequest
    - Estrutura UpdateCsvClassifierRequest
    - Operações
    - Ação CreateClassifier (Python: create_classifier)
    - Ação DeleteClassifier (Python: delete_classifier)
    - Ação GetClassifier (Python: get_classifier)
    - Ação GetClassifiers (Python: get_classifiers)
    - Ação UpdateClassifier (Python: update_classifier)
  - API do crawler
    - Tipos de dados
    - Estrutura Crawler

- Estrutura Schedule
- Estrutura CrawlerTargets
- Estrutura S3Target
- Estrutura S3DeltaCatalogTarget
- Estrutura S3DeltaDirectTarget
- Estrutura JdbcTarget
- Estrutura MongoDBTarget
- Estrutura DynamoDBTarget
- Estrutura DeltaTarget
- Estrutura do IcebergTarget
- Estrutura HudiTarget
- Estrutura CatalogTarget
- Estrutura CrawlerMetrics
- Estrutura de CrawlerHistory
- Estrutura de CrawlsFilter
- Estrutura SchemaChangePolicy
- Estrutura LastCrawlInfo
- Estrutura RecrawlPolicy
- Estrutura LineageConfiguration
- Estrutura LakeFormationConfiguration
- Operações
- Ação CreateCrawler (Python: create_crawler)
- Ação DeleteCrawler (Python: delete_crawler)
- Ação GetCrawler (Python: get_crawler)
- Ação GetCrawlers (Python: get_crawlers)
- Ação GetCrawlerMetrics (Python: get_crawler_metrics)
- Ação UpdateCrawler (Python: update_crawler)
- Ação StartCrawler (Python: start_crawler)
- Ação StopCrawler (Python: stop_crawler)
- Ação BatchGetCrawlers (Python: batch_get_crawlers)

- Ação ListCrawlers (Python: list_crawlers)
- Ação ListCrawls (Python: list_crawls)

- API de estatísticas de colunas
  - Tipos de dados
  - Estrutura ColumnStatisticsTaskRun
  - Estrutura ColumnStatisticsTaskSettings
  - Estrutura ExecutionAttempt
  - Operações
  - Ação StartColumnStatisticsTaskRun (Python: start_column_statistics_task_run)
  - Ação GetColumnStatisticsTaskRun (Python: get_column_statistics_task_run)
  - Ação GetColumnStatisticsTaskRuns (Python: get_column_statistics_task_runs)
  - Ação ListColumnStatisticsTaskRuns (Python: list_column_statistics_task_runs)
  - Ação StopColumnStatisticsTaskRun (Python: stop_column_statistics_task_run)
  - Ação CreateColumnStatisticsTaskSettings (Python: create_column_statistics_task_settings)
  - Ação UpdateColumnStatisticsTaskSettings (Python: update_column_statistics_task_settings)
  - Ação GetColumnStatisticsTaskSettings (Python: get_column_statistics_task_settings)
  - Ação DeleteColumnStatisticsTaskSettings (Python: delete_column_statistics_task_settings)
  - Ação StartColumnStatisticsTaskRunSchedule (Python: start_column_statistics_task_run_schedule)
  - Ação StopColumnStatisticsTaskRunSchedule (Python: stop_column_statistics_task_run_schedule)
  - Exceções
  - Estrutura ColumnStatisticsTaskRunningException
  - Estrutura ColumnStatisticsTaskNotRunningException
  - Estrutura ColumnStatisticsTaskStoppingException
  - Estrutura ColumnStatisticsTaskAutoConcurrencyLimitException
  - Estrutura InvalidCatalogSettingException

- API do programador do crawler
  - Tipos de dados
  - Estrutura Schedule
  - Operações

    - Ação UpdateCrawlerSchedule (Python: update_crawler_schedule)
    - Ação StartCrawlerSchedule (Python: start_crawler_schedule)
    - Ação StopCrawlerSchedule (Python: stop_crawler_schedule)
- API de scripts de ETL de geração automática
    - Tipos de dados
    - Estrutura CodeGenNode
    - Estrutura CodeGenNodeArg
    - Estrutura CodeGenEdge
    - Estrutura Location
    - Estrutura CatalogEntry
    - Estrutura MappingEntry
    - Operações
    - Ação CreateScript (Python: create_script)
    - Ação GetDataflowGraph (Python: get_dataflow_graph)
    - Ação GetMapping (Python: get_mapping)
    - Ação GetPlan (Python: get_plan)
- API de trabalhos visuais
    - Tipos de dados
    - Estrutura CodeGenConfigurationNode
    - Estrutura JDBCConnectorOptions
    - Estrutura StreamingDataPreviewOptions
    - Estrutura AthenaConnectorSource
    - Estrutura JDBCConnectorSource
    - Estrutura SparkConnectorSource
    - Estrutura CatalogSource
    - Estrutura MySQLCatalogSource
    - Estrutura PostgreSQLCatalogSource
    - Estrutura OracleSQLCatalogSource
    - Estrutura MicrosoftSQLServerCatalogSource
    - Estrutura CatalogKinesisSource

- Estrutura DirectKinesisSource
- Estrutura KinesisStreamingSourceOptions
- Estrutura CatalogKafkaSource
- Estrutura DirectKafkaSource
- Estrutura KafkaStreamingSourceOptions
- Estrutura RedshiftSource
- Estrutura AmazonRedshiftSource
- Estrutura AmazonRedshiftNodeData
- Estrutura AmazonRedshiftAdvancedOption
- Estrutura Option
- Estrutura S3CatalogSource
- Estrutura S3SourceAdditionalOptions
- Estrutura S3CsvSource
- Estrutura DirectJDBCSource
- Estrutura S3DirectSourceAdditionalOptions
- Estrutura S3JsonSource
- Estrutura S3ParquetSource
- Estrutura S3DeltaSource
- Estrutura S3CatalogDeltaSource
- Estrutura CatalogDeltaSource
- Estrutura S3HudiSource
- Estrutura S3CatalogHudiSource
- Estrutura de S3ExcelSource
- Estrutura CatalogHudiSource
- Estrutura DynamoDBCatalogSource
- Estrutura RelationalCatalogSource
- Estrutura JDBCConnectorTarget
- Estrutura SparkConnectorTarget
- Estrutura BasicCatalogTarget
- Estrutura MySQLCatalogTarget

- Estrutura PostgreSQLCatalogTarget
- Estrutura OracleSQLCatalogTarget
- Estrutura MicrosoftSQLServerCatalogTarget
- Estrutura RedshiftTarget
- Estrutura AmazonRedshiftTarget
- Estrutura UpsertRedshiftTargetOptions
- Estrutura S3CatalogTarget
- Estrutura S3GlueParquetTarget
- Estrutura CatalogSchemaChangePolicy
- Estrutura S3DirectTarget
- Estrutura S3HudiCatalogTarget
- Estrutura S3HudiDirectTarget
- Estrutura S3DeltaCatalogTarget
- Estrutura S3DeltaDirectTarget
- Estrutura de S3HyperDirectTarget
- Estrutura de S3IcebergDirectTarget
- Estrutura DirectSchemaChangePolicy
- Estrutura ApplyMapping
- Estrutura Mapping
- Estrutura SelectFields
- Estrutura DropFields
- Estrutura RenameField
- Estrutura Spigot
- Estrutura Join
- Estrutura JoinColumn
- Estrutura SplitFields
- Estrutura SelectFromCollection
- Estrutura FillMissingValues
- Estrutura Filter
- Estrutura FilterExpression

- Estrutura FilterValue
- Estrutura CustomCode
- Estrutura SparkSQL
- Estrutura SqlAlias
- Estrutura DropNullFields
- Estrutura NullCheckBoxList
- Estrutura NullValueField
- Estrutura Datatype
- Estrutura Merge
- Estrutura Union
- Estrutura PIIDetection
- Estrutura Aggregate
- Estrutura DropDuplicates
- Estrutura GovernedCatalogTarget
- Estrutura GovernedCatalogSource
- Estrutura AggregateOperation
- Estrutura GlueSchema
- Estrutura GlueStudioSchemaColumn
- Estrutura GlueStudioColumn
- Estrutura DynamicTransform
- Estrutura TransformConfigParameter
- Estrutura EvaluateDataQuality
- Estrutura DQResultsPublishingOptions
- Estrutura DQStopJobOnFailureOptions
- Estrutura EvaluateDataQualityMultiFrame
- Estrutura da fórmula
- Estrutura SchemaReference
- Estrutura SnowflakeNodeData
- Estrutura SnowflakeSource
- Estrutura SnowflakeTarget

- Estrutura ConnectorDataSource
- Estrutura ConnectorDataTarget
- Estrutura RecipeStep
- Estrutura RecipeAction
- Estrutura ConditionExpression

- API de trabalhos
  - Tarefas
    - Tipos de dados
    - Estrutura Job
    - Estrutura ExecutionProperty
    - Estrutura NotificationProperty
    - Estrutura JobCommand
    - Estrutura ConnectionsList
    - Estrutura JobUpdate
    - Estrutura SourceControlDetails
    - Operações
    - Ação CreateJob (Python: create_job)
    - Ação UpdateJob (Python: update_job)
    - Ação GetJob (Python: get_job)
    - Ação GetJobs (Python: get_jobs)
    - Ação DeleteJob (Python: delete_job)
    - Ação ListJobs (Python: list_jobs)
    - Ação BatchGetJobs (Python: batch_get_jobs)
  - Execuções de trabalhos
    - Tipos de dados
    - Estrutura JobRun
    - Estrutura Predecessor
    - Estrutura JobBookmarkEntry
    - Estrutura BatchStopJobRunSuccessfulSubmission
    - Estrutura BatchStopJobRunError

    - Estrutura NotificationProperty
    - Operações
    - Ação StartJobRun (Python: start_job_run)
    - Ação BatchStopJobRun (Python: batch_stop_job_run)
    - Ação GetJobRun (Python: get_job_run)
    - Ação GetJobRuns (Python: get_job_runs)
    - Ação GetJobBookmark (Python: get_job_bookmark)
    - Ação GetJobBookmarks (Python: get_job_bookmarks)
    - Ação ResetJobBookmark (Python: reset_job_bookmark)
- Acionadores
    - Tipos de dados
    - Estrutura de acionador
    - Estrutura TriggerUpdate
    - Estrutura Predicate
    - Estrutura Condition
    - Estrutura Action
    - Estrutura EventBatchingCondition
    - Operações
    - Ação CreateTrigger (Python: create_trigger)
    - Ação StartTrigger (Python: start_trigger)
    - Ação GetTrigger (Python: get_trigger)
    - Ação GetTriggers (Python: get_triggers)
    - Ação UpdateTrigger (Python: update_trigger)
    - Ação StopTrigger (Python: stop_trigger)
    - Ação DeleteTrigger (Python: delete_trigger)
    - Ação ListTriggers (Python: list_triggers)
    - Ação BatchGetTriggers (Python: batch_get_triggers)
- APIs de integração no AWS Glue
- Tipos de dados
    - Estrutura da integração

- Estrutura de IntegrationConfig
- Estrutura IntegrationPartition
- Estrutura IntegrationError
- Estrutura IntegrationFilter
- Estrutura InboundIntegration
- Estrutura SourceProcessingProperties
- Estrutura TargetProcessingProperties
- Estrutura SourceTableConfig
- Estrutura TargetTableConfig
- Operações
- Ação CreateIntegration action (Python: create_integration)
- Ação ModifyIntegration (Python: modify_integration)
- Ação DescribeIntegrations (Python: describe_integrations)
- Ação DeleteIntegration (Python: delete_integration)
- Ação DescribeInboundIntegrations (Python: describe_inbound_integrations)
- Ação CreateIntegrationTableProperties (Python: create_integration_table_properties)
- Ação UpdateIntegrationTableProperties (Python: update_integration_table_properties)
- Ação GetIntegrationTableProperties (Python: get_integration_table_properties)
- Ação DeleteIntegrationTableProperties (Python: delete_integration_table_properties)
- Ação CreateIntegrationResourceProperty (Python: create_integration_resource_property)
- Ação UpdateIntegrationResourceProperty (Python: update_integration_resource_property)
- Ação GetIntegrationResourceProperty (Python: get_integration_resource_property)
- Ação UntagResource (Python: untag_resource)
- Ação ListTagsForResource (Python: list_tags_for_resource)
- Exceções
- Estrutura ResourceNotFoundException
- Estrutura InternalServiceException
- Estrutura IntegrationAlreadyExistsFault
- Estrutura IntegrationConflictOperationFault
- Estrutura IntegrationQuotaExceededFault

- Estrutura KMSKeyNotAccessibleFault
- Estrutura IntegrationNotFoundFault
- Estrutura TargetResourceNotFound
- Estrutura InvalidIntegrationStateFault

- Sessões API interativas
  - Tipos de dados
  - Estrutura Session
  - Estrutura SessionCommand
  - Estrutura Statement
  - Estrutura StatementOutput
  - Estrutura StatementOutputData
  - Estrutura ConnectionsList
  - Operações
  - Ação CreateSession (Python: create_session)
  - Ação StopSession (Python: stop_session)
  - Ação DeleteSession (Python: delete_session)
  - Ação GetSession (Python: get_session)
  - Ação ListSessions (Python: list_sessions)
  - Ação RunStatement (Python: run_statement)
  - Ação CancelStatement (Python: cancel_statement)
  - Ação GetStatement (Python: get_statement)
  - Ação ListStatations (Python: list_statements)
- API de endpoints de desenvolvimento
  - Tipos de dados
  - Estrutura DevEndpoint
  - Estrutura DevEndpointCustomLibraries
  - Operações
  - Ação CreateDevEndpoint (Python: create_dev_endpoint)
  - Ação UpdateDevEndpoint (Python: update_dev_endpoint)
  - Ação DeleteDevEndpoint (Python: delete_dev_endpoint)

- Ação GetDevEndpoint (Python: get_dev_endpoint)
- Ação GetDevEndpoints (Python: get_dev_endpoints)
- Ação BatchGetDevEndpoints (Python: batch_get_dev_endpoints)
- Ação ListDevEndpoints (Python: list_dev_endpoints)
- Registro de esquemas
  - Tipos de dados
  - Estrutura RegistryId
  - Estrutura RegistryListItem
  - Estrutura MetadataInfo
  - Estrutura OtherMetadataValueListItem
  - Estrutura SchemaListItem
  - Estrutura SchemaVersionListItem
  - Estrutura MetadataKeyValuePair
  - Estrutura SchemaVersionErrorItem
  - Estrutura ErrorDetails
  - Estrutura SchemaVersionNumber
  - Estrutura SchemaId
  - Operações
  - Ação CreateRegistry (Python: create_registry)
  - Ação CreateSchema (Python: create_esquema)
  - Ação GetSchema (Python: get_schema)
  - Ação ListSchemaVersions (Python: list_schema_versions)
  - Ação GetSchemaVersion (Python: get_schema_version)
  - Ação GetSchemaVersionsDiff (Python: get_schema_versions_diff)
  - Ação ListRegistries (Python: list_registries)
  - Ação ListSchemas (Python: list_schemas)
  - Ação RegisterSchemaVersion (Python: register_schema_version)
  - Ação UpdateSchema (Python: update_schema)
  - Ação CheckSchemaVersionValidity (Python: check_schema_version_validity)
  - Ação UpdateRegistry (Python: update_registry)

- Ação GetSchemaByDefinition (Python: get_schema_by_definition)
- Ação GetRegistry (Python: get_registry)
- Ação PutSchemaVersionMetadata (Python: put_schema_version_metadata)
- Ação QuerySchemaVersionMetadata (Python: query_schema_version_metadata)
- Ação RemoveSchemaVersionMetadata (Python: remove_schema_version_metadata)
- Ação DeleteRegistry (Python: delete_registry)
- Ação DeleteSchema (Python: delete_schema)
- Ação DeleteSchemaVersions (Python: delete_schema_versions)

- Fluxos de trabalho
  - Tipos de dados
  - Estrutura JobNodeDetails
  - Estrutura CrawlerNodeDetails
  - Estrutura TriggerNodeDetails
  - Estrutura Crawl
  - Estrutura Node
  - Estrutura Edge
  - Estrutura Workflow
  - Estrutura WorkflowGraph
  - Estrutura WorkflowRun
  - Estrutura WorkflowRunStatistics
  - Estrutura StartingEventBatchCondition
  - Estrutura Blueprint
  - Estrutura BlueprintDetails
  - Estrutura LastActiveDefinition
  - Estrutura BlueprintRun
  - Operações
  - Ação CreateWorkflow (Python: create_workflow)
  - Ação UpdateWorkflow (Python: update_workflow)
  - Ação DeleteWorkflow (Python: delete_workflow)
  - Ação GetWorkflow (Python: get_workflow)

- Ação ListWorkflows (Python: list_workflows)
- Ação BatchGetWorkflows (Python: batch_get_workflows)
- Ação GetWorkflowRun (Python: get_workflow_run)
- Ação GetWorkflowRuns (Python: get_workflow_runs)
- Ação GetWorkflowRunProperties (Python: get_workflow_run_properties)
- Ação PutWorkflowRunProperties (Python: put_workflow_run_properties)
- Ação CreateBlueprint (Python: create_blueprint)
- Ação UpdateBlueprint (Python: update_blueprint)
- Ação DeleteBlueprint (Python: delete_blueprint)
- Ação ListBlueprints (Python: list_blueprints)
- Ação BatchGetBlueprints (Python: batch_get_blueprints)
- Ação StartBlueprintRun (Python: start_blueprint_run)
- Ação GetBlueprintRun (Python: get_blueprint_run)
- Ação GetBlueprintRuns (Python: get_blueprint_runs)
- Ação StartWorkflowRun (Python: start_workflow_run)
- Ação StopWorkflowRun (Python: stop_workflow_run)
- Ação ResumeWorkflowRun (Python: resume_workflow_run)
- Perfis de uso
  - Tipos de dados
  - Estrutura ProfileConfiguration
  - Estrutura ConfigurationObject
  - Estrutura UsageProfileDefinition
  - Operações
  - Ação CreateUsageProfile (Python: create_usage_profile)
  - Ação GetUsageProfile (Python: get_usage_profile)
  - Ação UpdateUsageProfile (Python: update_usage_profile)
  - Ação DeleteUsageProfile (Python: delete_usage_profile)
  - Ação ListUsageProfiles (Python: list_usage_profiles)
- API de machine learning
  - Tipos de dados

- Estrutura TransformParameters
- Estrutura EvaluationMetrics
- Estrutura MLTransform
- Estrutura FindMatchesParameters
- Estrutura FindMatchesMetrics
- Estrutura ConfusionMatrix
- Estrutura GlueTable
- Estrutura TaskRun
- Estrutura TransformFilterCriteria
- Estrutura TransformSortCriteria
- Estrutura TaskRunFilterCriteria
- Estrutura TaskRunSortCriteria
- Estrutura TaskRunProperties
- Estrutura FindMatchesTaskRunProperties
- Estrutura ImportLabelsTaskRunProperties
- Estrutura ExportLabelsTaskRunProperties
- Estrutura LabelingSetGenerationTaskRunProperties
- Estrutura SchemaColumn
- Estrutura TransformEncryption
- Estrutura MLUserDataEncryption
- Estrutura ColumnImportance
- Operações
- Ação CreateMLTransform (Python: create_ml_transform)
- Ação UpdateMLTransform (Python: update_ml_transform)
- Ação DeleteMLTransform (Python: delete_ml_transform)
- Ação GetMLTransform (Python: get_ml_transform)
- Ação GetMLTransforms (Python: get_ml_transforms)
- Ação ListMLTransforms (Python: list_ml_transforms)
- Ação StartMLEvaluationTaskRun (Python: start_ml_evaluation_task_run)

- Ação StartMLLabelingSetGenerationTaskRun (Python: start_ml_labeling_set_generation_task_run)
- Ação GetMLTaskRun (Python: get_ml_task_run)
- Ação GetMLTaskRuns (Python: get_ml_task_runs)
- Ação CancelMLTaskRun (Python: cancel_ml_task_run)
- Ação StartExportLabelsTaskRun (Python: start_export_labels_task_run)
- Ação StartImportLabelsTaskRun (Python: start_import_labels_task_run)

- API Data Quality API
  - Tipos de dados
  - Estrutura DataSource
  - Estrutura DataQualityRulesetListDetails
  - Estrutura DataQualityTargetTable
  - Estrutura DataQualityRulesetEvaluationRunDescription
  - Estrutura DataQualityRulesetEvaluationRunFilter
  - Estrutura DataQualityEvaluationRunAdditionalRunOptions
  - Estrutura DataQualityRuleRecommendationRunDescription
  - Estrutura DataQualityRuleRecommendationRunFilter
  - Estrutura DataQualityResult
  - Estrutura DataQualityAnalyzerResult
  - Estrutura DataQualityObservation
  - Estrutura MetricBasedObservation
  - Estrutura DataQualityMetricValues
  - Estrutura DataQualityRuleResult
  - Estrutura DataQualityResultDescription
  - Estrutura DataQualityResultFilterCriteria
  - Estrutura DataQualityRulesetFilterCriteria
  - Estrutura DataQualityAggregatedMetrics
  - Estrutura StatisticAnotation
  - Estrutura TimestampedInclusionAnnotation
  - Estrutura AnnotationError

- Estrutura DatapointInclusionAnnotation
- Lista StatisticSummaryList
- Estrutura StatisticSummary
- Estrutura RunIdentifier
- Estrutura StatisticModelResult
- Operações
- Ação StartDataQualityRulesetEvaluationRun (Python: start_data_quality_ruleset_evaluation_run)
- Ação CancelDataQualityRulesetEvaluationRun (Python: cancel_data_quality_ruleset_evaluation_run)
- Ação GetDataQualityRulesetEvaluationRun (Python: get_data_quality_ruleset_evaluation_run)
- Ação ListDataQualityRulesetEvaluationRuns (Python: list_data_quality_ruleset_evaluation_runs)
- Ação StartDataQualityRuleRecommendationRun (Python: start_data_quality_rule_recommendation_run)
- Ação CancelDataQualityRuleRecommendationRun (Python: cancel_data_quality_rule_recommendation_run)
- Ação GetDataQualityRuleRecommendationRun (Python: get_data_quality_rule_recommendation_run)
- Ação ListDataQualityRuleRecommendationRuns (Python: list_data_quality_rule_recommendation_runs)
- Ação GetDataQualityResult (Python: get_data_quality_result)
- Ação BatchGetDataQualityResult (Python: batch_get_data_quality_result)
- Ação ListDataQualityResults (Python: list_data_quality_results)
- Ação CreateDataQualityRuleset (Python: create_data_quality_ruleset)
- Ação DeleteDataQualityRuleset (Python: delete_data_quality_ruleset)
- Ação GetDataQualityRuleset (Python: get_data_quality_ruleset)
- Ação ListDataQualityRulesets (Python: list_data_quality_rulesets)
- Ação UpdateDataQualityRuleset (Python: update_data_quality_ruleset)
- Ação ListDataQualityStatistics (Python: list_data_quality_statistics)
- Estrutura TimestampFilter
- Estrutura CreateDataQualityRulesetRequest
- Estrutura GetDataQualityRulesetResponse

- Estrutura GetDataQualityResultResponse
- Estrutura StartDataQualityRuleRecommendationRunRequest
- Estrutura GetDataQualityRuleRecommendationRunResponse
- Ação BatchPutDataQualityStatisticAnnotation (Python: batch_put_data_quality_statistic_annotation)
- Ação GetDataQualityModel (Python: get_data_quality_model)
- Ação GetDataQualityModelResult (Python: get_data_quality_model_result)
- Ação ListDataQualityStatisticAnnotations (Python: list_data_quality_statistic_annotations)
- Ação PutDataQualityProfileAnnotation (Python: put_data_quality_profile_annotation)
- API de detecção de dados sigilosos
  - Tipos de dados
  - Estrutura CustomEntityType
  - Operações
  - Ação CreateCustomEntityType (Python: create_custom_entity_type)
  - Ação DeleteCustomEntityType (Python: delete_custom_entity_type)
  - Ação GetCustomEntityType (Python: get_custom_entity_type)
  - Ação BatchGetCustomEntityTypes (Python: batch_get_custom_entity_types)
  - Ação ListCustomEntityTypes (Python: list_custom_entity_types)
- Marcação de APIs no AWS Glue
  - Tipos de dados
  - Estrutura Tag
  - Operações
  - Ação TagResource (Python: tag_resource)
  - Ação UntagResource (Python: untag_resource)
  - Ação GetTags (Python: get_tags)
- Tipos de dados comuns
  - Estrutura Tag
  - Estrutura DecimalNumber
  - Estrutura ErrorDetail
  - Estrutura PropertyPredicate

- Estrutura ResourceUri
- Estrutura ColumnStatistics
- Estrutura ColumnStatisticsError
- Estrutura ColumnError
- Estrutura ColumnStatisticsData
- Estrutura BooleanColumnStatisticsData
- Estrutura DateColumnStatisticsData
- Estrutura DecimalColumnStatisticsData
- Estrutura DoubleColumnStatisticsData
- Estrutura LongColumnStatisticsData
- Estrutura StringColumnStatisticsData
- Estrutura BinaryColumnStatisticsData
- Padrões de string

- Exceções
  - Estrutura AccessDeniedException
  - Estrutura AlreadyExistsException
  - Estrutura ConcurrentModificationException
  - Estrutura ConcurrentRunsExceededException
  - Estrutura CrawlerNotRunningException
  - Estrutura CrawlerRunningException
  - Estrutura CrawlerStoppingException
  - Estrutura EntityNotFoundException
  - Estrutura FederationSourceException
  - Estrutura FederationSourceRetryableException
  - Estrutura de GlueEncryptionException
  - Estrutura IdempotentParameterMismatchException
  - Estrutura IllegalWorkflowStateException
  - Estrutura InternalServiceException
  - Estrutura InvalidExecutionEngineException
  - Estrutura InvalidInputException

- Estrutura InvalidStateException
- Estrutura InvalidTaskStatusTransitionException
- Estrutura JobDefinitionErrorException
- Estrutura JobRunInTerminalStateException
- Estrutura JobRunInvalidStateTransitionException
- Estrutura JobRunNotInTerminalStateException
- Estrutura LateRunnerException
- Estrutura NoScheduleException
- Estrutura OperationTimeoutException
- Estrutura ResourceNotReadyException
- Estrutura ResourceNumberLimitExceededException
- Estrutura SchedulerNotRunningException
- Estrutura SchedulerRunningException
- Estrutura SchedulerTransitioningException
- Estrutura UnrecognizedRunnerException
- Estrutura ValidationException
- Estrutura VersionMismatchException

APIs de segurança no AWS Glue

A API de segurança descreve os tipos de dados de segurança e a API relacionada à segurança no AWS Glue.

Tipos de dados

- Estrutura DataCatalogEncryptionSettings
- Estrutura EncryptionAtRest
- Estrutura ConnectionPasswordEncryption
- Estrutura EncryptionConfiguration
- Estrutura S3Encryption
- Estrutura CloudWatchEncryption
- Estrutura JobBookmarksEncryption

- Estrutura SecurityConfiguration
- Estrutura GluePolicy
- Estrutura DataQualityEncryption

Estrutura DataCatalogEncryptionSettings

Contém informações de configuração para manter a segurança do Catálogo de dados.

Campos

- `EncryptionAtRest` – Um objeto EncryptionAtRest.

  Especifica a configuração de criptografia em repouso para o Catálogo de dados.
- `ConnectionPasswordEncryption` – Um objeto ConnectionPasswordEncryption.

  Quando a proteção por senha de conexão é habilitada, o Catálogo de dados usa uma chave fornecida pelo cliente para criptografar a senha como parte do `CreateConnection` ou `UpdateConnection` armazená-la no `ENCRYPTED_PASSWORD` campo nas propriedades da conexão. Você pode habilitar a criptografia de catálogo ou apenas a criptografia de senha.

Estrutura EncryptionAtRest

Especifica a configuração de criptografia em repouso para o Catálogo de dados.

Campos

- `CatalogEncryptionMode` – Obrigatório: string UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"` | `SSE-KMS-WITH-SERVICE-ROLE="SSEKMSWITHSERVICEROLE"`).

  O modo de criptografia em repouso para a configuração de dados do Catálogo de dados.
- `SseAwsKmsKeyId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da chave do AWS KMS a ser usada para a criptografia em repouso.
- `CatalogEncryptionServiceRole` – String UTF-8 correspondente a Custom string pattern #51.

  O perfil assumido pelo AWS Glue para criptografar e descriptografar os objetos do Catálogo de Dados em nome do chamador.

Estrutura ConnectionPasswordEncryption

A estrutura de dados usada pelo Catálogo de dados para criptografar a senha como parte do `CreateConnection` ou `UpdateConnection` e armazená-la no `ENCRYPTED_PASSWORD` campo nas propriedades da conexão. Você pode habilitar a criptografia de catálogo ou apenas a criptografia de senha.

Quando uma solicitação `CreationConnection` chega contendo uma senha, o Data Catalog primeiro criptografa a senha usando a sua chave do AWS KMS. Em seguida, criptografa todo o objeto de conexão novamente se a criptografia do catálogo também estiver habilitada.

Essa criptografia requer que as permissões de chave do AWS KMS sejam definidas para habilitar ou restringir o acesso à chave da senha de acordo com os seus requisitos de segurança. Por exemplo, você pode querer que apenas administradores tenham permissão para descriptografar a chave da senha.

Campos

- `ReturnConnectionPasswordEncrypted`: obrigatório: booleano.

  Quando o `ReturnConnectionPasswordEncrypted` sinalizador estiver definido como "verdadeiro", as senhas permanecem criptografadas nas respostas de `GetConnection` e `GetConnections`. Esta criptografia entra em vigor independentemente da criptografia de catálogo.

- `AwsKmsKeyId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Uma chave do AWS KMS usada para criptografar a senha de conexão.

  Se a proteção por senha da conexão estiver habilitada, o autor da chamada de `CreateConnection` e `UpdateConnection` precisará, pelo menos, da permissão `kms:Encrypt` na chave do AWS KMS especificada para criptografar as senhas antes de armazená-las no Data Catalog.

  Você pode definir a permissão de descriptografia para habilitar ou restringir o acesso à chave de senha, de acordo com os seus requisitos de segurança.

Estrutura EncryptionConfiguration

Especifica uma configuração de criptografia.

Campos

- `S3Encryption`: um array de objetos S3Encryption.

  A configuração da criptografia para os dados do Amazon Simple Storage Service (Amazon S3).
- `CloudWatchEncryption` – Um objeto CloudWatchEncryption.

  A configuração da criptografia para o Amazon CloudWatch.
- `JobBookmarksEncryption` – Um objeto JobBookmarksEncryption.

  A configuração da criptografia para marcadores de trabalho.
- `DataQualityEncryption` – Um objeto DataQualityEncryption.

  A configuração de criptografia para os ativos do AWS Glue Data Quality.

Estrutura S3Encryption

Especifica como os dados do Amazon Simple Storage Service (Amazon S3) devem ser criptografados.

Campos

- `S3EncryptionMode` – String UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"` | `SSE-S3="SSES3"`).

  O modo de criptografia a ser usado para dados do Amazon S3.
- `KmsKeyArn` – String UTF-8 correspondente a Custom string pattern #29.

  O nome de recurso da Amazon (ARN) da chave do KMS a ser usada para criptografar os dados.

Estrutura CloudWatchEncryption

Especifica como os dados do Amazon CloudWatch devem ser criptografados.

Campos

- `CloudWatchEncryptionMode`: string UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"`).

  O modo de criptografia a ser usado para dados do CloudWatch.

- `KmsKeyArn` – String UTF-8 correspondente a Custom string pattern #29.

  O nome de recurso da Amazon (ARN) da chave do KMS a ser usada para criptografar os dados.

Estrutura JobBookmarksEncryption

Especifica como os dados de marcadores de trabalho devem ser criptografados.

Campos

- `JobBookmarksEncryptionMode`: string UTF-8 (valores válidos: `DISABLED` | `CSE-KMS="CSEKMS"`).

  O modo de criptografia a ser usado para dados de marcadores de trabalho.

- `KmsKeyArn` – String UTF-8 correspondente a Custom string pattern #29.

  O nome de recurso da Amazon (ARN) da chave do KMS a ser usada para criptografar os dados.

Estrutura SecurityConfiguration

Especifica uma configuração de segurança.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança.

- `CreatedTimeStamp` – Timestamp.

  O momento em que esta configuração de segurança foi criada.

- `EncryptionConfiguration` – Um objeto EncryptionConfiguration.

A configuração de criptografia associada a essa configuração de segurança.

Estrutura GluePolicy

Uma estrutura para retornar uma política de recursos.

Campos

- `PolicyInJson` – String UTF-8, com pelo menos 2 bytes de comprimento.

  Contém o documento da política solicitada no formato JSON.
- `PolicyHash` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Contém o valor de hash associado a essa política.
- `CreateTime` – Timestamp.

  A data e hora em que a política foi criada.
- `UpdateTime` – Timestamp.

  A data e hora em que a política foi atualizada pela última vez.

Estrutura DataQualityEncryption

Especifica como os ativos do Data Quality em sua conta devem ser criptografados.

Campos

- `DataQualityEncryptionMode`: string UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"`).

  O modo de criptografia a ser usado para a criptografia dos ativos do Data Quality. Esses ativos incluem conjuntos de regras de qualidade de dados, resultados, estatísticas, modelos de detecção de anomalias e observações.

  Os valores válidos são `SSEKMS`, para a criptografia com uma chave do KMS gerenciada pelo cliente, ou `DISABLED`.
- `KmsKeyArn` – String UTF-8 correspondente a Custom string pattern #29.

O nome de recurso da Amazon (ARN) da chave do KMS a ser usada para criptografar os dados.

Operações

- Ação GetDataCatalogEncryptionSettings (Python: get_data_catalog_encryption_settings)
- Ação PutDataCatalogEncryptionSettings (Python: put_data_catalog_encryption_settings)
- Ação PutResourcePolicy (Python: put_resource_policy)
- Ação GetResourcePolicy (Python: get_resource_policy)
- Ação DeleteResourcePolicy (Python: delete_resource_policy)
- Ação CreateSecurityConfiguration (Python: create_security_configuration)
- Ação DeleteSecurityConfiguration (Python: delete_security_configuration)
- Ação GetSecurityConfiguration (Python: get_security_configuration)
- Ação GetSecurityConfigurations (Python: get_security_configurations)
- Ação GetResourcePolicies (Python: get_resource_policies)

Ação GetDataCatalogEncryptionSettings (Python: get_data_catalog_encryption_settings)

Recupera a configuração de segurança de um determinado catálogo.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do Catálogo de dados para o qual recuperar a configuração de segurança. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

Resposta

- `DataCatalogEncryptionSettings` – Um objeto DataCatalogEncryptionSettings.

  A configuração de segurança solicitada.

Erros

- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação PutDataCatalogEncryptionSettings (Python: put_data_catalog_encryption_settings)

Define a configuração de segurança de um determinado catálogo. Depois que a configuração tiver sido definida, a criptografia especificada será aplicada a cada gravação de catálogo a partir de então.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do Catálogo de dados para o qual definir a configuração de segurança. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DataCatalogEncryptionSettings` – Obrigatório: um objeto DataCatalogEncryptionSettings.

  A configuração de segurança a ser definida.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação PutResourcePolicy (Python: put_resource_policy)

Define a política de recurso de catálogo de dados para controle de acesso.

Solicitação

- `PolicyInJson` – Obrigatório: String UTF-8, com pelo menos 2 bytes de comprimento.

  Contém o documento de política a ser definido, no formato JSON.

- `ResourceArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  Não use. Apenas para uso interno.

- `PolicyHashCondition` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O valor de hash retornado quando a política anterior foi definida usando `PutResourcePolicy`. O objetivo é impedir modificações simultâneas de uma política. Não use esse parâmetro se nenhuma política anterior tiver sido definida.

- `PolicyExistsCondition` – String UTF-8 (valores válidos: `MUST_EXIST` | `NOT_EXIST` | `NONE`).

  Um valor de `MUST_EXIST` é usado para atualizar uma política. Um valor de `NOT_EXIST` é usado para criar uma nova política. Se um valor de `NONE` ou um valor nulo for usado, a chamada não dependerá da existência de uma política.

- `EnableHybrid`: string UTF-8 (valores válidos: `TRUE` | `FALSE`).

  Se for `'TRUE'`, indica que você está usando os dois métodos para conceder acesso entre contas aos recursos do Data Catalog:

  - Atualizando diretamente a política de recursos com `PutResourePolicy`
  - Usando a opção Grant permissions (Conceder permissões) no AWS Management Console.

  Deve ser definida como `'TRUE'` se você já tiver usado o Console de Gerenciamento para conceder acesso entre contas, caso contrário, a chamada falhará. O padrão é “FALSE” (FALSO).

Resposta

- `PolicyHash` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um hash da política que acabou de ser definida. Isso deve ser incluído em uma chamada subsequente que substitui ou atualiza essa política.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ConditionCheckFailureException`

Ação GetResourcePolicy (Python: get_resource_policy)

Recupera uma política de recurso especificada.

Solicitação

- `ResourceArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O ARN do recurso do AWS Glue para o qual se deseja recuperar a política de recurso. Se não for fornecido, a política de recurso do Data Catalog será retornada. Use `GetResourcePolicies` para exibir todas as políticas de recursos existentes. Para obter mais informações, consulte Especificar ARNs de recurso do AWS Glue.

Resposta

- `PolicyInJson` – String UTF-8, com pelo menos 2 bytes de comprimento.

  Contém o documento da política solicitada no formato JSON.
- `PolicyHash` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Contém o valor de hash associado a essa política.
- `CreateTime` – Timestamp.

  A data e hora em que a política foi criada.
- `UpdateTime` – Timestamp.

  A data e hora em que a política foi atualizada pela última vez.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação DeleteResourcePolicy (Python: delete_resource_policy)

Exclui uma política especificada.

Solicitação

- `PolicyHashCondition` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O valor de hash retornado quando essa política foi definida.
- `ResourceArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O ARN do recurso do AWS Glue para a política de recursos a ser excluída.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ConditionCheckFailureException`

Ação CreateSecurityConfiguration (Python: create_security_configuration)

Cria uma nova configuração de segurança; Uma configuração de segurança é um conjunto de propriedades de segurança que pode ser usado pelo AWS Glue. Você pode usar uma configuração de segurança para criptografar dados em repouso. Para obter informações sobre como usar as configurações de segurança no AWS Glue, consulte Criptografar dados gravados por crawlers, trabalhos e endpoints de desenvolvimento.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da nova configuração de segurança.
- `EncryptionConfiguration` – Obrigatório: um objeto EncryptionConfiguration.

  A configuração de criptografia da nova configuração de segurança.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome atribuído à nova configuração de segurança.
- `CreatedTimestamp` – Timestamp.

  O momento em que a nova configuração de segurança foi criada.

Erros

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

Ação DeleteSecurityConfiguration (Python: delete_security_configuration)

Exclui uma configuração de segurança especificada.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da configuração de segurança a ser excluída.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetSecurityConfiguration (Python: get_security_configuration)

Recupera uma configuração de segurança especificada.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da configuração de segurança a ser recuperada.

Resposta

- `SecurityConfiguration` – Um objeto SecurityConfiguration.

  A configuração de segurança solicitada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetSecurityConfigurations (Python: get_security_configurations)

Recupera uma lista de todas as configurações de segurança.

Solicitação

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `SecurityConfigurations`: um array de objetos SecurityConfiguration.

  Uma lista de configurações de segurança.
- `NextToken` – String UTF-8.

  Um token de continuação, se houver mais configurações de segurança para retornar.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetResourcePolicies (Python: get_resource_policies)

Recupera as políticas de recursos definidas em recursos individuais pelo AWS Resource Access Manager durante concessões de permissões entre contas. Recupera também a política de recurso do Data Catalog.

Se você tiver ativado a criptografia de metadados nas definições do Data Catalog e não tiver permissão na chave do AWS KMS, a operação não poderá retornar a política de recurso do Data Catalog.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo de uma lista a ser retornada.

Resposta

- `GetResourcePoliciesResponseList`: um array de objetos GluePolicy.

  Uma lista das políticas de recursos individuais e a política de recursos de nível de conta.
- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não contiver a política de recurso mais recente disponível.

Erros

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

API Catalogar objetos

A API Catalogar objetos descreve os tipos de dados e a API relacionada trabalhar com catálogos no AWS Glue.

Tópicos

- API de catálogos
- API de banco de dados
- API de tabela
- API de partição
- API de conexões
- API User-defined Function
- Importar um catálogo do Athena para AWS Glue

API de catálogos

A API de catálogos descreve as APIs para criar, excluir, localizar, atualizar e listar catálogos.

Tipos de dados

- Estrutura do catálogo
- Estrutura CatalogInput
- Estrutura TargetRedshiftCatalog
- Estrutura CatalogPropriedades
- Estrutura CatalogPropertiesOutput
- Estrutura DataLakeAccessProperties
- Estrutura DataLakeAccessPropertiesOutput
- Estrutura FederatedCatalog

Estrutura do catálogo

O objeto de catálogo representa um agrupamento lógico de bancos de dados no Catálogo de Dados do AWS Glue ou em uma fonte federada. Agora você pode criar um catálogo federado do Redshift

ou um catálogo contendo links de recursos para bancos de dados do Redshift em outra conta ou região.

Campos

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo. Para conceder acesso ao catálogo padrão, esse campo não deve ser fornecido.
- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 64 bytes de comprimento e correspondente a Custom string pattern #25.

  O nome do catálogo. Não pode ser igual ao ID da conta.
- `ResourceArn` – String UTF-8.

  O nome do recurso da Amazon (ARN) atribuído ao recurso de catálogo.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  String de descrição com não mais de 2.048 bytes de comprimento que corresponde ao padrão de string com várias linhas do endereço URI. Uma descrição do catálogo.
- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Um array de mapa de pares de chave-valor que definem parâmetros e propriedades do catálogo.
- `CreateTime` – Timestamp.

  A hora em que o catálogo foi criado.
- `UpdateTime` – Timestamp.

  A hora em que o catálogo foi atualizado pela última vez.
- `TargetRedshiftCatalog` – Um objeto TargetRedshiftCatalog.

  Um objeto `TargetRedshiftCatalog` que descreve um catálogo de destino para vinculação de recursos de banco de dados.

- `FederatedCatalog` – Um objeto FederatedCatalog.

  Um objeto `FederatedCatalog` que aponta para uma entidade fora do Catálogo de Dados do AWS Glue.

- `CatalogProperties` – Um objeto CatalogPropertiesOutput.

  Um objeto `CatalogProperties` que especifica propriedades de acesso ao data lake e outras propriedades personalizadas.

- `CreateTableDefaultPermissions`: um array de objetos PrincipalPermissions.

  Uma matriz de objetos `PrincipalPermissions`. Cria um conjunto de permissões padrão nas tabelas para as entidades principais. Usado pelo AWS Lake Formation. Não usado no curso normal de operações do AWS Glue.

- `CreateDatabaseDefaultPermissions`: um array de objetos PrincipalPermissions.

  Uma matriz de objetos `PrincipalPermissions`. Cria um conjunto de permissões padrão nos bancos de dados para as entidades principais. Usado pelo AWS Lake Formation. Não usado no curso normal de operações do AWS Glue.

- `AllowFullTableExternalDataAccess`: string UTF-8 (valores válidos: `True` | `False`).

  Permite o acesso de mecanismos de entidades externas aos dados contidos nos locais do Amazon S3 registrados no Lake Formation.

Estrutura CatalogInput

Uma estrutura que descreve as propriedades do catálogo.

Campos

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  String de descrição com não mais de 2.048 bytes de comprimento que corresponde ao padrão de string com várias linhas do endereço URI. Uma descrição do catálogo.

- `FederatedCatalog` – Um objeto FederatedCatalog.

  Um objeto `FederatedCatalog`. Uma estrutura `FederatedCatalog` que faz referência a uma entidade fora do Catálogo de Dados do AWS Glue, por exemplo, um banco de dados do Redshift.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Um array de mapa de pares de chave-valor que definem os parâmetros e as propriedades do catálogo.
- `TargetRedshiftCatalog` – Um objeto TargetRedshiftCatalog.

  Um objeto `TargetRedshiftCatalog` que descreve um catálogo de destino para vinculação de recursos.
- `CatalogProperties` – Um objeto CatalogProperties.

  Um objeto `CatalogProperties` que especifica propriedades de acesso ao data lake e outras propriedades personalizadas.
- `CreateTableDefaultPermissions`: um array de objetos PrincipalPermissions.

  Uma matriz de objetos `PrincipalPermissions`. Cria um conjunto de permissões padrão nas tabelas para as entidades principais. Usado pelo AWS Lake Formation. Normalmente, deve ser definido explicitamente como uma lista vazia.
- `CreateDatabaseDefaultPermissions`: um array de objetos PrincipalPermissions.

  Uma matriz de objetos `PrincipalPermissions`. Cria um conjunto de permissões padrão nos bancos de dados para as entidades principais. Usado pelo AWS Lake Formation. Normalmente, deve ser definido explicitamente como uma lista vazia.
- `AllowFullTableExternalDataAccess`: string UTF-8 (valores válidos: `True` | `False`).

  Permite o acesso de mecanismos de entidades externas aos dados contidos nos locais do Amazon S3 registrados no Lake Formation.

Estrutura TargetRedshiftCatalog

Uma estrutura descreve um catálogo de destino para vinculação de recursos.

Campos

- `CatalogArn` – Obrigatório: string UTF-8.

O Nome do recurso da Amazon (ARN) do recurso de catálogo.

Estrutura CatalogPropriedades

Uma estrutura que especifica propriedades de acesso ao data lake e outras propriedades personalizadas.

Campos

- `DataLakeAccessProperties` – Um objeto DataLakeAccessProperties.

  Um objeto `DataLakeAccessProperties` que especifica propriedades para configurar o acesso ao data lake para seu recurso de catálogo no Catálogo de Dados do AWS Glue.
- `CustomProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Propriedades adicionais de chave-valor para o catálogo, como otimizações de estatísticas de colunas.

Estrutura CatalogPropertiesOutput

Atributos de propriedade que incluem propriedades de configuração para o recurso do catálogo.

Campos

- `DataLakeAccessProperties` – Um objeto DataLakeAccessPropertiesOutput.

  Um objeto `DataLakeAccessProperties` com propriedades de entrada para configurar o acesso ao data lake para seu recurso de catálogo no Catálogo de Dados do AWS Glue.
- `CustomProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

Propriedades adicionais de chave-valor para o catálogo, como otimizações de estatísticas de colunas.

Estrutura DataLakeAccessProperties

Propriedades de entrada para configurar o acesso ao data lake para seu recurso de catálogo no Catálogo de Dados do AWS Glue.

Campos

- `DataLakeAccess` – Booleano.

  Ativa ou desativa o acesso ao data lake para aplicações Apache Spark que acessam bancos de dados do Amazon Redshift no Catálogo de Dados por meio de qualquer mecanismo diferente do Redshift, como Amazon Athena, Amazon EMR ou AWS Glue ETL.

- `DataTransferRole` – String UTF-8 correspondente a Custom string pattern #51.

  Um perfil que será assumido pelo AWS Glue para transferir dados para dentro/fora do bucket de preparação durante uma consulta.

- `KmsKey` – String UTF-8.

  Uma chave de criptografia que será usada para o bucket de preparação que será criado junto com o catálogo.

- `CatalogType` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Especifica um tipo de catálogo federado para o recurso de catálogo nativo. No momento, o único tipo compatível é `aws:redshift`.

Estrutura DataLakeAccessPropertiesOutput

As propriedades de saída da configuração de acesso ao data lake para seu recurso de catálogo no Catálogo de Dados do AWS Glue.

Campos

- `DataLakeAccess` – Booleano.

Ativa ou desativa o acesso ao data lake para aplicações Apache Spark que acessam bancos de dados do Amazon Redshift no Catálogo de Dados.

- `DataTransferRole` – String UTF-8 correspondente a Custom string pattern #51.

  Um perfil que será assumido pelo AWS Glue para transferir dados para dentro/fora do bucket de preparação durante uma consulta.

- `KmsKey` – String UTF-8.

  Uma chave de criptografia que será usada para o bucket de preparação que será criado junto com o catálogo.

- `ManagedWorkgroupName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome computacional do Redshift sem servidor gerenciado criado para seu recurso de catálogo.

- `ManagedWorkgroupStatus` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O status computacional do Redshift sem servidor gerenciado.

- `RedshiftDatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do recurso de banco de dados do Redshift padrão na computação gerenciada.

- `StatusMessage` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Uma mensagem que fornece informações mais detalhadas sobre o status do grupo de trabalho gerenciado.

- `CatalogType` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Especifica um tipo de catálogo federado para o recurso de catálogo nativo. No momento, o único tipo compatível é `aws:redshift`.

Estrutura FederatedCatalog

Um catálogo que aponta para uma entidade fora do Catálogo de Dados do AWS Glue.

Campos

- `Identifier`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Single-line string pattern.

  Um identificador exclusivo para o catálogo federado.
- `ConnectionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da conexão com uma fonte de dados externa, por exemplo, um catálogo federado do Redshift.
- `ConnectionType` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O tipo de conexão usado para acessar o catálogo federado, especificando o protocolo ou método para conexão com a fonte de dados externa.

Operações

- Ação CreateCatalog (Python: create_catalog)
- Ação UpdateCatalog (Python: update_catalog)
- Ação DeleteCatalog (Python: delete_catalog)
- Ação GetCatalog (Python: get_catalog)
- Ação GetCatalogs (Python: get_catalogs)

Ação CreateCatalog (Python: create_catalog)

Cria um novo catálogo no Catálogo de Dados do AWS Glue.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 64 bytes de comprimento e correspondente a Custom string pattern #25.

  O nome do catálogo a ser criado.
- `CatalogInput` – Obrigatório: um objeto CatalogInput.

  Um objeto `CatalogInput` que define os metadados do catálogo.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Um array de mapa dos pares de chave-valor contendo não mais que 50 pares. Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes. Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento. As tags que você atribui ao catálogo.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederatedResourceAlreadyExistsException`
- `FederationSourceException`

Ação UpdateCatalog (Python: update_catalog)

Atualiza as propriedades de um catálogo existente no Catálogo de Dados do AWS Glue.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O ID do catálogo.

- `CatalogInput` – Obrigatório: um objeto CatalogInput.

  Um objeto `CatalogInput` que especifica as novas propriedades de um catálogo existente.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `AccessDeniedException`
- `FederationSourceException`

Ação DeleteCatalog (Python: delete_catalog)

Remove o catálogo especificado do Catálogo de Dados do AWS Glue.

Depois de concluir essa operação, você não terá mais acesso aos bancos de dados, às tabelas (e a todas as versões de tabela e partições que podem pertencer às tabelas) e às funções definidas pelo usuário no catálogo excluído. O AWS Glue exclui esses recursos "órfãos" de forma assíncrona e pontual, a critério do serviço.

Para garantir exclusão imediata de todos os recursos relacionados, antes de chamar a operação `DeleteCatalog`, use `DeleteTableVersion` (ou `BatchDeleteTableVersion`), `DeletePartition` (ou `BatchDeletePartition`), `DeleteTable` (ou `BatchDeleteTable`), `DeleteUserDefinedFunction` e `DeleteDatabase` para excluir qualquer recurso que pertence à tabela.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `AccessDeniedException`
- `FederationSourceException`

Ação GetCatalog (Python: get_catalog)

O nome do catálogo a ser recuperado. O nome deve ser totalmente em minúsculas.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo pai em que o catálogo reside. Se nenhum for fornecido, o número da conta da AWS será usado por padrão.

Resposta

- `Catalog` – Um objeto Catálogo.

Um objeto `Catalog`. A definição do catálogo especificado no Catálogo de Dados do AWS Glue.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação GetCatalogs (Python: get_catalogs)

Recupera todos os catálogos definidos em um catálogo no Catálogo de Dados do AWS Glue. Para um caso de uso de catálogo federado do Redshift, essa operação retorna a lista de catálogos mapeados em bancos de dados do Redshift no catálogo de namespaces do Redshift.

Solicitação

- `ParentCatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo pai em que o catálogo reside. Se nenhum for fornecido, o número da conta da AWS será usado por padrão.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de catálogos a ser retornado em uma resposta.
- `Recursive` – Booleano.

Determina se todos os catálogos existentes na hierarquia de catálogos devem ser listados, começando pelo `ParentCatalogId`. O padrão é `false`. Caso o valor seja `true`, a resposta incluirá a enumeração de todos os objetos de catálogo na hierarquia do `ParentCatalogID`.

- `IncludeRoot` – Booleano.

  Determina se o catálogo padrão, associado à conta e à região, deve ser incluído na listagem retornada. O padrão é `false`. Caso o valor seja `true` e `ParentCatalogId = NULL | AWS Account ID`, a resposta incluirá a enumeração de todos os catálogos, incluindo o catálogo padrão.

  Caso o `ParentCatalogId` não seja nulo e este atributo seja informado como `false` ou `true`, será gerada uma exceção do tipo `InvalidInputException`.

Resposta

- `CatalogList` – Obrigatório: uma matriz de objetos Catálogo.

  Uma matriz de objetos `Catalog`. Uma lista de objetos `Catalog` do catálogo pai especificado.

- `NextToken` – String UTF-8.

  Um token de continuação para paginação da lista de tokens retornada, retornado se o segmento atual da lista não for o último.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

API de banco de dados

O Banco de dados da API descreve os tipos de dados do banco de dados e inclui a API para criar, excluir, localizar, atualizar e listar bancos de dados.

Tipos de dados

- Estrutura Database
- Estrutura DatabaseInput
- Estrutura PrincipalPermissions
- Estrutura DataLakePrincipal
- Estrutura DatabaseIdentifier
- Estrutura FederatedDatabase

Estrutura Database

O objeto `Database` representa um agrupamento lógico de tabelas que podem residir em uma metastore do Hive ou um RDBMS.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados. Para a compatibilidade com o Hive, as letras são transformadas em minúsculas quando a tabela é armazenada.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do banco de dados.
- `LocationUri` – URI (Uniform Resource Identifier), maior que 1 ou maior que 1024 bytes de comprimento, correspondente a URI address multi-line string pattern.

  A localização do banco de dados (por exemplo, um caminho de HDFS).
- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

Esses pares de chave/valor definem parâmetros e propriedades do banco de dados.

- `CreateTime` – Timestamp.

  A hora em que o banco de dados de metadados foi criado no catálogo.

- `CreateTableDefaultPermissions`: um array de objetos PrincipalPermissions.

  Cria um conjunto de permissões padrão na tabela para as entidades principais. Usado pelo AWS Lake Formation. Não usado no curso normal de operações do AWS Glue.

- `TargetDatabase` – Um objeto DatabaseIdentifier.

  Uma estrutura de `DatabaseIdentifier` que descreve um banco de dados de destino para vinculação de recursos.

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados reside.

- `FederatedDatabase` – Um objeto FederatedDatabase.

  Uma estrutura `FederatedDatabase` que referencia uma entidade fora do AWS Glue Data Catalog.

Estrutura DatabaseInput

A estrutura usada para criar ou atualizar um banco de dados.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados. Para a compatibilidade com o Hive, as letras são transformadas em minúsculas quando a tabela é armazenada.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do banco de dados.

- `LocationUri` – URI (Uniform Resource Identifier), maior que 1 ou maior que 1024 bytes de comprimento, correspondente a URI address multi-line string pattern.

  A localização do banco de dados (por exemplo, um caminho de HDFS).

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Esses pares de chave/valor definem parâmetros e propriedades do banco de dados.

  Esses pares de chave/valor definem parâmetros e propriedades do banco de dados.

- `CreateTableDefaultPermissions`: um array de objetos PrincipalPermissions.

  Cria um conjunto de permissões padrão na tabela para as entidades principais. Usado pelo AWS Lake Formation. Não usado no curso normal de operações do AWS Glue.

- `TargetDatabase` – Um objeto DatabaseIdentifier.

  Uma estrutura de `DatabaseIdentifier` que descreve um banco de dados de destino para vinculação de recursos.

- `FederatedDatabase` – Um objeto FederatedDatabase.

  Uma estrutura `FederatedDatabase` que referencia uma entidade fora do AWS Glue Data Catalog.

Estrutura PrincipalPermissions

Permissões concedidas a uma entidade principal.

Campos

- `Principal` – Um objeto DataLakePrincipal.

  A entidade principal que recebe permissões.

- `Permissions` – Uma matriz de strings UTF-8.

  As permissões que são concedidas à entidade principal.

Estrutura DataLakePrincipal

A entidade principal do AWS Lake Formation.

Campos

- `DataLakePrincipalIdentifier`: string UTF-8, não menos do que 1 ou superior a 255 bytes de comprimento.

  Um identificador para a entidade principal do AWS Lake Formation.

Estrutura DatabaseIdentifier

Uma estrutura de que descreve um banco de dados de destino para vinculação de recursos.

Campos

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados reside.
- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo.
- `Region` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Região do banco de dados de destino.

Estrutura FederatedDatabase

Um banco de dados que aponta para uma entidade fora do AWS Glue Data Catalog.

Campos

- `Identifier`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Single-line string pattern.

  Um identificador exclusivo do banco de dados federado.

- `ConnectionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da conexão com o metastore externo.

- `ConnectionType` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O tipo de conexão usado para acessar o banco de dados federado, como JDBC, ODBC ou outros protocolos de conexão compatíveis.

Operações

- Ação CreateDatabase (Python: create_database)
- Ação UpdateDatabase (Python: update_database)
- Ação DeleteDatabase (Python: delete_database)
- Ação GetDatabase (Python: get_database)
- Ação GetDatabases (Python: get_databases)

Ação CreateDatabase (Python: create_database)

Cria um novo banco de dados em um catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados será criado. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

- `DatabaseInput` – Obrigatório: um objeto DatabaseInput.

  Os metadados para o banco de dados.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

As tags que você atribui ao banco de dados.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `FederatedResourceAlreadyExistsException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação UpdateDatabase (Python: update_database)

Atualiza uma definição de banco de dados existente no catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados de metadados reside. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados a ser atualizado no catálogo. Para a compatibilidade com o Hive, as letras são transformadas em minúsculas.

- `DatabaseInput` – Obrigatório: um objeto DatabaseInput.

  Um objeto `DatabaseInput` que especifica a nova definição do banco de dados de metadados no catálogo.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ConcurrentModificationException`
- `FederationSourceException`
- `FederationSourceRetryableException`
- `AlreadyExistsException`

Ação DeleteDatabase (Python: delete_database)

Remove um banco de dados especificado de um Catálogo de dados.

> **Note**
>
> Depois de concluir essa operação, você não terá mais acesso às tabelas (e a todas as versões de tabela e partições que podem pertencer às tabelas) e às funções definidas pelo usuário no banco de dados excluído. O AWS Glue exclui esses recursos "órfãos" de forma assíncrona e pontual, a critério do serviço.
> Para garantir exclusão imediata de todos os recursos relacionados, antes de chamar `DeleteDatabase`, use `DeleteTableVersion` ou `BatchDeleteTableVersion`, `DeletePartition` ou `BatchDeletePartition`, `DeleteUserDefinedFunction`,

e `DeleteTable` ou `BatchDeleteTable`, para excluir qualquer recurso que pertence à tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados reside. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados a ser excluído. Para a compatibilidade com o Hive, ele deve ser todo inserido em letras minúsculas.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação GetDatabase (Python: get_database)

Recupera a definição de um banco de dados especificado.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados reside. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados a ser recuperado. Para a compatibilidade com o Hive, ele deve ser inserido todo em letras minúsculas.

Resposta

- `Database` – Um objeto Banco de dados.

  A definição do banco de dados especificado no Catálogo de dados.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação GetDatabases (Python: get_databases)

Recupera todos os bancos de dados definidos em determinado Catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O ID do catálogo de dados de onde `Databases` será recuperado. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 100.

  O número máximo de bancos de dados a ser retornado em uma resposta.

- `ResourceShareType` – String UTF-8 (valores válidos: `FOREIGN` | `ALL` | `FEDERATED`).

  Permite que você especifique que deseja listar os bancos de dados compartilhados com sua conta. Os valores permitidos são `FEDERATED`, `FOREIGN` ou `ALL`.

  - Se definido como `FEDERATED`, listará os bancos de dados federados (que referenciam uma entidade externa) compartilhados com sua conta.
  - Se definido como `FOREIGN`, listará os bancos de dados compartilhados com sua conta.
  - Se definido como `ALL`, listará os bancos de dados compartilhados com sua conta, bem como os bancos de dados em sua conta local.

- `AttributesToGet` – Uma matriz de strings UTF-8.

  Especifica os campos do banco de dados retornados pela chamada `GetDatabases`. Esse parâmetro não aceita uma lista vazia. A solicitação deve incluir o `NAME`.

Resposta

- `DatabaseList` – Obrigatório: uma matriz de objetos Banco de dados.

  Uma lista de objetos `Database` do catálogo especificado.

- `NextToken` – String UTF-8.

  Um token de continuação para paginação da lista de tokens retornada, retornado se o segmento atual da lista não for o último.

Erros

- `InvalidInputException`
- `InternalServiceException`

- `OperationTimeoutException`
- `GlueEncryptionException`
- `EntityNotFoundException`
- `FederationSourceException`
- `FederationSourceRetryableException`

API de tabela

A Tabela da API descreve os tipos de dados e operações associadas a tabelas.

Tipos de dados

- Estrutura Table
- Estrutura TableInput
- Estrutura FederatedTable
- Estrutura da coluna
- Estrutura StorageDescriptor
- Estrutura SchemaReference
- Estrutura SerDeInfo
- Estrutura Order
- Estrutura SkewedInfo
- Estrutura TableVersion
- Estrutura TableError
- Estrutura TableVersionError
- Estrutura SortCriterion
- Estrutura TableIdentifier
- Estrutura KeySchemaElement
- Estrutura PartitionIndex
- Estrutura PartitionIndexDescriptor
- Estrutura BackfillError
- Estrutura IcebergInput

- Estrutura OpenTableFormatInput
- Estrutura ViewDefinition
- Estrutura ViewDefinitionInput
- Estrutura ViewRepresentation
- Estrutura ViewRepresentationInput
- Estrutura UpdateOpenTableFormatInput
- Estrutura UpdateIcebergInput
- Estrutura CreateIcebergTableInput
- Estrutura UpdateIcebergTableInput
- Estrutura IcebergSortOrder
- Estrutura IcebergSortField
- Estrutura IcebergPartitionSpec
- Estrutura IcebergPartitionField
- Estrutura IcebergSchema
- Estrutura IcebergStructField
- Estrutura IcebergTableUpdate

Estrutura Table

Representa uma coleção de dados relacionados, organizados em colunas e linhas.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela. Para a compatibilidade com o Hive, ele deve ser inserido todo em letras minúsculas.

- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados no qual os metadados da tabela residem. Para a compatibilidade com o Hive, ele deve ser todo inserido em letras minúsculas.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A descrição da tabela.

- `Owner` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O proprietário da tabela.

- `CreateTime` – Timestamp.

  A hora em que a definição da tabela foi criada no Catálogo de dados.

- `UpdateTime` – Timestamp.

  A última vez que a tabela foi atualizada.

- `LastAccessTime` – Timestamp.

  A última vez que a tabela foi acessada. Ela geralmente é extraída do HDFS e pode não ser confiável.

- `LastAnalyzedTime` – Timestamp.

  A última vez em que as estatísticas da coluna foram computadas para esta tabela.

- `Retention` – Número (inteiro), não mais do que None (Nenhum).

  O tempo de retenção para esta tabela.

- `StorageDescriptor` – Um objeto StorageDescriptor.

  Um descritor de armazenamento contendo informações sobre o armazenamento físico desta tabela.

- `PartitionKeys`: um array de objetos Coluna.

  Uma lista de colunas pela qual a tabela é particionada. Apenas os tipos primitivos são compatíveis como chaves de partição.

  Ao criar uma tabela usada pelo Amazon Athena, e você não especificar nenhum `partitionKeys`, você deve definir pelo menos o valor de `partitionKeys` para uma lista vazia. Por exemplo:

  ```
  "PartitionKeys": []
  ```

- `ViewOriginalText` – String UTF-8 com comprimento não superior a 409.600 bytes.

Incluído para compatibilidade com o Apache Hive. Não usado no curso normal de operações do AWS Glue. Se a tabela for uma `VIRTUAL_VIEW`, algumas configurações do Athena serão codificadas em base64.

- `ViewExpandedText` – String UTF-8 com comprimento não superior a 409.600 bytes.

  Incluído para compatibilidade com o Apache Hive. Não usado no curso normal de operações do AWS Glue.

- `TableType` – String UTF-8 com comprimento não superior a 255 bytes.

  O tipo dessa tabela. O AWS Glue criará tabelas com o tipo `EXTERNAL_TABLE`. Outros serviços, como o Athena, poderão criar tabelas com tipos adicionais de tabela.

  Tipos de tabela relacionados ao AWS Glue:

  EXTERNAL_TABLE

  Atributo compatível com o Hive: indica uma tabela não gerenciada pelo Hive.

  GOVERNED

  Usado pelo AWS Lake Formation. O AWS Glue Data Catalog entende `GOVERNED`.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Esses pares de chave/valor definem propriedades associadas com a tabela.

- `CreatedBy` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  A pessoa ou entidade que criou a tabela.

- `IsRegisteredWithLakeFormation` – Booleano.

  Indica se a tabela foi registrada com o AWS Lake Formation.

- `TargetTable` – Um objeto TableIdentifier.

  Uma estrutura de `TableIdentifier` que descreve uma tabela de destino para vinculação de recursos.

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que a tabela reside.

- `VersionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da versão da tabela.

- `FederatedTable` – Um objeto FederatedTable.

  Uma estrutura `FederatedTable` que referencia uma entidade fora do AWS Glue Data Catalog.

- `ViewDefinition` – Um objeto ViewDefinition.

  Uma estrutura que contém todas as informações que definem a visualização, incluindo o dialeto ou dialetos da visualização e a consulta.

- `IsMultiDialectView` – Booleano.

  Especifica se a visualização oferece suporte aos dialetos SQL de um ou mais mecanismos de consulta diferentes e, portanto, que ela pode ser lida por esses mecanismos.

Estrutura TableInput

Uma estrutura usado para definir uma tabela.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela. Para a compatibilidade com o Hive, as letras são transformadas em minúsculas quando a tabela é armazenada.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A descrição da tabela.

- `Owner` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O proprietário da tabela. Incluído para compatibilidade com o Apache Hive. Não usado no curso normal de operações do AWS Glue.

- `LastAccessTime` – Timestamp.

  A última vez que a tabela foi acessada.

- `LastAnalyzedTime` – Timestamp.

  A última vez em que as estatísticas da coluna foram computadas para esta tabela.

- `Retention` – Número (inteiro), não mais do que None (Nenhum).

  O tempo de retenção para esta tabela.

- `StorageDescriptor` – Um objeto StorageDescriptor.

  Um descritor de armazenamento contendo informações sobre o armazenamento físico desta tabela.

- `PartitionKeys`: um array de objetos Coluna.

  Uma lista de colunas pela qual a tabela é particionada. Apenas os tipos primitivos são compatíveis como chaves de partição.

  Ao criar uma tabela usada pelo Amazon Athena, e você não especificar nenhum `partitionKeys`, você deve definir pelo menos o valor de `partitionKeys` para uma lista vazia. Por exemplo:

  `"PartitionKeys": []`

- `ViewOriginalText` – String UTF-8 com comprimento não superior a 409.600 bytes.

  Incluído para compatibilidade com o Apache Hive. Não usado no curso normal de operações do AWS Glue. Se a tabela for uma `VIRTUAL_VIEW`, algumas configurações do Athena serão codificadas em base64.

- `ViewExpandedText` – String UTF-8 com comprimento não superior a 409.600 bytes.

  Incluído para compatibilidade com o Apache Hive. Não usado no curso normal de operações do AWS Glue.

- `TableType` – String UTF-8 com comprimento não superior a 255 bytes.

  O tipo dessa tabela. O AWS Glue criará tabelas com o tipo `EXTERNAL_TABLE`. Outros serviços, como o Athena, poderão criar tabelas com tipos adicionais de tabela.

Tipos de tabela relacionados ao AWS Glue:

EXTERNAL_TABLE

Atributo compatível com o Hive: indica uma tabela não gerenciada pelo Hive.

GOVERNED

Usado pelo AWS Lake Formation. O AWS Glue Data Catalog entende `GOVERNED`.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Esses pares de chave/valor definem propriedades associadas com a tabela.

- `TargetTable` – Um objeto TableIdentifier.

  Uma estrutura de `TableIdentifier` que descreve uma tabela de destino para vinculação de recursos.

- `ViewDefinition` – Um objeto ViewDefinitionInput.

  Uma estrutura que contém todas as informações que definem a visualização, incluindo o dialeto ou dialetos da visualização e a consulta.

Estrutura FederatedTable

Uma tabela que aponta para uma entidade fora do AWS Glue Data Catalog.

Campos

- `Identifier`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Single-line string pattern.

  Um identificador exclusivo da tabela federada.

- `DatabaseIdentifier`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Single-line string pattern.

  Um identificador exclusivo do banco de dados federado.

- `ConnectionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da conexão com o metastore externo.

- `ConnectionType` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O tipo de conexão usada para acessar a tabela federada, especificando o protocolo ou método de conexão com a fonte de dados externa.

Estrutura da coluna

Uma coluna em uma `Table`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da `Column`.

- `Type` – String UTF-8 com comprimento não superior a 131.072 bytes, correspondente a Single-line string pattern.

  O tipo de dados da `Column`.

- `Comment` – String de comentário, inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um comentário de texto livre.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Esses pares de chave-valor definem propriedades associadas à coluna.

Estrutura StorageDescriptor

Descreve o armazenamento físico dos dados da tabela.

Campos

- `Columns`: um array de objetos Coluna.

  Uma lista de `Columns` na tabela.

- `Location` – String de local, inferior a 2056 bytes de comprimento, correspondente a URI address multi-line string pattern.

  A localização física da tabela. Por padrão, assume o formato da localização do warehouse, seguida pela localização do banco de dados no warehouse, seguida pelo nome da tabela.

- `AdditionalLocations` – Uma matriz de strings UTF-8.

  Uma lista de locais que apontam para o caminho onde uma tabela do Delta está localizada.

- `InputFormat` – String de formato, inferior a 128 bytes de comprimento, correspondente a Single-line string pattern.

  O formato de entrada: `SequenceFileInputFormat` (binário), `TextInputFormat` ou um formato personalizado.

- `OutputFormat` – String de formato, inferior a 128 bytes de comprimento, correspondente a Single-line string pattern.

  O formato de saída: `SequenceFileOutputFormat` (binário), `IgnoreKeyTextOutputFormat` ou um formato personalizado.

- `Compressed` – Booleano.

  `True` se os dados da tabela estiverem compactados, ou `False` se não estiverem.

- `NumberOfBuckets` – Número (íntegro).

  Você deverá especificar se a tabela contiver qualquer coluna de dimensão.

- `SerdeInfo` – Um objeto SerDeInfo.

  As informações de serialização/desserialização (SerDe).

- `BucketColumns` – Uma matriz de strings UTF-8.

Uma lista de colunas de agrupamento, armazenamento em clusters e armazenamento em buckets de reducers na tabela.

- `SortColumns`: um array de objetos Ordem.

  Uma lista que especifica a ordem de classificação de cada bucket na tabela.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  As propriedades fornecidas pelo usuário em formato de chave/valor.

- `SkewedInfo` – Um objeto SkewedInfo.

  As informações sobre valores que aparecem com frequência em uma coluna (valores distorcidos).

- `StoredAsSubDirectories` – Booleano.

  `True`, se os dados na tabela estiverem armazenados em subdiretórios, ou `False`, caso contrário.

- `SchemaReference` – Um objeto SchemaReference.

  Um objeto que faz referência a um esquema armazenado no AWS Glue Schema Registry.

  Ao criar uma tabela, você pode passar uma lista vazia de colunas para o esquema e, em vez disso, usar uma referência de esquema.

Estrutura SchemaReference

Um objeto que faz referência a um esquema armazenado no AWS Glue Schema Registry.

Campos

- `SchemaId` – Um objeto SchemaId.

  Uma estrutura que contém campos de identidade de esquema. Esse ou o `SchemaVersionId` tem que ser fornecido.

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

O ID exclusivo atribuído a uma versão do esquema. Esse ou o `SchemaId` tem que ser fornecido.

- `SchemaVersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.

Estrutura SerDeInfo

As informações sobre um programa de serialização/desserialização (SerDe), que serve como extrator e carregador.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome de SerDe.

- `SerializationLibrary` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Normalmente, é a classe que implementa o SerDe. Um exemplo é `org.apache.hadoop.hive.serde2.columnar.ColumnarSerDe`.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Esses pares de chave/valor definem parâmetros de inicialização para SerDe.

Estrutura Order

Especifica a ordem de classificação de uma coluna classificada.

Campos

- `Column`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome da coluna.

- `SortOrder` – Obrigatório: Número (inteiro), não mais do que 1.

  Indica se a coluna é classificada em ordem crescente (`== 1`) ou decrescente (`==0`).

Estrutura SkewedInfo

Especifica valores distorcidos em uma tabela. Valores distorcidos são aqueles que ocorrem com muita frequência.

Campos

- `SkewedColumnNames` – Uma matriz de strings UTF-8.

  Uma lista de nomes de colunas que contêm valores distorcidos.

- `SkewedColumnValues` – Uma matriz de strings UTF-8.

  Uma lista de valores que aparecem com tanta frequência que devem ser considerados distorcidos.

- `SkewedColumnValueLocationMaps` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um mapeamento de valores distorcidos para as colunas nas quais estão presentes.

Estrutura TableVersion

Especifica a versão de uma tabela.

Campos

- `Table` – Um objeto Tabela.

  A tabela em questão.

- `VersionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O valor de ID que identifica esta versão da tabela. Um `VersionId` é uma representação em string de um inteiro. Cada versão é incrementada em 1.

Estrutura TableError

Um registro de erro para operações de tabela.

Campos

- `TableName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela. Para a compatibilidade com o Hive, ele deve ser inserido todo em letras minúsculas.

- `ErrorDetail` – Um objeto ErrorDetail.

  Os detalhes sobre o erro.

Estrutura TableVersionError

Um registro de erro para operações da versão da tabela.

Campos

- `TableName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela em questão.

- `VersionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O valor de ID da versão em questão. Um `VersionID` é uma representação em string de um inteiro. Cada versão é incrementada em 1.

- `ErrorDetail` – Um objeto ErrorDetail.

  Os detalhes sobre o erro.

Estrutura SortCriterion

Especifica um campo pelo qual classificar e uma ordem de classificação.

Campos

- `FieldName`: string Value com no mínimo 1 e no máximo 1.024 bytes de comprimento.

  O nome do campo no qual classificar.
- `Sort`: string UTF-8 (valores válidos: `ASC="ASCENDING"` | `DESC="DESCENDING"`).

  Uma classificação crescente ou decrescente.

Estrutura TableIdentifier

Uma estrutura de que descreve uma tabela de destino para vinculação de recursos.

Campos

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que a tabela reside.
- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados de catálogo que contém a tabela de destino.
- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela de destino.
- `Region` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Região da tabela de destino.

Estrutura KeySchemaElement

Um par de chaves de partição que consiste em um nome e um tipo.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome de uma chave de partição.

- `Type`: obrigatório: string UTF-8 com comprimento não superior a 131.072 bytes, correspondente a Single-line string pattern.

  O tipo de uma chave de partição.

Estrutura PartitionIndex

Uma estrutura para um índice de partição.

Campos

- `Keys` – Obrigatório: uma matriz de strings UTF-8, pelo menos 1 string.

  As chaves para o índice de partição.

- `IndexName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do índice de partição.

Estrutura PartitionIndexDescriptor

Um descritor para um índice de partição em uma tabela.

Campos

- `IndexName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do índice de partição.

- `Keys`: obrigatório: uma matriz de objetos KeySchemaElement, pelo menos uma estrutura.

  Uma lista de uma ou mais chaves, como estruturas `KeySchemaElement`, para o índice de partição.

- `IndexStatus`: obrigatório: string UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `DELETING` | `FAILED`).

  O status do índice de partição.

  Os possíveis status são:

  - CREATING (CRIANDO): o índice está sendo criado. Quando um índice está em um estado CREATING, o índice ou sua tabela não podem ser excluídos.
  - ACTIVE (ATIVO): a criação do índice foi bem-sucedida.
  - FAILED (FALHOU): a criação do índice falhou.
  - DELETING (EXCLUINDO): o índice é excluído da lista de índices.
- `BackfillErrors`: um array de objetos BackfillError.

  Uma lista de erros que podem ocorrer no registro de índices de partição para uma tabela existente.

Estrutura BackfillError

Uma lista de erros que podem ocorrer no registro de índices de partição para uma tabela existente.

Esses erros fornecem os detalhes sobre por que um registro de índice falhou e fornecem um número limitado de partições na resposta, para que você possa corrigir as partições com falha e tentar registrar o índice novamente. O conjunto mais comum de erros que podem ocorrer são categorizados da seguinte forma:

- EncryptedPartitionError: as partições são encriptadas.
- InvalidPartitionTypeDataError: o valor da partição não corresponde ao tipo de dados dessa coluna de partição.
- MissingPartitionValueError: as partições são criptografadas.
- UnsupportedPartitionCharacterError: caracteres dentro do valor da partição não são suportados. Por exemplo: U+0000, U+0001, U+0002.
- InternalError: qualquer erro que não pertence a outros códigos de erro.

Campos

- `Code` – String UTF-8 (valores válidos: `ENCRYPTED_PARTITION_ERROR` | `INTERNAL_ERROR` | `INVALID_PARTITION_TYPE_DATA_ERROR` | `MISSING_PARTITION_VALUE_ERROR` | `UNSUPPORTED_PARTITION_CHARACTER_ERROR`).

  O código de erro para um erro que ocorreu durante o registro de índices de partição para uma tabela existente.
- `Partitions`: um array de objetos PartitionValueList.

  Uma lista com um número limitado de partições na resposta.

Estrutura IcebergInput

Uma estrutura que define uma tabela de metadados do Apache Iceberg a ser criada no catálogo.

Campos

- `MetadataOperation`: obrigatório: string UTF-8 (valores válidos: `CREATE`).

  Uma operação de metadados obrigatória. Só pode ser definida como `CREATE`.
- `Version` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  A versão da tabela para a tabela do Iceberg. Padronizado como 2.
- `CreateIcebergTableInput` – Um objeto CreateIcebergTableInput.

  Os parâmetros de configuração necessários para criar uma nova tabela do Iceberg no Catálogo de Dados do AWS Glue, incluindo propriedades da tabela e especificações de metadados.

Estrutura OpenTableFormatInput

Uma estrutura que representa uma tabela de formato aberto.

Campos

- `IcebergInput` – Um objeto IcebergInput.

  Especifica uma estrutura `IcebergInput` que define uma tabela de metadados do Apache Iceberg.

Estrutura ViewDefinition

Uma estrutura que contém detalhes para representações.

Campos

- `IsProtected` – Booleano.

  É possível definir esse sinalizador como verdadeiro para instruir o mecanismo a não inserir as operações fornecidas pelo usuário no plano lógico da exibição durante o planejamento da consulta. No entanto, definir esse sinalizador não garante que o mecanismo estará em conformidade. Consulte a documentação do mecanismo para entender as garantias fornecidas, se houver.

- `Definer` – String UTF-8, superior a 20 e inferior a 2048 bytes de comprimento, correspondente a Single-line string pattern.

  O definidor de uma visualização em SQL.

- `SubObjects` – Uma matriz de strings UTF-8, no máximo 10 strings.

  Uma lista de nomes do recurso da Amazon (ARNs) da tabela.

- `Representations`: uma matriz de objetos ViewRepresentation, não menos do que 1 ou superior a 1.000 estruturas.

  Uma lista de representações.

Estrutura ViewDefinitionInput

Uma estrutura que contém detalhes para criar ou atualizar uma visualização do AWS Glue.

Campos

- `IsProtected` – Booleano.

  É possível definir esse sinalizador como verdadeiro para instruir o mecanismo a não inserir as operações fornecidas pelo usuário no plano lógico da exibição durante o planejamento da consulta. No entanto, definir esse sinalizador não garante que o mecanismo estará em conformidade. Consulte a documentação do mecanismo para entender as garantias fornecidas, se houver.

- `Definer` – String UTF-8, superior a 20 e inferior a 2048 bytes de comprimento, correspondente a Single-line string pattern.

  O definidor de uma visualização em SQL.

- `Representations`: uma matriz de objetos ViewRepresentationInput com não menos que 1 nem mais que 10 estruturas.

  Uma lista de estruturas que contém o dialeto da visualização e a consulta que define a visualização.

- `SubObjects` – Uma matriz de strings UTF-8, no máximo 10 strings.

  Uma lista dos ARNs da tabela base que compõem a visualização.

Estrutura ViewRepresentation

Uma estrutura que contém o dialeto da visualização e a consulta que define a visualização.

Campos

- `Dialect` – String UTF-8 (valores válidos: `REDSHIFT` | `ATHENA` | `SPARK`).

  O dialeto do mecanismo de consulta.

- `DialectVersion`: string UTF-8, não menos do que 1 ou superior a 255 bytes de comprimento.

  A versão do dialeto do mecanismo de consulta. Por exemplo, 3.0.0.

- `ViewOriginalText` – String UTF-8 com comprimento não superior a 409.600 bytes.

  A consulta `SELECT` fornecida pelo cliente durante `CREATE VIEW DDL`. Esse SQL não é usado durante uma consulta em uma visualização (`ViewExpandedText` é usado em vez disso). `ViewOriginalText` é usada para casos como `SHOW CREATE VIEW` quando os usuários querem ver o comando DDL original que criou a visualização.

- `ViewExpandedText` – String UTF-8 com comprimento não superior a 409.600 bytes.

  O SQL expandido para a visualização. Esse SQL é usado pelos mecanismos durante o processamento de uma consulta em uma visualização. Os mecanismos podem realizar operações durante a criação da visualização para transformar `ViewOriginalText` em `ViewExpandedText`. Por exemplo:

  - Identificadores totalmente qualificados: `SELECT * from table1 -> SELECT * from db1.table1`
- `ValidationConnection` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da conexão a ser usada para validar a representação específica da visualização.
- `IsStale` – Booleano.

  Os dialetos marcados como obsoletos não são mais válidos e devem ser atualizados antes que possam ser consultados em seus respectivos mecanismos de consulta.

Estrutura ViewRepresentationInput

Uma estrutura que contém detalhes de uma representação para atualizar ou criar uma visualização do Lake Formation.

Campos

- `Dialect` – String UTF-8 (valores válidos: `REDSHIFT` | `ATHENA` | `SPARK`).

  Um parâmetro que especifica o tipo do mecanismo de uma representação específica.
- `DialectVersion`: string UTF-8, não menos do que 1 ou superior a 255 bytes de comprimento.

  Um parâmetro que especifica a versão do mecanismo de uma representação específica.
- `ViewOriginalText` – String UTF-8 com comprimento não superior a 409.600 bytes.

  Uma string que representa a consulta SQL original que descreve a visualização.
- `ValidationConnection` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da conexão a ser usada para validar a representação específica da visualização.
- `ViewExpandedText` – String UTF-8 com comprimento não superior a 409.600 bytes.

  Uma string que representa a consulta SQL que descreve a exibição com ARNs de recursos expandidos

Estrutura UpdateOpenTableFormatInput

Parâmetros de entrada para atualizar tabelas de formato de tabela aberta no Catálogo de Dados do AWS Glue, servindo como um wrapper para operações de atualização de formatos específicos, como o Apache Iceberg.

Campos

- `UpdateIcebergInput` – Um objeto UpdateIcebergInput.

  Parâmetros de atualização específicos do Apache Iceberg que definem as modificações da tabela a serem aplicadas, incluindo alterações de esquema, especificações de partição e propriedades da tabela.

Estrutura UpdateIcebergInput

Parâmetros de entrada específicos para atualizar tabelas do Apache Iceberg no Catálogo de Dados do AWS Glue, contendo as operações de atualização a serem aplicadas a uma tabela existente do Iceberg.

Campos

- `UpdateIcebergTableInput` – Obrigatório: um objeto UpdateIcebergTableInput.

  As operações de atualização específicas a serem aplicadas à tabela do Iceberg, contendo uma lista de atualizações que definem o novo estado da tabela, incluindo esquema, partições e propriedades.

Estrutura CreateIcebergTableInput

Os parâmetros de configuração necessários para criar uma nova tabela do Iceberg no Catálogo de Dados do AWS Glue, incluindo propriedades da tabela e especificações de metadados.

Campos

- `Location`: – obrigatório: string de local com não mais do que 2.056 bytes de comprimento, combinando com URI address multi-line string pattern.

  O local no S3 onde os dados de tabelas do Iceberg serão armazenados.

- `Schema` – Obrigatório: um objeto IcebergSchema.

  A definição do esquema que especifica a estrutura, os tipos de campo e os metadados da tabela do Iceberg.

- `PartitionSpec` – Um objeto IcebergPartitionSpec.

  A especificação de particionamento que define como os dados da tabela do Iceberg serão organizados e particionados para otimizar o desempenho da consulta.

- `WriteOrder` – Um objeto IcebergSortOrder.

  A especificação da ordem de classificação que define como os dados deverão ser ordenados em cada partição para otimizar o desempenho da consulta.

- `Properties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Pares de chave e valor de propriedades adicionais de tabela e definições de configuração para a tabela do Iceberg.

Estrutura UpdateIcebergTableInput

Contém as operações de atualização a serem aplicadas a uma tabela existente do Iceberg no Catálogo de Dados do AWS Glue, definindo o novo estado dos metadados da tabela.

Campos

- `Updates` – Obrigatório: uma matriz de objetos IcebergTableUpdate.

  A lista de operações de atualização de tabela que especificam as alterações a serem feitas na tabela do Iceberg, incluindo modificações no esquema, especificações de partição e propriedades da tabela.

Estrutura IcebergSortOrder

Define a especificação da ordem de classificação para uma tabela do Iceberg, determinando como os dados deverão ser ordenados nas partições para otimizar o desempenho da consulta.

Campos

- `OrderId`: obrigatório: número (inteiro).

  O identificador exclusivo para essa especificação de ordem de classificação nos metadados da tabela do Iceberg.
- `Fields` – Obrigatório: uma matriz de objetos IcebergSortField.

  A lista de campos e suas direções de classificação que definem os critérios de ordenação dos dados da tabela do Iceberg.

Estrutura IcebergSortField

Define um único campo dentro de uma especificação de ordem de classificação do Iceberg, incluindo o campo de origem, transformação, direção de classificação e ordenação de valores nulos.

Campos

- `SourceId`: obrigatório: número (inteiro).

  O identificador do campo de origem do esquema da tabela no qual esse campo de classificação se baseia.
- `Transform` – Obrigatório: string UTF-8.

  A função de transformação aplicada ao campo de origem antes da classificação, como identidade, bucket ou truncar.
- `Direction` – Obrigatório: string UTF-8 (valores válidos: `asc="ASC"` | `desc="DESC"`).

  A direção de classificação desse campo, ascendente ou descendente.
- `NullOrder` – Obrigatório: string UTF-8 (valores válidos: `nulls-first="NULLS_FIRST"` | `nulls-last="NULLS_LAST"`).

  O comportamento de ordenação para os valores nulos nesse campo, especificando se os nulos devem aparecer primeiro ou por último na ordem de classificação.

Estrutura IcebergPartitionSpec

Define a especificação de particionamento para uma tabela do Iceberg, determinando como os dados da tabela serão organizados e particionados para um desempenho ideal de consulta.

Campos

- `Fields` – Obrigatório: uma matriz de objetos IcebergPartitionField.

  A lista de campos de partição que definem como os dados da tabela deverão ser particionados, incluindo campos de origem e suas transformações.
- `SpecId` – Número (íntegro).

  O identificador exclusivo para essa especificação de partição no histórico de metadados da tabela do Iceberg.

Estrutura IcebergPartitionField

Define um único campo de partição dentro de uma especificação de partição do Iceberg, incluindo o campo de origem, a função de transformação, o nome da partição e o identificador exclusivo.

Campos

- `SourceId`: obrigatório: número (inteiro).

  O identificador do campo de origem do esquema da tabela no qual esse campo de partição se baseia.
- `Transform` – Obrigatório: string UTF-8.

  A função de transformação aplicada ao campo de origem para criar a partição, como identidade, bucket, truncar, ano, mês, dia ou hora.
- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 1024 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do campo de partição conforme ele aparecerá na estrutura da tabela particionada.
- `FieldId` – Número (íntegro).

  O identificador exclusivo atribuído a esse campo de partição na especificação de partição da tabela do Iceberg.

Estrutura IcebergSchema

Define a estrutura do esquema para uma tabela do Iceberg, incluindo definições de campo, tipos de dados e metadados do esquema.

Campos

- `SchemaId` – Número (íntegro).

  O identificador exclusivo dessa versão do esquema no histórico de evolução do esquema da tabela do Iceberg.
- `IdentifierFieldIds` – Uma matriz de números inteiros de 32 bits com sinal.

  A lista de identificadores de campo que identificam exclusivamente os registros na tabela, usados para operações no nível de linha e desduplicação.
- `Type` – String UTF-8 (valores válidos: `struct="STRUCT"`).

  O tipo de raiz da estrutura do esquema, normalmente “struct” para esquemas de tabela do Iceberg.
- `Fields` – Obrigatório: uma matriz de objetos IcebergStructField.

  A lista de definições de campo que compõem o esquema da tabela, incluindo nomes, tipos e metadados de campo.

Estrutura IcebergStructField

Define um único campo em um esquema de tabela do Iceberg, incluindo seu identificador, nome, tipo de dados, nulidade e documentação.

Campos

- `Id`: obrigatório: número (inteiro).

  O identificador exclusivo atribuído a esse campo no esquema de tabela do Iceberg, usado para evolução do esquema e rastreamento de campo.
- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 1024 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do campo conforme ele aparece no esquema da tabela e nas operações de consulta.
- `Type` – obrigatório: uma estrutura vazia chamada `IcebergDocument`.

  A definição do tipo de dados para esse campo, especificando a estrutura e o formato dos dados que ele contém.
- `Required`: obrigatório: booleano.

Indica se esse campo é obrigatório (não passível de anulação) ou opcional (passível de anulação) no esquema da tabela.

- `Doc` – String de comentário, inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Texto opcional descritivo ou de documentação que fornece contexto adicional sobre a finalidade e o uso deste campo.

Estrutura IcebergTableUpdate

Define um conjunto completo de atualizações a serem aplicadas a uma tabela do Iceberg, incluindo alterações de esquema, modificações de particionamento, ajustes de ordem de classificação, atualizações de localização e alterações de propriedades.

Campos

- `Schema` – Obrigatório: um objeto IcebergSchema.

  A definição de esquema atualizada para a tabela do Iceberg, especificando quaisquer alterações na estrutura do campo, nos tipos de dados ou nos metadados do esquema.

- `PartitionSpec` – Um objeto IcebergPartitionSpec.

  A especificação de particionamento atualizada que define como os dados da tabela devem ser reorganizados e particionados.

- `SortOrder` – Um objeto IcebergSortOrder.

  A especificação atualizada da ordem de classificação que define como os dados deverão ser ordenados nas partições para um desempenho ideal de consulta.

- `Location`: – obrigatório: string de local com não mais do que 2.056 bytes de comprimento, combinando com URI address multi-line string pattern.

  O local atualizado no S3 onde os dados de tabelas do Iceberg serão armazenados.

- `Properties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

Pares atualizados de chave e valor de propriedades de tabela e definições de configuração para a tabela do Iceberg.

Operações

- Ação CreateTable (Python: create_table)
- Ação UpdateTable (Python: update_table)
- Ação DeleteTable (Python: delete_table)
- Ação BatchDeleteTable (Python: batch_delete_table)
- Ação GetTable (Python: get_table)
- Ação GetTables (Python: get_tables)
- Ação GetTableVersion (Python: get_table_version)
- Ação GetTableVersions (Python: get_table_versions)
- Ação DeleteTableVersion (Python: delete_table_version)
- Ação BatchDeleteTableVersion (Python: batch_delete_table_version)
- Ação SearchTables (Python: search_tables)
- Ação GetPartitionIndexes (Python: get_partitions_indexes)
- Ação CreatePartitionIndex (Python: create_partition_index)
- Ação DeletePartitionIndex (Python: delete_partition_index)
- Ação GetColumnStatisticsForTable (Python: get_column_statistics_for_table)
- Ação UpdateColumnStatisticsForTable (Python: update_column_statistics_for_table)
- Ação DeleteColumnStatisticsForTable (Python: delete_column_statistics_for_table)

Ação CreateTable (Python: create_table)

Cria uma definição de nova tabela no catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que a `Table` será criada. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O banco de dados do catálogo em que a nova tabela será criada. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da tabela no banco de dados especificado que será criado no Catálogo de Dados do AWS Glue.

- `TableInput` – Obrigatório: um objeto TableInput.

  O objeto `TableInput` que define a tabela de metadados a ser criada no catálogo.

- `PartitionIndexes`: uma matriz de objetos PartitionIndex, não mais do que três estruturas.

  Uma lista de índices de partição, estruturas `PartitionIndex`, para criar na tabela.

- `TransactionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #43.

  O ID da transação.

- `OpenTableFormatInput` – Um objeto OpenTableFormatInput.

  Especifica uma estrutura `OpenTableFormatInput` ao criar uma tabela de formato aberto.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AlreadyExistsException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`

- `GlueEncryptionException`
- `ConcurrentModificationException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação UpdateTable (Python: update_table)

Atualiza uma tabela de metadados no catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a tabela. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual a tabela reside. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da tabela no banco de dados especificado que será criado no Catálogo de Dados do AWS Glue.
- `TableInput` – Um objeto TableInput.

  O objeto `TableInput` atualizado que define a tabela de metadados no catálogo.
- `SkipArchive` – Booleano.

  Por padrão, o `UpdateTable` sempre cria uma versão arquivada da tabela antes de atualizá-la. No entanto, se `skipArchive` estiver definido como true, `UpdateTable` não cria a versão arquivada.
- `TransactionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #43.

O ID da transação na qual atualizar o conteúdo da tabela.

- `VersionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da versão na qual atualizar o conteúdo da tabela.

- `ViewUpdateAction` – String UTF-8 (valores válidos: `ADD` | `REPLACE` | `ADD_OR_REPLACE` | `DROP`).

  A operação a ser executada ao atualizar a visualização.

- `Force` – Booleano.

  Um sinalizador que pode ser definido como verdadeiro para ignorar os requisitos correspondentes de correspondência do descritor de armazenamento e do subobjeto.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`
- `AlreadyExistsException`

Ação DeleteTable (Python: delete_table)

Remove uma definição de tabela do catálogo de dados.

> **Note**
>
> Depois de concluir essa operação, você não terá mais acesso às partições e versões de tabela que pertençam à tabela excluída. O AWS Glue exclui esses recursos "órfãos" de forma assíncrona e pontual, a critério do serviço.
> Para garantir a exclusão imediata de todos os recursos relacionados, antes de chamar `DeleteTable`, use `DeleteTableVersion` ou `BatchDeleteTableVersion`, e `DeletePartition` ou `BatchDeletePartition`, para excluir qualquer recurso que pertence à tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a tabela. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual a tabela reside. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome da tabela a ser excluída. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `TransactionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #43.

  O ID da transação na qual excluir o conteúdo da tabela.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação BatchDeleteTable (Python: batch_delete_table)

Exclui várias tabelas ao mesmo tempo.

> **Note**
>
> Depois de concluir essa operação, você não terá mais acesso às partições e versões de tabela que pertençam à tabela excluída. O AWS Glue exclui esses recursos "órfãos" de forma assíncrona e pontual, a critério do serviço.
> Para garantir a exclusão imediata de todos os recursos relacionados, antes de chamar `BatchDeleteTable`, use `DeleteTableVersion` ou `BatchDeleteTableVersion`, e `DeletePartition` ou `BatchDeletePartition`, para excluir qualquer recurso que pertence à tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a tabela. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome do banco de dados de catálogo no qual as tabelas a serem excluídas residem. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.

- `TablesToDelete` – Obrigatório: uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista da tabela a ser excluída.

- `TransactionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #43.

  O ID da transação na qual excluir o conteúdo da tabela.

Resposta

- `Errors`: um array de objetos TableError.

  Uma lista de erros encontrados na tentativa de excluir as tabelas especificadas.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ResourceNotReadyException`

Ação GetTable (Python: get_table)

Recupera a definição da `Table` em um catálogo de dados para uma tabela especificada.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a tabela. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no catálogo em que a tabela reside. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela para o qual recuperar a definição. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `TransactionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #43.

  O ID da transação na qual ler o conteúdo da tabela.
- `QueryAsOfTime` – Timestamp.

  A hora de ler o conteúdo da tabela. Se não estiver definido, o tempo de confirmação de transação mais recente será usado. Não pode ser especificado junto com `TransactionId`.
- `IncludeStatusDetails` – Booleano.

  Especifica se devem ser incluídos detalhes de status relacionados a uma solicitação para criar ou atualizar uma exibição do Catálogo de Dados do AWS Glue.

Resposta

- `Table` – Um objeto Tabela.

  O objeto `Table` que define a tabela especificada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `ResourceNotReadyException`

- `FederationSourceException`
- `FederationSourceRetryableException`

Ação GetTables (Python: get_tables)

Recupera as definições de algumas ou todas as tabelas em um determinado `Database`.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as tabelas. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O banco de dados no catálogo cujas tabelas serão listadas. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `Expression`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a Single-line string pattern.

  Um padrão de expressão regular. Se presente, apenas as tabelas cujos nomes correspondem ao padrão serão retornadas.
- `NextToken` – String UTF-8.

  Um token de continuação, incluído se esta for uma chamada de continuação.
- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 100.

  O número máximo de tabelas a serem retornados em uma única resposta.
- `TransactionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #43.

  O ID da transação na qual ler o conteúdo da tabela.
- `QueryAsOfTime` – Timestamp.

  A hora de ler o conteúdo da tabela. Se não estiver definido, o tempo de confirmação de transação mais recente será usado. Não pode ser especificado junto com `TransactionId`.

- `IncludeStatusDetails` – Booleano.

  Especifica se devem ser incluídos detalhes de status relacionados a uma solicitação para criar ou atualizar uma exibição do Catálogo de Dados do AWS Glue.

- `AttributesToGet` – Uma matriz de strings UTF-8.

  Especifica os campos do banco de dados retornados pela chamada `GetTables`. Esse parâmetro não aceita uma lista vazia. A solicitação deve incluir `NAME`.

  As seguintes combinações de valores são válidas:

  - `NAME`: nomes de todas as tabelas no banco de dados.
  - `NAME`, `TABLE_TYPE`: nomes de todas as tabelas e dos tipos de tabelas.

Resposta

- `TableList`: um array de objetos Tabela.

  Uma lista de objetos `Table` solicitados.

- `NextToken` – String UTF-8.

  Um token de continuação, presente se o segmento de lista atual não for o último.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação GetTableVersion (Python: get_table_version)

Recupera uma versão especificada de uma tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as tabelas. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O banco de dados no catálogo em que a tabela reside. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.

- `VersionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O valor de ID da versão de tabela a ser recuperada. Um `VersionID` é uma representação em string de um inteiro. Cada versão é incrementada em 1.

Resposta

- `TableVersion` – Um objeto TableVersion.

  A versão da tabela solicitada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação GetTableVersions (Python: get_table_versions)

Recupera uma lista de strings que identificam as versões disponíveis de uma tabela especificada.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as tabelas. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O banco de dados no catálogo em que a tabela reside. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta não for a primeira chamada.
- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 100.

  O número máximo de versões de tabela a ser retornado em uma resposta.

Resposta

- `TableVersions`: um array de objetos TableVersion.

  Uma lista de strings identificando versões disponíveis da tabela especificada.
- `NextToken` – String UTF-8.

  Um token de continuação, se a lista de versões disponíveis não incluir o último token.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação DeleteTableVersion (Python: delete_table_version)

Exclui uma versão especificada de uma tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as tabelas. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O banco de dados no catálogo em que a tabela reside. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `VersionId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da versão de tabela a ser excluída. Um `VersionID` é uma representação em string de um inteiro. Cada versão é incrementada em 1.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação BatchDeleteTableVersion (Python: batch_delete_table_version)

Exclui um lote especificado de versões de uma tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as tabelas. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O banco de dados no catálogo em que a tabela reside. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela. Para a compatibilidade com o Hive, o nome deve ser inserido todo em letras minúsculas.
- `VersionIds` – Obrigatório: uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista dos IDs das versões a serem excluídas. Um `VersionId` é uma representação em string de um inteiro. Cada versão é incrementada em 1.

Resposta

- `Errors`: um array de objetos TableVersionError.

  Uma lista de erros encontrados durante a tentativa de excluir as versões de tabela especificadas.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação SearchTables (Python: search_tables)

Pesquisa um conjunto de tabelas com base nas propriedades dos metadados da tabela, bem como no banco de dados pai. Você pode pesquisar condições de texto ou filtro.

Você só pode obter tabelas às quais tem acesso com base nas políticas de segurança definidas no Lake Formation. Você precisa de pelo menos um acesso somente leitura à tabela para que ela seja retornada. Se você não tiver acesso a todas as colunas na tabela, essas colunas não serão pesquisadas ao retornar a lista de tabelas de volta para você. Se você tiver acesso às colunas, mas não aos dados nas colunas, essas colunas e os metadados associados a essas colunas serão incluídos na pesquisa.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Um identificador exclusivo, que consiste em *`account_id`*.
- `NextToken` – String UTF-8.

  Um token de continuação, incluído se esta for uma chamada de continuação.
- `Filters`: um array de objetos PropertyPredicate.

  Uma lista de pares de chave/valor e um comparador usado para filtrar os resultados da pesquisa. Retorna todas as entidades correspondentes ao predicado.

O membro `Comparator` da estrutura `PropertyPredicate` é usado apenas para campos de tempo, e pode ser omitido para outros tipos de campo. Além disso, ao comparar valores de string, como quando `Key=Name`, um algoritmo de correspondência difusa é usado. O campo `Key` (por exemplo, o valor do campo `Name`) é dividido em tokens em certos caracteres de pontuação, por exemplo, -, :, # etc. Em seguida, cada token é comparado por correspondência exata com o membro `Value` de `PropertyPredicate`. Por exemplo, se `Key=Name` e `Value=link`, as tabelas denominadas `customer-link` e `xx-link-yy` são retornadas, mas `xxlinkyy` não é.

- `SearchText`: string Value com no mínimo 1 e no máximo 1.024 bytes de comprimento.

  Uma string usada para uma pesquisa de texto.

  Especificar um valor em filtros de aspas com base em uma correspondência exata com o valor.

- `SortCriteria`: uma matriz de objetos SortCriterion, não mais do que uma estrutura.

  Uma lista de critérios para classificar os resultados por um nome de campo, em uma ordem crescente ou decrescente.

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de tabelas a serem retornados em uma única resposta.

- `ResourceShareType` – String UTF-8 (valores válidos: `FOREIGN` | `ALL` | `FEDERATED`).

  Permite que você especifique que deseja pesquisar as tabelas compartilhadas com sua conta. Os valores permitidos são `FOREIGN` ou `ALL`.

  - Se definido como `FOREIGN`, listará as tabelas compartilhadas com sua conta.
  - Se definido como `ALL`, listará as tabelas compartilhadas com sua conta, bem como as tabelas em sua conta local.

- `IncludeStatusDetails` – Booleano.

  Especifica se devem ser incluídos detalhes de status relacionados a uma solicitação para criar ou atualizar uma exibição do Catálogo de Dados do AWS Glue.

Resposta

- `NextToken` – String UTF-8.

  Um token de continuação, presente se o segmento de lista atual não for o último.

- `TableList`: um array de objetos Tabela.

  Uma lista de objetos `Table` solicitados. A resposta `SearchTables` retorna apenas as tabelas às quais você tem acesso.

Erros

- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação GetPartitionIndexes (Python: get_partitions_indexes)

Recupera os índices de partição associados a uma tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo no qual reside a tabela.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Especifica o nome de um banco de dados a partir do qual você deseja recuperar índices de partição.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Especifica o nome de uma tabela para a qual você deseja recuperar os índices da partição.
- `NextToken` – String UTF-8.

  Um token de continuação, incluído se esta for uma chamada de continuação.

Resposta

- `PartitionIndexDescriptorList`: um array de objetos PartitionIndexDescriptor.

Uma lista de descritores de índice.

- `NextToken` – String UTF-8.

  Um token de continuação, presente se o segmento de lista atual não for o último.

Erros

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ConflictException`

Ação CreatePartitionIndex (Python: create_partition_index)

Cria um índice de partição especificado em uma tabela existente.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo no qual reside a tabela.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Especifica o nome de um banco de dados no qual você deseja criar um índice de partição.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Especifica o nome de uma tabela na qual você deseja criar um índice de partição.

- `PartitionIndex` – Obrigatório: um objeto PartitionIndex.

  Especifica uma estrutura `PartitionIndex` para criar um índice de partição em uma tabela existente.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AlreadyExistsException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação DeletePartitionIndex (Python: delete_partition_index)

Exclui um índice de partição especificado de uma tabela existente.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo no qual reside a tabela.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Especifica o nome de um banco de dados do qual você deseja excluir um índice de partição.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Especifica o nome de uma tabela da qual você deseja excluir um índice de partição.
- `IndexName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do índice de partição a ser excluído.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `EntityNotFoundException`
- `ConflictException`
- `GlueEncryptionException`

Ação GetColumnStatisticsForTable (Python: get_column_statistics_for_table)

Recupera estatísticas de tabelas das colunas.

A permissão de Identity and Access Management (IAM) necessária para essa operação é `GetTable`.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual as partições residem.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela das partições.
- `ColumnNames` – Obrigatório: uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista de nomes de coluna.

Resposta

- `ColumnStatisticsList`: um array de objetos ColumnStatistics.

  Lista de ColumnStatistics.
- `Errors`: um array de objetos ColumnError.

  Lista de ColumnStatistics cuja recuperação falhou.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação UpdateColumnStatisticsForTable (Python: update_column_statistics_for_table)

Cria ou atualiza estatísticas de tabela das colunas.

A permissão de Identity and Access Management (IAM) necessária para essa operação é `UpdateTable`.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual as partições residem.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome da tabela das partições.

- `ColumnStatisticsList` – Obrigatório: uma matriz de objetos ColumnStatistics, não mais de 25 estruturas.

  Uma lista de estatísticas de coluna.

Resposta

- `Errors`: um array de objetos ColumnStatisticsError.

  Lista de ColumnStatisticsErrors.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação DeleteColumnStatisticsForTable (Python: delete_column_statistics_for_table)

Recupera estatísticas de tabelas das colunas.

A permissão de Identity and Access Management (IAM) necessária para essa operação é `DeleteTable`.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome do banco de dados de catálogos no qual as partições residem.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela das partições.

- `ColumnName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da coluna.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

API de partição

A Partição da API descreve os tipos de dados e operações usadas para trabalhar com partições.

Tipos de dados

- Estrutura Partition
- Estrutura PartitionInput
- Estrutura PartitionSpecWithSharedStorageDescriptor
- Estrutura PartitionListComposingSpec
- Estrutura PartitionSpecProxy
- Estrutura PartitionValueList

- Estrutura Segment
- Estrutura PartitionError
- Estrutura BatchUpdatePartitionFailureEntry
- Estrutura BatchUpdatePartitionRequestEntry
- Estrutura StorageDescriptor
- Estrutura SchemaReference
- Estrutura SerDeInfo
- Estrutura SkewedInfo

Estrutura Partition

Representa uma fatia dos dados da tabela.

Campos

- `Values` – Uma matriz de strings UTF-8.

  Os valores da partição.
- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados de catálogo no qual a função será criada.
- `TableName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela do banco de dados na qual criar a partição.
- `CreationTime` – Timestamp.

  A hora em que a partição foi criada.
- `LastAccessTime` – Timestamp.

  A hora em que a partição foi acessada pela última vez.
- `StorageDescriptor` – Um objeto StorageDescriptor.

  Fornece informações sobre o local físico no qual a partição está armazenada.
- `Parameters` – Um array de mapa dos pares de valor-chave.

Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

Esses pares de chave/valor definem parâmetros de partição.

- `LastAnalyzedTime` – Timestamp.

  A última vez em que as estatísticas da coluna foram computadas para esta partição.

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do Data Catalog em que a partição reside.

Estrutura PartitionInput

A estrutura usada para criar e atualizar uma partição.

Campos

- `Values` – Uma matriz de strings UTF-8.

  Os valores da partição. Embora este parâmetro não seja exigido pelo SDK, você deve especificá-lo para uma entrada válida.

  Os valores das chaves da nova partição devem ser passados como uma matriz de objetos String que devem ser classificados na mesma ordem que as chaves de partição que aparecem no prefixo do Amazon S3. Caso contrário, o AWS Glue adicionará os valores às chaves incorretas.

- `LastAccessTime` – Timestamp.

  A hora em que a partição foi acessada pela última vez.

- `StorageDescriptor` – Um objeto StorageDescriptor.

  Fornece informações sobre o local físico no qual a partição está armazenada.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

Esses pares de chave/valor definem parâmetros de partição.

- `LastAnalyzedTime` – Timestamp.

  A última vez em que as estatísticas da coluna foram computadas para esta partição.

Estrutura PartitionSpecWithSharedStorageDescriptor

Uma especificação de partição para partições que compartilham um local físico.

Campos

- `StorageDescriptor` – Um objeto StorageDescriptor.

  As informações do armazenamento físico compartilhado.

- `Partitions`: um array de objetos Partition.

  Uma lista das partições que compartilham este local físico.

Estrutura PartitionListComposingSpec

Lista as partições relacionadas.

Campos

- `Partitions`: um array de objetos Partition.

  Uma lista das partições na especificação de composição.

Estrutura PartitionSpecProxy

Fornece um caminho raiz para as partições especificadas.

Campos

- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O banco de dados de catálogo no qual residem as partições.

- `TableName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela que contém as partições.

- `RootPath` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O caminho raiz do proxy para as partições.

- `PartitionSpecWithSharedSD` – Um objeto PartitionSpecWithSharedStorageDescriptor.

  Uma especificação de partições que compartilham o mesmo local de armazenamento físico.

- `PartitionListComposingSpec` – Um objeto PartitionListComposingSpec.

  Especifica uma lista de partições.

Estrutura PartitionValueList

Contém uma lista dos valores que definem as partições.

Campos

- `Values`: obrigatório: uma matriz de strings UTF-8.

  A lista de valores.

Estrutura Segment

Define uma região não sobreposta das partições de uma tabela, permitindo que várias solicitações sejam executadas simultaneamente.

Campos

- `SegmentNumber` – Obrigatório: número (inteiro), não mais do que Nenhum.

  O número de índice baseado em zero do segmento. Por exemplo, se o número total de segmentos for 4, os valores de `SegmentNumber` vão variar de 0 a 3.

- `TotalSegments` – Obrigatório: número (inteiro), no mínimo 1 ou mais que 10.

O número total de segmentos.

Estrutura PartitionError

Contém informações sobre um erro de partição.

Campos

- `PartitionValues` – Uma matriz de strings UTF-8.

  Os valores que definem a partição.
- `ErrorDetail` – Um objeto ErrorDetail.

  Os detalhes sobre o erro de partição.

Estrutura BatchUpdatePartitionFailureEntry

Contém informações sobre um erro de partição de atualização em lote.

Campos

- `PartitionValueList` – Uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista dos valores que definem as partições.
- `ErrorDetail` – Um objeto ErrorDetail.

  Os detalhes sobre o erro de partição de atualização em lote.

Estrutura BatchUpdatePartitionRequestEntry

Uma estrutura que contém os valores e a estrutura usados para atualizar uma partição.

Campos

- `PartitionValueList` – Obrigatório: uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista dos valores que definem as partições.
- `PartitionInput` – Obrigatório: um objeto PartitionInput.

A estrutura usada para atualizar uma partição.

Estrutura StorageDescriptor

Descreve o armazenamento físico dos dados da tabela.

Campos

- `Columns`: um array de objetos Coluna.

  Uma lista de `Columns` na tabela.
- `Location` – String de local, inferior a 2056 bytes de comprimento, correspondente a URI address multi-line string pattern.

  A localização física da tabela. Por padrão, assume o formato da localização do warehouse, seguida pela localização do banco de dados no warehouse, seguida pelo nome da tabela.
- `AdditionalLocations` – Uma matriz de strings UTF-8.

  Uma lista de locais que apontam para o caminho onde uma tabela do Delta está localizada.
- `InputFormat` – String de formato, inferior a 128 bytes de comprimento, correspondente a Single-line string pattern.

  O formato de entrada: `SequenceFileInputFormat` (binário), `TextInputFormat` ou um formato personalizado.
- `OutputFormat` – String de formato, inferior a 128 bytes de comprimento, correspondente a Single-line string pattern.

  O formato de saída: `SequenceFileOutputFormat` (binário), `IgnoreKeyTextOutputFormat` ou um formato personalizado.
- `Compressed` – Booleano.

  `True` se os dados da tabela estiverem compactados, ou `False` se não estiverem.
- `NumberOfBuckets` – Número (íntegro).

  Você deverá especificar se a tabela contiver qualquer coluna de dimensão.
- `SerdeInfo` – Um objeto SerDeInfo.

  As informações de serialização/desserialização (SerDe).

- `BucketColumns` – Uma matriz de strings UTF-8.

  Uma lista de colunas de agrupamento, armazenamento em clusters e armazenamento em buckets de reducers na tabela.

- `SortColumns`: um array de objetos Ordem.

  Uma lista que especifica a ordem de classificação de cada bucket na tabela.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  As propriedades fornecidas pelo usuário em formato de chave/valor.

- `SkewedInfo` – Um objeto SkewedInfo.

  As informações sobre valores que aparecem com frequência em uma coluna (valores distorcidos).

- `StoredAsSubDirectories` – Booleano.

  `True`, se os dados na tabela estiverem armazenados em subdiretórios, ou `False`, caso contrário.

- `SchemaReference` – Um objeto SchemaReference.

  Um objeto que faz referência a um esquema armazenado no AWS Glue Schema Registry.

  Ao criar uma tabela, você pode passar uma lista vazia de colunas para o esquema e, em vez disso, usar uma referência de esquema.

Estrutura SchemaReference

Um objeto que faz referência a um esquema armazenado no AWS Glue Schema Registry.

Campos

- `SchemaId` – Um objeto SchemaId.

  Uma estrutura que contém campos de identidade de esquema. Esse ou o `SchemaVersionId` tem que ser fornecido.

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID exclusivo atribuído a uma versão do esquema. Esse ou o `SchemaId` tem que ser fornecido.

- `SchemaVersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.

Estrutura SerDeInfo

As informações sobre um programa de serialização/desserialização (SerDe), que serve como extrator e carregador.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome de SerDe.

- `SerializationLibrary` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Normalmente, é a classe que implementa o SerDe. Um exemplo é `org.apache.hadoop.hive.serde2.columnar.ColumnarSerDe`.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string de chave com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string UTF-8 com comprimento não superior a 512.000 bytes.

  Esses pares de chave/valor definem parâmetros de inicialização para SerDe.

Estrutura SkewedInfo

Especifica valores distorcidos em uma tabela. Valores distorcidos são aqueles que ocorrem com muita frequência.

Campos

- `SkewedColumnNames` – Uma matriz de strings UTF-8.

  Uma lista de nomes de colunas que contêm valores distorcidos.

- `SkewedColumnValues` – Uma matriz de strings UTF-8.

  Uma lista de valores que aparecem com tanta frequência que devem ser considerados distorcidos.

- `SkewedColumnValueLocationMaps` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um mapeamento de valores distorcidos para as colunas nas quais estão presentes.

Operações

- Ação CreatePartition (Python: create_partition)
- Ação BatchCreatePartition (Python: batch_create_partition)
- Ação UpdatePartition (Python: update_partition)
- Ação DeletePartition (Python: delete_partition)
- Ação BatchDeletePartition (Python: batch_delete_partition)
- Ação GetPartition (Python: get_partition)
- Ação GetPartitions (Python: get_partitions)
- Ação BatchGetPartition (Python: batch_get_partition)
- Ação BatchUpdatePartition (Python: batch_update_partition)
- Ação GetColumnStatisticsForPartition (Python: get_column_statistics_for_partition)
- Ação UpdateColumnStatisticsForPartition (Python: update_column_statistics_for_partition)
- Ação DeleteColumnStatisticsForPartition (Python: delete_column_statistics_for_partition)

Ação CreatePartition (Python: create_partition)

Cria uma nova partição.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da conta da AWS do catálogo no qual a partição deve ser criada.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de metadados no qual a partição deve ser criada.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela de metadados na qual a partição deve ser criada.
- `PartitionInput` – Obrigatório: um objeto PartitionInput.

  Uma estrutura `PartitionInput` que define a partição a ser criada.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação BatchCreatePartition (Python: batch_create_partition)

Cria uma ou mais partições em uma operação em lote.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo no qual a partição deve ser criada. No momento, deve ser o ID da conta da AWS.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de metadados no qual a partição deve ser criada.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela de metadados na qual a partição deve ser criada.
- `PartitionInputList` – Obrigatório: uma matriz de objetos PartitionInput, não mais de 100 estruturas.

  Uma lista das estruturas `PartitionInput` que definem as partições a serem criadas.

Resposta

- `Errors`: um array de objetos PartitionError.

  Os erros encontrados ao tentar criar as partições solicitadas.

Erros

- `InvalidInputException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação UpdatePartition (Python: update_partition)

Atualiza uma partição.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a partição a ser atualizada. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual a tabela em questão reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela de metadados na qual a partição a ser atualizada está localizada.
- `PartitionValueList` – Obrigatório: uma matriz de strings UTF-8, no máximo 100 strings.

  Lista de valores de chaves-valor de partição que definem a partição a ser atualizada.
- `PartitionInput` – Obrigatório: um objeto PartitionInput.

  O novo objeto de partição para o qual a partição será atualizada.

  A propriedade `Values` não pode ser alterada. Se você quiser alterar as chaves-valor de uma partição, exclua e recrie a partição.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

- `OperationTimeoutException`
- `GlueEncryptionException`

Ação DeletePartition (Python: delete_partition)

Exclui uma partição especificada.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a partição a ser excluída. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual a tabela em questão reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela que contém a partição a ser excluída.
- `PartitionValues`: obrigatório: uma matriz de strings UTF-8.

  Os valores que definem a partição.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação BatchDeletePartition (Python: batch_delete_partition)

Exclui uma ou mais partições em uma operação em lote.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a partição a ser excluída. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual a tabela em questão reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela que contém as partições a serem excluídas.
- `PartitionsToDelete` – Obrigatório: uma matriz de objetos PartitionValueList, não mais de 25 estruturas.

  Uma lista das estruturas `PartitionInput` que definem as partições a serem excluídas.

Resposta

- `Errors`: um array de objetos PartitionError.

  Os erros encontrados ao tentar excluir as partições solicitadas.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetPartition (Python: get_partition)

Recupera informações sobre uma partição especificada.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a partição em questão. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual a partição reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela da partição.
- `PartitionValues`: obrigatório: uma matriz de strings UTF-8.

  Os valores que definem a partição.

Resposta

- `Partition` – Um objeto Partition.

  A informação solicitada, na forma de um objeto `Partition`.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`
- `FederationSourceException`

- `FederationSourceRetryableException`

Ação GetPartitions (Python: get_partitions)

Recupera informações sobre as partições em uma tabela.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual as partições residem.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela das partições.
- `Expression` – String de predicado, inferior a 2048 bytes de comprimento, correspondente a URI address multi-line string pattern.

  Uma expressão que filtra as partições a serem retornadas.

  A expressão usa sintaxe SQL semelhante à cláusula de filtro SQL `WHERE`. O analisador de instrução SQL JSQLParser analisa a expressão.

  Operadores: estes são os operadores que você pode usar na chamada de API `Expression`:

  =

  Verifica se os valores dos dois operandos são iguais. Em caso afirmativo, a condição é verdadeira.

  Exemplo: suponha que a "variável a" seja 10 e a "variável b" 20.

  (a = b) não é verdadeiro.

< >

Verifica se os valores dos dois operandos são iguais. Se os valores não forem iguais, a condição será verdadeira.

Exemplo: (a **< >** b) é verdadeiro.

>

Verifica se o valor do operando esquerdo é maior que o valor do operando direito. Em caso afirmativo, a condição é verdadeira.

Exemplo: (a **>** b) não é verdadeiro.

<

Verifica se o valor do operando esquerdo é menor que o valor do operando direito. Em caso afirmativo, a condição é verdadeira.

Exemplo: (a **<** b) é verdadeiro.

>=

Verifica se o valor do operando esquerdo é maior ou igual ao valor do operando direito. Em caso afirmativo, a condição é verdadeira.

Exemplo: (a **>=** b) não é verdadeiro.

<=

Verifica se o valor do operando esquerdo é menor ou igual ao valor do operando direito. Em caso afirmativo, a condição é verdadeira.

Exemplo: (a {**<=** b) é verdadeiro.

AND, OR, IN, BETWEEN, LIKE, NOT, IS NULL

Operadores lógicos.

Tipos de chave de partição compatíveis: veja a seguir as chaves de partição compatíveis.

- `string`
- `date`
- `timestamp`

- `int`
- `bigint`
- `long`
- `tinyint`
- `smallint`
- `decimal`

Se um tipo que não seja válido for encontrado, uma exceção será lançada.

A lista a seguir mostra os operadores válidos em cada tipo. Quando você define um crawler, o tipo `partitionKey` é criado como um `STRING`, para ser compatível com as partições do catálogo.

Exemplo de chamada de API:

Example

A tabela `twitter_partition` tem três partições:

```
year = 2015
        year = 2016
        year = 2017
```

Example

Obter `year` da partição igual a 2015

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
        --expression "year*=*'2015'"
```

Example

Obter `year` da partição entre 2016 e 2018 (exclusivo)

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
        --expression "year>'2016' AND year<'2018'"
```

Example

Obtenha o `year` da partição entre 2015 e 2018 (inclusivo). As seguintes chamadas de API são equivalentes entre si:

```
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)"
```

Example

Um filtro de partição curinga, onde a saída de chamada a seguir terá o ano de partição = 2017. Uma expressão regular não é suportada em `LIKE`.

```
aws glue get-partitions --database-name dbname --table-name twitter_partition
        --expression "year LIKE '%7'"
```

- `NextToken` – String UTF-8.

  Um token de continuação, se esta não for a primeira chamada para recuperar essas partições.

- `Segment` – Um objeto Segment.

  O segmento de partições da tabela a ser verificado nesta solicitação.

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de partições a serem retornados em uma única resposta.

- `ExcludeColumnSchema` – Booleano.

  Quando verdadeiro, especifica não retornar o esquema da coluna de partição. Útil quando você está interessado apenas em outros atributos de partição, como valores ou localização de partição. Essa abordagem evita o problema de uma resposta grande ao não retornar dados duplicados.

- `TransactionId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #43.

  O ID da transação na qual ler o conteúdo da partição.

- `QueryAsOfTime` – Timestamp.

  A hora de ler o conteúdo da partição. Se não estiver definido, o tempo de confirmação de transação mais recente será usado. Não pode ser especificado junto com `TransactionId`.

Resposta

- `Partitions`: um array de objetos Partition.

  Uma lista de partições solicitadas.

- `NextToken` – String UTF-8.

  Um token de continuação, se a lista de partições retornada não incluir o último token.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `InvalidStateException`
- `ResourceNotReadyException`
- `FederationSourceException`
- `FederationSourceRetryableException`

Ação BatchGetPartition (Python: batch_get_partition)

Recupera partições em uma solicitação de lote.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual as partições residem.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela das partições.
- `PartitionsToGet` – Obrigatório: uma matriz de objetos PartitionValueList, não mais de 1000 estruturas.

  Uma lista de valores de partição que identifica as partições a serem recuperadas.

Resposta

- `Partitions`: um array de objetos Partition.

  Uma lista das partições solicitadas.
- `UnprocessedKeys` – Uma matriz de objetos PartitionValueList, não mais de 1000 estruturas.

  Uma lista dos valores de partição na solicitação para a qual as partições não foram retornadas.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`
- `InvalidStateException`

- `FederationSourceException`
- `FederationSourceRetryableException`

Ação BatchUpdatePartition (Python: batch_update_partition)

Atualiza uma ou mais partições em uma operação em lote.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo no qual a partição deve ser atualizada. No momento, deve ser o ID da conta da AWS.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de metadados no qual a partição deve ser atualizada.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela de metadados na qual a partição deve ser atualizada.
- `Entries`: obrigatório: uma matriz de objetos BatchUpdatePartitionRequestEntry, com número de estruturas entre 1 e 100.

  Uma lista de até 100 objetos `BatchUpdatePartitionRequestEntry` a serem atualizados.

Resposta

- `Errors`: um array de objetos BatchUpdatePartitionFailureEntry.

  Os erros encontrados ao tentar atualizar as partições solicitadas. Uma lista dos objetos `BatchUpdatePartitionFailureEntry`.

Erros

- `InvalidInputException`
- `EntityNotFoundException`

- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`

Ação GetColumnStatisticsForPartition (Python: get_column_statistics_for_partition)

Recupera estatísticas de partição das colunas.

A permissão de Identity and Access Management (IAM) necessária para essa operação é `GetPartition`.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual as partições residem.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela das partições.
- `PartitionValues`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de valores de partição que identifica a partição.
- `ColumnNames` – Obrigatório: uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista de nomes de coluna.

Resposta

- `ColumnStatisticsList`: um array de objetos ColumnStatistics.

  Lista de ColumnStatistics cuja recuperação falhou.

- `Errors`: um array de objetos ColumnError.

  Ocorreu um erro durante a recuperação de dados de estatísticas de coluna.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação UpdateColumnStatisticsForPartition (Python: update_column_statistics_for_partition)

Cria ou atualiza estatísticas de partição de colunas.

A permissão de Identity and Access Management (IAM) necessária para essa operação é `UpdatePartition`.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual as partições residem.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela das partições.
- `PartitionValues`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de valores de partição que identifica a partição.

- `ColumnStatisticsList` – Obrigatório: uma matriz de objetos ColumnStatistics, não mais de 25 estruturas.

  Uma lista de estatísticas de coluna.

Resposta

- `Errors`: um array de objetos ColumnStatisticsError.

  Ocorreu um erro durante a atualização de dados de estatísticas de coluna

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação DeleteColumnStatisticsForPartition (Python: delete_column_statistics_for_partition)

Exclui as estatísticas de coluna de partição de uma coluna.

A permissão de Identity and Access Management (IAM) necessária para essa operação é `DeletePartition`.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual residem as partições em questão. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual as partições residem.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela das partições.

- `PartitionValues`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de valores de partição que identifica a partição.

- `ColumnName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da coluna.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

API de conexões

A API de conexões descreve os tipos de dados e a API relacionados a trabalhar com conexões no AWS Glue.

Tópicos

- API de conexão
- API de tipos de conexão
- Metadados de conexão e API de visualização

API de conexão

A API de conexão descreve os tipos de dados de conexão do AWS Glue e a API para criar, excluir, atualizar e listar conexões.

Tipos de dados

- Estrutura Connection
- Estrutura ConnectionInput
- Estrutura TestConnectionInput
- Estrutura PhysicalConnectionRequirements
- Estrutura GetConnectionsFilter
- Estrutura AuthenticationConfiguration
- Estrutura AuthenticationConfigurationInput
- Estrutura OAuth2Properties
- Estrutura OAuth2PropertiesInput
- Estrutura OAuth2ClientApplication
- Estrutura AuthorizationCodeProperties
- Estrutura BasicAuthenticationCredentials
- Estrutura OAuth2Credentials

Estrutura Connection

Define uma conexão para uma fonte de dados.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da definição da conexão.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A descrição da conexão.

- `ConnectionType`: string UTF-8 (valores válidos: `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`).

  O tipo da conexão. No momento, o SFTP não é compatível.

- `MatchCriteria` – Uma matriz de strings UTF-8, no máximo 10 strings.

  Uma lista de critérios que podem ser usados na seleção dessa conexão.

- `ConnectionProperties`: um array de mapa dos pares de chave-valor com não mais do que 100 pares.

  Cada chave é uma string UTF-8 (valores válidos: `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`).

  Cada chave é uma string Value com no mínimo 1 e no máximo 1.024 bytes de comprimento.

  Esses pares de chave-valor definem parâmetros para a conexão ao usar o esquema de conexão versão 1:

- HOST - O URI do host: o nome de domínio totalmente qualificado (FQDN) ou o endereço IPv4 do host do banco de dados.
- PORT - O número da porta, entre 1024 e 65535, da porta na qual o host do banco de dados está escutando conexões de banco de dados.
- USER_NAME - O nome com o qual realizar login no banco de dados. O valor da string para USER_NAME é "USERNAME".
- PASSWORD - Uma senha, se for usada, para o nome do usuário.
- ENCRYPTED_PASSWORD - Ao habilitar a proteção por senha de conexão, definindo as configurações de criptografia ConnectionPasswordEncryption no Catálogo de dados, este campo armazena a senha criptografada.
- JDBC_DRIVER_JAR_URI – o caminho do Amazon Simple Storage Service (Amazon S3) do arquivo JAR que contém o driver JDBC a ser usado.
- JDBC_DRIVER_CLASS_NAME - A classe do nome do driver do JDBC a ser usado.
- JDBC_ENGINE - O nome do mecanismo JDBC a ser usado.
- JDBC_ENGINE_VERSION - A versão do nome do mecanismo JDBC a ser usado.
- CONFIG_FILES – (reservado para uso futuro.)
- INSTANCE_ID - O ID da instância a ser usada.
- JDBC_CONNECTION_URL – o URL para conexão com uma fonte de dados JDBC.
- JDBC_ENFORCE_SSL: uma string boleana que não diferencia maiúsculas de minúsculas (true, false), que especifica se a correspondência do Secure Sockets Layer (SSL) com o nome do host será aplicada para a conexão JDBC no cliente. O padrão é falso.
- CUSTOM_JDBC_CERT: um local do Amazon S3 que especifica o certificado raiz do cliente. O AWS Glue usa esse certificado raiz para validar o certificado do cliente ao se conectar ao banco de dados do cliente. O AWS Glue processa somente certificados X.509. O certificado fornecido deve ter codificação DER e ser fornecido no formato PEM de codificação Base64.
- SKIP_CUSTOM_JDBC_CERT_VALIDATION: Por padrão, é `false`. O AWS Glue valida o algoritmo de assinatura e o algoritmo de chave pública de requerente para o certificado do cliente. Os únicos algoritmos permitidos para o algoritmo de assinatura são SHA256withRSA, SHA384withRSA ou SHA512withRSA. Para o algoritmo de chave pública do assunto, o comprimento da chave deve ser pelo menos 2048. Você pode definir o valor dessa propriedade como `true` para ignorar a validação do certificado do cliente pelo AWS Glue.
- CUSTOM_JDBC_CERT_STRING — uma string de certificado JDBC personalizado que é usada para correspondência de domínio ou correspondência de nome distinto para evitar um ataque

"man-in-the-middle". No banco de dados Oracle, ela é usada como `SSL_SERVER_CERT_DN`; no Microsoft SQL Server, ela é usada como `hostNameInCertificate`.

- `CONNECTION_URL` – o URL para conexão com uma fonte de dados geral (não JDBC).
- `SECRET_ID`: o ID secreto usado para o gerente secreto de credenciais.
- `CONNECTOR_URL`: o URL do conector para uma conexão MARKETPLACE ou CUSTOM (personalizada).
- `CONNECTOR_TYPE`: o tipo do conector para uma conexão MARKETPLACE ou CUSTOM (personalizada).
- `CONNECTOR_CLASS_NAME`: o nome da classe do conector para uma conexão MARKETPLACE ou CUSTOM (personalizada).
- `KAFKA_BOOTSTRAP_SERVERS` – Uma lista separada por vírgulas de pares de host e porta que são os endereços dos agentes do Apache Kafka em um cluster do Kafka ao qual um cliente Kafka se conectará e se executará o próprio bootstrap.
- `KAFKA_SSL_ENABLED`: para habilitar ou desabilitar o SSL em uma conexão Apache Kafka. O valor padrão é "true" (verdadeiro).
- `KAFKA_CUSTOM_CERT`: o URL do Amazon S3 para o arquivo de certificado CA privado (formato.pem). O padrão é uma string vazia.
- `KAFKA_SKIP_CUSTOM_CERT_VALIDATION`: para ignorar ou não a validação do arquivo de certificado CA. O AWS Glue valida para três algoritmos: SHA256withRSA, SHA384withRSA e SHA512withRSA. O valor padrão é "false" (falso).
- `KAFKA_CLIENT_KEYSTORE`: a localização do Amazon S3 do arquivo de repositório de chaves do cliente para autenticação do lado do cliente Kafka (opcional).
- `KAFKA_CLIENT_KEYSTORE_PASSWORD`: a senha para acessar o repositório de chaves fornecido (opcional).
- `KAFKA_CLIENT_KEY_PASSWORD`: um repositório de chaves pode consistir em várias chaves, então essa é a senha para acessar a chave do cliente a ser usada com a chave do lado do servidor Kafka (opcional).
- `ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD`: a versão criptografada da senha do repositório de chaves do cliente Kafka (se o usuário tiver a configuração de senhas de criptografia do AWS Glue selecionada).
- `ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD`: a versão criptografada da senha da chave do cliente Kafka (se o usuário tiver a configuração de senhas de criptografia do AWS Glue selecionada).

- KAFKA_SASL_MECHANISM: "SCRAM-SHA-512", "GSSAPI", "AWS_MSK_IAM" ou "PLAIN". Esses são os mecanismos SASL compatíveis.
- KAFKA_SASL_PLAIN_USERNAME: um nome de usuário em texto simples usado para autenticar com o mecanismo "PLAIN".
- KAFKA_SASL_PLAIN_PASSWORD: uma senha em texto simples usado para autenticar com o mecanismo "PLAIN".
- ENCRYPTED_KAFKA_SASL_PLAIN_PASSWORD: a versão criptografada da senha Kafka SASL PLAIN (se o usuário tiver a configuração de senhas de criptografia AWS Glue selecionada).
- KAFKA_SASL_SCRAM_USERNAME - Um nome de usuário em texto simples usado para autenticar com o mecanismo "SCRAM-SHA-512".
- KAFKA_SASL_SCRAM_PASSWORD - Uma senha de texto simples usada para autenticar com o mecanismo "SCRAM-SHA-512".
- ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD - A versão criptografada da senha Kafka SASL SCRAM (se o usuário tiver a configuração de senhas de criptografia AWS Glue selecionada).
- KAFKA_SASL_SCRAM_SECRETS_ARN: o nome do recurso da Amazon de um segredo do AWS Secrets Manager.
- KAFKA_SASL_GSSAPI_KEYTAB - A localização S3 de um arquivo Kerberos `keytab`. Um keytab armazena chaves de longo prazo para um ou mais principais. Para obter mais informações, consulte Documentação do MIT Kerberos: Keytab.
- KAFKA_SASL_GSSAPI_KRB5_CONF - A localização S3 de um arquivo Kerberos `krb5.conf`. Um krb5.conf armazena informações de configuração do Kerberos, como a localização do servidor KDC. Para obter mais informações, consulte Documentação do MIT Kerberos: krb5.conf.
- KAFKA_SASL_GSSAPI_SERVICE - O nome do serviço Kerberos, conforme definido com `sasl.kerberos.service.name` na sua Configuração do Kafka.
- KAFKA_SASL_GSSAPI_PRINCIPAL- O nome do princial Kerberos usado por AWS Glue. Para obter mais informações, consulte Documentação do Kafka: Configurando agentes do Kafka.
- ROLE_ARN: a função a ser usada para executar consultas.
- REGION: a região da AWS onde as consultas serão executadas.
- WORKGROUP_NAME: o nome de um grupo de trabalho do Amazon Redshift sem servidor ou grupo de trabalho do Amazon Athena no qual as consultas serão executadas.
- CLUSTER_IDENTIFIER: o identificador de cluster de um cluster do Amazon Redshift no qual as consultas serão executadas.

  - `DATABASE`: o banco de dados do Amazon Redshift ao qual você está se conectando.
- `SparkProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Propriedades de conexão específicas para o ambiente computacional Spark.
- `AthenaProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Propriedades de conexão específicas para o ambiente computacional Athena.
- `PythonProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Propriedades de conexão específicas para o ambiente computacional Python.
- `PhysicalConnectionRequirements` – Um objeto PhysicalConnectionRequirements.

  Os requisitos de conexão física, como nuvem virtual privada (VPC) e `SecurityGroup`, que são necessários para fazer essa conexão com êxito.
- `CreationTime` – Timestamp.

  A marca de data e hora em que essa definição de conexão foi criada.
- `LastUpdatedTime` – Timestamp.

  A marca de data e hora em que a definição de conexão foi atualizada pela última vez.
- `LastUpdatedBy` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O usuário, grupo ou função que atualizou pela última vez essa definição de conexão.
- `Status` – String UTF-8 (valores válidos: `READY` | `IN_PROGRESS` | `FAILED`).

  O status da conexão. Pode ser `READY`, `IN_PROGRESS` ou `FAILED`.

- `StatusReason`: string UTF-8 com não menos que 1 nem mais que 16.384 bytes de comprimento.

  O motivo do status da conexão.
- `LastConnectionValidationTime` – Timestamp.

  Uma marca de data e hora da última validação dessa conexão.
- `AuthenticationConfiguration` – Um objeto AuthenticationConfiguration.

  As propriedades de autenticação da conexão.
- `ConnectionSchemaVersion`: número (inteiro) não inferior a 1 nem superior a 2.

  A versão do esquema de conexão para esta conexão. A versão 2 oferece suporte a propriedades para ambientes computacionais específicos.
- `CompatibleComputeEnvironments` – Uma matriz de strings UTF-8.

  Uma lista de ambientes computacionais compatíveis com a conexão.

Estrutura ConnectionInput

Uma estrutura usada para especificar uma conexão para criar ou atualizar.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da conexão.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A descrição da conexão.
- `ConnectionType`: Obrigatório: string UTF-8 (valores válidos: `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`).

  O tipo da conexão. No momento, estes tipos são compatíveis:

- JDBC – Designa uma conexão com um banco de dados por meio do Java Database Connectivity (JDBC).

  As conexões de JDBC usam o seguinte ConnectionParameters.

  - Obrigatório: todos (HOST, PORT, JDBC_ENGINE) ou JDBC_CONNECTION_URL.
  - Obrigatório: todos (USERNAME, PASSWORD) ou SECRET_ID.
  - Opcional: JDBC_ENFORCE_SSL, CUSTOM_JDBC_CERT, CUSTOM_JDBC_CERT_STRING, SKIP_CUSTOM_JDBC_CERT_VALIDATION. Esses parâmetros são usados para configurar o SSL com o JDBC.
- KAFKA – Designa uma conexão com uma plataforma de streaming do Apache Kafka.

  As conexões de KAFKA usam o seguinte ConnectionParameters.

  - Obrigatório: KAFKA_BOOTSTRAP_SERVERS.
  - Opcional: KAFKA_SSL_ENABLED, KAFKA_CUSTOM_CERT, KAFKA_SKIP_CUSTOM_CERT_VALIDATION. Esses parâmetros são usados para configurar o SSL com o KAFKA.
  - Opcional: KAFKA_CLIENT_KEYSTORE, KAFKA_CLIENT_KEYSTORE_PASSWORD, KAFKA_CLIENT_KEY_PASSWORD, ENCRYPTED_KAFKA_CLIENT_KEYSTORE_PASSWORD, ENCRYPTED_KAFKA_CLIENT_KEY_PASSWORD. Esses parâmetros são usados para definir a configuração de cliente TLS com SSL no KAFKA.
  - (Opcional): KAFKA_SASL_MECHANISM. Pode ser especificado como SCRAM-SHA-512, GSSAPI ou AWS_MSK_IAM.
  - Opcional: KAFKA_SASL_SCRAM_USERNAME, KAFKA_SASL_SCRAM_PASSWORD, ENCRYPTED_KAFKA_SASL_SCRAM_PASSWORD. Esses parâmetros são usados para configurar a autenticação SASL/SCRAM-SHA-512 com o KAFKA.
  - Opcional: KAFKA_SASL_GSSAPI_KEYTAB, KAFKA_SASL_GSSAPI_KRB5_CONF, KAFKA_SASL_GSSAPI_SERVICE, KAFKA_SASL_GSSAPI_PRINCIPAL. Esses parâmetros são usados para configurar a autenticação SASL/GSSAPI com o KAFKA.
- MONGODB – Designa uma conexão com um banco de dados de documentos do MongoDB.

  As conexões de MONGODB usam o seguinte ConnectionParameters.

  - Obrigatório: CONNECTION_URL.
  - Obrigatório: todos (USERNAME, PASSWORD) ou SECRET_ID.

- VIEW_VALIDATION_REDSHIFT: designa uma conexão usada para validação de visualizações pelo Amazon Redshift.
- VIEW_VALIDATION_ATHENA: designa uma conexão usada para validação de visualizações pelo Amazon Athena.
- NETWORK: designa uma conexão de rede a uma fonte de dados dentro de um ambiente do Amazon Virtual Private Cloud (Amazon VPC).

  As conexões de NETWORK não exigem ConnectionParameters. Em vez disso, forneça PhysicalConnectionRequirements.
- MARKETPLACE: usa as definições de configurações contidas em um conector adquirido de AWS Marketplace para ler e gravar em armazenamentos de dados que não são suportados nativamente pelo AWS Glue.

  As conexões de MARKETPLACE usam o seguinte ConnectionParameters.
  - Obrigatório: CONNECTOR_TYPE, CONNECTOR_URL, CONNECTOR_CLASS_NAME, CONNECTION_URL.
  - Obrigatório para conexões de JDBC CONNECTOR_TYPE: todos (USERNAME, PASSWORD) ou SECRET_ID.
- CUSTOM: usa as definições de configurações contidas em um conector personalizado para ler e gravar em armazenamentos de dados que não são suportados nativamente pelo AWS Glue.

Além disso, há suporte a um ConnectionType para os seguintes conectores SaaS:

- FACEBOOKADS: define uma conexão com o Facebook Ads.
- GOOGLEADS: define uma conexão com o Google Ads.
- GOOGLESHEETS: define uma conexão com o Planilhas Google.
- GOOGLEANALYTICS4: define uma conexão com o Google Analytics 4.
- HUBSPOT: define uma conexão com o HubSpot.
- INSTAGRAMADS: define uma conexão com o Instagram Ads.
- INTERCOM: define uma conexão com a Intercom.
- JIRACLOUD: define uma conexão com o Jira Cloud.
- MARKETO: define uma conexão com o Adobe Marketo Engage.
- NETSUITEERP: define uma conexão com o Oracle NetSuite.
- SALESFORCE: define uma conexão com o Salesforce usando a autenticação OAuth.

- SALESFORCEMARKETINGCLOUD: define uma conexão com a plataforma Salesforce Marketing Cloud.
- SALESFORCEPARDOT: define uma conexão com a plataforma Salesforce Marketing Cloud Account Engagement (MCAE).
- SAPODATA: define uma conexão com o SAP OData.
- SERVICENOW: define uma conexão com a ServiceNow.
- SLACK: define uma conexão com a plataforma Slack.
- SNAPCHATADS: define uma conexão com o Snapchat Ads.
- STRIPE: define uma conexão com a Stripe.
- ZENDESK: define uma conexão com a Zendesk.
- ZOHOCRM: define uma conexão com o Zoho CRM.

Para obter mais informações sobre os parâmetros de conexão necessários para um conector específico, consulte a documentação do conector em Adicionar uma conexão do AWS Glue no Guia do usuário do AWS Glue.

Não há suporte ao SFTP.

Para obter mais informações sobre como ConnectionProperties opcionais são usadas para configurar recursos no AWS Glue, consulte Propriedades da conexão do AWS Glue.

Para obter mais informações sobre como ConnectionProperties opcionais são usadas para configurar recursos no AWS Glue Studio, consulte Usar conectores e conexões.

- MatchCriteria – Uma matriz de strings UTF-8, no máximo 10 strings.

  Uma lista de critérios que podem ser usados na seleção dessa conexão.

- ConnectionProperties: obrigatório: uma matriz de mapa dos pares de chave-valor, no máximo 100 pares.

  Cada chave é uma string UTF-8 (valores válidos: 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).

Cada chave é uma string Value com no mínimo 1 e no máximo 1.024 bytes de comprimento.

Esses pares de chave/valor definem parâmetros para a conexão.

- `SparkProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Propriedades de conexão específicas para o ambiente computacional Spark.
- `AthenaProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Propriedades de conexão específicas para o ambiente computacional Athena.
- `PythonProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Propriedades de conexão específicas para o ambiente computacional Python.
- `PhysicalConnectionRequirements` – Um objeto PhysicalConnectionRequirements.

  Os requisitos de conexão física, como nuvem privada virtual (VPC) e `SecurityGroup`, que são necessários para estabelecer essa conexão com êxito.

- `AuthenticationConfiguration` – Um objeto AuthenticationConfigurationInput.

  As propriedades de autenticação da conexão.

- `ValidateCredentials` – Booleano.

  Um sinalizador para validar as credenciais durante a criação da conexão. O padrão é true (verdadeiro).

- `ValidateForComputeEnvironments` – Uma matriz de strings UTF-8.

  Os ambientes computacionais em relação aos quais as propriedades de conexão especificadas são validadas.

Estrutura TestConnectionInput

Uma estrutura usada para especificar o teste de uma conexão para um serviço.

Campos

- `ConnectionType`: Obrigatório: string UTF-8 (valores válidos: `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`).

  O tipo da conexão a ser testada. Essa operação está disponível somente para os tipos de conexão `JDBC` ou `SALESFORCE`.

- `ConnectionProperties`: obrigatório: uma matriz de mapa dos pares de chave-valor, no máximo 100 pares.

  Cada chave é uma string UTF-8 (valores válidos: `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).

Cada chave é uma string Value com no mínimo 1 e no máximo 1.024 bytes de comprimento.

Os pares de chave-valor que definem parâmetros para a conexão.

As conexões do JDBC usam as seguintes propriedades de conexão:

- Obrigatório: todos (HOST, PORT, JDBC_ENGINE) ou JDBC_CONNECTION_URL.
- Obrigatório: todos (USERNAME, PASSWORD) ou SECRET_ID.
- Opcional: JDBC_ENFORCE_SSL, CUSTOM_JDBC_CERT, CUSTOM_JDBC_CERT_STRING, SKIP_CUSTOM_JDBC_CERT_VALIDATION. Esses parâmetros são usados para configurar o SSL com o JDBC.

As conexões do SALESFORCE exigem que o membro AuthenticationConfiguration seja configurado.

- AuthenticationConfiguration – Um objeto AuthenticationConfigurationInput.

  Uma estrutura que contém a configuração de autenticação na solicitação TestConnection. Necessária para uma conexão ao Salesforce usando a autenticação OAuth.

Estrutura PhysicalConnectionRequirements

O aplicativo cliente OAuth na resposta GetConnection.

Campos

- SubnetId – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O ID da sub-rede usada pela conexão.

- `SecurityGroupIdList` – Uma matriz de strings UTF-8, no máximo 50 strings.

  A lista de IDs de security group usada pela conexão.

- `AvailabilityZone` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  A zona de disponibilidade da conexão.

Estrutura GetConnectionsFilter

Filtra as definições de conexão retornadas pela `GetConnections` operação da API.

Campos

- `MatchCriteria` – Uma matriz de strings UTF-8, no máximo 10 strings.

  Uma cadeia de critérios que deve corresponder aos critérios registrados na definição de conexão para a definição de conexão a ser retornada.

- `ConnectionType`: string UTF-8 (valores válidos: `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`).

  O tipo de conexão a ser retornada. No momento, o SFTP não é compatível.

- `ConnectionSchemaVersion`: número (inteiro) não inferior a 1 nem superior a 2.

  Indica se a conexão foi criada com a versão 1 ou 2 do esquema.

Estrutura AuthenticationConfiguration

Uma estrutura que contém a configuração de autenticação.

Campos

- `AuthenticationType` – String UTF-8 (valores válidos: `BASIC` | `OAUTH2` | `CUSTOM` | `IAM`).

Uma estrutura que contém a configuração de autenticação.

- `SecretArn` – String UTF-8 correspondente a Custom string pattern #36.

  O ARN do gerenciador de segredos para armazenar credenciais.

- `KmsKeyArn` – String UTF-8 correspondente a Custom string pattern #29.

  O nome do recurso da Amazon (ARN) da chave do KMS usada para criptografar informações de autenticação sensíveis. Essa chave é usada para proteger credenciais e outros dados sensíveis armazenados na configuração de autenticação.

- `OAuth2Properties` – Um objeto OAuth2Properties.

  As propriedades da autenticação OAuth2.

Estrutura AuthenticationConfigurationInput

Uma estrutura que contém a configuração de autenticação na solicitação CreateConnection.

Campos

- `AuthenticationType` – String UTF-8 (valores válidos: `BASIC` | `OAUTH2` | `CUSTOM` | `IAM`).

  Uma estrutura que contém a configuração de autenticação na solicitação CreateConnection.

- `OAuth2Properties` – Um objeto OAuth2PropertiesInput.

  As propriedades da autenticação OAuth2 na solicitação CreateConnection.

- `SecretArn` – String UTF-8 correspondente a Custom string pattern #36.

  O ARN do gerenciador de segredos para armazenar as credenciais na solicitação CreateConnection.

- `KmsKeyArn` – String UTF-8 correspondente a Custom string pattern #29.

  O ARN da chave do KMS usada para criptografar a conexão. Recebida somente como entrada na solicitação e armazenada no Secret Manager.

- `BasicAuthenticationCredentials` – Um objeto BasicAuthenticationCredentials.

  As credenciais usadas quando o tipo de autenticação é autenticação básica.

- `CustomAuthenticationCredentials` – Um array de mapa dos pares de valor-chave.

Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

As credenciais usadas quando o tipo de autenticação é autenticação personalizada.

Estrutura OAuth2Properties

Uma estrutura que contém propriedades da autenticação OAuth2.

Campos

- `OAuth2GrantType` – String UTF-8 (valores válidos: `AUTHORIZATION_CODE` | `CLIENT_CREDENTIALS` | `JWT_BEARER`).

  O tipo de concessão de OAuth2. Por exemplo, `AUTHORIZATION_CODE`, `JWT_BEARER` ou `CLIENT_CREDENTIALS`.
- `OAuth2ClientApplication` – Um objeto OAuth2ClientApplication.

  O tipo de aplicação do cliente. Por exemplo, AWS_MANAGED ou USER_MANAGED.
- `TokenUrl`: string UTF-8 com no máximo 256 bytes de comprimento e correspondente a Custom string pattern #40.

  O URL do servidor de autenticação do provedor para trocar um código de autorização por um token de acesso.
- `TokenUrlParametersMap` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com comprimento mínimo de 1 e comprimento máximo de 512 bytes.

  Um mapa de parâmetros que são adicionados à solicitação de token `GET`.

Estrutura OAuth2PropertiesInput

Uma estrutura que contém propriedades de OAuth2 na solicitação CreateConnection.

Campos

- `OAuth2GrantType` – String UTF-8 (valores válidos: `AUTHORIZATION_CODE` | `CLIENT_CREDENTIALS` | `JWT_BEARER`).

  O tipo de concessão OAuth2 na solicitação CreateConnection. Por exemplo, `AUTHORIZATION_CODE`, `JWT_BEARER` ou `CLIENT_CREDENTIALS`.

- `OAuth2ClientApplication` – Um objeto OAuth2ClientApplication.

  O tipo de aplicação cliente na solicitação CreateConnection. Por exemplo, `AWS_MANAGED` ou `USER_MANAGED`.

- `TokenUrl`: string UTF-8 com no máximo 256 bytes de comprimento e correspondente a Custom string pattern #40.

  O URL do servidor de autenticação do provedor para trocar um código de autorização por um token de acesso.

- `TokenUrlParametersMap` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com comprimento mínimo de 1 e comprimento máximo de 512 bytes.

  Um mapa de parâmetros que são adicionados à solicitação de token `GET`.

- `AuthorizationCodeProperties` – Um objeto AuthorizationCodeProperties.

  O conjunto de propriedades necessárias para o tipo de concessão `AUTHORIZATION_CODE` de OAuth2.

- `OAuth2Credentials` – Um objeto OAuth2Credentials.

  As credenciais usadas quando o tipo de autenticação é autenticação OAuth2.

Estrutura OAuth2ClientApplication

A aplicação cliente OAuth2 usada para a conexão.

Campos

- `UserManagedClientApplicationClientId`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a Custom string pattern #37.

  O ClientID da aplicação cliente se ClientAppType for `USER_MANAGED`.
- `AWSManagedClientApplicationReference`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a Custom string pattern #37.

  A referência à aplicação cliente do lado SaaS que é gerenciada pela AWS.

Estrutura AuthorizationCodeProperties

O conjunto de propriedades necessárias para o fluxo de trabalho do tipo de concessão `AUTHORIZATION_CODE` de OAuth2.

Campos

- `AuthorizationCode`: string UTF-8 com no mínimo 1 e no máximo 4.096 bytes de comprimento e correspondente a Custom string pattern #37.

  Um código de autorização a ser usado na terceira etapa do fluxo de trabalho de concessão de `AUTHORIZATION_CODE`. Esse é um código de uso único que se torna inválido quando trocado por um token de acesso, portanto, é aceitável ter esse valor como parâmetro de solicitação.
- `RedirectUri`: string UTF-8 com no máximo 512 bytes de comprimento e correspondente a Custom string pattern #41.

  O URI de redirecionamento para o qual o usuário é redirecionado pelo servidor de autorização ao emitir um código de autorização. O URI é usado posteriormente quando o código de autorização é trocado por um token de acesso.

Estrutura BasicAuthenticationCredentials

Usado para fornecer credenciais de autenticação básica caso nenhum valor tenha sido especificado para `SecretArn`.

Campos

- `Username`: string UTF-8 com no máximo 512 bytes de comprimento e correspondente a Custom string pattern #37.

O nome de usuário usado para efetuar a conexão com a fonte de dados.

- `Password`: string UTF-8 com no máximo 512 bytes de comprimento e correspondente a Custom string pattern #33.

  A senha usada para efetuar a conexão com a fonte de dados.

Estrutura OAuth2Credentials

As credenciais usadas quando o tipo de autenticação é autenticação OAuth2.

Campos

- `UserManagedClientApplicationClientSecret`: string UTF-8 com no máximo 512 bytes de comprimento e correspondente a Custom string pattern #38.

  O segredo do cliente da aplicação cliente, caso a aplicação cliente seja gerenciada pelo usuário.
- `AccessToken`: string UTF-8 com no máximo 4.096 bytes de comprimento e correspondente a Custom string pattern #38.

  O token de acesso usado quando o tipo de autenticação é OAuth2.
- `RefreshToken`: string UTF-8 com no máximo 4.096 bytes de comprimento e correspondente a Custom string pattern #38.

  O token de atualização usado quando o tipo de autenticação é OAuth2.
- `JwtToken`: string UTF-8 com no máximo 8.000 bytes de comprimento e correspondente a Custom string pattern #39.

  O padrão JSON Web Token (JWT) usado quando o tipo de autenticação é OAuth2.

Operações

- Ação CreateConnection (Python: create_connection)
- Ação DeleteConnection (Python: delete_connection)
- Ação GetConnection (Python: get_connection)
- Ação GetConnections (Python: get_connections)
- Ação UpdateConnection (Python: update_connection)
- Ação TestConnection (Python: test_connection)

- Ação BatchDeleteConnection (Python: batch_delete_connection)

Ação CreateConnection (Python: create_connection)

Cria uma definição de conexão no catálogo de dados.

As conexões usadas para criar recursos federados exigem a permissão `glue:PassConnection` do IAM.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que a conexão será criada. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `ConnectionInput` – Obrigatório: um objeto ConnectionInput.

  Um objeto `ConnectionInput` que define a conexão a ser criada.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags que você atribui à conexão.

Resposta

- `CreateConnectionStatus` – String UTF-8 (valores válidos: `READY` | `IN_PROGRESS` | `FAILED`).

  O status da solicitação de criação da conexão. A solicitação pode levar algum tempo para determinados tipos de autenticação, por exemplo, ao criar uma conexão OAuth com troca de tokens via VPC.

Erros

- `AlreadyExistsException`
- `InvalidInputException`

- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`

Ação DeleteConnection (Python: delete_connection)

Exclui uma conexão do catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que a conexão residirá. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `ConnectionName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da conexão a ser excluída.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`

Ação GetConnection (Python: get_connection)

Recupera uma definição de conexão do catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O ID do catálogo de dados em que a conexão residirá. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da definição de conexão a ser recuperada.

- `HidePassword` – Booleano.

  Permite recuperar os metadados de conexão sem retornar a senha. Por exemplo, o console do AWS Glue usa esse sinalizador para recuperar a conexão e não exibe a senha. Defina esse parâmetro quando o autor da chamada não tem permissão para usar a chave do AWS KMS para descriptografar a senha, mas tem permissão para acessar o restante das propriedades da conexão.

- `ApplyOverrideForComputeEnvironment` – String UTF-8 (valores válidos: `SPARK` | `ATHENA` | `PYTHON`).

  Para conexões que podem ser usadas em vários serviços, especifica as propriedades de retorno para o ambiente computacional especificado.

Resposta

- `Connection` – Um objeto Conexão.

  A definição de conexão solicitada.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

Ação GetConnections (Python: get_connections)

Recupera uma lista de definições de conexão do catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que as conexões residirão. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `Filter` – Um objeto GetConnectionsFilter.

  Um filtro que controla quais conexões são retornadas.
- `HidePassword` – Booleano.

  Permite recuperar os metadados de conexão sem retornar a senha. Por exemplo, o console do AWS Glue usa esse sinalizador para recuperar a conexão e não exibe a senha. Defina esse parâmetro quando o autor da chamada não tem permissão para usar a chave do AWS KMS para descriptografar a senha, mas tem permissão para acessar o restante das propriedades da conexão.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de conexões a ser retornado em uma resposta.

Resposta

- `ConnectionList`: um array de objetos Conexão.

  Uma lista das definições de conexão solicitadas.
- `NextToken` – String UTF-8.

  Um token de continuação, se a lista de conexões retornada não incluir a última das conexões filtradas.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`

- `InvalidInputException`
- `GlueEncryptionException`

Ação UpdateConnection (Python: update_connection)

Atualiza uma definição de conexão no catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que a conexão residirá. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da definição de conexão a ser atualizada.
- `ConnectionInput` – Obrigatório: um objeto ConnectionInput.

  Um objeto `ConnectionInput` que redefine a conexão em questão.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`

Ação TestConnection (Python: test_connection)

Testa uma conexão com um serviço para validar as credenciais de serviço que você fornece.

Você pode fornecer um nome de conexão existente ou uma `TestConnectionInput` para testar uma entrada de conexão não existente. Fornecer ambos ao mesmo tempo causará um erro.

Se a ação for bem-sucedida, o serviço retornará uma resposta HTTP 200.

Solicitação

- `ConnectionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Opcional. O nome da conexão a ser testada. Se apenas o nome for fornecido, a operação obterá a conexão e a usará para o teste.
- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo no qual a conexão está localizada.
- `TestConnectionInput` – Um objeto TestConnectionInput.

  Uma estrutura usada para especificar o teste de uma conexão para um serviço.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`
- `FederationSourceException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConflictException`
- `InternalServiceException`

Ação BatchDeleteConnection (Python: batch_delete_connection)

Exclui uma lista de definições de conexão do catálogo de dados.

Solicitação

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que as conexões residirão. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `ConnectionNameList` – Obrigatório: uma matriz de strings UTF-8, no máximo 25 strings.

  Uma lista de nomes das conexões a serem excluídas.

Resposta

- `Succeeded` – Uma matriz de strings UTF-8.

  Uma lista de nomes das definições de conexão que foram excluídas com sucesso.
- `Errors` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é um objeto ErrorDetail.

  Um mapa dos nomes das conexões que não foram excluídas com sucesso (para acessar detalhes do erro).

Erros

- `InternalServiceException`
- `OperationTimeoutException`

API de tipos de conexão

A API de tipo de conexão descreve as APIs do AWS Glue relacionadas à descrição dos tipos de conexão.

APIs de gerenciamento de conexões

- Ação DescribeConnectionType (Python: describe_connection_type)
- Ação ListConnectionTypes (Python: list_connection_types)
- Estrutura ConnectionTypeBrief
- Estrutura de ConnectionTypeVariant

Ação DescribeConnectionType (Python: describe_connection_type)

A API `DescribeConnectionType` fornece detalhes completos das opções válidas para um determinado tipo de conexão no AWS Glue.

Solicitação

- `ConnectionType`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do tipo de conexão a ser descrito.

Resposta

- `ConnectionType` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do tipo de conexão.
- `Description`: string UTF-8, com no máximo 1.024 bytes.

  Uma descrição do tipo de conexão.
- `Capabilities` – Um objeto Capacidades.

  Os tipos de autenticação, os tipos de interface de dados (ambientes de computação) e as operações de dados compatíveis do conector.
- `ConnectionProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Propriedades da conexão que são comuns entre ambientes computacionais.

- `ConnectionOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Retorna propriedades que podem ser definidas ao criar uma conexão no `ConnectionInput.ConnectionProperties`. `ConnectionOptions` define parâmetros que podem ser definidos em um script ETL do Spark no mapa de opções de conexão passado para um quadro de dados.
- `AuthenticationConfiguration` – Um objeto AuthConfiguration.

  O tipo da autenticação usada para a conexão.
- `ComputeEnvironmentConfigurations` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto ComputeEnvironmentConfiguration A.

  Os ambientes computacionais aceitos pela conexão.
- `PhysicalConnectionRequirements` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Requisitos físicos para uma conexão, como especificações de VPC, sub-rede e grupo de segurança.
- `AthenaConnectionProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Propriedades de conexão específicas para o ambiente computacional Athena.
- `PythonConnectionProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

Propriedades de conexão específicas para o ambiente computacional Python.

- `SparkConnectionProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Propriedades de conexão específicas para o ambiente computacional Spark.

Erros

- `ValidationException`
- `InvalidInputException`
- `InternalServiceException`

Ação ListConnectionTypes (Python: list_connection_types)

A API `ListConnectionTypes` fornece um mecanismo de descoberta para aprender os tipos de conexão disponíveis no AWS Glue. A resposta contém uma lista de tipos de conexão com detalhes de alto nível do que é aceito para cada tipo de conexão. Os tipos de conexão listados são o conjunto de opções válidas para o valor `ConnectionType` na API `CreateConnection`.

Solicitação

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.
- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `ConnectionTypes`: um array de objetos ConnectionTypeBrief.

  Uma lista de objetos `ConnectionTypeBrief` contendo informações breves sobre os tipos de conexão válidos.

- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

  Um token de continuação, se o segmento de lista atual não for o último.

Erros

- `InternalServiceException`

Estrutura ConnectionTypeBrief

Informações breves sobre um tipo de conexão compatível retornado pela API `ListConnectionTypes`.

Campos

- `ConnectionType`: string UTF-8 (valores válidos: `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`).

  O nome do tipo de conexão.
- `DisplayName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome legível por humanos para o tipo de conexão exibido no console do AWS Glue.
- `Vendor` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome do fornecedor ou provedor que criou ou mantém esse tipo de conexão.
- `Description`: string UTF-8, com no máximo 1.024 bytes.

  Uma descrição do tipo de conexão.
- `Categories` – Uma matriz de strings UTF-8.

  Uma lista das categorias às quais esse tipo de conexão pertence. As categorias ajudam os usuários a filtrar e encontrar os tipos de conexões apropriados com base em seus casos de uso.
- `Capabilities` – Um objeto Capacidades.

Os tipos de autenticação, os tipos de interface de dados (ambientes de computação) e as operações de dados compatíveis do conector.

- `LogoUrl` – String UTF-8.

  O URL do logotipo associado a um tipo de conexão.

- `ConnectionTypeVariants`: um array de objetos ConnectionTypeVariant.

  Uma lista das variantes disponíveis para esse tipo de conexão. Variantes diferentes podem oferecer configurações especializadas para determinados casos de uso ou implementações do mesmo tipo geral de conexão.

Estrutura de ConnectionTypeVariant

Representa uma variante de um tipo de conexão do AWS Glue Data Catalog. Variantes de tipos de conexões oferecem configurações e comportamentos específicos para diferentes implementações do mesmo tipo geral de conexão.

Campos

- `ConnectionTypeVariantName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O identificador exclusivo da variante de tipo de conexão. Esse nome é usado internamente para identificar a variante específica de um tipo de conexão.

- `DisplayName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome legível por humanos da variante de tipo de conexão que é exibida no console do AWS Glue.

- `Description`: string UTF-8, com no máximo 1.024 bytes.

  Uma descrição detalhada da variante de tipo de conexão, incluindo finalidade, casos de uso e requisitos específicos de configuração.

- `LogoUrl` – String UTF-8.

  A URL do logotipo associado a uma variante de tipo de conexão.

datatypes

- Estrutura Validation
- Estrutura AuthConfiguration
- Estrutura de capacidades
- Estrutura Property
- Estrutura AllowedValue
- Estrutura ComputeEnvironmentConfiguration

Estrutura Validation

Define como a validação é executada em uma propriedade de conexão.

Campos

- `ValidationType` – Obrigatório: string UTF-8 (valores válidos: `REGEX` | `RANGE`).

  O tipo de validação a ser realizada, como `REGEX`.
- `Patterns` – Uma matriz de strings UTF-8.

  Uma lista de padrões que se aplicam à validação.
- `Description` (obrigatório): string UTF-8, podendo ter entre 1 e 1.024 bytes.

  Uma descrição da validação.
- `MaxLength` – Número (íntegro).

  Um comprimento máximo para uma propriedade de conexão de string.
- `Maximum` – Número (íntegro).

  Um valor máximo ao especificar um tipo de validação `RANGE`.
- `Minimum` – Número (íntegro).

  Um valor mínimo ao especificar um tipo de validação `RANGE`.

Estrutura AuthConfiguration

A configuração de autenticação para uma conexão retornada pela API `DescribeConnectionType`.

Campos

- `AuthenticationType` – Obrigatório: um objeto Propriedade.

  O tipo da autenticação de uma conexão.

- `SecretArn` – Um objeto Propriedade.

  O nome do recurso da Amazon (ARN) do Secrets Manager.

- `OAuth2Properties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Um mapa de pares de chave-valore para as propriedades da OAuth2. Cada valor é um objeto `Property`.

- `BasicAuthenticationProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Um mapa de pares de chave-valore para as propriedades da OAuth2. Cada valor é um objeto `Property`.

- `CustomAuthenticationProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Um mapa de pares de chave-valore para as propriedades da autenticação personalizada. Cada valor é um objeto `Property`.

Estrutura de capacidades

Especifica os tipos de autenticação compatíveis retornados pela API `DescribeConnectionType`.

Campos

- `SupportedAuthenticationTypes`: obrigatório: uma matriz de strings UTF-8.

Uma lista dos tipos de autenticação compatíveis.

- `SupportedDataOperations`: obrigatório: uma matriz de strings UTF-8.

  Uma lista das operações de dados compatíveis.

- `SupportedComputeEnvironments`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de ambientes computacionais compatíveis.

Estrutura Property

Um objeto que define um tipo de conexão para um ambiente computacional.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome da propriedade.

- `Description`: obrigatório: string UTF-8 com no máximo 1.024 bytes de comprimento.

  Uma descrição da propriedade.

- `Required`: obrigatório: booleano.

  Indica se a propriedade é obrigatória.

- `DefaultValue` – String UTF-8.

  O valor padrão da propriedade.

- `PropertyTypes`: obrigatório: uma matriz de strings UTF-8.

  Descreve o tipo de propriedade.

- `AllowedValues`: um array de objetos AllowedValue.

  Uma lista de objetos `AllowedValue` representando os valores permitidos para a propriedade.

- `DataOperationScopes` – Uma matriz de strings UTF-8.

  Indica quais operações de dados são aplicáveis à propriedade.

Estrutura AllowedValue

Um objeto que representa um valor permitido para uma propriedade.

Campos

- `Description`: string UTF-8, com no máximo 1.024 bytes.

  Uma descrição do valor permitido.
- `Value`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O valor permitido para a propriedade.

Estrutura ComputeEnvironmentConfiguration

Um objeto contendo a configuração de um ambiente computacional (como Spark, Python ou Athena) retornado pela API `DescribeConnectionType`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Um nome para a configuração do ambiente computacional.
- `Description`: obrigatório: string UTF-8 com no máximo 1.024 bytes de comprimento.

  Uma descrição do ambiente computacional.
- `ComputeEnvironment` – Obrigatório: string UTF-8 (valores válidos: `SPARK` | `ATHENA` | `PYTHON`).

  O tipo do ambiente de computação.
- `SupportedAuthenticationTypes`: obrigatório: uma matriz de strings UTF-8.

  Os tipos de autenticação com suporte para o ambiente computacional.
- `ConnectionOptions`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é um objeto Propriedade A.

  Os parâmetros usados como opções de conexão para o ambiente computacional.

- `ConnectionPropertyNameOverrides`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome da propriedade de conexão é substituído para ambiente computacional.
- `ConnectionOptionNameOverrides`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome da opção de conexão é substituído para ambiente computacional.
- `ConnectionPropertiesRequiredOverrides`: obrigatório: uma matriz de strings UTF-8.

  As propriedades de conexão que são necessárias como substituição para o ambiente computacional.
- `PhysicalConnectionPropertiesRequired` – Booleano.

  Indica se as `PhysicalConnectionProperties` são necessários para o ambiente computacional.

Metadados de conexão e API de visualização

As APIs de conexão a seguir descrevem as operações necessárias para descrever os metadados da conexão.

Tipos de dados

- Estrutura Entity
- Estrutura Field

Estrutura Entity

Uma entidade sustentada por um determinado `ConnectionType`.

Campos

- `EntityName` – String UTF-8.

  O nome da entidade.
- `Label` – String UTF-8.

  Rótulo usado para a entidade.
- `IsParentEntity` – Booleano.

  Um valor booleano que ajuda a determinar se há subobjetos que podem ser listados.
- `Description` – String UTF-8.

  Uma descrição da entidade.
- `Category` – String UTF-8.

  O tipo das entidades que estão presentes na resposta. Esse valor depende da conexão de origem. Por exemplo, ele é `SObjects` para o Salesforce e `databases` ou `schemas` ou `tables` para fontes como o Amazon Redshift.
- `CustomProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um mapa opcional de chaves que pode ser retornado para uma entidade por um conector.

Estrutura Field

O objeto `Field` tem informações sobre as diferentes propriedades associadas a um campo no conector.

Campos

- `FieldName` – String UTF-8.

  O identificador exclusivo do campo.
- `Label` – String UTF-8.

  Um rótulo legível usado para o campo.

- `Description` – String UTF-8.

  Uma descrição do campo.

- `FieldType`: string UTF-8 (valores válidos: `INT` | `SMALLINT` | `BIGINT` | `FLOAT` | `LONG` | `DATE` | `BOOLEAN` | `MAP` | `ARRAY` | `STRING` | `TIMESTAMP` | `DECIMAL` | `BYTE` | `SHORT` | `DOUBLE` | `STRUCT`).

  O tipo dos dados no campo.

- `IsPrimaryKey` – Booleano.

  Indica se esse campo pode ser usado como chave primária para a entidade em questão.

- `IsNullable` – Booleano.

  Indica se esse campo pode ser anulável ou não.

- `IsRetrievable` – Booleano.

  Indica se esse campo pode ser adicionado na cláusula Select da consulta SQL ou se é recuperável ou não.

- `IsFilterable` – Booleano.

  Indica se esse campo pode ser usado em uma cláusula de filtro (cláusula `WHERE`) de uma instrução SQL ao consultar dados.

- `IsPartitionable` – Booleano.

  Indica se um determinado campo pode ser usado no particionamento da consulta feita para SaaS.

- `IsCreateable` – Booleano.

  Indica se esse campo pode ser criado como parte de uma gravação de destino.

- `IsUpdateable` – Booleano.

  Indica se esse campo pode ser atualizado como parte de uma gravação de destino.

- `IsUpsertable` – Booleano.

  Indica se esse campo pode ser upserted como parte de uma gravação de destino.

- `IsDefaultOnCreate` – Booleano.

  Indica se esse campo é preenchido automaticamente quando o objeto é criado, como um campo criado no timestamp.

- `SupportedValues` – Uma matriz de strings UTF-8.

Uma lista de valores compatíveis para o campo.

- `SupportedFilterOperators` – Uma matriz de strings UTF-8.

  Indica os operadores de filtro de suporte para esse campo.

- `ParentField` – String UTF-8.

  O nome do campo principal ao qual um campo aninhado está associado.

- `NativeDataType` – String UTF-8.

  O tipo de dado retornado pela API de um serviço SaaS, como “picklist” ou “textarea” usados na Salesforce.

- `CustomProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Mapa opcional das chaves que podem ser devolvidas.

Operações

- Ação ListEntities (Python: list_entities)
- Ação DescribeEntity (Python: describe_entity)
- Ação GetEntityRecords (Python: get_entity_records)

Ação ListEntities (Python: list_entities)

Retorna as entidades disponíveis compatíveis com o tipo de conexão.

Solicitação

- `ConnectionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome para a conexão que tem as credenciais necessárias para consultar qualquer tipo de conexão.

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O ID do catálogo que contém a conexão. Esse valor pode ser nulo. Por padrão, o ID da conta da AWS é o ID do catálogo.

- `ParentEntityName` – String UTF-8.

  O nome entidade pai para a qual você deseja escutar as filhas. Esse parâmetro usa um caminho totalmente qualificado da entidade para listar as entidades filhas.

- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

  Um token de continuação, incluído se esta for uma chamada de continuação.

- `DataStoreApiVersion`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #23.

  A versão da API do conector SaaS.

Resposta

- `Entities`: um array de objetos Entidade.

  Uma lista dos objetos `Entity`.

- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

  Um token de continuação, presente se o segmento atual não for o último.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`
- `ValidationException`
- `FederationSourceException`
- `AccessDeniedException`

Ação DescribeEntity (Python: describe_entity)

Fornece detalhes sobre a entidade usada com o tipo de conexão, com uma descrição do modelo de dados para cada campo na entidade selecionada.

A resposta inclui todos os campos que compõem a entidade.

Solicitação

- `ConnectionName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da conexão que contém as credenciais do tipo de conexão.
- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo que contém a conexão. Esse valor pode ser nulo. Por padrão, o ID da conta da AWS é o ID do catálogo.
- `EntityName` – Obrigatório: string UTF-8.

  O nome da entidade que você deseja descrever com base no tipo de conexão.
- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

  Um token de continuação, incluído se esta for uma chamada de continuação.
- `DataStoreApiVersion`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #23.

  A versão da API usada para o armazenamento de dados.

Resposta

- `Fields`: um array de objetos Campo.

  Descreve os campos dessa entidade de conector. Essa é a lista de objetos `Field`. `Field` é muito semelhante a uma tabela em um banco de dados. O objeto `Field` tem informações sobre as diferentes propriedades associadas a campos no conector.
- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

Um token de continuação, presente se o segmento atual não for o último.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`
- `ValidationException`
- `FederationSourceException`
- `AccessDeniedException`

Ação GetEntityRecords (Python: get_entity_records)

Essa API é usada para consultar dados de prévia de um determinado tipo de conexão ou de um Catálogo de Dados do AWS Glue nativo baseado no Amazon S3.

Retorna registros como um array de blobs JSON. Cada registro é formatado usando Jackson JsonNode com base no tipo de campo definido pela API `DescribeEntity`.

Os conectores Spark geram esquemas de acordo com o mesmo mapeamento de tipos de dados da API `DescribeEntity`. Os conectores Spark convertem dados nos tipos de dados apropriados e correspondentes ao esquema ao retornar linhas.

Solicitação

- `ConnectionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da conexão que contém as credenciais do tipo de conexão.
- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo que contém a conexão. Esse valor pode ser nulo. Por padrão, o ID da conta da AWS é o ID do catálogo.
- `EntityName` – Obrigatório: string UTF-8.

Nome da entidade na qual queremos consultar os dados de prévia do tipo de conexão determinado.

- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

  Um token de continuação, incluído se esta for uma chamada de continuação.

- `DataStoreApiVersion`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #23.

  A versão da API do conector SaaS.

- `ConnectionOptions`: um array de mapa dos pares de chave-valor com não mais do que 100 pares.

  Cada chave é uma string UTF-8 com no mínimo 1 e no máximo 256 bytes de comprimento e correspondente a Custom string pattern #18.

  Cada valor é uma string UTF-8 com no mínimo 1 e no máximo 256 bytes de comprimento e correspondente a Custom string pattern #17.

  Opções de conector necessárias para consultar os dados.

- `FilterPredicate`: string UTF-8 com no mínimo 1 e no máximo 100.000 bytes de comprimento.

  Um predicado de filtro que pode ser aplicado à solicitação de consulta.

- `Limit`: obrigatório: número (longo) no mínimo igual a 1 e no máximo igual a 1.000.

  Limita o número de registros buscados como resultado da solicitação.

- `OrderBy` – String UTF-8.

  Um parâmetro que ordena os dados de prévia da resposta.

- `SelectedFields`: um array de strings UTF-8 com no mínimo 1 e no máximo 1.000 strings.

  Lista de campos que queremos buscar como parte dos dados de prévia.

Resposta

- `Records`: uma matriz de estruturas.

  Uma lista de objetos solicitados.

- `NextToken` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #11.

  Um token de continuação, presente se o segmento atual não for o último.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`
- `GlueEncryptionException`
- `ValidationException`
- `FederationSourceException`
- `AccessDeniedException`

API User-defined Function

A API User-defined Function descreve os tipos de dados e as operações do AWS Glue usados para trabalhar com funções.

Tipos de dados

- Estrutura UserDefinedFunction
- Estrutura UserDefinedFunctionInput

Estrutura UserDefinedFunction

Representa o equivalente a uma definição de função do Hive definida pelo usuário (`UDF`).

Campos

- `FunctionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome da função.
- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O nome do banco de dados de catálogo que contém a função.

- `ClassName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  A classe Java que contém o código da função.

- `OwnerName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O proprietário da função.

- `OwnerType` – String UTF-8 (valores válidos: `USER` | `ROLE` | `GROUP`).

  Tipo do proprietário.

- `CreateTime` – Timestamp.

  A hora em que a função foi criada.

- `ResourceUris` – Uma matriz de objetos ResourceUri, não mais de 1000 estruturas.

  Os URIs do recurso para a função.

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do Data Catalog em que a função reside.

Estrutura UserDefinedFunctionInput

Uma estrutura usada para criar ou atualizar uma função definida pelo usuário.

Campos

- `FunctionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome da função.

- `ClassName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  A classe Java que contém o código da função.

- `OwnerName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O proprietário da função.

- `OwnerType` – String UTF-8 (valores válidos: `USER` | `ROLE` | `GROUP`).

  Tipo do proprietário.

- `ResourceUris` – Uma matriz de objetos ResourceUri, não mais de 1000 estruturas.

  Os URIs do recurso para a função.

Operações

- Ação CreateUserDefinedFunction (Python: create_user_defined_function)
- Ação UpdateUserDefinedFunction (Python: update_user_defined_function)
- Ação DeleteUserDefinedFunction (Python: delete_user_defined_function)
- Ação GetUserDefinedFunction (Python: get_user_defined_function)
- Ação GetUserDefinedFunctions (Python: get_user_defined_functions)

Ação CreateUserDefinedFunction (Python: create_user_defined_function)

Cria uma definição de nova função no catálogo de dados.

Solicitação

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados em que a função será criada. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.

- `DatabaseName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados de catálogos no qual a função será criada.

- `FunctionInput` – Obrigatório: um objeto UserDefinedFunctionInput.

  Um objeto `FunctionInput` que define a função a ser criada no catálogo de dados.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `GlueEncryptionException`

Ação UpdateUserDefinedFunction (Python: update_user_defined_function)

Atualiza uma definição de função existente no catálogo de dados.

Solicitação

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual está a função a ser atualizada. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual está a função a ser atualizada.
- `FunctionName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome da função.
- `FunctionInput` – Obrigatório: um objeto UserDefinedFunctionInput.

  Um objeto `FunctionInput` que redefine a função no Catálogo de dados.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação DeleteUserDefinedFunction (Python: delete_user_defined_function)

Exclui uma definição função existente do catálogo de dados.

Solicitação

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual está a função a ser excluída. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.

- `DatabaseName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual a função está.

- `FunctionName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da definição de função a ser excluída.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetUserDefinedFunction (Python: get_user_defined_function)

Recupera uma definição de função especificada do catálogo de dados.

Solicitação

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual está a função a ser recuperada. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual a função está.
- `FunctionName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome da função.

Resposta

- `UserDefinedFunction` – Um objeto UserDefinedFunction.

  A definição de função solicitada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`

- `InternalServiceException`
- `OperationTimeoutException`
- `GlueEncryptionException`

Ação GetUserDefinedFunctions (Python: get_user_defined_functions)

Recupera várias definições de função do Catálogo de dados.

Solicitação

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual estão as funções a serem recuperadas. Se nenhum for fornecido, o ID da conta da AWS será usado por padrão.
- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados do catálogo no qual as funções estão localizadas. Se nenhum for fornecido, as funções de todos os bancos de dados no catálogo serão retornadas.
- `Pattern` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  Uma string de padrão de função-nome opcional que filtra as definições de função retornadas.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.
- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 100.

  O número máximo de funções a ser retornado em uma resposta.

Resposta

- `UserDefinedFunctions` – Uma matriz de objetos UserDefinedFunction.

  Uma lista das definições de função solicitadas.
- `NextToken` – String UTF-8.

Um token de continuação, se a lista de funções retornadas não incluir a última função solicitada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `GlueEncryptionException`

Importar um catálogo do Athena para AWS Glue

A API Migration descreve os tipos de dados e as operações do AWS Glue relacionados à migração de um catálogo de dados do Athena para o AWS Glue.

Tipos de dados

- Estrutura CatalogImportStatus

Estrutura CatalogImportStatus

Uma estrutura que contém informações sobre o status da migração.

Campos

- `ImportCompleted` – Booleano.

  `True` se a migração for concluída, ou `False` caso contrário.

- `ImportTime` – Timestamp.

  A hora em que a migração foi iniciada.

- `ImportedBy` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da pessoa que iniciou a migração.

Operações

- Ação ImportCatalogToGlue (Python: import_catalog_to_glue)
- Ação GetCatalogImportStatus (Python: get_catalog_import_status)

Ação ImportCatalogToGlue (Python: import_catalog_to_glue)

Importa um Data Catalog existente do Amazon Athena para o AWS Glue.

Solicitação

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo a ser importado. No momento, deve ser o ID da conta da AWS.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InternalServiceException`
- `OperationTimeoutException`

Ação GetCatalogImportStatus (Python: get_catalog_import_status)

Recupera o status de uma operação de migração.

Solicitação

- `CatalogId` – String de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo a ser migrado. No momento, deve ser o ID da conta da AWS.

Resposta

- `ImportStatus` – Um objeto CatalogImportStatus.

  O status de migração do catálogo especificado.

Erros

- `InternalServiceException`
- `OperationTimeoutException`

API do otimizador de tabelas

A API do otimizador de tabelas descreve a API do AWS Glue para habilitar a compactação a fim de melhorar a performance de leitura.

Tipos de dados

- Estrutura do TableOptimizer
- Estrutura do TableOptimizerConfiguration
- Estrutura de TableOptimizerVpcConfiguration
- Estrutura CompactionConfiguration
- Estrutura IcebergCompactionConfiguration
- Estrutura TableOptimizerRun
- Estrutura BatchGetTableOptimizerEntry
- Estrutura BatchTableTableOptimizer
- Estrutura BatchGetTableOptimizerError
- Estrutura RetentionConfiguration
- Estrutura IcebergRetentionConfiguration
- Estrutura OrphanFileDeletionConfiguration
- Estrutura IcebergOrphanFileDeletionConfiguration
- Estrutura CompactionMetrics
- Estrutura RetentionMetrics

- Estrutura OrphanFileDeletionMetrics
- Estrutura IcebergCompactionMetrics
- Estrutura IcebergRetentionMetrics
- Estrutura IcebergOrphanFileDeletionMetrics
- Estrutura RunMetrics

Estrutura do TableOptimizer

Contém detalhes sobre um otimizador associado a uma tabela.

Campos

- `type` – String UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas. Os valores válidos são:

  - `compaction`: para gerenciar a compactação com um otimizador de tabela.
  - `retention`: para gerenciar a retenção de snapshots com um otimizador de tabela.
  - `orphan_file_deletion`: para gerenciar a exclusão de arquivos órfãos com um otimizador de tabela.
- `configuration` – Um objeto TableOptimizerConfiguration.

  Um objeto `TableOptimizerConfiguration` que foi especificado ao criar ou atualizar um otimizador de tabelas.
- `lastRun` – Um objeto TableOptimizerRun.

  Um objeto `TableOptimizerRun` que representa a última execução do otimizador de tabelas.

Estrutura do TableOptimizerConfiguration

Contém detalhes sobre a configuração de um otimizador de tabelas. Você passa essa configuração ao criar ou atualizar um otimizador de tabelas.

Campos

- `roleArn` – String UTF-8, superior a 20 e inferior a 2048 bytes de comprimento, correspondente a Single-line string pattern.

Uma função passada pelo chamador que concede ao serviço permissão para atualizar os recursos associados ao otimizador em nome do chamador.

- `enabled` – Booleano.

  Se a otimização da tabela está habilitada.

- `vpcConfiguration` – Um objeto TableOptimizerVpcConfiguration.

  Um objeto `TableOptimizerVpcConfiguration` que representa a configuração da VPC de um otimizador de tabela.

  Essa configuração é necessária para a execução da otimização de tabelas que estão na VPC de um cliente.

- `compactionConfiguration` – Um objeto CompactionConfiguration.

  A configuração de um otimizador de compactação. Essa configuração define como os arquivos de dados em sua tabela serão compactados para melhorar o desempenho das consultas e reduzir os custos de armazenamento.

- `retentionConfiguration` – Um objeto RetentionConfiguration.

  A configuração de um otimizador de retenção de snapshots.

- `orphanFileDeletionConfiguration` – Um objeto OrphanFileDeletionConfiguration.

  A configuração de um otimizador de exclusão de arquivos órfãos.

Estrutura de TableOptimizerVpcConfiguration

Um objeto que descreve a configuração da VPC de um otimizador de tabela.

Essa configuração é necessária para a execução da otimização de tabelas que estão na VPC de um cliente.

Campos

- `glueConnectionName`: string UTF-8 com pelo menos 1 byte de comprimento.

  O nome da conexão do AWS Glue usada para a VPC do otimizador de tabelas.

Estrutura CompactionConfiguration

A configuração de um otimizador de compactação. Essa configuração define como os arquivos de dados em sua tabela serão compactados para melhorar o desempenho das consultas e reduzir os custos de armazenamento.

Campos

- `icebergConfiguration` – Um objeto IcebergCompactionConfiguration.

  A configuração de um otimizador de compactação do Iceberg.

Estrutura IcebergCompactionConfiguration

A configuração de um otimizador de compactação do Iceberg. Essa configuração define parâmetros para otimizar o layout dos arquivos de dados nas tabelas do Iceberg.

Campos

- `strategy` – String UTF-8 (valores válidos: `binpack="BINPACK"` | `sort="SORT"` | `z-order="ZORDER"`).

  A estratégia a ser usada para compactação. Os valores válidos são:
  - `binpack`: combina arquivos pequenos em arquivos maiores, geralmente direcionado a tamanhos acima de 100 MB, enquanto aplica todas as exclusões pendentes. Essa é a estratégia de compactação recomendada para a maioria dos casos de uso.
  - `sort`: organiza os dados com base em colunas especificadas que são classificadas hierarquicamente durante a compactação, melhorando o desempenho da consulta para operações filtradas. Essa estratégia é recomendada quando suas consultas filtram frequentemente colunas específicas. Para usar essa estratégia, primeiro você precisará definir uma ordem de classificação nas propriedades da tabela do Iceberg usando a propriedade de tabela `sort_order`.
  - `z-order`: otimiza a organização de dados combinando vários atributos em um único valor escalar que pode ser usado para classificação, permitindo consultas eficientes em várias dimensões. Essa estratégia é recomendada quando você precisa consultar dados em várias dimensões simultaneamente. Para usar essa estratégia, primeiro você precisará definir uma ordem de classificação nas propriedades da tabela do Iceberg usando a propriedade de tabela `sort_order`.

Se uma entrada não for fornecida, o valor padrão “binpack” será usado.

Estrutura TableOptimizerRun

Contém detalhes para a execução de um otimizador de tabelas.

Campos

- `eventType` – String UTF-8 (valores válidos: `starting="STARTING"` | `completed="COMPLETED"` | `failed="FAILED"` | `in_progress="IN_PROGRESS"`).

  Um tipo de evento que representa o status da execução do otimizador de tabelas.

- `startTimestamp` – Timestamp.

  Representa a marca de data e hora do epoch em que o trabalho de compactação foi iniciado no Lake Formation.

- `endTimestamp` – Timestamp.

  Representa a marca de data e hora do epoch em que o trabalho de compactação terminou.

- `metrics` – Um objeto RunMetrics.

  Um objeto `RunMetrics` que contém métricas para a execução do otimizador.

  Esse membro é obsoleto. Veja os membros individuais da métrica para compactação, retenção e exclusão de arquivos órfãos.

- `error` – String UTF-8.

  Um erro que ocorreu durante a execução do otimizador.

- `compactionMetrics` – Um objeto CompactionMetrics.

  Um objeto `CompactionMetrics` que contém métricas para a execução do otimizador.

- `compactionStrategy` – String UTF-8 (valores válidos: `binpack="BINPACK"` | `sort="SORT"` | `z-order="ZORDER"`).

  A estratégia usada para a execução da compactação. Indica qual algoritmo foi aplicado para determinar como os arquivos foram selecionados e combinados durante o processo de compactação. Os valores válidos são:

  - `binpack`: combina arquivos pequenos em arquivos maiores, geralmente direcionado a tamanhos acima de 100 MB, enquanto aplica todas as exclusões pendentes. Essa é a estratégia de compactação recomendada para a maioria dos casos de uso.
  - `sort`: organiza os dados com base em colunas especificadas que são classificadas hierarquicamente durante a compactação, melhorando o desempenho da consulta para operações filtradas. Essa estratégia é recomendada quando suas consultas filtram frequentemente colunas específicas. Para usar essa estratégia, primeiro você precisará definir uma ordem de classificação nas propriedades da tabela do Iceberg usando a propriedade de tabela `sort_order`.
  - `z-order`: otimiza a organização de dados combinando vários atributos em um único valor escalar que pode ser usado para classificação, permitindo consultas eficientes em várias dimensões. Essa estratégia é recomendada quando você precisa consultar dados em várias dimensões simultaneamente. Para usar essa estratégia, primeiro você precisará definir uma ordem de classificação nas propriedades da tabela do Iceberg usando a propriedade de tabela `sort_order`.
- `retentionMetrics` – Um objeto RetentionMetrics.

  Um objeto `RetentionMetrics` que contém métricas para a execução do otimizador.
- `orphanFileDeletionMetrics` – Um objeto OrphanFileDeletionMetrics.

  Um objeto `OrphanFileDeletionMetrics` que contém métricas para a execução do otimizador.

Estrutura BatchGetTableOptimizerEntry

Representa um otimizador de tabelas a ser recuperado na operação `BatchGetTableOptimizer`.

Campos

- `catalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo da tabela.
- `databaseName`: string UTF-8 com pelo menos 1 byte de comprimento.

  O nome do banco de dados no catálogo em que a tabela reside.
- `tableName`: string UTF-8 com pelo menos 1 byte de comprimento.

O nome da tabela.

- `type` – String UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas.

Estrutura BatchTableTableOptimizer

Contém detalhes de um dos otimizadores de tabela retornados pela operação `BatchGetTableOptimizer`.

Campos

- `catalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo da tabela.
- `databaseName`: string UTF-8 com pelo menos 1 byte de comprimento.

  O nome do banco de dados no catálogo em que a tabela reside.
- `tableName`: string UTF-8 com pelo menos 1 byte de comprimento.

  O nome da tabela.
- `tableOptimizer` – Um objeto TableOptimizer.

  Um objeto `TableOptimizer` que contém detalhes da configuração e da última execução de um otimizador de tabelas.

Estrutura BatchGetTableOptimizerError

Contém detalhes sobre um dos erros na lista de erros retornada pela operação `BatchGetTableOptimizer`.

Campos

- `error` – Um objeto ErrorDetail.

  Um objeto `ErrorDetail` que contém detalhes de código e mensagens sobre o erro.

- `catalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo da tabela.

- `databaseName`: string UTF-8 com pelo menos 1 byte de comprimento.

  O nome do banco de dados no catálogo em que a tabela reside.

- `tableName`: string UTF-8 com pelo menos 1 byte de comprimento.

  O nome da tabela.

- `type` – String UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas.

Estrutura RetentionConfiguration

A configuração de um otimizador de retenção de snapshots.

Campos

- `icebergConfiguration` – Um objeto IcebergRetentionConfiguration.

  A configuração de um otimizador de retenção de snapshots do Iceberg.

Estrutura IcebergRetentionConfiguration

A configuração de um otimizador de retenção de snapshots do Iceberg.

Campos

- `snapshotRetentionPeriodInDays` – Número (íntegro).

  O número de dias para reter os snapshots do Iceberg. Se uma entrada não for fornecida, o campo de configuração da tabela Iceberg correspondente será usado ou, se não estiver presente, o valor padrão 5 será usado.

- `numberOfSnapshotsToRetain` – Número (íntegro).

O número de snapshots do Iceberg a serem retidos no período de retenção. Se uma entrada não for fornecida, o campo de configuração da tabela Iceberg correspondente será usado ou, se não estiver presente, o valor padrão 1 será usado.

- `cleanExpiredFiles` – Booleano.

  Se definido como false, os snapshots são excluídos somente dos metadados da tabela, e os arquivos de dados e metadados subjacentes não são excluídos.

Estrutura OrphanFileDeletionConfiguration

A configuração de um otimizador de exclusão de arquivos órfãos.

Campos

- `icebergConfiguration` – Um objeto IcebergOrphanFileDeletionConfiguration.

  A configuração de um otimizador de exclusão de arquivos órfãos do Iceberg.

Estrutura IcebergOrphanFileDeletionConfiguration

A configuração de um otimizador de exclusão de arquivos órfãos do Iceberg.

Campos

- `orphanFileRetentionPeriodInDays` – Número (íntegro).

  O número de dias que os arquivos órfãos devem ser retidos antes da exclusão do arquivo. Se uma entrada de não for fornecida, o valor padrão 3 será usado.

- `location` – String UTF-8.

  Especifica um diretório no qual procurar arquivos (o padrão é a localização da tabela). Você pode escolher um subdiretório em vez da localização da tabela de nível superior.

Estrutura CompactionMetrics

Uma estrutura que contém as métricas de compactação para a execução do otimizador.

Campos

- `IcebergMetrics` – Um objeto IcebergCompactionMetrics.

  Uma estrutura que contém as métricas de compactação do Iceberg para a execução do otimizador.

Estrutura RetentionMetrics

Uma estrutura que contém as métricas de retenção para a execução do otimizador.

Campos

- `IcebergMetrics` – Um objeto IcebergRetentionMetrics.

  Uma estrutura que contém as métricas de retenção do Iceberg para a execução do otimizador.

Estrutura OrphanFileDeletionMetrics

Uma estrutura que contém as métricas de exclusão de arquivos órfãos para a execução do otimizador.

Campos

- `IcebergMetrics` – Um objeto IcebergOrphanFileDeletionMetrics.

  Uma estrutura que contém as métricas de exclusão de arquivos órfãos do Iceberg para a execução do otimizador.

Estrutura IcebergCompactionMetrics

Métricas de compactação do Iceberg para a execução do otimizador.

Campos

- `DpuHours` – Número (duplo).

  O número de horas de DPU consumidas pelo trabalho.

- `NumberOfDpus`: número (inteiro).

O número de DPUs consumidas pela tarefa, arredondado para o número inteiro mais próximo.

- `JobDurationInHour` – Número (duplo).

  A duração do trabalho, em horas.

Estrutura IcebergRetentionMetrics

Métricas de retenção de snapshots do Iceberg para a execução do otimizador.

Campos

- `DpuHours` – Número (duplo).

  O número de horas de DPU consumidas pelo trabalho.

- `NumberOfDpus`: número (inteiro).

  O número de DPUs consumidas pela tarefa, arredondado para o número inteiro mais próximo.

- `JobDurationInHour` – Número (duplo).

  A duração do trabalho, em horas.

Estrutura IcebergOrphanFileDeletionMetrics

Métricas de exclusão de arquivos órfãos do Iceberg para a execução do otimizador.

Campos

- `DpuHours` – Número (duplo).

  O número de horas de DPU consumidas pelo trabalho.

- `NumberOfDpus`: número (inteiro).

  O número de DPUs consumidas pela tarefa, arredondado para o número inteiro mais próximo.

- `JobDurationInHour` – Número (duplo).

  A duração do trabalho, em horas.

Estrutura RunMetrics

Métricas para a execução do otimizador.

Esta estrutura está obsoleta. Veja os membros individuais da métrica para compactação, retenção e exclusão de arquivos órfãos.

Campos

- `NumberOfBytesCompacted` – String UTF-8.

  O número de bytes removidos pela execução do trabalho de compactação.
- `NumberOfFilesCompacted` – String UTF-8.

  O número de arquivos removidos pela execução do trabalho de compactação.
- `NumberOfDpus` – String UTF-8.

  O número de DPUs consumidas pela tarefa, arredondado para o número inteiro mais próximo.
- `JobDurationInHour` – String UTF-8.

  A duração do trabalho, em horas.

Operações

- Ação GetTableOptimizer (Python: get_table_optimizer)
- Ação BatchGetTableOptimizer (Python: batch_get_table_optimizer)
- Ação ListTableOptimizerRuns (Python: list_table_optimizer_runs)
- Ação CreateTableOptimizer (Python: create_table_optimizer)
- Ação DeleteTableOptimizer (Python: delete_table_optimizer)
- Ação UpdateTableOptimizer (Python: update_table_optimizer)

Ação GetTableOptimizer (Python: get_table_optimizer)

Retorna a configuração de todos os otimizadores associados a uma tabela especificada.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de catálogo da tabela.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no catálogo em que a tabela reside.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela.

- `Type` – Obrigatório: string UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas.

Resposta

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo da tabela.

- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados no catálogo em que a tabela reside.

- `TableName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela.

- `TableOptimizer` – Um objeto TableOptimizer.

  O otimizador associado à tabela especificada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

Ação BatchGetTableOptimizer (Python: batch_get_table_optimizer)

Retorna a configuração para os otimizadores de tabela especificados.

Solicitação

- `Entries` – Obrigatório: uma matriz de objetos BatchGetTableOptimizerEntry.

  Uma lista de objetos `BatchGetTableOptimizerEntry` que especifica os otimizadores de tabelas a serem recuperados.

Resposta

- `TableOptimizers`: um array de objetos BatchTableOptimizer.

  Uma lista dos objetos `BatchTableOptimizer`.
- `Failures`: um array de objetos BatchGetTableOptimizerError.

  Uma lista de erros da operação.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

Ação ListTableOptimizerRuns (Python: list_table_optimizer_runs)

Lista o histórico de execuções anteriores do otimizador para uma tabela específica.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de catálogo da tabela.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no catálogo em que a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela.
- `Type` – Obrigatório: string UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas.
- `MaxResults` – Número (íntegro).

  O número máximo de execuções do otimizador a serem retornadas em cada chamada.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `CatalogId`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de catálogo da tabela.
- `DatabaseName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do banco de dados no catálogo em que a tabela reside.

- `TableName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela.
- `NextToken` – String UTF-8.

  Um token de continuação para paginação da lista de execuções do otimizador retornada, retornado se o segmento atual da lista não for o último.
- `TableOptimizerRuns`: um array de objetos TableOptimizerRun.

  Uma lista das execuções de otimizador associadas a uma tabela.

Erros

- `EntityNotFoundException`
- `AccessDeniedException`
- `InvalidInputException`
- `ValidationException`
- `InternalServiceException`
- `ThrottlingException`

Ação CreateTableOptimizer (Python: create_table_optimizer)

Cria um novo otimizador de tabela para uma função específica.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de catálogo da tabela.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no catálogo em que a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome da tabela.

- `Type` – Obrigatório: string UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas.

- `TableOptimizerConfiguration` – Obrigatório: um objeto TableOptimizerConfiguration.

  Um `TableOptimizerConfiguration` objeto que representa a configuração de um otimizador de tabela.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `ValidationException`
- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `InternalServiceException`
- `ThrottlingException`

Ação DeleteTableOptimizer (Python: delete_table_optimizer)

Exclui um otimizador e todos os metadados associados de uma tabela. A otimização não será mais executada na tabela.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de catálogo da tabela.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no catálogo em que a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela.
- `Type` – Obrigatório: string UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`
- `ThrottlingException`

Ação UpdateTableOptimizer (Python: update_table_optimizer)

Atualiza a configuração de um otimizador de tabela existente.

Solicitação

- `CatalogId` – Obrigatório: string de ID de catálogo, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de catálogo da tabela.
- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome do banco de dados no catálogo em que a tabela reside.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela.

- `Type` – Obrigatório: string UTF-8 (valores válidos: `compaction="COMPACTION"` | `retention="RETENTION"` | `orphan_file_deletion="ORPHAN_FILE_DELETION"`).

  O tipo de otimizador de tabelas.

- `TableOptimizerConfiguration` – Obrigatório: um objeto TableOptimizerConfiguration.

  Um `TableOptimizerConfiguration` objeto que representa a configuração de um otimizador de tabela.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `AccessDeniedException`
- `ValidationException`
- `InternalServiceException`
- `ThrottlingException`
- `ConcurrentModificationException`

API de crawlers e classificadores

A API Crawler and classifiers descreve os tipos de dados de crawler e de classificador do AWS Glue e inclui a API para criar, excluir, atualizar e listar crawlers ou classificadores.

Tópicos

- API do classificador

- API do crawler
- API de estatísticas de colunas
- API do programador do crawler

API do classificador

A API de classificador descreve os tipos de dados de classificador do AWS Glue e inclui a API para criar, excluir, atualizar e listar classificadores.

Tipos de dados

- Estrutura Classifier
- Estrutura GrokClassifier
- Estrutura XMLClassifier
- Estrutura JsonClassifier
- Estrutura CsvClassifier
- Estrutura CreateGrokClassifierRequest
- Estrutura UpdateGrokClassifierRequest
- Estrutura CreateXMLClassifierRequest
- Estrutura UpdateXMLClassifierRequest
- Estrutura CreateJsonClassifierRequest
- Estrutura UpdateJsonClassifierRequest
- Estrutura CreateCsvClassifierRequest
- Estrutura UpdateCsvClassifierRequest

Estrutura Classifier

Os classificadores são acionados durante um trabalho de rastreamento. Um classificador verifica se determinado arquivo está em um formato que pode ser processado. Se estiver, o classificador cria um esquema na forma de um objeto `StructType` que corresponde a esse formato de dados.

Você pode usar os classificadores padrão fornecidos pelo AWS Glue ou gravar seus próprios classificadores para categorizar melhor suas fontes de dados e especificar os esquemas apropriados

a serem usados para eles. Ele pode ser um classificador `grok`, `XML` ou `JSON`, ou um `CSV` personalizado, conforme especificado em um dos campos no objeto `Classifier`.

Campos

- `GrokClassifier` – Um objeto GrokClassifier.

  Um classificador que usa `grok`.
- `XMLClassifier` – Um objeto XMLClassifier.

  Um classificador para o conteúdo XML.
- `JsonClassifier` – Um objeto JsonClassifier.

  Um classificador para o conteúdo JSON.
- `CsvClassifier` – Um objeto CsvClassifier.

  Um classificador para valores separados por vírgula (CSV, comma-separated values).

Estrutura GrokClassifier

Um classificador que usa padrões `grok`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.
- `Classification` – Obrigatório: string UTF-8.

  Um identificador do formato de dados com o qual o classificador corresponde, como Twitter, JSON, logs da Omniture, e assim por diante.
- `CreationTime` – Timestamp.

  A hora em que o classificador foi registrado.
- `LastUpdated` – Timestamp.

  A hora em que o classificador foi atualizado pela última vez.
- `Version` – Número (extenso).

A versão do classificador.

- `GrokPattern` – Obrigatório: string UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a A Logstash Grok string pattern.

  O padrão grok aplicado a um armazenamento de dados por este classificador. Para obter mais informações, consulte os padrões integrados em Escrever classificadores personalizados.
- `CustomPatterns` – String UTF-8 com comprimento não superior a 16.000 bytes, correspondente a URI address multi-line string pattern.

  Padrões grok personalizados opcionais definidos por este classificador. Para obter mais informações, consulte os padrões personalizados em Escrever classificadores personalizados.

Estrutura XMLClassifier

Um classificador para o conteúdo `XML`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.
- `Classification` – Obrigatório: string UTF-8.

  Um identificador do formato de dados aos quais o classificador corresponde.
- `CreationTime` – Timestamp.

  A hora em que o classificador foi registrado.
- `LastUpdated` – Timestamp.

  A hora em que o classificador foi atualizado pela última vez.
- `Version` – Número (extenso).

  A versão do classificador.
- `RowTag` – String UTF-8.

  A tag XML que designa o elemento que contém cada registro em um documento XML sendo analisado. Isso não pode identificar um elemento de fechamento automático (fechado por `/>`). Um

elemento de linha vazio que contém somente atributos pode ser analisado desde que ele termine com uma tag de fechamento (por exemplo, `<row item_a="A" item_b="B"></row>` ok, mas `<row item_a="A" item_b="B" />` não).

Estrutura JsonClassifier

Um classificador para o conteúdo `JSON`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.
- `CreationTime` – Timestamp.

  A hora em que o classificador foi registrado.
- `LastUpdated` – Timestamp.

  A hora em que o classificador foi atualizado pela última vez.
- `Version` – Número (extenso).

  A versão do classificador.
- `JsonPath` – Obrigatório: string UTF-8.

  Uma string `JsonPath` define os dados JSON para o classificador classificar. O AWS Glue oferece suporte a um subconjunto de JsonPath, conforme descrito em Gravar classificadores personalizados JsonPath.

Estrutura CsvClassifier

Um classificador para conteúdo `CSV` personalizado.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.

- `CreationTime` – Timestamp.

  A hora em que o classificador foi registrado.

- `LastUpdated` – Timestamp.

  A hora em que o classificador foi atualizado pela última vez.

- `Version` – Número (extenso).

  A versão do classificador.

- `Delimiter`: string UTF-8, não menos do que 1 ou superior a 1 byte de comprimento, correspondente a Custom string pattern #26.

  Um símbolo personalizado para indicar o que separa cada entrada de coluna na linha.

- `QuoteSymbol`: string UTF-8, não menos do que 1 ou superior a 1 byte de comprimento, correspondente a Custom string pattern #26.

  Um símbolo personalizado para indicar o que combina o conteúdo em um único valor da coluna. Deve ser diferente do delimitador de coluna.

- `ContainsHeader` – String UTF-8 (valores válidos: `UNKNOWN` | `PRESENT` | `ABSENT`).

  Indica se o arquivo CSV contém um cabeçalho.

- `Header` – Uma matriz de strings UTF-8.

  Uma lista de strings que representam nomes de coluna.

- `DisableValueTrimming` – Booleano.

  Especifica para não remover valores antes de identificar o tipo dos valores de coluna. O valor padrão é `true`.

- `AllowSingleColumn` – Booleano.

  Habilita o processamento de arquivos que contêm apenas uma coluna.

- `CustomDatatypeConfigured` – Booleano.

  Permite que o tipo de dados personalizado seja configurado.

- `CustomDatatypes` – Uma matriz de strings UTF-8.

  Uma lista de tipos de dados personalizados, incluindo “BINARY”, “BOOLEAN”, “DATE”, “DECIMAL”, “DOUBLE”, “FLOAT”, “INT”, “LONG”, “SHORT”, “STRING”, “TIMESTAMP”.

- `Serde` – String UTF-8 (valores válidos: `OpenCSVSerDe` | `LazySimpleSerDe` | `None`).

  Define o SerDe para processamento de CSV no classificador, que será aplicado no catálogo de dados. Os valores válidos são `OpenCSVSerDe`, `LazySimpleSerDe` e `None`. Você pode especificar o valor `None` quando quiser que o crawler faça a detecção.

Estrutura CreateGrokClassifierRequest

Especifica um classificador `grok` a ser criado por `CreateClassifier`.

Campos

- `Classification` – Obrigatório: string UTF-8.

  Um identificador do formato de dados com o qual o classificador corresponde, como Twitter, JSON, logs da Omniture, Amazon CloudWatch Logs e assim por diante.
- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do novo classificador.
- `GrokPattern` – Obrigatório: string UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a A Logstash Grok string pattern.

  O padrão grok que é usado por este classificador.
- `CustomPatterns` – String UTF-8 com comprimento não superior a 16.000 bytes, correspondente a URI address multi-line string pattern.

  Padrões grok personalizados opcionais usados por este classificador.

Estrutura UpdateGrokClassifierRequest

Especifica um classificador grok a ser atualizado quando transmitido para `UpdateClassifier`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da `GrokClassifier`.

- `Classification` – String UTF-8.

  Um identificador do formato de dados com o qual o classificador corresponde, como Twitter, JSON, logs da Omniture, Amazon CloudWatch Logs e assim por diante.

- `GrokPattern` – String UTF-8, superior a 1 e inferior a 2048 bytes de comprimento, correspondente a A Logstash Grok string pattern.

  O padrão grok que é usado por este classificador.

- `CustomPatterns` – String UTF-8 com comprimento não superior a 16.000 bytes, correspondente a URI address multi-line string pattern.

  Padrões grok personalizados opcionais usados por este classificador.

Estrutura CreateXMLClassifierRequest

Especifica um classificador XML a ser criado por `CreateClassifier`.

Campos

- `Classification` – Obrigatório: string UTF-8.

  Um identificador do formato de dados aos quais o classificador corresponde.

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.

- `RowTag` – String UTF-8.

  A tag XML que designa o elemento que contém cada registro em um documento XML sendo analisado. Isso não pode identificar um elemento de fechamento automático (fechado por `/>`). Um elemento de linha vazio que contém somente atributos pode ser analisado desde que ele termine com uma tag de fechamento (por exemplo, `<row item_a="A" item_b="B"></row>` ok, mas `<row item_a="A" item_b="B" />` não).

Estrutura UpdateXMLClassifierRequest

Especifica um classificador XML a ser atualizado.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.

- `Classification` – String UTF-8.

  Um identificador do formato de dados aos quais o classificador corresponde.

- `RowTag` – String UTF-8.

  A tag XML que designa o elemento que contém cada registro em um documento XML sendo analisado. Ela não pode identificar um elemento de fechamento automático (fechado por `/>`). Um elemento de linha vazio que contém somente atributos pode ser analisado desde que ele termine com uma tag de fechamento (por exemplo, `<row item_a="A" item_b="B"></row>` ok, mas `<row item_a="A" item_b="B" />` não).

Estrutura CreateJsonClassifierRequest

Especifica um classificador JSON a ser criado por `CreateClassifier`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.

- `JsonPath` – Obrigatório: string UTF-8.

  Uma string `JsonPath` define os dados JSON para o classificador classificar. O AWS Glue oferece suporte a um subconjunto de JsonPath, conforme descrito em Gravar classificadores personalizados JsonPath.

Estrutura UpdateJsonClassifierRequest

Especifica um classificador JSON a ser atualizado.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.

- `JsonPath` – String UTF-8.

  Uma string `JsonPath` define os dados JSON para o classificador classificar. O AWS Glue oferece suporte a um subconjunto de JsonPath, conforme descrito em Gravar classificadores personalizados JsonPath.

Estrutura CreateCsvClassifierRequest

Especifica um classificador CSV personalizado a ser criado por `CreateClassifier`.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.

- `Delimiter`: string UTF-8, não menos do que 1 ou superior a 1 byte de comprimento, correspondente a Custom string pattern #26.

  Um símbolo personalizado para indicar o que separa cada entrada de coluna na linha.

- `QuoteSymbol`: string UTF-8, não menos do que 1 ou superior a 1 byte de comprimento, correspondente a Custom string pattern #26.

  Um símbolo personalizado para indicar o que combina o conteúdo em um único valor da coluna. Deve ser diferente do delimitador de coluna.

- `ContainsHeader` – String UTF-8 (valores válidos: `UNKNOWN` | `PRESENT` | `ABSENT`).

  Indica se o arquivo CSV contém um cabeçalho.

- `Header` – Uma matriz de strings UTF-8.

  Uma lista de strings que representam nomes de coluna.

- `DisableValueTrimming` – Booleano.

Especifica para não remover valores antes de identificar o tipo dos valores de coluna. O valor padrão é true.

- `AllowSingleColumn` – Booleano.

  Habilita o processamento de arquivos que contêm apenas uma coluna.

- `CustomDatatypeConfigured` – Booleano.

  Permite a configuração de tipos de dados personalizados.

- `CustomDatatypes` – Uma matriz de strings UTF-8.

  Cria uma lista de tipos de dados personalizados válidos.

- `Serde` – String UTF-8 (valores válidos: `OpenCSVSerDe` | `LazySimpleSerDe` | `None`).

  Define o SerDe para processamento de CSV no classificador, que será aplicado no catálogo de dados. Os valores válidos são `OpenCSVSerDe`, `LazySimpleSerDe` e `None`. Você pode especificar o valor `None` quando quiser que o crawler faça a detecção.

Estrutura UpdateCsvClassifierRequest

Especifica um classificador CSV personalizado a ser atualizado.

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do classificador.

- `Delimiter`: string UTF-8, não menos do que 1 ou superior a 1 byte de comprimento, correspondente a Custom string pattern #26.

  Um símbolo personalizado para indicar o que separa cada entrada de coluna na linha.

- `QuoteSymbol`: string UTF-8, não menos do que 1 ou superior a 1 byte de comprimento, correspondente a Custom string pattern #26.

  Um símbolo personalizado para indicar o que combina o conteúdo em um único valor da coluna. Deve ser diferente do delimitador de coluna.

- `ContainsHeader` – String UTF-8 (valores válidos: `UNKNOWN` | `PRESENT` | `ABSENT`).

Indica se o arquivo CSV contém um cabeçalho.

- `Header` – Uma matriz de strings UTF-8.

  Uma lista de strings que representam nomes de coluna.

- `DisableValueTrimming` – Booleano.

  Especifica para não remover valores antes de identificar o tipo dos valores de coluna. O valor padrão é true.

- `AllowSingleColumn` – Booleano.

  Habilita o processamento de arquivos que contêm apenas uma coluna.

- `CustomDatatypeConfigured` – Booleano.

  Especifica a configuração de tipos de dados personalizados.

- `CustomDatatypes` – Uma matriz de strings UTF-8.

  Especifica uma lista de tipos de dados personalizados válidos.

- `Serde` – String UTF-8 (valores válidos: `OpenCSVSerDe` | `LazySimpleSerDe` | `None`).

  Define o SerDe para processamento de CSV no classificador, que será aplicado no catálogo de dados. Os valores válidos são `OpenCSVSerDe`, `LazySimpleSerDe` e `None`. Você pode especificar o valor `None` quando quiser que o crawler faça a detecção.

Operações

- Ação CreateClassifier (Python: create_classifier)
- Ação DeleteClassifier (Python: delete_classifier)
- Ação GetClassifier (Python: get_classifier)
- Ação GetClassifiers (Python: get_classifiers)
- Ação UpdateClassifier (Python: update_classifier)

Ação CreateClassifier (Python: create_classifier)

Cria um classificador na conta do usuário. Pode ser um `GrokClassifier`, um `XMLClassifier`, um `JsonClassifier` ou um `CsvClassifier`, dependendo de qual campo da solicitação está presente.

Solicitação

- `GrokClassifier` – Um objeto CreateGrokClassifierRequest.

  Um objeto `GrokClassifier` que especifica o classificador a ser criado.
- `XMLClassifier` – Um objeto CreateXMLClassifierRequest.

  Um objeto `XMLClassifier` que especifica o classificador a ser criado.
- `JsonClassifier` – Um objeto CreateJsonClassifierRequest.

  Um objeto `JsonClassifier` que especifica o classificador a ser criado.
- `CsvClassifier` – Um objeto CreateCsvClassifierRequest.

  Um objeto `CsvClassifier` que especifica o classificador a ser criado.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação DeleteClassifier (Python: delete_classifier)

Remove uma classificador do catálogo de dados.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do classificador a ser removido.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`

Ação GetClassifier (Python: get_classifier)

Recuperar um classificador por nome.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do classificador a ser recuperado.

Resposta

- `Classifier` – Um objeto Classificador.

  O classificador solicitado.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`

Ação GetClassifiers (Python: get_classifiers)

Lista todos os objetos de classificador no catálogo de dados.

Solicitação

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

O tamanho da lista a ser retornada (opcional).

- `NextToken` – String UTF-8.

  Um token de continuação opcional.

Resposta

- `Classifiers`: um array de objetos Classificador.

  A lista solicitada de objetos do classificador.

- `NextToken` – String UTF-8.

  Um token de continuação.

Erros

- `OperationTimeoutException`

Ação UpdateClassifier (Python: update_classifier)

Modifica um classificador existente (`GrokClassifier`, `XMLClassifier`, `JsonClassifier` ou `CsvClassifier`, dependendo de qual campo estiver presente).

Solicitação

- `GrokClassifier` – Um objeto UpdateGrokClassifierRequest.

  Um objeto `GrokClassifier` com campos atualizados.

- `XMLClassifier` – Um objeto UpdateXMLClassifierRequest.

  Um objeto `XMLClassifier` com campos atualizados.

- `JsonClassifier` – Um objeto UpdateJsonClassifierRequest.

  Um objeto `JsonClassifier` com campos atualizados.

- `CsvClassifier` – Um objeto UpdateCsvClassifierRequest.

  Um objeto `CsvClassifier` com campos atualizados.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `VersionMismatchException`
- `EntityNotFoundException`
- `OperationTimeoutException`

API do crawler

A API de crawler descreve os tipos de dados de crawler do AWS Glue, juntamente com a API para criar, excluir, atualizar e listar crawlers.

Tipos de dados

- Estrutura Crawler
- Estrutura Schedule
- Estrutura CrawlerTargets
- Estrutura S3Target
- Estrutura S3DeltaCatalogTarget
- Estrutura S3DeltaDirectTarget
- Estrutura JdbcTarget
- Estrutura MongoDBTarget
- Estrutura DynamoDBTarget
- Estrutura DeltaTarget
- Estrutura do IcebergTarget
- Estrutura HudiTarget
- Estrutura CatalogTarget
- Estrutura CrawlerMetrics
- Estrutura de CrawlerHistory
- Estrutura de CrawlsFilter

- Estrutura SchemaChangePolicy
- Estrutura LastCrawlInfo
- Estrutura RecrawlPolicy
- Estrutura LineageConfiguration
- Estrutura LakeFormationConfiguration

Estrutura Crawler

Especifica um programa de crawler que examina uma fonte de dados e usa classificadores para tentar determinar seu esquema. Se for bem-sucedido, o crawler registrará metadados da fonte de dados no AWS Glue Data Catalog.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do crawler.
- `Role` – String UTF-8.

  O nome de recurso da Amazon (ARN) de uma função do IAM que é usada para acessar os recursos do cliente, como o Amazon Simple Storage Service (Amazon S3).
- `Targets` – Um objeto CrawlerTargets.

  Uma coleção de destinos a serem rastreados.
- `DatabaseName` – String UTF-8.

  O nome do banco de dados no qual a saída do crawler é armazenada.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do crawler.
- `Classifiers` – Uma matriz de strings UTF-8.

  Uma lista de strings UTF-8 que especificam os classificadores personalizados associados ao crawler.
- `RecrawlPolicy` – Um objeto RecrawlPolicy.

Uma política que especifica se deseja rastrear todo o conjunto de dados novamente ou rastrear somente pastas que foram adicionadas desde a última execução do crawler.

- `SchemaChangePolicy` – Um objeto SchemaChangePolicy.

  A política que especifica os comportamentos de atualização e exclusão do crawler.

- `LineageConfiguration` – Um objeto LineageConfiguration.

  Uma configuração que especifica se a linhagem de dados está habilitada para o crawler.

- `State` – String UTF-8 (valores válidos: `READY` | `RUNNING` | `STOPPING`).

  Indica se o crawler está em execução ou se uma execução está pendente.

- `TablePrefix` – String UTF-8 com comprimento não superior a 128 bytes.

  O prefixo adicionado aos nomes das tabelas criadas.

- `Schedule` – Um objeto Programação.

  Para crawlers programados, a programação quando o crawler é executado.

- `CrawlElapsedTime` – Número (extenso).

  Se o crawler estiver em execução, conterá o tempo decorrido total desde o início do rastreamento.

- `CreationTime` – Timestamp.

  A hora em que o crawler foi criado.

- `LastUpdated` – Timestamp.

  A hora em que o crawler foi atualizado pela última vez.

- `LastCrawl` – Um objeto LastCrawlInfo.

  O status do último rastreamento e informações de erro (se houver algum).

- `Version` – Número (extenso).

  A versão do crawler.

- `Configuration` – String UTF-8.

  Informações de configuração do crawler. Esta string JSON com versionamento permite que os usuários especifiquem os aspectos do comportamento de um crawler. Para obter mais informações, consulte Definir opções de configuração do crawler.

- `CrawlerSecurityConfiguration` – String UTF-8 com comprimento não superior a 128 bytes.

  O nome da estrutura `SecurityConfiguration` a ser usada por este crawler.
- `LakeFormationConfiguration` – Um objeto LakeFormationConfiguration.

  Especifica se o crawler deve usar credenciais AWS Lake Formation para o crawler em vez das credenciais de função do IAM.

Estrutura Schedule

Um objeto de programação que usa uma instrução `cron` para programar um evento.

Campos

- `ScheduleExpression` – String UTF-8.

  Uma expressão `cron` usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers. Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.
- `State` – String UTF-8 (valores válidos: `SCHEDULED` | `NOT_SCHEDULED` | `TRANSITIONING`).

  O estado da programação.

Estrutura CrawlerTargets

Especifica os armazenamentos de dados a serem rastreados.

Campos

- `S3Targets`: um array de objetos S3Target.

  Especifica os destinos do Amazon Simple Storage Service (Amazon S3).
- `JdbcTargets`: um array de objetos JdbcTarget.

  Especifica destinos JDBC.
- `MongoDBTargets`: um array de objetos MongoDBTarget.

  Especifica destinos do Amazon DocumentDB ou MongoDB.
- `DynamoDBTargets`: um array de objetos DynamoDBTarget.

Especifica os destinos do Amazon DynamoDB.

- `CatalogTargets`: um array de objetos CatalogTarget.

  Especifica destinos do AWS Glue Data Catalog.

- `DeltaTargets`: um array de objetos DeltaTarget.

  Especifica os destinos do armazenamento de dados Delta.

- `IcebergTargets`: um array de objetos IcebergTarget.

  Especifica os destinos do armazenamento de dados do Apache Iceberg.

- `HudiTargets`: um array de objetos HudiTarget.

  Especifica os destinos do armazenamento de dados do Apache Hudi.

Estrutura S3Target

Especifica um armazenamento de dados no Amazon Simple Storage Service (Amazon S3).

Campos

- `Path` – String UTF-8.

  O caminho do destino do Amazon S3.

- `Exclusions` – Uma matriz de strings UTF-8.

  Uma lista de padrões glob utilizados para a exclusão do rastreamento. Para obter mais informações, consulte Catalogar tabelas com um crawler.

- `ConnectionName`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O nome de uma conexão que permite que um trabalho ou crawler acesse dados no Amazon S3 em um ambiente do Amazon Virtual Private Cloud (Amazon VPC).

- `SampleSize` – Número (íntegro).

  Define o número de arquivos em cada pasta de folha a serem rastreados ao realizar crawling de arquivos de amostra em um conjunto de dados. Se não for definido, todos os arquivos serão rastreados. Um valor válido é um número inteiro entre 1 e 249.

- `EventQueueArn` – String UTF-8.

Um ARN válido do Amazon SQS. Por exemplo, .`arn:aws:sqs:region:account:sqs`

- `DlqEventQueueArn` – String UTF-8.

  Um ARN do SQS de mensagem morta válida da Amazon. Por exemplo, .`arn:aws:sqs:region:account:deadLetterQueue`

Estrutura S3DeltaCatalogTarget

Especifica um destino que grava em uma fonte de dados do Delta Lake no catálogo de dados do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.

- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica as opções de conexão adicionais para o conector.

- `SchemaChangePolicy` – Um objeto CatalogSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura S3DeltaDirectTarget

Especifica um destino que grava em uma fonte de dados do Delta Lake no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.

- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O caminho do Amazon S3 da fonte de dados do Delta Lake na qual gravar.

- `Compression` – Obrigatório: string UTF-8 (valores válidos: `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).

- `NumberTargetPartitions` – String UTF-8.

  Especifica o número de partições de destino para distribuição dos arquivos do conjunto de dados do Data Lake no Amazon S3.

- `Format`: obrigatório: string UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica o formato de saída de dados para o destino.

- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica as opções de conexão adicionais para o conector.

- `SchemaChangePolicy` – Um objeto DirectSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura JdbcTarget

Especifica um armazenamento de dados JDBC a ser rastreado.

Campos

- `ConnectionName`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O nome da conexão a ser usada para se conectar com o destino JDBC.
- `Path` – String UTF-8.

  O caminho do destino do JDBC.
- `Exclusions` – Uma matriz de strings UTF-8.

  Uma lista de padrões glob utilizados para a exclusão do rastreamento. Para obter mais informações, consulte Catalogar tabelas com um crawler.
- `EnableAdditionalMetadata` – Uma matriz de strings UTF-8.

  Especifique um valor de `RAWTYPES` ou `COMMENTS` para habilitar metadados adicionais nas respostas da tabela. O `RAWTYPES` fornece o tipo de dados de nível nativo. O `COMMENTS` fornece comentários associados a uma coluna ou tabela no banco de dados.

  Se você não precisar de metadados adicionais, deixe o campo vazio.

Estrutura MongoDBTarget

Especifica um armazenamento de dados do Amazon DocumentDB ou MongoDB a ser rastreado.

Campos

- `ConnectionName`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O nome da conexão a ser usada para se conectar com o destino do Amazon DocumentDB ou MongoDB.
- `Path` – String UTF-8.

O caminho do destino do Amazon DocumentDB ou MongoDB (banco de dados/coleção).

- `ScanAll` – Booleano.

  Indica se deseja verificar todos os registros ou amostras de linhas da tabela. A verificação de todos os registros pode levar muito tempo quando a tabela não é de throughput alto.

  Um valor de `true` indica para verificar todos os registros, enquanto um valor de `false` indica para criar amostra dos registros. Se nenhum valor for especificado, o valor `true` será assumido como padrão.

Estrutura DynamoDBTarget

Especifica uma tabela do Amazon DynamoDB para ser rastreada.

Campos

- `Path` – String UTF-8.

  O nome da tabela do DynamoDB a ser rastreada.

- `scanAll` – Booleano.

  Indica se deseja verificar todos os registros ou amostras de linhas da tabela. A verificação de todos os registros pode levar muito tempo quando a tabela não é de throughput alto.

  Um valor de `true` indica para verificar todos os registros, enquanto um valor de `false` indica para criar amostra dos registros. Se nenhum valor for especificado, o valor `true` será assumido como padrão.

- `scanRate` – Número (duplo).

  A porcentagem das unidades de capacidade de leitura configuradas a serem usadas pelo crawler do AWS Glue. Unidades de capacidade de leitura é um termo definido pelo DynamoDB e é um valor numérico que atua como limitador de taxa para o número de leituras que podem ser executadas nessa tabela por segundo.

  Os valores válidos são nulos ou um valor entre 0,1 e 1,5. Um valor nulo é usado quando o usuário não fornece um valor e é usado como padrão 0,5 da unidade de capacidade de leitura configurada (para tabelas provisionadas) ou 0,25 da unidade de capacidade de leitura máxima configurada (para tabelas que usam o modo sob demanda).

Estrutura DeltaTarget

Especifica um armazenamento de dados Delta para rastrear uma ou mais tabelas Delta.

Campos

- `DeltaTables` – Uma matriz de strings UTF-8.

  Uma lista de caminhos do Amazon S3 para as tabelas Delta.
- `ConnectionName`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O nome da conexão a ser usada para se conectar ao destino da tabela Delta.
- `WriteManifest` – Booleano.

  Especifica se os arquivos de manifesto devem ser gravados no caminho da tabela Delta.
- `CreateNativeDeltaTable` – Booleano.

  Especifica se o crawler criará tabelas nativas para permitir a integração com mecanismos de consulta compatíveis consulta direta ao log de transações do Delta.

Estrutura do IcebergTarget

Especifica uma fonte de dados do Apache Iceberg na qual as tabelas do Iceberg são armazenadas no Amazon S3.

Campos

- `Paths` – Uma matriz de strings UTF-8.

  Um ou mais caminhos do Amazon S3 que contêm pastas de metadados do Iceberg como `s3://bucket/prefix`.
- `ConnectionName`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O nome da conexão a ser usada para se conectar com o destino do Iceberg.
- `Exclusions` – Uma matriz de strings UTF-8.

  Uma lista de padrões glob utilizados para a exclusão do rastreamento. Para obter mais informações, consulte Catalogar tabelas com um crawler.
- `MaximumTraversalDepth` – Número (íntegro).

A profundidade máxima de caminhos do Amazon S3 que o crawler pode percorrer para descobrir a pasta de metadados do Iceberg no caminho do Amazon S3. Usado para limitar o runtime do crawler.

Estrutura HudiTarget

Especifica uma fonte de dados do Apache Hudi.

Campos

- `Paths` – Uma matriz de strings UTF-8.

  Uma matriz de strings de localização do Amazon S3 para o Hudi, cada uma indicando a pasta raiz na qual residem os arquivos de metadados de uma tabela do Hudi. A pasta do Hudi pode estar localizada em uma pasta secundária da pasta raiz.

  O crawler examinará todas as pastas abaixo de um caminho para uma pasta do Hudi.
- `ConnectionName`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O nome da conexão a ser usada para se conectar com o destino do Hudi. Se seus arquivos do Hudi estiverem armazenados em buckets que exigem autorização de VPC, você pode definir suas propriedades de conexão aqui.
- `Exclusions` – Uma matriz de strings UTF-8.

  Uma lista de padrões glob utilizados para a exclusão do rastreamento. Para obter mais informações, consulte Catalogar tabelas com um crawler.
- `MaximumTraversalDepth` – Número (íntegro).

  A profundidade máxima de caminhos do Amazon S3 que o crawler pode percorrer para descobrir a pasta de metadados do Hudi no caminho do Amazon S3. Usado para limitar o runtime do crawler.

Estrutura CatalogTarget

Especifica um destino do AWS Glue Data Catalog.

Campos

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados a ser sincronizado.

- `Tables` – Obrigatório: uma matriz de strings UTF-8, pelo menos 1 string.

  Uma lista de tabelas a serem sincronizadas.

- `ConnectionName`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O nome da conexão de uma tabela de catálogo de dados baseada no Amazon S3 é um destino do crawl quando um tipo de conexão `Catalog` pareado a um tipo de conexão `NETWORK` é usado.

- `EventQueueArn` – String UTF-8.

  Um ARN válido do Amazon SQS. Por exemplo, `.arn:aws:sqs:region:account:sqs`

- `DlqEventQueueArn` – String UTF-8.

  Um ARN do SQS de mensagem morta válida da Amazon. Por exemplo, `.arn:aws:sqs:region:account:deadLetterQueue`

Estrutura CrawlerMetrics

Métricas para um crawler especificado.

Campos

- `CrawlerName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do crawler.

- `TimeLeftSeconds` – Número (dobro), não mais do que None (Nenhum).

  O tempo estimado restante para concluir um rastreamento em execução.

- `StillEstimating` – Booleano.

  True se o crawler ainda estiver estimando quanto tempo demorará para concluir a execução.

- `LastRuntimeSeconds` – Número (dobro), não mais do que None (Nenhum).

A duração da execução mais recente do crawler em segundos.

- `MedianRuntimeSeconds` – Número (dobro), não mais do que None (Nenhum).

  A duração média da execução do crawler em segundos.

- `TablesCreated` – Número (inteiro), não mais do que None (Nenhum).

  O número de tabelas criadas por este crawler.

- `TablesUpdated` – Número (inteiro), não mais do que None (Nenhum).

  O número de tabelas atualizadas por este crawler.

- `TablesDeleted` – Número (inteiro), não mais do que None (Nenhum).

  O número de tabelas excluídas por este crawler.

Estrutura de CrawlerHistory

Contém as informações sobre uma execução de um crawler.

Campos

- `CrawlId` – String UTF-8.

  Um identificador UUID para cada crawl.

- `State` – String UTF-8 (valores válidos: `RUNNING` | `COMPLETED` | `FAILED` | `STOPPED`).

  O estado do crawl.

- `StartTime` – Timestamp.

  A data e a hora em que o monitoramento foi iniciado.

- `EndTime` – Timestamp.

  A data e a hora em que o crawl terminou.

- `Summary` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um resumo da execução para o crawl específico em JSON. Contém as partições e tabelas de catálogo que foram adicionadas, atualizadas ou excluídas.

- `ErrorMessage`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Em caso de erro, a mensagem de erro associada ao crawl.

- `LogGroup`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Log group string pattern.

  O grupo de logs associado ao crawl.

- `LogStream`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Log-stream string pattern.

  O fluxo de logs associado ao rastreamento.

- `MessagePrefix` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O prefixo de uma mensagem do CloudWatch sobre este crawl.

- `DPUHour` – Número (dobro), não mais do que None (Nenhum).

  O número de data processing units (DPU – Unidades de processamento de dados) usadas para o crawl em horas.

Estrutura de CrawlsFilter

Uma lista de campos, comparadores e valores que você pode usar para filtrar as execuções de crawler para um crawler especificado.

Campos

- `FieldName` – String UTF-8 (valores válidos: `CRAWL_ID` | `STATE` | `START_TIME` | `END_TIME` | `DPU_HOUR`).

  Uma chave usada para filtrar as execuções de crawler para um crawler especificado. Os valores válidos para cada um dos nomes de campo são:

  - `CRAWL_ID`: uma string que representa o identificador UUID para um crawl.
  - `STATE`: uma string que representa o estado do crawl.
  - `START_TIME` e `END_TIME`: o carimbo de data e hora de época em milissegundos.
  - `DPU_HOUR`: O número de horas de DPU usadas para o crawl.

- `FilterOperator` – String UTF-8 (valores válidos: `GT` | `GE` | `LT` | `LE` | `EQ` | `NE`).

  Um comparador definido que opera no valor. Os operadores disponíveis são:

  - `GT`: maior que.
  - `GE`: maior ou igual a.
  - `LT`: menor que.
  - `LE`: menor ou igual a.
  - `EQ`: igual a.
  - `NE`: não é igual a.
- `FieldValue` – String UTF-8.

  O valor fornecido para comparação no campo de crawl.

Estrutura SchemaChangePolicy

Uma política que especifica os comportamentos de atualização e exclusão do crawler.

Campos

- `UpdateBehavior`: string UTF-8 (valores válidos: `LOG` | `UPDATE_IN_DATABASE`).

  O comportamento de atualização quando o crawler encontra um esquema alterado.
- `DeleteBehavior` – String UTF-8 (valores válidos: `LOG` | `DELETE_FROM_DATABASE` | `DEPRECATE_IN_DATABASE`).

  O comportamento de exclusão quando o crawler encontra um objeto excluído.

Estrutura LastCrawlInfo

Informações de status e erro do rastreamento mais recente.

Campos

- `Status` – String UTF-8 (valores válidos: `SUCCEEDED` | `CANCELLED` | `FAILED`).

  Status do último rastreamento.
- `ErrorMessage`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

Se ocorrer um erro, as informações de erro do último rastreamento.

- `LogGroup`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Log group string pattern.

  O grupo de logs do último rastreamento.

- `LogStream`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Log-stream string pattern.

  O stream de logs do último rastreamento.

- `MessagePrefix` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O prefixo de uma mensagem sobre este rastreamento.

- `StartTime` – Timestamp.

  A hora em que o rastreamento foi iniciado.

Estrutura RecrawlPolicy

Ao realizar o crawling de uma fonte de dados do Amazon S3 após a conclusão do primeiro rastreamento, especifica se deseja rastrear todo o conjunto de dados novamente ou somente pastas que foram adicionadas desde a última execução do crawler. Para obter mais informações, consulte Crawls incrementais no AWS Glue no guia do desenvolvedor.

Campos

- `RecrawlBehavior` – String UTF-8 (valores válidos: `CRAWL_EVERYTHING` | `CRAWL_NEW_FOLDERS_ONLY` | `CRAWL_EVENT_MODE`).

  Especifica se deseja rastrear todo o conjunto de dados novamente ou somente as pastas que foram adicionadas desde a última execução do crawler.

  Um valor de `CRAWL_EVERYTHING` especifica o crawling de todo o conjunto de dados novamente.

  Um valor de `CRAWL_NEW_FOLDERS_ONLY` especifica o crawling de somente as pastas que foram adicionadas desde a última execução do crawler.

Um valor de `CRAWL_EVENT_MODE` especifica o crawling somente das alterações identificadas pelos eventos do Amazon S3.

Estrutura LineageConfiguration

Especifica as definições de configuração de linhagem de dados para o crawler.

Campos

- `CrawlerLineageSettings`: string UTF-8 (valores válidos: `ENABLE` | `DISABLE`).

  Especifica se a linhagem de dados está habilitada para o crawler. Os valores válidos são:

  - ENABLE (Habilitar): habilita a linhagem de dados para o crawler
  - DISABLE (Desabilitar): desabilita a linhagem de dados para o crawler

Estrutura LakeFormationConfiguration

Especifica as definições de configuração do AWS Lake Formation para o crawler.

Campos

- `UseLakeFormationCredentials` – Booleano.

  Especifica se as credenciais AWS Lake Formation devem ser usadas para o crawler em vez das credenciais de função do IAM.

- `AccountId` – String UTF-8, não mais de 12 bytes.

  Obrigatório para rastreamentos de conta cruzada. Para os mesmos rastreamentos de conta que os dados de destino, isso pode ser deixado como nulo.

Operações

- Ação CreateCrawler (Python: create_crawler)
- Ação DeleteCrawler (Python: delete_crawler)
- Ação GetCrawler (Python: get_crawler)
- Ação GetCrawlers (Python: get_crawlers)

- Ação GetCrawlerMetrics (Python: get_crawler_metrics)
- Ação UpdateCrawler (Python: update_crawler)
- Ação StartCrawler (Python: start_crawler)
- Ação StopCrawler (Python: stop_crawler)
- Ação BatchGetCrawlers (Python: batch_get_crawlers)
- Ação ListCrawlers (Python: list_crawlers)
- Ação ListCrawls (Python: list_crawls)

Ação CreateCrawler (Python: create_crawler)

Cria um novo crawler com destinos específicos, função, configuração e programação opcional. Pelo menos um destino de rastreamento deve ser especificado no campos `s3Targets`, `jdbcTargets` ou `DynamoDBTargets`.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do novo crawler.
- `Role` – Obrigatório: string UTF-8.

  A função do IAM ou o nome de recurso da Amazon (ARN) de uma função do IAM usada pelo novo crawler para acessar os recursos do cliente.
- `DatabaseName` – String UTF-8.

  O banco de dados do AWS Glue em que os resultados são gravados, como: `arn:aws:daylight:us-east-1::database/sometable/*`.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do novo crawler.
- `Targets` – Obrigatório: um objeto CrawlerTargets.

  Uma lista da coleção de destinos a serem rastreados.
- `Schedule` – String UTF-8.

Uma expressão `cron` usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers. Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.

- `Classifiers` – Uma matriz de strings UTF-8.

  Uma lista de classificadores personalizados que o usuário registrou. Por padrão, todos os classificadores integrados são incluídos em um rastreamento. No entanto, esses classificadores personalizados sempre substituem os classificadores padrão de uma determinada classificação.

- `TablePrefix` – String UTF-8 com comprimento não superior a 128 bytes.

  O prefixo que é usado para tabelas de catálogo criadas.

- `SchemaChangePolicy` – Um objeto SchemaChangePolicy.

  A política do comportamento de atualização e exclusão do crawler.

- `RecrawlPolicy` – Um objeto RecrawlPolicy.

  Uma política que especifica se deseja rastrear todo o conjunto de dados novamente ou rastrear somente pastas que foram adicionadas desde a última execução do crawler.

- `LineageConfiguration` – Um objeto LineageConfiguration.

  Especifica as definições de configuração de linhagem de dados para o crawler.

- `LakeFormationConfiguration` – Um objeto LakeFormationConfiguration.

  Especifica as definições de configuração do AWS Lake Formation para o crawler.

- `Configuration` – String UTF-8.

  Informações de configuração do crawler. Esta string JSON com versionamento permite que os usuários especifiquem os aspectos do comportamento de um crawler. Para obter mais informações, consulte Definir opções de configuração do crawler.

- `CrawlerSecurityConfiguration` – String UTF-8 com comprimento não superior a 128 bytes.

  O nome da estrutura `SecurityConfiguration` a ser usada por este crawler.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

As tags a serem usadas com essa solicitação de crawler. Você pode usar tags para limitar o acesso ao crawler. Para obter mais informações sobre tags no AWS Glue, consulte Tags da AWS no AWS Glue no guia do desenvolvedor.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

Ação DeleteCrawler (Python: delete_crawler)

Remove um crawler especificado do AWS Glue Data Catalog, a menos que o estado do crawler seja `RUNNING`.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do crawler a ser removido.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `CrawlerRunningException`
- `SchedulerTransitioningException`

- `OperationTimeoutException`

Ação GetCrawler (Python: get_crawler)

Recupera metadados para um crawler especificado.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do crawler para o qual recuperar os metadados.

Resposta

- `Crawler` – Um objeto Crawler.

  Os metadados para o crawler especificado.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`

Ação GetCrawlers (Python: get_crawlers)

Recupera metadados para todos os crawlers definidos na conta do cliente.

Solicitação

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número de crawlers a ser retornado em cada chamada.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.

Resposta

- `Crawlers`: um array de objetos Crawler.

  Uma lista de metadados do crawler.

- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não tiver chegado ao final conforme definido nesta conta de cliente.

Erros

- `OperationTimeoutException`

Ação GetCrawlerMetrics (Python: get_crawler_metrics)

Recupera métricas dos crawlers especificados.

Solicitação

- `CrawlerNameList` – Uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista dos nomes dos crawlers de onde as métricas serão recuperadas.

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo de uma lista a ser retornada.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `CrawlerMetricsList`: um array de objetos CrawlerMetrics.

  Uma lista de métricas para o crawler especificado.

- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não contiver a métrica mais recente disponível.

Erros

- `OperationTimeoutException`

Ação UpdateCrawler (Python: update_crawler)

Atualiza um crawler. Se um crawler estiver em execução, você precisará interrompê-lo usando `StopCrawler` antes de fazer a atualização.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do novo crawler.

- `Role` – String UTF-8.

  A função do IAM ou o nome de recurso da Amazon (ARN) de uma função do IAM que é usada pelo novo crawler para acessar os recursos do cliente.

- `DatabaseName` – String UTF-8.

  O banco de dados do AWS Glue em que os resultados são armazenados, como: `arn:aws:daylight:us-east-1::database/sometable/*`.

- `Description`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a URI address multi-line string pattern.

  Uma descrição do novo crawler.

- `Targets` – Um objeto CrawlerTargets.

  Uma lista de destinos a serem rastreados.

- `Schedule` – String UTF-8.

  Uma expressão `cron` usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers. Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.

- `Classifiers` – Uma matriz de strings UTF-8.

Uma lista de classificadores personalizados que o usuário registrou. Por padrão, todos os classificadores integrados são incluídos em um rastreamento. No entanto, esses classificadores personalizados sempre substituem os classificadores padrão de uma determinada classificação.

- `TablePrefix` – String UTF-8 com comprimento não superior a 128 bytes.

  O prefixo que é usado para tabelas de catálogo criadas.

- `SchemaChangePolicy` – Um objeto SchemaChangePolicy.

  A política do comportamento de atualização e exclusão do crawler.

- `RecrawlPolicy` – Um objeto RecrawlPolicy.

  Uma política que especifica se deseja rastrear todo o conjunto de dados novamente ou rastrear somente pastas que foram adicionadas desde a última execução do crawler.

- `LineageConfiguration` – Um objeto LineageConfiguration.

  Especifica as definições de configuração de linhagem de dados para o crawler.

- `LakeFormationConfiguration` – Um objeto LakeFormationConfiguration.

  Especifica as definições de configuração do AWS Lake Formation para o crawler.

- `Configuration` – String UTF-8.

  Informações de configuração do crawler. Esta string JSON com versionamento permite que os usuários especifiquem os aspectos do comportamento de um crawler. Para obter mais informações, consulte Definir opções de configuração do crawler.

- `CrawlerSecurityConfiguration` – String UTF-8 com comprimento não superior a 128 bytes.

  O nome da estrutura `SecurityConfiguration` a ser usada por este crawler.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `VersionMismatchException`

- `EntityNotFoundException`
- `CrawlerRunningException`
- `OperationTimeoutException`

Ação StartCrawler (Python: start_crawler)

Inicia um rastreamento usando o crawler especificado, independentemente do que estiver programado. Se o crawler já está em execução, ele retorna um CrawlerRunningException.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do crawler a ser iniciado.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `CrawlerRunningException`
- `OperationTimeoutException`

Ação StopCrawler (Python: stop_crawler)

Se o crawler especificado estiver em execução, o rastreamento será interrompido.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do crawler a ser interrompido.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `CrawlerNotRunningException`
- `CrawlerStoppingException`
- `OperationTimeoutException`

Ação BatchGetCrawlers (Python: batch_get_crawlers)

Retorna uma lista de metadados do recurso para uma lista de nomes de crawler. Depois de chamar a operação `ListCrawlers`, você pode chamar essa operação para acessar os dados aos quais você recebeu permissões. Essa operação oferece suporte a todas as permissões do IAM, incluindo condições de permissão que usam tags.

Solicitação

- `CrawlerNames` – Obrigatório: uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista de nomes de crawler, que podem ser os nomes retornados da operação `ListCrawlers`.

Resposta

- `Crawlers`: um array de objetos Crawler.

  Uma lista de definições do crawler.
- `CrawlersNotFound` – Uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista de nomes de crawlers que não foram encontrados.

Erros

- `InvalidInputException`

- `OperationTimeoutException`

Ação ListCrawlers (Python: list_crawlers)

Recupera os nomes de todos os recursos do crawler nessa conta da AWS ou os recursos com a tag especificada. Essa operação permite que você veja quais recursos estão disponíveis em sua conta e seus nomes.

Essa operação aceita o campo `Tags` opcional, que pode ser usado como um filtro na resposta, para que recursos com tags possam ser recuperados como um grupo. Se você optar por usar a filtragem por tags, apenas os recursos com a tag serão recuperados.

Solicitação

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo de uma lista a ser retornada.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Especifica apenas o retorno desses recursos com tags.

Resposta

- `CrawlerNames` – Uma matriz de strings UTF-8, no máximo 100 strings.

  Os nomes de todos os crawlers na conta ou os crawlers com as tags especificadas.
- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não contiver a métrica mais recente disponível.

Erros

- `OperationTimeoutException`

Ação ListCrawls (Python: list_crawls)

Retorna todos os crawls de um crawler especificado. Retorna apenas os crawls que ocorreram desde a data de execução do recurso de histórico do crawler e retém apenas até 12 meses de crawls. Crawls mais antigos não serão retornados.

Você pode usar essa API para:

- Recuperar todos os crawls de um crawler especificado.
- Recuperar todos os crawls de um crawler especificado dentro de uma contagem limitada.
- Recuperar todos os crawls de um crawler especificado em um intervalo de tempo específico.
- Recuperar todos os crawls de um crawler especificado com um determinado estado, ID de crawl ou valor de hora de DPU.

Solicitação

- `CrawlerName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do crawler cujas execuções você deseja recuperar.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados. O padrão é 20 e o máximo é 100.
- `Filters`: um array de objetos CrawlsFilter.

  Filtra os crawls de acordo com os critérios especificados em uma lista de objetos de `CrawlsFilter`.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `Crawls`: um array de objetos CrawlerHistory.

Uma lista de objetos de `CrawlerHistory` que representam as execuções de crawl que satisfazem seus critérios.

- `NextToken` – String UTF-8.

  Um token de continuação para paginação da lista de tokens retornada, retornado se o segmento atual da lista não for o último.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`

API de estatísticas de colunas

A API de estatísticas de colunas descreve as APIs do AWS Glue para retornar estatísticas em colunas em uma tabela.

Tipos de dados

- Estrutura ColumnStatisticsTaskRun
- Estrutura ColumnStatisticsTaskSettings
- Estrutura ExecutionAttempt

Estrutura ColumnStatisticsTaskRun

O objeto que mostra os detalhes da execução das estatísticas da coluna.

Campos

- `CustomerId` – String UTF-8, não mais de 12 bytes.

  O ID da conta da AWS.
- `ColumnStatisticsTaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador para a execução da tarefa de estatísticas de coluna específica.

- `DatabaseName` – String UTF-8.

  O banco de dados em que a tabela reside.

- `TableName` – String UTF-8.

  O nome da tabela para a qual as estatísticas da coluna são geradas.

- `ColumnNameList` – Uma matriz de strings UTF-8.

  Uma lista de nomes de coluna. Se nenhum valor for fornecido, todos os nomes de colunas da tabela serão usados por padrão.

- `CatalogID`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual reside a tabela. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.

- `Role` – String UTF-8.

  O perfil do IAM assumido pelo serviço para gerar estatísticas.

- `SampleSize`: número (double), no máximo 100.

  O percentual de linhas usadas para gerar estatísticas. Se nenhum valor for fornecido, a tabela inteira será usada para gerar estatísticas.

- `SecurityConfiguration` – String UTF-8 com comprimento não superior a 128 bytes.

  Nome da configuração de segurança usada para criptografar os logs do CloudWatch para a execução da tarefa de estatísticas da coluna.

- `NumberOfWorkers` – Número (inteiro), pelo menos 1.

  O número de operadores usados para gerar estatísticas de coluna. O trabalho é pré-configurado para escalar automaticamente para até 25 instâncias.

- `WorkerType` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O tipo dos operadores usados para gerar estatísticas. O padrão é `g.1x`.

- `ComputationType`: string UTF-8 (valores válidos: `FULL` | `INCREMENTAL`).

  O tipo de cálculo de estatísticas de coluna.

- `Status` – String UTF-8 (valores válidos: `STARTING` | `RUNNING` | `SUCCEEDED` | `FAILED` | `STOPPED`).

  O status da execução da tarefa.
- `CreationTime` – Timestamp.

  O horário em que a tarefa foi criada.
- `LastUpdated` – Timestamp.

  O momento em que a tarefa foi modificada pela última vez.
- `StartTime` – Timestamp.

  A hora de início da tarefa.
- `EndTime` – Timestamp.

  A hora de término da tarefa.
- `ErrorMessage`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A mensagem de erro para o trabalho.
- `DPUSeconds` – Número (dobro), não mais do que None (Nenhum).

  O uso calculado da DPU em segundos para todos os operadores com escalonamento automático.

Estrutura ColumnStatisticsTaskSettings

As configurações para uma tarefa de estatísticas de coluna.

Campos

- `DatabaseName` – String UTF-8.

  O nome do banco de dados no qual a tabela reside.
- `TableName` – String UTF-8.

  O nome da tabela para a qual as estatísticas de coluna serão geradas.
- `Schedule` – Um objeto Programação.

  Uma programação para executar as estatísticas de coluna especificada na sintaxe CRON.

- `ColumnNameList` – Uma matriz de strings UTF-8.

  Uma lista de nomes de colunas para as quais estatísticas devem ser executadas.
- `CatalogID`: string de ID de catálogo com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados reside.
- `Role` – String UTF-8.

  O perfil usado para executar as estatísticas de coluna.
- `SampleSize`: número (double), no máximo 100.

  O percentual de dados para amostrar.
- `SecurityConfiguration` – String UTF-8 com comprimento não superior a 128 bytes.

  Nome da configuração de segurança usada para criptografar os logs do CloudWatch.
- `ScheduleType`: string UTF-8 (valores válidos: `CRON` | `AUTO`).

  O tipo de programação para uma tarefa de estatísticas de coluna. Os valores possíveis podem ser `CRON` ou `AUTO`.
- `SettingSource`: string UTF-8 (valores válidos: `CATALOG` | `TABLE`).

  A fonte de configuração da tarefa de estatísticas de coluna. Os valores possíveis podem ser `CATALOG` ou `TABLE`.
- `LastExecutionAttempt` – Um objeto ExecutionAttempt.

  A última `ExecutionAttempt` da execução da tarefa de estatísticas de coluna.

Estrutura ExecutionAttempt

Uma tentativa de execução de uma tarefa de estatísticas de coluna.

Campos

- `Status`: string UTF-8 (valores válidos: `FAILED` | `STARTED`).

  O status da última execução da tarefa de estatísticas de coluna.
- `ColumnStatisticsTaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

Um ID de execução de tarefa para a última execução da tarefa de estatísticas de coluna.

- `ExecutionTimestamp` – Timestamp.

  Um timestamp em que a última execução da tarefa de estatísticas de coluna ocorreu.

- `ErrorMessage`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma mensagem de erro associada à última execução da tarefa de estatísticas de coluna.

Operações

- Ação StartColumnStatisticsTaskRun (Python: start_column_statistics_task_run)
- Ação GetColumnStatisticsTaskRun (Python: get_column_statistics_task_run)
- Ação GetColumnStatisticsTaskRuns (Python: get_column_statistics_task_runs)
- Ação ListColumnStatisticsTaskRuns (Python: list_column_statistics_task_runs)
- Ação StopColumnStatisticsTaskRun (Python: stop_column_statistics_task_run)
- Ação CreateColumnStatisticsTaskSettings (Python: create_column_statistics_task_settings)
- Ação UpdateColumnStatisticsTaskSettings (Python: update_column_statistics_task_settings)
- Ação GetColumnStatisticsTaskSettings (Python: get_column_statistics_task_settings)
- Ação DeleteColumnStatisticsTaskSettings (Python: delete_column_statistics_task_settings)
- Ação StartColumnStatisticsTaskRunSchedule (Python: start_column_statistics_task_run_schedule)
- Ação StopColumnStatisticsTaskRunSchedule (Python: stop_column_statistics_task_run_schedule)

Ação StartColumnStatisticsTaskRun (Python: start_column_statistics_task_run)

Inicia a execução de uma tarefa de estatísticas de colunas para uma tabela e colunas especificadas.

Solicitação

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no qual a tabela reside.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome da tabela para gerar estatísticas.

- `ColumnNameList` – Uma matriz de strings UTF-8.

  Uma lista de nomes de colunas para gerar estatísticas. Se nenhum valor for fornecido, todos os nomes de colunas da tabela serão usados por padrão.

- `Role`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O perfil do IAM assumido pelo serviço para gerar estatísticas.

- `SampleSize`: número (double), no máximo 100.

  O percentual de linhas usadas para gerar estatísticas. Se nenhum valor for fornecido, a tabela inteira será usada para gerar estatísticas.

- `CatalogID` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados no qual a tabela reside. Se nenhum valor for fornecido, o ID da conta da AWS será usado por padrão.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome da configuração de segurança usada para criptografar os logs do CloudWatch para a execução da tarefa de estatísticas da coluna.

Resposta

- `ColumnStatisticsTaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador para a execução da tarefa de estatísticas de colunas.

Erros

- `AccessDeniedException`
- `EntityNotFoundException`
- `ColumnStatisticsTaskRunningException`

- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `InvalidInputException`

Ação GetColumnStatisticsTaskRun (Python: get_column_statistics_task_run)

Obtenha os metadados/informações associados para a execução de uma tarefa com um ID de execução de tarefa específico.

Solicitação

- `ColumnStatisticsTaskRunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador para a execução da tarefa de estatísticas de coluna específica.

Resposta

- `ColumnStatisticsTaskRun` – Um objeto ColumnStatisticsTaskRun.

  Um `ColumnStatisticsTaskRun` objeto que representa os detalhes da execução de estatísticas de colunas.

Erros

- `EntityNotFoundException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação GetColumnStatisticsTaskRuns (Python: get_column_statistics_task_runs)

Recupera informações sobre todas as execuções associadas à tabela especificada.

Solicitação

- `DatabaseName` – Obrigatório: string UTF-8.

  O nome do banco de dados no qual a tabela reside.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela.

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo da resposta.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `ColumnStatisticsTaskRuns`: um array de objetos ColumnStatisticsTaskRun.

  Uma lista de execuções de tarefas de estatísticas de colunas.

- `NextToken` – String UTF-8.

  Um token de continuação, se todas as execuções de tarefas ainda não tiverem sido retornadas.

Erros

- `OperationTimeoutException`

Ação ListColumnStatisticsTaskRuns (Python: list_column_statistics_task_runs)

Liste todas as execuções tarefas para uma conta específica.

Solicitação

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo da resposta.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `ColumnStatisticsTaskRunIds` – Uma matriz de strings UTF-8, no máximo 100 strings.

  Uma lista IDs de execuções de tarefas de estatísticas de colunas.
- `NextToken` – String UTF-8.

  Um token de continuação, se todos os IDs de execução de tarefas ainda não tiverem sido retornados.

Erros

- `OperationTimeoutException`

Ação StopColumnStatisticsTaskRun (Python: stop_column_statistics_task_run)

Interrompe a execução de uma tarefa para a tabela especificada.

Solicitação

- `DatabaseName` – Obrigatório: string UTF-8.

  O nome do banco de dados no qual a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `ColumnStatisticsTaskNotRunningException`
- `ColumnStatisticsTaskStoppingException`
- `OperationTimeoutException`

Ação CreateColumnStatisticsTaskSettings (Python: create_column_statistics_task_settings)

Cria configurações para uma tarefa de estatísticas de coluna.

Solicitação

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no qual a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela para a qual as estatísticas de coluna serão geradas.
- `Role`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O perfil usado para executar as estatísticas de coluna.
- `Schedule` – String UTF-8.

  Uma programação para executar as estatísticas de coluna especificada na sintaxe CRON.
- `ColumnNameList` – Uma matriz de strings UTF-8.

  Uma lista de nomes de colunas para as quais estatísticas devem ser executadas.
- `SampleSize`: número (double), no máximo 100.

  O percentual de dados para amostrar.
- `CatalogID` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados reside.
- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome da configuração de segurança usada para criptografar os logs do CloudWatch.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

Um mapa de tags.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AlreadyExistsException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ColumnStatisticsTaskRunningException`

Ação UpdateColumnStatisticsTaskSettings (Python: update_column_statistics_task_settings)

Atualiza as configurações para uma tarefa de estatísticas de coluna.

Solicitação

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no qual a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela para a qual as estatísticas de coluna serão geradas.
- `Role` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O perfil usado para executar as estatísticas de coluna.

- `Schedule` – String UTF-8.

  Uma programação para executar as estatísticas de coluna especificada na sintaxe CRON.

- `ColumnNameList` – Uma matriz de strings UTF-8.

  Uma lista de nomes de colunas para as quais estatísticas devem ser executadas.

- `SampleSize`: número (double), no máximo 100.

  O percentual de dados para amostrar.

- `CatalogID` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo de dados em que o banco de dados reside.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome da configuração de segurança usada para criptografar os logs do CloudWatch.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AccessDeniedException`
- `EntityNotFoundException`
- `InvalidInputException`
- `VersionMismatchException`
- `OperationTimeoutException`

Ação GetColumnStatisticsTaskSettings (Python: get_column_statistics_task_settings)

Obtém configurações para uma tarefa de estatísticas de coluna.

Solicitação

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no qual a tabela reside.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela para a qual as estatísticas de coluna serão recuperadas.

Resposta

- `ColumnStatisticsTaskSettings` – Um objeto ColumnStatisticsTaskSettings.

  Um objeto `ColumnStatisticsTaskSettings` que representa as configurações da tarefa de estatísticas de coluna.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação DeleteColumnStatisticsTaskSettings (Python: delete_column_statistics_task_settings)

Exclui configurações para uma tarefa de estatísticas de coluna.

Solicitação

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no qual a tabela reside.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

O nome da tabela para a qual as estatísticas de coluna serão excluídas.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação StartColumnStatisticsTaskRunSchedule (Python: start_column_statistics_task_run_schedule)

Inicia a programação de execução de uma tarefa de estatísticas de coluna.

Solicitação

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no qual a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela para a qual a programação de execução de uma tarefa de estatísticas de coluna será iniciada.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AccessDeniedException`

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação StopColumnStatisticsTaskRunSchedule (Python: stop_column_statistics_task_run_schedule)

Interrompe uma programação de execução de uma tarefa de estatísticas de coluna.

Solicitação

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no qual a tabela reside.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela para a qual a programação de execução de uma tarefa de estatísticas de coluna será interrompida.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`

Exceções

- Estrutura ColumnStatisticsTaskRunningException
- Estrutura ColumnStatisticsTaskNotRunningException
- Estrutura ColumnStatisticsTaskStoppingException

- Estrutura ColumnStatisticsTaskAutoConcurrencyLimitException
- Estrutura InvalidCatalogSettingException

Estrutura ColumnStatisticsTaskRunningException

Uma exceção lançada quando você tenta iniciar outro trabalho enquanto executa um trabalho de geração de estatísticas de coluna.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura ColumnStatisticsTaskNotRunningException

Uma exceção lançada quando você tenta interromper a execução de uma tarefa quando não há nenhuma tarefa em execução.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura ColumnStatisticsTaskStoppingException

Uma exceção lançada quando você tenta interromper a execução de uma tarefa.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura ColumnStatisticsTaskAutoConcurrencyLimitException

Uma exceção lançada quando você já atingiu o limite de trabalhos simultâneos de estatísticas automáticas.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura InvalidCatalogSettingException

Uma exceção lançada quando há um problema com as configurações do catálogo.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

API do programador do crawler

A API Crawler scheduler descreve os tipos de dados de crawler do AWS Glue, juntamente com a API para criar, excluir, atualizar e listar crawlers.

Tipos de dados

- Estrutura Schedule

Estrutura Schedule

Um objeto de programação que usa uma instrução `cron` para programar um evento.

Campos

- `ScheduleExpression` – String UTF-8.

  Uma expressão `cron` usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers. Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.
- `State` – String UTF-8 (valores válidos: `SCHEDULED` | `NOT_SCHEDULED` | `TRANSITIONING`).

  O estado da programação.

Operações

- Ação UpdateCrawlerSchedule (Python: update_crawler_schedule)
- Ação StartCrawlerSchedule (Python: start_crawler_schedule)
- Ação StopCrawlerSchedule (Python: stop_crawler_schedule)

Ação UpdateCrawlerSchedule (Python: update_crawler_schedule)

Atualiza a programação de um crawler usando uma expressão `cron`.

Solicitação

- `CrawlerName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do crawler cuja programação será atualizada.
- `Schedule` – String UTF-8.

  A expressão `cron` atualizada usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers). Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `VersionMismatchException`
- `SchedulerTransitioningException`
- `OperationTimeoutException`

Ação StartCrawlerSchedule (Python: start_crawler_schedule)

Altera o estado da programação do crawler especificado para `SCHEDULED`, a menos que ele já esteja em execução ou o estado da programação já seja `SCHEDULED`.

Solicitação

- `CrawlerName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do crawler a ser programado.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `SchedulerRunningException`
- `SchedulerTransitioningException`
- `NoScheduleException`
- `OperationTimeoutException`

Ação StopCrawlerSchedule (Python: stop_crawler_schedule)

Define o estado da programação do crawler especificado para `NOT_SCHEDULED`, mas não o interrompe se já estiver em execução.

Solicitação

- `CrawlerName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do crawler cujo estado da programação será definido.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `SchedulerNotRunningException`
- `SchedulerTransitioningException`
- `OperationTimeoutException`

API de scripts de ETL de geração automática

A API de geração de script de ETL descreve os tipos de dados e a API para gerar scripts de ETL no AWS Glue.

Tipos de dados

- Estrutura CodeGenNode
- Estrutura CodeGenNodeArg
- Estrutura CodeGenEdge
- Estrutura Location
- Estrutura CatalogEntry
- Estrutura MappingEntry

Estrutura CodeGenNode

Representa um nó em um gráfico acíclico dirigido (DAG)

Campos

- `Id` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Identifier string pattern.

  Um identificador de nó que é exclusivo no gráfico do nó.
- `NodeType` – Obrigatório: string UTF-8.

Qual é o tipo de nó.

- `Args` – Obrigatório: uma matriz de CodeGenNodeArg objetos, não mais de 50 estruturas.

  Propriedades do nó, na forma de pares nome-valor.

- `LineNumber` – Número (íntegro).

  O número de linha do nó.

Estrutura CodeGenNodeArg

Argumento ou propriedade de um nó.

Campos

- `Name` – Obrigatório: string UTF-8.

  O nome do argumento ou da propriedade.

- `Value` – Obrigatório: string UTF-8.

  O valor do argumento ou da propriedade.

- `Param` – Booleano.

  True, se o valor for usado como um parâmetro.

Estrutura CodeGenEdge

Representa um ponto direcional em um gráfico acíclico dirigido (DAG).

Campos

- `Source` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Identifier string pattern.

  O ID do nó onde o ponto será iniciado.

- `Target` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Identifier string pattern.

  O ID do nó onde o ponto será encerrado.

- `TargetParameter` – String UTF-8.

  O destino do ponto.

Estrutura Location

O local dos recursos.

Campos

- `Jdbc` – Uma matriz de CodeGenNodeArg objetos, não mais de 50 estruturas.

  Um local JDBC.
- `S3` – Uma matriz de CodeGenNodeArg objetos, não mais de 50 estruturas.

  Uma localização do Amazon Simple Storage Service (Amazon S3).
- `DynamoDB` – Uma matriz de CodeGenNodeArg objetos, não mais de 50 estruturas.

  O local de uma tabela do Amazon DynamoDB.

Estrutura CatalogEntry

Especifica uma definição de tabela no AWS Glue Data Catalog.

Campos

- `DatabaseName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O banco de dados em que os metadados de tabela residem.
- `TableName` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da tabela em questão.

Estrutura MappingEntry

Define um mapeamento.

Campos

- `SourceTable` – String UTF-8.

  O nome da tabela de origem.

- `SourcePath` – String UTF-8.

  O caminho de origem do .

- `SourceType` – String UTF-8.

  O tipo de origem.

- `TargetTable` – String UTF-8.

  O nome da tabela.

- `TargetPath` – String UTF-8.

  O caminho de destino.

- `TargetType` – String UTF-8.

  O tipo de destino.

Operações

- Ação CreateScript (Python: create_script)
- Ação GetDataflowGraph (Python: get_dataflow_graph)
- Ação GetMapping (Python: get_mapping)
- Ação GetPlan (Python: get_plan)

Ação CreateScript (Python: create_script)

Transforma um gráfico acíclico dirigido (DAG) em código.

Solicitação

- `DagNodes` – Uma matriz de objetos CodeGenNode.

  Uma lista de nós no DAG.

- `DagEdges` – Uma matriz de objetos CodeGenEdge.

  Uma lista de pontos no DAG.
- `Language`: string UTF-8 (valores válidos: `PYTHON` | `SCALA`).

  A linguagem de programação do código resultante do DAG.

Resposta

- `PythonScript` – String UTF-8.

  O script Python gerado a partir do DAG.
- `ScalaCode` – String UTF-8.

  O código Scala gerado a partir do DAG.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetDataflowGraph (Python: get_dataflow_graph)

Transforma um script Python em um gráfico acíclico dirigido (DAG).

Solicitação

- `PythonScript` – String UTF-8.

  O script Python a ser transformado.

Resposta

- `DagNodes` – Uma matriz de objetos CodeGenNode.

  Uma lista de nós no DAG resultante.
- `DagEdges` – Uma matriz de objetos CodeGenEdge.

Uma lista de pontos no DAG resultante.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetMapping (Python: get_mapping)

Cria mapeamentos.

Solicitação

- `Source` – Obrigatório: um objeto CatalogEntry.

  Especifica a tabela de origem.
- `Sinks` – Uma matriz de objetos CatalogEntry.

  Uma lista de tabelas de destino.
- `Location` – Um objeto Local.

  Parâmetros para o mapeamento.

Resposta

- `Mapping` – Obrigatório: uma matriz de objetos MappingEntry.

  Uma lista de mapeamentos para os destinos especificados.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `EntityNotFoundException`

Ação GetPlan (Python: get_plan)

Obtém o código para executar um mapeamento especificado.

Solicitação

- `Mapping` – Obrigatório: uma matriz de objetos MappingEntry.

  A lista de mapeamentos de uma tabela de origem para tabelas de destino.
- `Source` – Obrigatório: um objeto CatalogEntry.

  A tabela de origem.
- `Sinks` – Uma matriz de objetos CatalogEntry.

  O nome das tabelas.
- `Location` – Um objeto Local.

  Os parâmetros para o mapeamento.
- `Language`: string UTF-8 (valores válidos: `PYTHON` | `SCALA`).

  A linguagem de programação do código para executar o mapeamento.
- `AdditionalPlanOptionsMap` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um mapa para conter parâmetros de chave-valor opcionais extras.

  Atualmente, estes pares de chave-valor são suportados:

  - `inferSchema`: especifica se é para definir `inferSchema` como true ou false para o script padrão gerado por um trabalho do AWS Glue. Por exemplo, para definir `inferSchema` como true, passe o seguinte par de chave-valor:

    ```
    --additional-plan-options-map '{"inferSchema":"true"}'
    ```

Resposta

- `PythonScript` – String UTF-8.

Um script Python para executar o mapeamento.

- `ScalaCode` – String UTF-8.

  O código Scala para executar o mapeamento.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

API de trabalhos visuais

A API de trabalhos visuais permite que você crie trabalhos de integração de dados usando a API do AWS Glue com base em um objeto JSON que representa uma configuração visual de um trabalho do AWS Glue.

Uma lista de `CodeGenConfigurationNodes` é fornecida a uma API de trabalho de criação ou atualização para registrar um DAG no AWS Glue Studio para o trabalho criado e gerar o código associado.

Tipos de dados

- Estrutura CodeGenConfigurationNode
- Estrutura JDBCConnectorOptions
- Estrutura StreamingDataPreviewOptions
- Estrutura AthenaConnectorSource
- Estrutura JDBCConnectorSource
- Estrutura SparkConnectorSource
- Estrutura CatalogSource
- Estrutura MySQLCatalogSource
- Estrutura PostgreSQLCatalogSource
- Estrutura OracleSQLCatalogSource
- Estrutura MicrosoftSQLServerCatalogSource

- Estrutura CatalogKinesisSource
- Estrutura DirectKinesisSource
- Estrutura KinesisStreamingSourceOptions
- Estrutura CatalogKafkaSource
- Estrutura DirectKafkaSource
- Estrutura KafkaStreamingSourceOptions
- Estrutura RedshiftSource
- Estrutura AmazonRedshiftSource
- Estrutura AmazonRedshiftNodeData
- Estrutura AmazonRedshiftAdvancedOption
- Estrutura Option
- Estrutura S3CatalogSource
- Estrutura S3SourceAdditionalOptions
- Estrutura S3CsvSource
- Estrutura DirectJDBCSource
- Estrutura S3DirectSourceAdditionalOptions
- Estrutura S3JsonSource
- Estrutura S3ParquetSource
- Estrutura S3DeltaSource
- Estrutura S3CatalogDeltaSource
- Estrutura CatalogDeltaSource
- Estrutura S3HudiSource
- Estrutura S3CatalogHudiSource
- Estrutura de S3ExcelSource
- Estrutura CatalogHudiSource
- Estrutura DynamoDBCatalogSource
- Estrutura RelationalCatalogSource
- Estrutura JDBCConnectorTarget
- Estrutura SparkConnectorTarget

- Estrutura BasicCatalogTarget
- Estrutura MySQLCatalogTarget
- Estrutura PostgreSQLCatalogTarget
- Estrutura OracleSQLCatalogTarget
- Estrutura MicrosoftSQLServerCatalogTarget
- Estrutura RedshiftTarget
- Estrutura AmazonRedshiftTarget
- Estrutura UpsertRedshiftTargetOptions
- Estrutura S3CatalogTarget
- Estrutura S3GlueParquetTarget
- Estrutura CatalogSchemaChangePolicy
- Estrutura S3DirectTarget
- Estrutura S3HudiCatalogTarget
- Estrutura S3HudiDirectTarget
- Estrutura S3DeltaCatalogTarget
- Estrutura S3DeltaDirectTarget
- Estrutura de S3HyperDirectTarget
- Estrutura de S3IcebergDirectTarget
- Estrutura DirectSchemaChangePolicy
- Estrutura ApplyMapping
- Estrutura Mapping
- Estrutura SelectFields
- Estrutura DropFields
- Estrutura RenameField
- Estrutura Spigot
- Estrutura Join
- Estrutura JoinColumn
- Estrutura SplitFields
- Estrutura SelectFromCollection

- Estrutura FillMissingValues
- Estrutura Filter
- Estrutura FilterExpression
- Estrutura FilterValue
- Estrutura CustomCode
- Estrutura SparkSQL
- Estrutura SqlAlias
- Estrutura DropNullFields
- Estrutura NullCheckBoxList
- Estrutura NullValueField
- Estrutura Datatype
- Estrutura Merge
- Estrutura Union
- Estrutura PIIDetection
- Estrutura Aggregate
- Estrutura DropDuplicates
- Estrutura GovernedCatalogTarget
- Estrutura GovernedCatalogSource
- Estrutura AggregateOperation
- Estrutura GlueSchema
- Estrutura GlueStudioSchemaColumn
- Estrutura GlueStudioColumn
- Estrutura DynamicTransform
- Estrutura TransformConfigParameter
- Estrutura EvaluateDataQuality
- Estrutura DQResultsPublishingOptions
- Estrutura DQStopJobOnFailureOptions
- Estrutura EvaluateDataQualityMultiFrame
- Estrutura da fórmula

- Estrutura SchemaReference
- Estrutura SnowflakeNodeData
- Estrutura SnowflakeSource
- Estrutura SnowflakeTarget
- Estrutura ConnectorDataSource
- Estrutura ConnectorDataTarget
- Estrutura RecipeStep
- Estrutura RecipeAction
- Estrutura ConditionExpression

Estrutura CodeGenConfigurationNode

O `CodeGenConfigurationNode` enumera todos os tipos de nós válidos. Uma e apenas uma de suas variáveis membro podem ser preenchidas.

Campos

- `AthenaConnectorSource` – Um objeto AthenaConnectorSource.

  Especifica um conector para uma fonte de dados do Amazon Athena.
- `JDBCConnectorSource` – Um objeto JDBCConnectorSource.

  Especifica um conector para uma fonte de dados JDBC.
- `SparkConnectorSource` – Um objeto SparkConnectorSource.

  Especifica um conector para uma fonte de dados do Apache Spark.
- `CatalogSource` – Um objeto CatalogSource.

  Especifica um datastore no catálogo de dados do.AWS Glue
- `RedshiftSource` – Um objeto RedshiftSource.

  Especifica um datastore do Amazon Redshift.
- `S3CatalogSource` – Um objeto S3CatalogSource.

  Especifica um datastore do Amazon S3 no catálogo de dados do.AWS Glue
- `S3CsvSource` – Um objeto S3CSVSource.

Especifica um datastore CSV (valores separados por comando) armazenado no Amazon S3.

- `S3ExcelSource` – Um objeto S3ExcelSource.

  Define os parâmetros de configuração para leitura de arquivos do Excel no Amazon S3.

- `S3JsonSource` – Um objeto S3JsonSource.

  Especifica um datastore JSON armazenado no Amazon S3.

- `S3ParquetSource` – Um objeto S3ParquetSource.

  Especifica um datastore do Apache Parquet armazenado no Amazon S3.

- `RelationalCatalogSource` – Um objeto RelationalCatalogSource.

  Especifica um datastore de catálogo relacional no AWS Glue Data Catalog.

- `DynamoDBCatalogSource` – Um objeto DynamoDBCatalogSource.

  Especifica um datastore de catálogo relacional do DynamoDBC no AWS Glue Data Catalog.

- `JDBCConnectorTarget` – Um objeto JDBCConnectorTarget.

  Especifica um destino de dados que grava no Amazon S3 no armazenamento colunar do Apache Parquet.

- `SparkConnectorTarget` – Um objeto SparkConnectorTarget.

  Especifica um destino que usa um conector Apache Spark.

- `CatalogTarget` – Um objeto BasicCatalogTarget.

  Especifica um destino que usa uma tabela do catálogo de dados do AWS Glue.

- `RedshiftTarget` – Um objeto RedshiftTarget.

  Especifica um destino que usa o Amazon Redshift.

- `S3CatalogTarget` – Um objeto S3CatalogTarget.

  Especifica um destino de dados que grava no Amazon S3 usando o catálogo de dados do AWS Glue.

- `S3GlueParquetTarget` – Um objeto S3GlueParquetTarget.

  Especifica um destino de dados que grava no Amazon S3 no armazenamento colunar do Apache Parquet.

- `S3HyperDirectTarget` – Um objeto S3HyperDirectTarget.

  Define os parâmetros de configuração para gravação de dados no Amazon S3 usando a otimização HyperDirect.

- `S3DirectTarget` – Um objeto S3DirectTarget.

  Especifica um destino de dados que grava no Amazon S3.

- `S3IcebergDirectTarget` – Um objeto S3IcebergDirectTarget.

  Define os parâmetros de configuração para gravação de dados no Amazon S3 como uma tabela do Apache Iceberg.

- `ApplyMapping` – Um objeto ApplyMapping.

  Especifica uma transformação que mapeia chaves de propriedade de dados na fonte dos dados para chaves de propriedade de dados no destino dos dados. Você pode renomear chaves, modificar os tipos de dados para chaves e escolher quais chaves remover do conjunto de dados.

- `SelectFields` – Um objeto SelectFields.

  Especifica uma transformação que escolhe as chaves de propriedade de dados que você deseja manter.

- `DropFields` – Um objeto DropFields.

  Especifica uma transformação que escolhe as chaves de propriedade de dados que você deseja descartar.

- `RenameField` – Um objeto RenameField.

  Especifica uma transformação que renomeia uma única chave de propriedade de dados.

- `Spigot` – Um objeto Spigot.

  Especifica uma transformação que grava amostras dos dados em um bucket do Amazon S3.

- `Join` – Um objeto Ingressar.

  Especifica uma transformação que une dois conjuntos de dados em um só, usando uma frase de comparação nas chaves de propriedade de dados especificadas. Você pode usar junção inner (interna), outer (externa), left (à esquerda), right (à direita), left semi (semi à esquerda) e left anti (anti à esquerda).

- `SplitFields` – Um objeto SplitFields.

Especifica uma transformação que divide chaves de propriedade de dados em dois `DynamicFrames`. A saída é uma coleção de `DynamicFrames`: um com chaves de propriedade de dados selecionadas e outro com as chaves de propriedade de dados restantes.

- `SelectFromCollection` – Um objeto SelectFromCollection.

  Especifica uma transformação que escolhe um `DynamicFrame` de uma coleção de `DynamicFrames`. A saída é o `DynamicFrame` selecionado.

- `FillMissingValues` – Um objeto FillMissingValues.

  Especifica uma transformação que localiza registros no conjunto de dados que tenham valores ausentes e adiciona um novo campo com um valor determinado por imputação. O conjunto de dados de entrada é usado para treinar o modelo de machine learning que determina qual deve ser o valor ausente.

- `Filter` – Um objeto Filtro.

  Especifica uma transformação que divide um conjunto de dados em dois, com base em uma condição de filtro.

- `CustomCode` – Um objeto CustomCode.

  Especifica uma transformação que usa código personalizado que você fornece para executar a transformação de dados. A saída é uma coleção de DynamicFrames.

- `SparkSQL` – Um objeto SparkSQL.

  Especifica uma transformação em que você insere uma consulta de SQL usando a sintaxe do Spark SQL para transformar os dados. A saída é um único `DynamicFrame`.

- `DirectKinesisSource` – Um objeto DirectKinesisSource.

  Especifica uma fonte de dados direta do Amazon Kinesis.

- `DirectKafkaSource` – Um objeto DirectKafkaSource.

  Especifica um datastore do Apache Kafka.

- `CatalogKinesisSource` – Um objeto CatalogKinesisSource.

  Especifica uma fonte de dados do Kinesis no catálogo de dados do AWS Glue.

- `CatalogKafkaSource` – Um objeto CatalogKafkaSource.

  Especifica um datastore do Apache Kafka no catálogo de dados.

- `DropNullFields` – Um objeto DropNullFields.

  Especifica uma transformação que remove colunas do conjunto de dados se todos os valores na coluna forem 'null'. Por padrão, o AWS Glue Studio reconhecerá objetos nulos, mas alguns valores, como strings vazias, strings que sejam "nulas", inteiros -1 ou outros espaços reservados, como zeros, não são automaticamente reconhecidos como nulos.
- `Merge` – Um objeto Mesclar.

  Especifica uma transformação que mescla um `DynamicFrame` com um `DynamicFrame` de preparação, de acordo com as chaves primárias especificadas para identificar registros. Registros duplicados (com as mesmas chaves primárias) não são eliminados.
- `Union` – Um objeto Union.

  Especifica uma transformação que combina as linhas de dois ou mais conjuntos de dados em um único resultado.
- `PIIDetection` – Um objeto PIIdetection.

  Especifica uma transformação que identifica, remove ou mascara dados de PII.
- `Aggregate` – Um objeto Agregar.

  Especifica uma transformação que agrupa linhas por campos escolhidos e calcula o valor agregado por função especificada.
- `DropDuplicates` – Um objeto DropDuplicates.

  Especifica uma transformação que remove linhas de dados repetidos de um conjunto de dados.
- `GovernedCatalogTarget` – Um objeto GovernedCatalogTarget.

  Especifica um destino de dados que grava em um catálogo governado.
- `GovernedCatalogSource` – Um objeto GovernedCatalogSource.

  Especifica uma fonte de dados em um catálogo de dados governado.
- `MicrosoftSQLServerCatalogSource` – Um objeto MicrosoftSQLServerCatalogSource.

  Especifica uma fonte de dados do Microsoft SQL Server no AWS Glue Data Catalog.
- `MySQLCatalogSource` – Um objeto MySQLCatalogSource.

  Especifica uma fonte de dados do MySQL no AWS Glue Data Catalog.
- `OracleSQLCatalogSource` – Um objeto OracleSQLCatalogSource.

Especifica uma fonte de dados do Oracle no AWS Glue Data Catalog.

- `PostgreSQLCatalogSource` – Um objeto PostgreSQLCatalogSource.

  Especifica uma fonte de dados do Postgres SQL no AWS Glue Data Catalog.

- `MicrosoftSQLServerCatalogTarget` – Um objeto MicrosoftSQLServerCatalogTarget.

  Especifica um destino que usa o Microsoft SQL.

- `MySQLCatalogTarget` – Um objeto MySQLCatalogTarget.

  Especifica um destino que usa o MySQL.

- `OracleSQLCatalogTarget` – Um objeto OracleSQLCatalogTarget.

  Especifica um destino que usa o Oracle SQL.

- `PostgreSQLCatalogTarget` – Um objeto PostgreSQLCatalogTarget.

  Especifica um destino que usa o Postgres SQL.

- `DynamicTransform` – Um objeto DynamicTransform.

  Especifica uma transformação visual personalizada criada por um usuário.

- `EvaluateDataQuality` – Um objeto EvaluateDataQuality.

  Especifica os critérios da avaliação de qualidade dos dados.

- `S3CatalogHudiSource` – Um objeto S3CatalogHudiSource.

  Especifica uma fonte de dados Hudi registrada no AWS Glue Data Catalog. A fonte de dados deve estar armazenada no Amazon S3.

- `CatalogHudiSource` – Um objeto CatalogHudiSource.

  Especifica uma fonte de dados Hudi registrada no AWS Glue Data Catalog.

- `S3HudiSource` – Um objeto S3HudiSource.

  Especifica uma fonte de dados Hudi armazenada no Amazon S3.

- `S3HudiCatalogTarget` – Um objeto S3HudiCatalogTarget.

  Especifica um destino de dados que grava em uma fonte de dados Hudi no AWS Glue.

- `S3HudiDirectTarget` – Um objeto S3HudiDirectTarget.

Especifica um destino que grava em uma fonte de dados Hudi no Amazon S3.

- `S3CatalogDeltaSource` – Um objeto S3CatalogDeltaSource.

  Especifica uma fonte de dados do Delta Lake que é registrada no catálogo de dados do AWS Glue. A fonte de dados deve estar armazenada no Amazon S3.

- `CatalogDeltaSource` – Um objeto CatalogDeltaSource.

  Especifica uma fonte de dados do Delta Lake que é registrada no catálogo de dados do AWS Glue.

- `S3DeltaSource` – Um objeto S3DeltaSource.

  Especifica uma fonte de dados do Delta Lake armazenada no Amazon S3.

- `S3DeltaCatalogTarget` – Um objeto S3DeltaCatalogTarget.

  Especifica um destino que grava em uma fonte de dados do Delta Lake no catálogo de dados do AWS Glue.

- `S3DeltaDirectTarget` – Um objeto S3DeltaDirectTarget.

  Especifica um destino que grava em uma fonte de dados do Delta Lake no Amazon S3.

- `AmazonRedshiftSource` – Um objeto AmazonRedshiftSource.

  Especifica um destino que grava em uma fonte de dados no Amazon Redshift.

- `AmazonRedshiftTarget` – Um objeto AmazonRedshiftTarget.

  Especifica um destino que grava em um destino de dados no Amazon Redshift.

- `EvaluateDataQualityMultiFrame` – Um objeto EvaluateDataQualityMultiFrame.

  Especifica os critérios da avaliação de qualidade dos dados. Permite vários dados de entrada e retorna um conjunto de quadros dinâmicos.

- `Recipe` – Um objeto Fórmula.

  Especifica um nó de fórmula do AWS Glue DataBrew.

- `SnowflakeSource` – Um objeto SnowflakeSource.

  Especifica uma fonte de dados do Snowflake.

- `SnowflakeTarget` – Um objeto SnowflakeTarget.

Especifica um destino que grava em uma fonte de dados do Snowflake.

- `ConnectorDataSource` – Um objeto ConnectorDataSource.

  Especifica uma fonte gerada com opções de conexão padrão.

- `ConnectorDataTarget` – Um objeto ConnectorDataTarget.

  Especifica um destino gerado com opções de conexão padrão.

Estrutura JDBCConnectorOptions

Opções de conexão adicionais para o conector.

Campos

- `FilterPredicate` – String UTF-8 correspondente a Custom string pattern #59.

  Cláusula de condição extra para filtrar dados da fonte. Por exemplo:

  ```
  BillingCity='Mountain View'
  ```

  Ao usar uma consulta em vez de um nome de tabela, você deve validar que a consulta funciona com o `filterPredicate` especificado.

- `PartitionColumn` – String UTF-8 correspondente a Custom string pattern #59.

  O nome de uma coluna de inteiros usada para o particionamento. Essa opção só funciona quando está incluída em `lowerBound`, `upperBound` e `numPartitions`. Essa opção funciona da mesma maneira que no leitor JDBC Spark SQL.

- `LowerBound`: número (inteiro longo), no máximo None (Nenhum).

  O valor mínimo de `partitionColumn` que é usado para decidir o passo de partição.

- `UpperBound`: número (inteiro longo), no máximo None (Nenhum).

  O valor máximo de `partitionColumn` que é usado para decidir o passo de partição.

- `NumPartitions`: número (inteiro longo), no máximo None (Nenhum).

  O número de partições. Esse valor, juntamente com `lowerBound` (inclusive) e `upperBound` (exclusive), forma os passos de partição para as expressões de cláusula `WHERE` geradas que são usadas para dividir a `partitionColumn`.

- `JobBookmarkKeys` – Uma matriz de strings UTF-8.

  O nome das chaves de marcador de trabalho pelas quais classificar.

- `JobBookmarkKeysSortOrder` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica ordem de classificação ascendente ou descendente.

- `DataTypeMapping` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 (valores válidos: `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`).

  Cada valor é uma string UTF-8 (valores válidos: `DATE` | `STRING` | `TIMESTAMP` | `INT` | `FLOAT` | `LONG` | `BIGDECIMAL` | `BYTE` | `SHORT` | `DOUBLE`).

  Mapeamento de tipo de dados personalizado que constrói um mapeamento a partir de um tipo de dados JDBC para um tipo de dados do AWS Glue. Por exemplo, a opção `"dataTypeMapping":{"FLOAT":"STRING"}` mapeia campos de dados JDBC do tipo `FLOAT` para o tipo `String` do Java chamando o método `ResultSet.getString()` do driver e o usa para construir o registro AWS Glue. O objeto `ResultSet` é implantado por cada driver, portanto, o comportamento é específico para o driver que você usa. Consulte a documentação do driver do JDBC para entender como ele executa as conversões.

Estrutura StreamingDataPreviewOptions

Especifica opções relacionadas à previsualização de dados para exibir uma amostra de seus dados.

Campos

- `PollingTime`: número (longo), pelo menos 10.

  O tempo de sondagem, em milissegundos.

- `RecordPollingLimit`: número (longo), pelo menos 1.

  O limite para o número de registros sondados.

Estrutura AthenaConnectorSource

Especifica um conector para uma fonte de dados do Amazon Athena.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.
- `ConnectionName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da conexão associada ao conector.
- `ConnectorName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome de um conector que ajuda a acessar o datastore no AWS Glue Studio.
- `ConnectionType` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O tipo de conexão, como marketplace.athena ou custom.athena, designando uma conexão com um datastore do Amazon Athena.
- `ConnectionTable` – String UTF-8 correspondente a Custom string pattern #59.

  O nome da tabela na fonte de dados.
- `SchemaName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do grupo de logs do CloudWatch a ser lido. Por exemplo, `./aws-glue/jobs/output`
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte do Athena personalizada.

Estrutura JDBCConnectorSource

Especifica um conector para uma fonte de dados JDBC.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.
- `ConnectionName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

O nome da conexão associada ao conector.

- `ConnectorName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome de um conector que ajuda a acessar o datastore no AWS Glue Studio.

- `ConnectionType` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O tipo de conexão, como marketplace.jdbc ou custom.jdbc, designando uma conexão com um datastore JDBC.

- `AdditionalOptions` – Um objeto JDBCConnectorOptions.

  Opções de conexão adicionais para o conector.

- `ConnectionTable` – String UTF-8 correspondente a Custom string pattern #59.

  O nome da tabela na fonte de dados.

- `Query` – String UTF-8 correspondente a Custom string pattern #60.

  A tabela ou consulta SQL da qual obter os dados. Você pode especificar `ConnectionTable` ou `query`, mas não os dois.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte do JDBC personalizada.

Estrutura SparkConnectorSource

Especifica um conector para uma fonte de dados do Apache Spark.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.

- `ConnectionName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da conexão associada ao conector.

- `ConnectorName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome de um conector que ajuda a acessar o datastore no AWS Glue Studio.

- `ConnectionType` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O tipo de conexão, como marketplace.spark ou custom.spark, designando uma conexão com um datastore do Apache Spark.
- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Opções de conexão adicionais para o conector.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte do Spark personalizada.

Estrutura CatalogSource

Especifica um datastore no catálogo de dados do.AWS Glue

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.

Estrutura MySQLCatalogSource

Especifica uma fonte de dados do MySQL no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.

Estrutura PostgreSQLCatalogSource

Especifica uma fonte de dados do Postgres SQL no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.

Estrutura OracleSQLCatalogSource

Especifica uma fonte de dados do Oracle no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.

Estrutura MicrosoftSQLServerCatalogSource

Especifica uma fonte de dados do Microsoft SQL Server no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.

Estrutura CatalogKinesisSource

Especifica uma fonte de dados do Kinesis no catálogo de dados do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.
- `WindowSize` – Número (inteiro), não mais do que None (Nenhum).

  A quantidade de tempo gasto no processamento de cada micro lote.
- `DetectSchema` – Booleano.

  Se o esquema deve ser determinado automaticamente a partir dos dados recebidos.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `StreamingOptions` – Um objeto KinesisStreamingSourceOptions.

Opções adicionais para a fonte de dados de transmissão do Kinesis.

- `DataPreviewOptions` – Um objeto StreamingDataPreviewOptions.

  Opções adicionais para previsualização de dados.

Estrutura DirectKinesisSource

Especifica uma fonte de dados direta do Amazon Kinesis.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.

- `WindowSize` – Número (inteiro), não mais do que None (Nenhum).

  A quantidade de tempo gasto no processamento de cada micro lote.

- `DetectSchema` – Booleano.

  Se o esquema deve ser determinado automaticamente a partir dos dados recebidos.

- `StreamingOptions` – Um objeto KinesisStreamingSourceOptions.

  Opções adicionais para a fonte de dados de transmissão do Kinesis.

- `DataPreviewOptions` – Um objeto StreamingDataPreviewOptions.

  Opções adicionais para previsualização de dados.

Estrutura KinesisStreamingSourceOptions

Opções adicionais para a fonte de dados de transmissão do Amazon Kinesis.

Campos

- `EndpointUrl` – String UTF-8 correspondente a Custom string pattern #59.

  O URL do endpoint do Kinesis.

- `StreamName` – String UTF-8 correspondente a Custom string pattern #59.

O nome do fluxo de dados do Kinesis.

- `Classification` – String UTF-8 correspondente a Custom string pattern #59.

  Uma classificação opcional.

- `Delimiter` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica o caractere delimitador.

- `StartingPosition` – String UTF-8 (valores válidos: `latest="LATEST"` | `trim_horizon="TRIM_HORIZON"` | `earliest="EARLIEST"` | `timestamp="TIMESTAMP"`).

  A posição inicial no fluxo de dados do Kinesis de onde ler os dados. Os valores possíveis são `"latest"`, `"trim_horizon"`, `"earliest"` ou uma string de timestamp no formato UTC no padrão `yyyy-mm-ddTHH:MM:SSZ` (onde `Z` representa um desvio do fuso horário UTC com +/-). Por exemplo: "2023-04-04T08:00:00-04:00"). O valor padrão é `"latest"`.

  Observação: o uso de um valor que é uma string de timestamp no formato UTC para “StartingPosition” só é compatível com o AWS Glue a versão 4.0 ou posterior.

- `MaxFetchTimeInMs`: número (inteiro longo), no máximo None (Nenhum).

  O tempo máximo para o executor do trabalho ler registros referentes ao lote atual do fluxo de dados do Kinesis especificado em milissegundos (ms). Várias chamadas de API `GetRecords` podem ser feitas nesse período. O valor padrão é `1000`.

- `MaxFetchRecordsPerShard`: número (inteiro longo), no máximo None (Nenhum).

  O número máximo de registros a serem obtidos por fragmento no fluxo de dados do Kinesis por microlote. Observação: o cliente poderá exceder esse limite se o trabalho de streaming já tiver lido registros extras do Kinesis (na mesma chamada get-records). Se `MaxFetchRecordsPerShard` precisa ser rigoroso, então precisa ser um múltiplo de `MaxRecordPerRead`. O valor padrão é `100000`.

- `MaxRecordPerRead`: número (inteiro longo), no máximo None (Nenhum).

  O número máximo de registros a serem obtidos por fragmento no fluxo de dados do Kinesis em cada operação getRecords. O valor padrão é `10000`.

- `AddIdleTimeBetweenReads` – Booleano.

  Adiciona um atraso de tempo entre duas operações getRecords consecutivas. O valor padrão é `"False"`. Essa opção apenas pode ser configurada para o AWS Glue versão 2.0 e acima.

- `IdleTimeBetweenReadsInMs`: número (inteiro longo), no máximo None (Nenhum).

  O atraso mínimo entre duas operações getRecords consecutivas, especificado em ms. O valor padrão é `1000`. Essa opção apenas pode ser configurada para o AWS Glue versão 2.0 e acima.
- `DescribeShardInterval`: número (inteiro longo), no máximo None (Nenhum).

  O intervalo de tempo mínimo entre duas chamadas de API ListShards para que seu script considere a refragmentação. O valor padrão é `1s`.
- `NumRetries` – Número (inteiro), não mais do que None (Nenhum).

  O número máximo de novas tentativas para solicitações de API do Kinesis Data Streams. O valor padrão é `3`.
- `RetryIntervalMs`: número (inteiro longo), no máximo None (Nenhum).

  O período de espera (especificado em ms) antes de repetir a chamada da API Kinesis Data Streams. O valor padrão é `1000`.
- `MaxRetryIntervalMs`: número (inteiro longo), no máximo None (Nenhum).

  O período de espera máximo (especificado em ms) entre duas tentativas de uma chamada de API Kinesis Data Streams. O valor padrão é `10000`.
- `AvoidEmptyBatches` – Booleano.

  Evita a criação de um trabalho de microlote vazio verificando se há dados não lidos no fluxo de dados do Kinesis antes do lote ser iniciado. O valor padrão é `"False"`.
- `StreamArn` – String UTF-8 correspondente a Custom string pattern #59.

  O nome de recurso da Amazon (ARN) do fluxo de dados do Kinesis.
- `RoleArn` – String UTF-8 correspondente a Custom string pattern #59.

  O nome do recurso da Amazon (ARN) da função a ser assumida pelo uso do AWS Security Token Service (AWS STS). Essa função deve ter permissões para descrever ou ler operações de registro para o fluxo de dados do Kinesis. Você deve usar esse parâmetro ao acessar um fluxo de dados em uma conta diferente. Usado em conjunto com `"awsSTSSessionName"`.
- `RoleSessionName` – String UTF-8 correspondente a Custom string pattern #59.

  Um identificador para a sessão que assume a função usando o AWS STS. Você deve usar esse parâmetro ao acessar um fluxo de dados em uma conta diferente. Usado em conjunto com `"awsSTSRoleARN"`.

- `AddRecordTimestamp` – String UTF-8 correspondente a Custom string pattern #59.

  Quando essa opção for definida como "true", a saída de dados conterá uma coluna adicional denominada "__src_timestamp" que indica a hora que o registro correspondente é recebido pelo fluxo. O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.

- `EmitConsumerLagMetrics` – String UTF-8 correspondente a Custom string pattern #59.

  Quando a opção for definida como "true", para cada lote, serão emitidas métricas durante o período entre a hora que o registro mais antigo é recebido pelo tópico e a hora que ele chega ao AWS Glue para o CloudWatch. O nome da métrica é "glue.driver.streaming.maxConsumerLagInMs". O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.

- `StartingTimestamp` – String UTF-8.

  O timestamp do registro no fluxo de dados do Kinesis para começar a ler os dados. Os valores possíveis são uma string de timestamp no formato UTC no padrão `yyyy-mm-ddTHH:MM:SSZ` (onde Z representa um desvio do fuso horário UTC com +/-). Por exemplo: "2023-04-04T08:00:00+08:00").

Estrutura CatalogKafkaSource

Especifica um datastore do Apache Kafka no catálogo de dados.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.

- `WindowSize` – Número (inteiro), não mais do que None (Nenhum).

  A quantidade de tempo gasto no processamento de cada micro lote.

- `DetectSchema` – Booleano.

  Se o esquema deve ser determinado automaticamente a partir dos dados recebidos.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

O nome do banco de dados do qual a leitura será feita.

- `StreamingOptions` – Um objeto KafkaStreamingSourceOptions.

  Especifica as opções de transmissão.

- `DataPreviewOptions` – Um objeto StreamingDataPreviewOptions.

  Especifica opções relacionadas à previsualização de dados para exibir uma amostra de seus dados.

Estrutura DirectKafkaSource

Especifica um datastore do Apache Kafka.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.

- `StreamingOptions` – Um objeto KafkaStreamingSourceOptions.

  Especifica as opções de transmissão.

- `WindowSize` – Número (inteiro), não mais do que None (Nenhum).

  A quantidade de tempo gasto no processamento de cada micro lote.

- `DetectSchema` – Booleano.

  Se o esquema deve ser determinado automaticamente a partir dos dados recebidos.

- `DataPreviewOptions` – Um objeto StreamingDataPreviewOptions.

  Especifica opções relacionadas à previsualização de dados para exibir uma amostra de seus dados.

Estrutura KafkaStreamingSourceOptions

Opções adicionais para transmissões.

Campos

- `BootstrapServers` – String UTF-8 correspondente a Custom string pattern #59.

  Uma lista de URLs do servidor de bootstrap, por exemplo, como `b-1.vpc-test-2.o4q88o.c6.kafka.us-east-1.amazonaws.com:9094`. Essa opção deve ser especificada na chamada de API ou definida nos metadados da tabela no Data Catalog.

- `SecurityProtocol` – String UTF-8 correspondente a Custom string pattern #59.

  O protocolo usado para se comunicar com os agentes. Os valores possíveis são `"SSL"` ou `"PLAINTEXT"`.

- `ConnectionName` – String UTF-8 correspondente a Custom string pattern #59.

  O nome da conexão.

- `TopicName` – String UTF-8 correspondente a Custom string pattern #59.

  O nome do tópico conforme especificado no Apache Kafka. É necessário especificar pelo menos um `"topicName"`, `"assign"` ou `"subscribePattern"`.

- `Assign` – String UTF-8 correspondente a Custom string pattern #59.

  As `TopicPartitions` específicas a consumir. É necessário especificar pelo menos um `"topicName"`, `"assign"` ou `"subscribePattern"`.

- `SubscribePattern` – String UTF-8 correspondente a Custom string pattern #59.

  Uma string regex Java que identifica a lista de tópicos para assinar. É necessário especificar pelo menos um `"topicName"`, `"assign"` ou `"subscribePattern"`.

- `Classification` – String UTF-8 correspondente a Custom string pattern #59.

  Uma classificação opcional.

- `Delimiter` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica o caractere delimitador.

- `StartingOffsets` – String UTF-8 correspondente a Custom string pattern #59.

  A posição inicial no tópico do Kafka de onde ler os dados. Os valores possíveis são `"earliest"` ou `"latest"`. O valor padrão é `"latest"`.

- `EndingOffsets` – String UTF-8 correspondente a Custom string pattern #59.

O ponto final quando uma consulta em lote é encerrada. Os valores possíveis são `"latest"` ou uma string JSON que especifica um deslocamento final para cada `TopicPartition`.

- `PollTimeoutMs`: número (inteiro longo), no máximo None (Nenhum).

  O tempo limite em milissegundos para sondar dados do Kafka em executores de trabalho do Spark. O valor padrão é `512`.

- `NumRetries` – Número (inteiro), não mais do que None (Nenhum).

  O número de novas tentativas antes de falhar em obter os deslocamentos do Kafka. O valor padrão é `3`.

- `RetryIntervalMs`: número (inteiro longo), no máximo None (Nenhum).

  O tempo em milissegundos a se esperar antes de tentar novamente buscar os deslocamentos do Kafka. O valor padrão é `10`.

- `MaxOffsetsPerTrigger`: número (inteiro longo), no máximo None (Nenhum).

  O limite de taxa no número máximo de deslocamentos que são processados por intervalo do acionador. O número total especificado de deslocamentos é dividido proporcionalmente entre `topicPartitions` de diferentes volumes. O valor padrão é nulo, o que significa que o consumidor lê todos os deslocamentos até o deslocamento mais recente conhecido.

- `MinPartitions` – Número (inteiro), não mais do que None (Nenhum).

  O número mínimo desejado de partições a serem lidas do Kafka. O valor padrão é nulo, o que significa que o número de partições do Spark é igual ao número de partições do Kafka.

- `IncludeHeaders` – Booleano.

  Se cabeçalhos do Kafka devem ser incluídos. Quando a opção estiver definida como "true", a saída de dados conterá uma coluna adicional chamada "glue_streaming_kafka_headers" com o tipo `Array[Struct(key: String, value: String)]`. O valor padrão é “false”. Essa opção só está disponível no AWS Glue versão 3.0 ou posterior.

- `AddRecordTimestamp` – String UTF-8 correspondente a Custom string pattern #59.

  Quando essa opção for definida como “true“, a saída de dados conterá uma coluna adicional denominada "__src_timestamp" que indica a hora que o registro correspondente é recebido pelo tópico. O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.

- `EmitConsumerLagMetrics` – String UTF-8 correspondente a Custom string pattern #59.

  Quando essa opção for definida como "true", para cada lote, serão emitidas métricas durante o período entre a hora que o registro mais antigo é recebido pelo tópico e a hora que ele chega ao AWS Glue. O nome da métrica é "glue.driver.streaming.maxConsumerLagInMs". O valor padrão é "false". Essa opção é compatível com o AWS Glue versão 4.0 ou posterior.

- `StartingTimestamp` – String UTF-8.

  O timestamp do registro no tópico do Kafka para começar a ler os dados. Os valores possíveis são uma string de timestamp no formato UTC no padrão `yyyy-mm-ddTHH:MM:SSZ` (onde Z representa um desvio do fuso horário UTC com +/-). Por exemplo: "2023-04-04T08:00:00+08:00").

  Somente um de `StartingTimestamp` ou `StartingOffsets` deve ser definido.

Estrutura RedshiftSource

Especifica um datastore do Amazon Redshift.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore do Amazon Redshift.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O banco de dados do qual a leitura será feita.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  A tabela do banco de dados da qual a leitura será feita.

- `RedshiftTmpDir` – String UTF-8 correspondente a Custom string pattern #59.

  O caminho do Amazon S3 onde dados temporários podem ser preparados ao serem copiados do banco de dados.

- `TmpDirIAMRole` – String UTF-8 correspondente a Custom string pattern #59.

  A função do IAM com permissões.

Estrutura AmazonRedshiftSource

Especifica uma fonte do Amazon Redshift.

Campos

- `Name` – String UTF-8 correspondente a Custom string pattern #61.

  O nome da fonte do Amazon Redshift.
- `Data` – Um objeto AmazonRedshiftNodeData.

  Especifica os dados do nó da fonte do Amazon Reshift.

Estrutura AmazonRedshiftNodeData

Especifica um nó do Amazon Redshift.

Campos

- `AccessType` – String UTF-8 correspondente a Custom string pattern #58.

  O tipo de acesso para a conexão do Redshift. Pode ser uma conexão direta ou conexões de catálogo.
- `SourceType` – String UTF-8 correspondente a Custom string pattern #58.

  O tipo de origem para especificar se uma determinada tabela é a fonte ou uma consulta personalizada.
- `Connection` – Um objeto Opção.

  A conexão do AWS Glue com o cluster do Redshift.
- `Schema` – Um objeto Opção.

  O nome do esquema do Redshift ao trabalhar com uma conexão direta.
- `Table` – Um objeto Opção.

  O nome da tabela do Redshift ao trabalhar com uma conexão direta.
- `CatalogDatabase` – Um objeto Opção.

O nome do banco de dados do catálogo de dados do AWS Glue ao trabalhar com um catálogo de dados.

- `CatalogTable` – Um objeto Opção.

  O nome da tabela do catálogo de dados do AWS Glue ao trabalhar com um catálogo de dados.

- `CatalogRedshiftSchema` – String UTF-8.

  O nome do esquema do Redshift ao trabalhar com um catálogo de dados.

- `CatalogRedshiftTable` – String UTF-8.

  A tabela do banco de dados da qual a leitura será feita.

- `TempDir` – String UTF-8 correspondente a Custom string pattern #59.

  O caminho do Amazon S3 onde dados temporários podem ser preparados ao serem copiados do banco de dados.

- `IamRole` – Um objeto Opção.

  Opcional. O nome do perfil usado ao conectar com o S3. O perfil do IAM, quando deixado em branco, assumirá como padrão o perfil no trabalho.

- `AdvancedOptions`: um array de objetos AmazonRedshiftAdvancedOption.

  Valores opcionais ao se conectar ao cluster do Redshift.

- `SampleQuery` – String UTF-8.

  O SQL usado para buscar os dados de uma fonte do Redshift quando o SourceType é "consulta".

- `PreAction` – String UTF-8.

  O SQL usado antes de um MERGE ou APPEND com upsert ser executado.

- `PostAction` – String UTF-8.

  O SQL usado antes de um MERGE ou APPEND com upsert ser executado.

- `Action` – String UTF-8.

  Especifica como a gravação em um cluster do Redshift ocorrerá.

- `TablePrefix` – String UTF-8 correspondente a Custom string pattern #58.

  Especifica o prefixo de uma tabela.

- `Upsert` – Booleano.

  A ação usada no Redshift vai para o coletor ao fazer um APPEND.

- `MergeAction` – String UTF-8 correspondente a Custom string pattern #58.

  A ação usada para determinar como um MERGE em um coletor do Redshift será tratado.

- `MergeWhenMatched` – String UTF-8 correspondente a Custom string pattern #58.

  A ação usada para determinar como um MERGE em um coletor do Redshift será tratado quando um registro existente corresponder a um novo registro.

- `MergeWhenNotMatched` – String UTF-8 correspondente a Custom string pattern #58.

  A ação usada para determinar como um MERGE em um coletor do Redshift será tratado quando um registro existente não corresponder a um novo registro.

- `MergeClause` – String UTF-8.

  O SQL usado em uma mesclagem personalizada para lidar com registros correspondentes.

- `CrawlerConnection` – String UTF-8.

  Especifica o nome da conexão associada à tabela do catálogo usada.

- `TableSchema`: um array de objetos Opção.

  A matriz de saída do esquema para um determinado nó.

- `StagingTable` – String UTF-8.

  O nome da tabela de preparação temporária usada ao fazer um MERGE ou APPEND com upsert.

- `SelectedColumns`: um array de objetos Opção.

  A lista de nomes de colunas usada para determinar um registro correspondente ao fazer MERGE ou APPEND com upsert.

Estrutura AmazonRedshiftAdvancedOption

Especifica um valor opcional ao se conectar ao cluster do Redshift.

Campos

- `Key` – String UTF-8.

A chave para a opção de conexão adicional.

- `Value` – String UTF-8.

  O valor para a opção de conexão adicional.

Estrutura Option

Especifica um valor de opção.

Campos

- `Value` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica o valor da opção.

- `Label` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica o rótulo da opção.

- `Description` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica a descrição dae opção.

Estrutura S3CatalogSource

Especifica um datastore do Amazon S3 no catálogo de dados do.AWS Glue

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O banco de dados do qual a leitura será feita.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  A tabela do banco de dados da qual a leitura será feita.

- `PartitionPredicate` – String UTF-8 correspondente a Custom string pattern #59.

As partições que satisfazem a esse predicado são excluídas. Os arquivos dentro do período de retenção nessas partições não são excluídos. Definido como `""`, vazio por padrão.

- `AdditionalOptions` – Um objeto S3SourceAdditionalOptions.

  Especifica opções de conexão adicionais.

Estrutura S3SourceAdditionalOptions

Especifica opções de conexão adicionais para o datastore do Amazon S3.

Campos

- `BoundedSize` – Número (extenso).

  Define o limite superior para o tamanho de destino do conjunto de dados em bytes que serão processados.
- `BoundedFiles` – Número (extenso).

  Define o limite superior para o número alvo de arquivos que serão processados.

Estrutura S3CsvSource

Especifica um datastore CSV (valores separados por comando) armazenado no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.
- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de caminhos do Amazon S3 dos quais fazer a leitura.
- `CompressionType`: string UTF-8 (valores válidos: `gzip="GZIP"` | `bzip2="BZIP2"`).

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).
- `Exclusions` – Uma matriz de strings UTF-8.

Uma string contendo uma lista JSON de padrões glob a excluir estilo Unix. Por exemplo, "[\"**.pdf \"]" exclui todos os arquivos PDF.

- `GroupSize` – String UTF-8 correspondente a Custom string pattern #59.

  O tamanho do grupo de destino em bytes. O padrão é calculado com base no tamanho de dados de entrada e o tamanho de seu cluster. Quando há menos de 50.000 arquivos de entrada, `"groupFiles"` deve ser definido como `"inPartition"` para poder entrar em vigor.

- `GroupFiles` – String UTF-8 correspondente a Custom string pattern #59.

  O agrupamento de arquivos é ativado por padrão quando a entrada contiver mais de 50.000 arquivos. Para habilitar o agrupamento com menos de 50.000 arquivos, defina esse parâmetro como "inPartition". Para desabilitar o agrupamento quando houver mais de 50.000 arquivos, defina esse parâmetro como `"none"`.

- `Recurse` – Booleano.

  Se definido como verdadeiro, recursivamente lê arquivos em todos os subdiretórios de acordo com os caminhos especificados.

- `MaxBand` – Número (inteiro), não mais do que None (Nenhum).

  Esta opção controla a duração, em milissegundos, após a qual a listagem do s3 provavelmente será consistente. Os arquivos com carimbos de data e hora de modificação que estão dentro dos últimos maxBand milissegundos são rastreados principalmente ao usar JobBookmarks para considerar a consistência final do Amazon S3. A maioria dos usuários não precisa definir essa opção. O valor padrão é 900.000 milissegundos, ou 15 minutos.

- `MaxFilesInBand` – Número (inteiro), não mais do que None (Nenhum).

  Esta opção especifica o número máximo de arquivos para salvar nos últimos maxBand segundos. Se esse número for excedido, os arquivos extras são ignorados e apenas processados na próxima execução do trabalho.

- `AdditionalOptions` – Um objeto S3DirectSourceAdditionalOptions.

  Especifica opções de conexão adicionais.

- `Separator` – obrigatório: string UTF-8 (valores válidos: `comma="COMMA"` | `ctrla="CTRLA"` | `pipe="PIPE"` | `semicolon="SEMICOLON"` | `tab="TAB"`).

  Especifica o caractere delimitador. O padrão é uma vírgula: ",", mas qualquer outro caractere pode ser especificado.

- `Escaper` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica um caractere a ser usado para escape. Essa opção é usada somente ao ler arquivos CSV. O valor padrão é `none`. Se ativado, o caractere que imediatamente segue é usado no estado em que se encontram, exceto para um pequeno conjunto de escapes conhecidos (`\n`, `\r`, `\t` e `\0`).

- `QuoteChar`: obrigatório: string UTF-8 (valores válidos: `quote="QUOTE"` | `quillemet="QUILLEMET"` | `single_quote="SINGLE_QUOTE"` | `disabled="DISABLED"`).

  Especifica o caractere a ser usado para aspas. O padrão é aspas duplas: `'"'`. Defina como `-1` para desativar as aspas por completo.

- `Multiline` – Booleano.

  Um valor booleano que especifica se um único registro pode abranger várias linhas. Isso pode ocorrer quando um campo contém um caractere de nova linha entre aspas. Você deve definir essa opção como True (Verdadeira) se qualquer registro ocupar várias linhas. O valor padrão é `False`, que permite uma divisão de arquivos mais radical durante a análise.

- `WithHeader` – Booleano.

  Um valor booleano que especifica se é necessário tratar a primeira linha como um cabeçalho. O valor padrão é `False`.

- `WriteHeader` – Booleano.

  Um valor booleano que especifica se é necessário escrever o cabeçalho na saída. O valor padrão é `True`.

- `SkipFirst` – Booleano.

  Um valor booleano que especifica se é necessário ignorar a primeira linha de dados. O valor padrão é `False`.

- `OptimizePerformance` – Booleano.

  Um valor booleano que especifica se deve usar o leitor SIMD para CSV avançado junto com formatos de memória colunar baseados no Apache Arrow. Disponível somente no AWS Glue versão 3.0.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte CSV do S3.

Estrutura DirectJDBCSource

Especifica a conexão direta da fonte JDBC.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da conexão da fonte JDBC.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O banco de dados da conexão da fonte JDBC.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  A tabela da conexão da fonte JDBC.
- `ConnectionName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da conexão da fonte JDBC.
- `ConnectionType` – obrigatório: string UTF-8 (valores válidos: `sqlserver` | `mysql` | `oracle` | `postgresql` | `redshift`).

  O tipo de conexão da fonte JDBC.
- `RedshiftTmpDir` – String UTF-8 correspondente a Custom string pattern #59.

  O diretório temporário da fonte JDBC do Redshift.

Estrutura S3DirectSourceAdditionalOptions

Especifica opções de conexão adicionais para o datastore do Amazon S3.

Campos

- `BoundedSize` – Número (extenso).

  Define o limite superior para o tamanho de destino do conjunto de dados em bytes que serão processados.
- `BoundedFiles` – Número (extenso).

  Define o limite superior para o número alvo de arquivos que serão processados.

- `EnableSamplePath` – Booleano.

  Define a opção para ativar um caminho de exemplo.

- `SamplePath` – String UTF-8 correspondente a Custom string pattern #59.

  Se ativado, especifica o caminho de exemplo.

Estrutura S3JsonSource

Especifica um datastore JSON armazenado no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.

- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de caminhos do Amazon S3 dos quais fazer a leitura.

- `CompressionType`: string UTF-8 (valores válidos: `gzip="GZIP"` | `bzip2="BZIP2"`).

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).

- `Exclusions` – Uma matriz de strings UTF-8.

  Uma string contendo uma lista JSON de padrões glob a excluir estilo Unix. Por exemplo, "[\"**.pdf \"]" exclui todos os arquivos PDF.

- `GroupSize` – String UTF-8 correspondente a Custom string pattern #59.

  O tamanho do grupo de destino em bytes. O padrão é calculado com base no tamanho de dados de entrada e o tamanho de seu cluster. Quando há menos de 50.000 arquivos de entrada, `"groupFiles"` deve ser definido como `"inPartition"` para poder entrar em vigor.

- `GroupFiles` – String UTF-8 correspondente a Custom string pattern #59.

  O agrupamento de arquivos é ativado por padrão quando a entrada contiver mais de 50.000 arquivos. Para habilitar o agrupamento com menos de 50.000 arquivos, defina esse parâmetro como "inPartition". Para desabilitar o agrupamento quando houver mais de 50.000 arquivos, defina esse parâmetro como `"none"`.

- `Recurse` – Booleano.

  Se definido como verdadeiro, recursivamente lê arquivos em todos os subdiretórios de acordo com os caminhos especificados.

- `MaxBand` – Número (inteiro), não mais do que None (Nenhum).

  Esta opção controla a duração, em milissegundos, após a qual a listagem do s3 provavelmente será consistente. Os arquivos com carimbos de data e hora de modificação que estão dentro dos últimos maxBand milissegundos são rastreados principalmente ao usar JobBookmarks para considerar a consistência final do Amazon S3. A maioria dos usuários não precisa definir essa opção. O valor padrão é 900.000 milissegundos, ou 15 minutos.

- `MaxFilesInBand` – Número (inteiro), não mais do que None (Nenhum).

  Esta opção especifica o número máximo de arquivos para salvar nos últimos maxBand segundos. Se esse número for excedido, os arquivos extras são ignorados e apenas processados na próxima execução do trabalho.

- `AdditionalOptions` – Um objeto S3DirectSourceAdditionalOptions.

  Especifica opções de conexão adicionais.

- `JsonPath` – String UTF-8 correspondente a Custom string pattern #59.

  Uma string JsonPath que define os dados JSON.

- `Multiline` – Booleano.

  Um valor booleano que especifica se um único registro pode abranger várias linhas. Isso pode ocorrer quando um campo contém um caractere de nova linha entre aspas. Você deve definir essa opção como True (Verdadeira) se qualquer registro ocupar várias linhas. O valor padrão é `False`, que permite uma divisão de arquivos mais radical durante a análise.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte JSON do S3.

Estrutura S3ParquetSource

Especifica um datastore do Apache Parquet armazenado no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.

- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de caminhos do Amazon S3 dos quais fazer a leitura.

- `CompressionType` – String UTF-8 (valores válidos: `snappy="SNAPPY"` | `lzo="LZO"` | `gzip="GZIP"` | `brotli="BROTLI"` | `lz4="LZ4"` | `uncompressed="UNCOMPRESSED"` | `none="NONE"`).

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).

- `Exclusions` – Uma matriz de strings UTF-8.

  Uma string contendo uma lista JSON de padrões glob a excluir estilo Unix. Por exemplo, "[\"**.pdf \"]" exclui todos os arquivos PDF.

- `GroupSize` – String UTF-8 correspondente a Custom string pattern #59.

  O tamanho do grupo de destino em bytes. O padrão é calculado com base no tamanho de dados de entrada e o tamanho de seu cluster. Quando há menos de 50.000 arquivos de entrada, `"groupFiles"` deve ser definido como `"inPartition"` para poder entrar em vigor.

- `GroupFiles` – String UTF-8 correspondente a Custom string pattern #59.

  O agrupamento de arquivos é ativado por padrão quando a entrada contiver mais de 50.000 arquivos. Para habilitar o agrupamento com menos de 50.000 arquivos, defina esse parâmetro como "inPartition". Para desabilitar o agrupamento quando houver mais de 50.000 arquivos, defina esse parâmetro como `"none"`.

- `Recurse` – Booleano.

  Se definido como verdadeiro, recursivamente lê arquivos em todos os subdiretórios de acordo com os caminhos especificados.

- `MaxBand` – Número (inteiro), não mais do que None (Nenhum).

  Esta opção controla a duração, em milissegundos, após a qual a listagem do s3 provavelmente será consistente. Os arquivos com carimbos de data e hora de modificação que estão dentro dos últimos maxBand milissegundos são rastreados principalmente ao usar JobBookmarks para

considerar a consistência final do Amazon S3. A maioria dos usuários não precisa definir essa opção. O valor padrão é 900.000 milissegundos, ou 15 minutos.

- `MaxFilesInBand` – Número (inteiro), não mais do que None (Nenhum).

  Esta opção especifica o número máximo de arquivos para salvar nos últimos maxBand segundos. Se esse número for excedido, os arquivos extras são ignorados e apenas processados na próxima execução do trabalho.

- `AdditionalOptions` – Um objeto S3DirectSourceAdditionalOptions.

  Especifica opções de conexão adicionais.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte Parquet do S3.

Estrutura S3DeltaSource

Especifica uma fonte de dados do Delta Lake armazenada no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte do Delta Lake.

- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de caminhos do Amazon S3 dos quais fazer a leitura.

- `AdditionalDeltaOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica opções de conexão adicionais.

- `AdditionalOptions` – Um objeto S3DirectSourceAdditionalOptions.

  Especifica opções adicionais para o conector.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte do Delta Lake.

Estrutura S3CatalogDeltaSource

Especifica uma fonte de dados do Delta Lake que é registrada no catálogo de dados do AWS Glue. A fonte de dados deve estar armazenada no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados do Delta Lake.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.
- `AdditionalDeltaOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica opções de conexão adicionais.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte do Delta Lake.

Estrutura CatalogDeltaSource

Especifica uma fonte de dados do Delta Lake que é registrada no catálogo de dados do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados do Delta Lake.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.
- `AdditionalDeltaOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica opções de conexão adicionais.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte do Delta Lake.

Estrutura S3HudiSource

Especifica uma fonte de dados Hudi armazenada no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte Hudi.
- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de caminhos do Amazon S3 dos quais fazer a leitura.
- `AdditionalHudiOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica opções de conexão adicionais.
- `AdditionalOptions` – Um objeto S3DirectSourceAdditionalOptions.

  Especifica opções adicionais para o conector.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte Hudi.

Estrutura S3CatalogHudiSource

Especifica uma fonte de dados Hudi registrada no AWS Glue Data Catalog. A fonte de dados Hudi deve ser armazenada no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados Hudi.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.
- `AdditionalHudiOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica opções de conexão adicionais.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte Hudi.

Estrutura de S3ExcelSource

Especifica uma fonte de dados no S3 Excel.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados no S3 Excel.
- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Os caminhos do S3 onde os arquivos do Excel estão localizados.

- `CompressionType` – String UTF-8 (valores válidos: `snappy="SNAPPY"` | `lzo="LZO"` | `gzip="GZIP"` | `brotli="BROTLI"` | `lz4="LZ4"` | `uncompressed="UNCOMPRESSED"` | `none="NONE"`).

  O formato de compactação usado para os arquivos do Excel.

- `Exclusions` – Uma matriz de strings UTF-8.

  Padrões para excluir determinados arquivos ou caminhos do processamento.

- `GroupSize` – String UTF-8 correspondente a Custom string pattern #59.

  Define o tamanho dos grupos de arquivos para processamento em lotes.

- `GroupFiles` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica como os arquivos devem ser agrupados para processamento.

- `Recurse` – Booleano.

  Indica se os subdiretórios devem ser processados recursivamente.

- `MaxBand` – Número (inteiro), não mais do que None (Nenhum).

  O número máximo de faixas de processamento a serem usadas.

- `MaxFilesInBand` – Número (inteiro), não mais do que None (Nenhum).

  O número máximo de arquivos a serem processados em cada faixa.

- `AdditionalOptions` – Um objeto S3DirectSourceAdditionalOptions.

  Opções adicionais de configuração para processamento direto da fonte no S3.

- `NumberRows` – Número (extenso).

  O número de linhas a serem processadas de cada arquivo do Excel.

- `SkipFooter` – Número (inteiro), não mais do que None (Nenhum).

  O número de linhas a serem ignoradas no fim de cada arquivo do Excel.

- `OutputSchemas`: um array de objetos GlueSchema.

  Os esquemas do AWS Glue a serem aplicados aos dados processados.

Estrutura CatalogHudiSource

Especifica uma fonte de dados Hudi registrada no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados Hudi.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.
- `AdditionalHudiOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica opções de conexão adicionais.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a fonte Hudi.

Estrutura DynamoDBCatalogSource

Especifica uma fonte de dados do DynamoDB no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

O nome da tabela no banco de dados da qual a leitura será feita.

Estrutura RelationalCatalogSource

Especifica uma fonte de dados de banco de dados relacional no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados da qual a leitura será feita.

Estrutura JDBCConnectorTarget

Especifica um destino de dados que grava no Amazon S3 no armazenamento colunar do Apache Parquet.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.
- `ConnectionName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da conexão associada ao conector.
- `ConnectionTable` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no destino dos dados.
- `ConnectorName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

O nome de um conector que será usado.

- `ConnectionType` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O tipo de conexão, como marketplace.jdbc ou custom.jdbc, designando uma conexão com um destino de dados JDBC.

- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Opções de conexão adicionais para o conector.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para o destino do JDBC.

Estrutura SparkConnectorTarget

Especifica um destino que usa um conector Apache Spark.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `ConnectionName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome de uma conexão para um conector do Apache Spark.

- `ConnectorName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome de um conector do Apache Spark.

- `ConnectionType` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O tipo de conexão, como marketplace.spark ou custom.spark, designando uma conexão com um datastore do Apache Spark.

- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Opções de conexão adicionais para o conector.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para o destino do Spark personalizado.

Estrutura BasicCatalogTarget

Especifica um destino que usa uma tabela do catálogo de dados do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do seu destino de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.
- `PartitionKeys` – Uma matriz de strings UTF-8.

  As chaves de partição usadas para distribuir dados em várias partições ou fragmentos com base em uma chave específica ou em um conjunto de chaves.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O banco de dados que contém a tabela que você deseja usar como destino. Esse banco de dados já deve existir no Data Catalog.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  A tabela que define o esquema dos dados de saída. Essa tabela já deve existir no Data Catalog.

Estrutura MySQLCatalogTarget

Especifica um destino que usa o MySQL.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.

Estrutura PostgreSQLCatalogTarget

Especifica um destino que usa o Postgres SQL.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.

Estrutura OracleSQLCatalogTarget

Especifica um destino que usa o Oracle SQL.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.

Estrutura MicrosoftSQLServerCatalogTarget

Especifica um destino que usa o Microsoft SQL.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.

Estrutura RedshiftTarget

Especifica um destino que usa o Amazon Redshift.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.

- `RedshiftTmpDir` – String UTF-8 correspondente a Custom string pattern #59.

  O caminho do Amazon S3 onde dados temporários podem ser preparados ao serem copiados do banco de dados.

- `TmpDirIAMRole` – String UTF-8 correspondente a Custom string pattern #59.

  A função do IAM com permissões.

- `UpsertRedshiftOptions` – Um objeto UpsertRedshiftTargetOptions.

  O conjunto de opções para configurar uma operação upsert ao gravar em um destino do Redshift.

Estrutura AmazonRedshiftTarget

Especifica um destino do Amazon Redshift.

Campos

- `Name` – String UTF-8 correspondente a Custom string pattern #61.

  O nome do destino do Amazon Redshift.

- `Data` – Um objeto AmazonRedshiftNodeData.

  Especifica os dados do nó de destino do Amazon Redshift.

- `Inputs`: uma matriz de strings UTF-8, com não menos que 1 nem mais que 1 string.

Os nós que são entradas para o destino de dados.

Estrutura UpsertRedshiftTargetOptions

As opções para configurar uma operação upsert ao gravar em um destino do Redshift.

Campos

- `TableLocation` – String UTF-8 correspondente a Custom string pattern #59.

  A localização física da tabela do Redshift.
- `ConnectionName` – String UTF-8 correspondente a Custom string pattern #59.

  O nome da conexão a ser usada para gravar no Redshift.
- `UpsertKeys` – Uma matriz de strings UTF-8.

  As chaves usadas para determinar se uma atualização ou uma inserção será executada.

Estrutura S3CatalogTarget

Especifica um destino de dados que grava no Amazon S3 usando o catálogo de dados do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.
- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

O nome do banco de dados no qual gravar.

- `SchemaChangePolicy` – Um objeto CatalogSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura S3GlueParquetTarget

Especifica um destino de dados que grava no Amazon S3 no armazenamento colunar do Apache Parquet.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.

- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Um único caminho do Amazon S3 no qual gravar.

- `Compression` – String UTF-8 (valores válidos: `snappy="SNAPPY"` | `lzo="LZO"` | `gzip="GZIP"` | `brotli="BROTLI"` | `lz4="LZ4"` | `uncompressed="UNCOMPRESSED"` | `none="NONE"`).

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).

- `NumberTargetPartitions` – String UTF-8.

  Especifica o número de partições de destino para os arquivos Parquet ao gravar no Amazon S3 usando o AWS Glue.

- `SchemaChangePolicy` – Um objeto DirectSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura CatalogSchemaChangePolicy

Uma política que especifica o comportamentos de atualização do crawler.

Campos

- `EnableUpdateCatalog` – Booleano.

  Se comportamento de atualização especificado deve ser usado quando o crawler encontra um esquema alterado.
- `UpdateBehavior`: string UTF-8 (valores válidos: `UPDATE_IN_DATABASE` | `LOG`).

  O comportamento de atualização quando o crawler encontra um esquema alterado.

Estrutura S3DirectTarget

Especifica um destino de dados que grava no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.
- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.
- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Um único caminho do Amazon S3 no qual gravar.
- `Compression` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).
- `NumberTargetPartitions` – String UTF-8.

  Especifica o número de partições de destino ao gravar dados diretamente no Amazon S3.

- `Format`: obrigatório: string UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica o formato de saída de dados para o destino.

- `SchemaChangePolicy` – Um objeto DirectSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura S3HudiCatalogTarget

Especifica um destino de dados que grava em uma fonte de dados Hudi no AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.

- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.

- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.

- `AdditionalOptions`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica as opções de conexão adicionais para o conector.

- `SchemaChangePolicy` – Um objeto CatalogSchemaChangePolicy.

Uma política que especifica o comportamentos de atualização do crawler.

Estrutura S3HudiDirectTarget

Especifica um destino que grava em uma fonte de dados Hudi no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.

- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O caminho do Amazon S3 da fonte de dados Hudi na qual gravar.

- `Compression`: obrigatório: string UTF-8 (valores válidos: `gzip="GZIP"` | `lzo="LZO"` | `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).

- `NumberTargetPartitions` – String UTF-8.

  Especifica o número de partições de destino para distribuição dos arquivos do conjunto de dados do Hudi no Amazon S3.

- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.

- `Format`: obrigatório: string UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica o formato de saída de dados para o destino.

- `AdditionalOptions`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

Especifica as opções de conexão adicionais para o conector.

- `SchemaChangePolicy` – Um objeto DirectSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura S3DeltaCatalogTarget

Especifica um destino que grava em uma fonte de dados do Delta Lake no catálogo de dados do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.
- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.
- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica as opções de conexão adicionais para o conector.
- `SchemaChangePolicy` – Um objeto CatalogSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura S3DeltaDirectTarget

Especifica um destino que grava em uma fonte de dados do Delta Lake no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.
- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.
- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O caminho do Amazon S3 da fonte de dados do Delta Lake na qual gravar.
- `Compression` – Obrigatório: string UTF-8 (valores válidos: `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

  Especifica como os dados são compactados. Isso geralmente não é necessário se os dados tem uma extensão de arquivo padrão. Os possíveis valores são `"gzip"` e `"bzip"`).
- `NumberTargetPartitions` – String UTF-8.

  Especifica o número de partições de destino para distribuição dos arquivos do conjunto de dados do Data Lake no Amazon S3.
- `Format`: obrigatório: string UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica o formato de saída de dados para o destino.
- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica as opções de conexão adicionais para o conector.

- `SchemaChangePolicy` – Um objeto DirectSchemaChangePolicy.

  Uma política que especifica o comportamentos de atualização do crawler.

Estrutura de S3HyperDirectTarget

Especifica um destino de dados HyperDirect que grava no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O identificador exclusivo do nó de destino HyperDirect.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Especifica a fonte dos dados de entrada para o destino HyperDirect.
- `PartitionKeys` – Uma matriz de strings UTF-8.

  Define a estratégia de particionamento dos dados de saída.
- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O local no S3 onde os dados de saída serão gravados.
- `Compression` – String UTF-8 (valores válidos: `uncompressed="UNCOMPRESSED"`).

  O tipo de compactação a ser aplicado aos dados de saída.
- `SchemaChangePolicy` – Um objeto DirectSchemaChangePolicy.

  Define como alterações de esquemas são tratadas durante as operações de gravação.

Estrutura de S3IcebergDirectTarget

Especifica um destino que grava em uma fonte de dados do Iceberg no Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  Especifica o identificador exclusivo do nó de destino do Iceberg no pipeline de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

Define a única fonte de entrada que fornece dados para esse destino do Iceberg.

- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica as colunas usadas para particionar dados de tabelas do Iceberg no S3.

- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Define o local no S3 onde os dados de tabelas do Iceberg serão armazenados.

- `Format`: obrigatório: string UTF-8 (valores válidos: `json="JSON"` | `csv="CSV"` | `avro="AVRO"` | `orc="ORC"` | `parquet="PARQUET"` | `hudi="HUDI"` | `delta="DELTA"` | `iceberg="ICEBERG"` | `hyper="HYPER"` | `xml="XML"`).

  Especifica o formato de arquivo usado para armazenar dados de tabelas do Iceberg (por exemplo, Parquet, ORC).

- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Fornece outras opções de configuração para personalizar o comportamento das tabelas do Iceberg.

- `SchemaChangePolicy` – Um objeto DirectSchemaChangePolicy.

  Define como as alterações de esquemas são tratadas ao gravar dados na tabela do Iceberg.

- `Compression`: obrigatório: string UTF-8 (valores válidos: `gzip="GZIP"` | `lzo="LZO"` | `uncompressed="UNCOMPRESSED"` | `snappy="SNAPPY"`).

  Especifica o codec de compactação usado para arquivos de tabelas do Iceberg no S3.

- `NumberTargetPartitions` – String UTF-8.

  Define o número de partições de destino para distribuição de arquivos de tabelas do Iceberg no S3.

Estrutura DirectSchemaChangePolicy

Uma política que especifica o comportamentos de atualização do crawler.

Campos

- `EnableUpdateCatalog` – Booleano.

  Se comportamento de atualização especificado deve ser usado quando o crawler encontra um esquema alterado.

- `UpdateBehavior`: string UTF-8 (valores válidos: `UPDATE_IN_DATABASE` | `LOG`).

  O comportamento de atualização quando o crawler encontra um esquema alterado.

- `Table` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica a tabela no banco de dados à qual a política de alteração de esquema se aplica.

- `Database` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica o banco de dados no qual a política de alteração de esquema se aplica.

Estrutura ApplyMapping

Especifica uma transformação que mapeia chaves de propriedade de dados na fonte dos dados para chaves de propriedade de dados no destino dos dados. Você pode renomear chaves, modificar os tipos de dados para chaves e escolher quais chaves remover do conjunto de dados.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.

- `Mapping` – Obrigatório: uma matriz de objetos Mapeamento.

  Especifica o mapeamento das chaves de propriedade de dados na fonte dos dados para chaves de propriedade de dados no destino dos dados.

Estrutura Mapping

Especifica o mapeamento de chaves de propriedade de dados.

Campos

- `ToKey` – String UTF-8 correspondente a Custom string pattern #59.

  Após o mapeamento de aplicação, qual deve ser o nome da coluna. Pode ser igual a `FromPath`.
- `FromPath` – Uma matriz de strings UTF-8.

  A tabela ou coluna a ser modificada.
- `FromType` – String UTF-8 correspondente a Custom string pattern #59.

  O tipo dos dados a serem modificados.
- `ToType` – String UTF-8 correspondente a Custom string pattern #59.

  O tipo de dados para o qual os dados devem ser modificados.
- `Dropped` – Booleano.

  Se verdadeiro, a coluna será removida.
- `Children`: um array de objetos Mapeamento.

  Aplicável somente a estruturas de dados aninhadas. Se você quiser alterar a estrutura pai, mas também um de seus filhos, você pode preencher esta estrutura de dados. É também `Mapping`, mas seu `FromPath` será o `FromPath` dos pais mais o `FromPath` dessa estrutura.

  Para a parte dos filhos, suponha que você tenha a estrutura:

  ```
  { "FromPath": "OuterStructure", "ToKey": "OuterStructure", "ToType":
  "Struct", "Dropped": false, "Chidlren": [{ "FromPath": "inner", "ToKey":
  "inner", "ToType": "Double", "Dropped": false, }] }
  ```

  É possível especificar um `Mapping` parecido com:

  ```
  { "FromPath": "OuterStructure", "ToKey": "OuterStructure", "ToType":
  "Struct", "Dropped": false, "Chidlren": [{ "FromPath": "inner", "ToKey":
  "inner", "ToType": "Double", "Dropped": false, }] }
  ```

Estrutura SelectFields

Especifica uma transformação que escolhe as chaves de propriedade de dados que você deseja manter.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Um caminho JSON para uma variável na estrutura de dados.

Estrutura DropFields

Especifica uma transformação que escolhe as chaves de propriedade de dados que você deseja descartar.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Um caminho JSON para uma variável na estrutura de dados.

Estrutura RenameField

Especifica uma transformação que renomeia uma única chave de propriedade de dados.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

As entradas de dados identificadas por seus nomes de nós.

- `SourcePath`: obrigatório: uma matriz de strings UTF-8.

  Um caminho JSON para uma variável na estrutura de dados para os dados da fonte.

- `TargetPath`: obrigatório: uma matriz de strings UTF-8.

  Um caminho JSON para uma variável na estrutura de dados para os dados do destino.

Estrutura Spigot

Especifica uma transformação que grava amostras dos dados em um bucket do Amazon S3.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.

- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Um caminho no Amazon S3 onde a transformação grava um subconjunto de registros do conjunto de dados em um arquivo JSON, em um bucket do Amazon S3.

- `Topk`: número (inteiro), não mais do que 100.

  Especifica vários registros a serem gravados a partir do início do conjunto de dados.

- `Prob`: número (double), no máximo 1.

  A probabilidade (um valor decimal com um valor máximo de 1) de escolher qualquer registro. Um valor de 1 indica que cada linha lida do conjunto de dados deve ser incluída na saída de amostra.

Estrutura Join

Especifica uma transformação que une dois conjuntos de dados em um só, usando uma frase de comparação nas chaves de propriedade de dados especificadas. Você pode usar junção inner

(interna), outer (externa), left (à esquerda), right (à direita), left semi (semi à esquerda) e left anti (anti à esquerda).

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 2 ou mais de 2 strings.

  As entradas de dados identificadas por seus nomes de nós.

- `JoinType` – obrigatório: string UTF-8 (valores válidos: `equijoin="EQUIJOIN"` | `left="LEFT"` | `right="RIGHT"` | `outer="OUTER"` | `leftsemi="LEFT_SEMI"` | `leftanti="LEFT_ANTI"`).

  Especifica o tipo de junção a ser executada nos conjuntos de dados.

- `Columns`: obrigatório: uma matriz de objetos JoinColumn, não menos de 2 ou mais de 2 estruturas.

  Uma lista das duas colunas a serem unidas.

Estrutura JoinColumn

Especifica uma coluna a ser unida.

Campos

- `From` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  A coluna a ser unida.

- `Keys`: obrigatório: uma matriz de strings UTF-8.

  A chave da coluna a ser unida.

Estrutura SplitFields

Especifica uma transformação que divide chaves de propriedade de dados em dois `DynamicFrames`. A saída é uma coleção de `DynamicFrames`: um com chaves de propriedade de dados selecionadas e outro com as chaves de propriedade de dados restantes.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `Paths`: obrigatório: uma matriz de strings UTF-8.

  Um caminho JSON para uma variável na estrutura de dados.

Estrutura SelectFromCollection

Especifica uma transformação que escolhe um `DynamicFrame` de uma coleção de `DynamicFrames`. A saída é o `DynamicFrame` selecionado.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `Index` – Obrigatório: número (inteiro), não mais do que Nenhum.

  O índice para o DynamicFrame a ser selecionado.

Estrutura FillMissingValues

Especifica uma transformação que localiza registros no conjunto de dados que tenham valores ausentes e adiciona um novo campo com um valor determinado por imputação. O conjunto de dados de entrada é usado para treinar o modelo de machine learning que determina qual deve ser o valor ausente.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `ImputedPath` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Um caminho JSON para uma variável na estrutura de dados para o conjunto de dados imputado.
- `FilledPath` – String UTF-8 correspondente a Custom string pattern #59.

  Um caminho JSON para uma variável na estrutura de dados para o conjunto de dados preenchido.

Estrutura Filter

Especifica uma transformação que divide um conjunto de dados em dois, com base em uma condição de filtro.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `LogicalOperator` – Obrigatório: string UTF-8 (valores válidos: `AND` | `OR`).

  O operador costumava filtrar linhas comparando o valor da chave com um valor especificado.
- `Filters` – Obrigatório: uma matriz de objetos FilterExpression.

  Especifica uma expressão de filtro.

Estrutura FilterExpression

Especifica uma expressão de filtro.

Campos

- `Operation`: obrigatório: string UTF-8 (valores válidos: `EQ` | `LT` | `GT` | `LTE` | `GTE` | `REGEX` | `ISNULL`).

O tipo de operação a ser executada na expressão.

- `Negated` – Booleano.

  Se a expressão deve ser negada.

- `Values` – Obrigatório: uma matriz de objetos FilterValue.

  Uma lista de valores de filtro.

Estrutura FilterValue

Representa uma única entrada na lista de valores de uma `FilterExpression`.

Campos

- `Type` – Obrigatório: string UTF-8 (valores válidos: `COLUMNEXTRACTED` | `CONSTANT`).

  O tipo de valor do filtro.

- `Value`: obrigatório: uma matriz de strings UTF-8.

  O valor a ser associado.

Estrutura CustomCode

Especifica uma transformação que usa código personalizado que você fornece para executar a transformação de dados. A saída é uma coleção de DynamicFrames.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs` – Obrigatório: uma matriz de strings UTF-8, pelo menos 1 string.

  As entradas de dados identificadas por seus nomes de nós.

- `Code` – Obrigatório: string UTF-8, correspondente a Custom string pattern #52.

  O código personalizado usado para executar a transformação de dados.

- `ClassName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

O nome definido para a classe de nó de código personalizado.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a transformação de código personalizada.

Estrutura SparkSQL

Especifica uma transformação em que você insere uma consulta de SQL usando a sintaxe do Spark SQL para transformar os dados. A saída é um único `DynamicFrame`.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs` – Obrigatório: uma matriz de strings UTF-8, pelo menos 1 string.

  As entradas de dados identificadas por seus nomes de nós. Você pode associar um nome de tabela a cada nó de entrada a ser usado na consulta SQL. O nome escolhido deve atender às restrições de nomenclatura do Spark SQL.

- `SqlQuery` – Obrigatório: string UTF-8, correspondente a Custom string pattern #60.

  Uma consulta SQL que deve usar a sintaxe do Spark SQL e retornar um único conjunto de dados.

- `SqlAliases` – Obrigatório: uma matriz de objetos SqlAlias.

  Uma lista de aliases. Um alias permite especificar qual nome usar no SQL para uma determinada entrada. Por exemplo, você tem uma fonte de dados chamada "MyDataSource". Se você especificar `From` como MyDataSource, e `Alias` como SqlName, então, em seu SQL, você pode fazer:

  ```
  select * from SqlName
  ```

  e isso obtém dados de MyDataSource.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a transformação do SparkSQL.

Estrutura SqlAlias

Representa uma única entrada na lista de valores de `SqlAliases`.

Campos

- `From` – Obrigatório: string UTF-8, correspondente a Custom string pattern #58.

  Uma tabela ou uma coluna em uma tabela.

- `Alias` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Um nome temporário dado a uma tabela ou a uma coluna em uma tabela.

Estrutura DropNullFields

Especifica uma transformação que remove colunas do conjunto de dados se todos os valores na coluna forem 'null'. Por padrão, o AWS Glue Studio reconhecerá objetos nulos, mas alguns valores, como strings vazias, strings que sejam "nulas", inteiros -1 ou outros espaços reservados, como zeros, não são automaticamente reconhecidos como nulos.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.

- `NullCheckBoxList` – Um objeto NullCheckBoxList.

  Uma estrutura que representa se determinados valores são reconhecidos como valores nulos para remoção.

- `NullTextList` – Uma matriz de NullValueField objetos, não mais de 50 estruturas.

  Uma estrutura que especifica uma lista de estruturas NullValueField que representam um valor nulo personalizado, como zero ou outro valor sendo usado como um espaço reservado nulo exclusivo para o conjunto de dados.

A transformação `DropNullFields` remove valores nulos personalizados somente se o valor do espaço reservado nulo e o tipo de dados corresponderem aos dados.

Estrutura NullCheckBoxList

Representa se determinados valores são reconhecidos como valores nulos para remoção.

Campos

- `IsEmpty` – Booleano.

  Especifica que uma string vazia é considerada como um valor nulo.

- `IsNullString` – Booleano.

  Especifica que um valor com a palavra "null" é considerado como um valor nulo.

- `IsNegOne` – Booleano.

  Especifica que um valor inteiro de -1 é considerado como um valor nulo.

Estrutura NullValueField

Representa um valor nulo personalizado, como zeros ou outros valores sendo usados como um espaço reservado para nulo exclusivo para o conjunto de dados.

Campos

- `Value` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O valor do espaço reservado para nulo.

- `Datatype` – Obrigatório: um objeto DataType.

  O tipo de dados do valor.

Estrutura Datatype

Uma estrutura que representa o tipo de dados do valor.

Campos

- `Id` – Obrigatório: string UTF-8, correspondente a Custom string pattern #58.

  O tipo de dados do valor.
- `Label` – Obrigatório: string UTF-8, correspondente a Custom string pattern #58.

  Um rótulo atribuído ao tipo de dados.

Estrutura Merge

Especifica uma transformação que mescla um `DynamicFrame` com um `DynamicFrame` de preparação, de acordo com as chaves primárias especificadas para identificar registros. Registros duplicados (com as mesmas chaves primárias) não são eliminados.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 2 ou mais de 2 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `Source` – Obrigatório: string UTF-8, correspondente a Custom string pattern #58.

  O `DynamicFrame` da fonte que será mesclado com um `DynamicFrame` de preparação.
- `PrimaryKeys`: obrigatório: uma matriz de strings UTF-8.

  A lista de campos de chave primária para corresponder aos registros da fonte e quadros dinâmicos de preparação.

Estrutura Union

Especifica uma transformação que combina as linhas de dois ou mais conjuntos de dados em um único resultado.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 2 ou mais de 2 strings.

  A entrada do ID do nó na transformação.

- `UnionType` – Obrigatório: string UTF-8 (valores válidos: `ALL` | `DISTINCT`).

  Indica o tipo de transformação Union.

  Especifica `ALL` para unir todas as linhas de fontes de dados ao DynamicFrame resultante. A união resultante não remove linhas duplicadas.

  Especifica `DISTINCT` para remover linhas duplicadas no DynamicFrame resultante.

Estrutura PIIDetection

Especifica uma transformação que identifica, remove ou mascara dados de PII.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  A entrada do ID do nó na transformação.

- `PiiType`: obrigatório: string UTF-8 (valores válidos: `RowAudit` | `RowMasking` | `ColumnAudit` | `ColumnMasking`).

  Indica o tipo de transformação PIIDetection.

- `EntityTypesToDetect`: obrigatório: uma matriz de strings UTF-8.

  Indica os tipos de entidades que a transformação PIIDetection identificará como dados de PII.

  As entidades do tipo PII incluem: 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_IDENTIFI

- `OutputColumnName` – String UTF-8 correspondente a Custom string pattern #59.

  Indica o nome da coluna de saída que conterá qualquer tipo de entidade detectado nessa linha.

- `SampleFraction`: número (double), no máximo 1.

  Indica a fração dos dados a serem amostrados ao verificar entidades de PII.

- `ThresholdFraction`: número (double), no máximo 1.

  Indica a fração dos dados que devem ser atendidos para que uma coluna seja identificada como dados de PII.

- `MaskValue`: string UTF-8 com no máximo 256 bytes de comprimento e correspondente a Custom string pattern #56.

  Indica o valor que substituirá a entidade detectada.

Estrutura Aggregate

Especifica uma transformação que agrupa linhas por campos escolhidos e calcula o valor agregado por função especificada.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Especifica os campos e linhas a serem usados como entradas para a transformação agregada.

- `Groups`: obrigatório: uma matriz de strings UTF-8.

  Especifica os campos a serem agrupados.

- `Aggs`: obrigatório: uma matriz de objetos AggregateOperation, com, no mínimo, 1 e, no máximo, 30 estruturas.

  Especifica as funções agregadas a serem executadas em campos especificados.

Estrutura DropDuplicates

Especifica uma transformação que remove linhas de dados repetidos de um conjunto de dados.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó de transformação.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas de dados identificadas por seus nomes de nós.
- `Columns` – Uma matriz de strings UTF-8.

  O nome das colunas a serem mescladas ou removidas caso sejam repetidas.

Estrutura GovernedCatalogTarget

Especifica um destino de dados que grava no Amazon S3 usando o catálogo de dados do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino de dados.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são entradas para o destino de dados.
- `PartitionKeys` – Uma matriz de strings UTF-8.

  Especifica o particionamento nativo usando uma sequência de chaves.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome da tabela no banco de dados na qual gravar.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O nome do banco de dados no qual gravar.
- `SchemaChangePolicy` – Um objeto CatalogSchemaChangePolicy.

Uma política que especifica o comportamento do catálogo governado.

Estrutura GovernedCatalogSource

Especifica o datastore no AWS Glue Data Catalog.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do datastore.
- `Database` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O banco de dados do qual a leitura será feita.
- `Table` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  A tabela do banco de dados da qual a leitura será feita.
- `PartitionPredicate` – String UTF-8 correspondente a Custom string pattern #59.

  As partições que satisfazem a esse predicado são excluídas. Os arquivos dentro do período de retenção nessas partições não são excluídos. Definido como `""`, vazio por padrão.
- `AdditionalOptions` – Um objeto S3SourceAdditionalOptions.

  Especifica opções de conexão adicionais.

Estrutura AggregateOperation

Especifica o conjunto de parâmetros necessários para realizar agregação na transformação dinâmica.

Campos

- `Column`: obrigatório: uma matriz de strings UTF-8.

  Especifica a coluna no conjunto de dados em que a função de agregação será aplicada.
- `AggFunc`: obrigatório: string UTF-8 (valores válidos: `avg` | `countDistinct` | `count` | `first` | `last` | `kurtosis` | `max` | `min` | `skewness` | `stddev_samp` | `stddev_pop` | `sum` | `sumDistinct` | `var_samp` | `var_pop`).

Especifica a função de agregação a ser aplicada.

As possíveis funções de agregação incluem: avg countDistinct, count, first, last, kurtosis, max, min, skewness, stddev_samp, stddev_pop, sum, sumDistinct, var_samp, var_pop

Estrutura GlueSchema

Especifica um esquema definido pelo usuário quando um esquema não pode ser determinado pelo AWS Glue.

Campos

- `Columns`: um array de objetos GlueStudioSchemaColumn.

  Especifica as definições de coluna que compõem um esquema do AWS Glue.

Estrutura GlueStudioSchemaColumn

Especifica uma única coluna em uma definição de esquema do AWS Glue.

Campos

- `Name`: – Obrigatório: string UTF-8 com não mais do que 1024 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da coluna no esquema do AWS Glue Studio.
- `Type` – String UTF-8 com comprimento não superior a 131.072 bytes, correspondente a Single-line string pattern.

  O tipo de hive para esta coluna no esquema do AWS Glue Studio.

Estrutura GlueStudioColumn

Especifica uma única coluna no AWS Glue Studio.

Campos

- `Key` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

A chave da coluna no AWS Glue Studio.

- `FullPath`: obrigatório: uma matriz de strings UTF-8.

  O URL completo da coluna no AWS Glue Studio.

- `Type` – Obrigatório: string UTF-8 (valores válidos: `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"`).

  O tipo da coluna no AWS Glue Studio.

- `Children`: uma matriz de estruturas.

  Os itens secundários da coluna principal no AWS Glue Studio.

Estrutura DynamicTransform

Especifica o conjunto de parâmetros necessários para realizar a transformação dinâmica.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Especifica o nome da transformação dinâmica.

- `TransformName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Especifica o nome da transformação dinâmica como aparece no editor visual do AWS Glue Studio.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Especifica as entradas necessárias para a transformação dinâmica.

- `Parameters`: um array de objetos TransformConfigParameter.

  Especifica os parâmetros da transformação dinâmica.

- `FunctionName` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Especifica o nome da função da transformação dinâmica.

- `Path` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Especifica o caminho da origem da transformação dinâmica e dos arquivos de configuração.

- `Version` – String UTF-8 correspondente a Custom string pattern #59.

  Esse campo não é usado e será removido em uma versão futura.

- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para a transformação dinâmica.

Estrutura TransformConfigParameter

Especifica os parâmetros no arquivo de configuração da transformação dinâmica.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  Especifica o nome do parâmetro no arquivo de configuração da transformação dinâmica.

- `Type`: obrigatório: string UTF-8 (valores válidos: `str="STR"` | `int="INT"` | `float="FLOAT"` | `complex="COMPLEX"` | `bool="BOOL"` | `list="LIST"` | `null="NULL"`).

  Especifica o tipo de parâmetro no arquivo de configuração da transformação dinâmica.

- `ValidationRule` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica a regra de validação no arquivo de configuração da transformação dinâmica.

- `ValidationMessage` – String UTF-8 correspondente a Custom string pattern #59.

  Especifica a mensagem de validação no arquivo de configuração da transformação dinâmica.

- `Value` – Uma matriz de strings UTF-8.

  Especifica o valor do parâmetro no arquivo de configuração da transformação dinâmica.

- `ListType` – String UTF-8 (valores válidos: `str="STR"` | `int="INT"` | `float="FLOAT"` | `complex="COMPLEX"` | `bool="BOOL"` | `list="LIST"` | `null="NULL"`).

  Especifica o tipo de lista do parâmetro no arquivo de configuração da transformação dinâmica.

- `IsOptional` – Booleano.

  Especifica se o parâmetro é opcional ou não no arquivo de configuração da transformação dinâmica.

Estrutura EvaluateDataQuality

Especifica os critérios da avaliação de qualidade dos dados.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da avaliação de qualidade dos dados.

- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  As entradas da avaliação de qualidade dos dados.

- `Ruleset`: obrigatório: string UTF-8, não menos que 1 ou mais que 65.536 bytes de comprimento, correspondente ao Custom string pattern #57.

  O conjunto de regras para a avaliação de qualidade dos dados.

- `Output`: string UTF-8 (valores válidos: `PrimaryInput` | `EvaluationResults`).

  As resultado da avaliação de qualidade dos dados.

- `PublishingOptions` – Um objeto DQResultsPublishingOptions.

  Opções para configurar como os resultados são publicados.

- `StopJobOnFailureOptions` – Um objeto DQStopJobOnFailureOptions.

  Opções para configurar como o trabalho será interrompido se a avaliação de qualidade dos dados falhar.

Estrutura DQResultsPublishingOptions

Opções para configurar como os resultados da avaliação de qualidade dos dados são publicados.

Campos

- `EvaluationContext` – String UTF-8 correspondente a Custom string pattern #58.

  O contexto da avaliação.
- `ResultsS3Prefix` – String UTF-8 correspondente a Custom string pattern #59.

  O prefixo do Amazon S3 adicionado aos resultados.
- `CloudWatchMetricsEnabled` – Booleano.

  Habilitar métricas para os resultados de qualidade dos dados.
- `ResultsPublishingEnabled` – Booleano.

  Habilitar a publicação dos resultados de qualidade dos dados.

Estrutura DQStopJobOnFailureOptions

Opções para configurar como o trabalho será interrompido se a avaliação de qualidade dos dados falhar.

Campos

- `StopJobOnFailureTiming`: string UTF-8 (valores válidos: `Immediate` | `AfterDataLoad`).

  Quando interromper o trabalho se a avaliação de qualidade dos dados falhar. As opções são Immediate ou AfterDataLoad.

Estrutura EvaluateDataQualityMultiFrame

Especifica os critérios da avaliação de qualidade dos dados.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da avaliação de qualidade dos dados.

- `Inputs` – Obrigatório: uma matriz de strings UTF-8, pelo menos 1 string.

  As entradas da avaliação de qualidade dos dados. A primeira entrada nessa lista é a fonte de dados primária.

- `AdditionalDataSources` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #61.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Os aliases de todas as fontes de dados, exceto a primária.

- `Ruleset`: obrigatório: string UTF-8, não menos que 1 ou mais que 65.536 bytes de comprimento, correspondente ao Custom string pattern #57.

  O conjunto de regras para a avaliação de qualidade dos dados.

- `PublishingOptions` – Um objeto DQResultsPublishingOptions.

  Opções para configurar como os resultados são publicados.

- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 (valores válidos: `performanceTuning.caching="CacheOption"` | `observations.scope="ObservationsOption"`).

  Cada valor é uma sequência de caracteres UTF-8.

  Opções para configurar o comportamento do runtime da transformação.

- `StopJobOnFailureOptions` – Um objeto DQStopJobOnFailureOptions.

  Opções para configurar como o trabalho será interrompido se a avaliação de qualidade dos dados falhar.

Estrutura da fórmula

Um nó do AWS Glue Studio que usa uma fórmula do AWS Glue DataBrew em trabalhos do AWS Glue.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do nó do AWS Glue Studio.
- `Inputs`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 1 strings.

  Os nós que são inseridos no nó da fórmula, identificados por ID.
- `RecipeReference` – Um objeto RecipeReference.

  Uma referência à fórmula do DataBrew usada pelo nó.
- `RecipeSteps`: um array de objetos RecipeStep.

  Etapas de transformação usadas no nó da fórmula.

Estrutura SchemaReference

Uma referência a uma fórmula do AWS Glue DataBrew.

Campos

- `RecipeArn` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O ARN da fórmula do DataBrew.
- `RecipeVersion` - obrigatório: string UTF-8, com não menos do que 1 nem mais do que 16 bytes de comprimento.

  A RecipeVersion da fórmula do DataBrew.

Estrutura SnowflakeNodeData

Especifica a configuração dos nós do Snowflake no AWS Glue Studio

Campos

- `SourceType` – String UTF-8 correspondente a Custom string pattern #58.

  Especifica como os dados recuperados são especificados. Valores válidos: `"table"`, `"query"`.
- `Connection` – Um objeto Opção.

Especifica uma conexão do catálogo de dados do AWS Glue com um endpoint do Snowflake.

- `Schema` – String UTF-8.

  Especifica um esquema de banco de dados do Snowflake para seu nó usar.

- `Table` – String UTF-8.

  Especifica uma tabela do Snowflake para seu nó usar.

- `Database` – String UTF-8.

  Especifica um banco de dados do Snowflake para seu nó usar.

- `TempDir` – String UTF-8 correspondente a Custom string pattern #59.

  Não utilizado no momento.

- `IamRole` – Um objeto Opção.

  Não utilizado no momento.

- `AdditionalOptions` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #59.

  Cada valor é uma string UTF-8 que corresponde a Custom string pattern #59.

  Especifica opções adicionais passadas ao conector do Snowflake. Se as opções forem especificadas em outro lugar neste nó, isso terá precedência.

- `SampleQuery` – String UTF-8.

  Uma string SQL usada para recuperar dados com o tipo de fonte `query`.

- `PreAction` – String UTF-8.

  Uma string SQL executada antes que o conector do Snowflake execute suas ações padrão.

- `PostAction` – String UTF-8.

  Uma string SQL executada depois que o conector do Snowflake executa suas ações padrão.

- `Action` – String UTF-8.

  Especifica a ação a ser realizada ao gravar em uma tabela com dados preexistentes. Valores válidos: `append`, `merge`, `truncate`, `drop`.

- `Upsert` – Booleano.

  Usado quando a ação é `append`. Especifica o comportamento da resolução quando uma linha já existe. Se verdadeiro, as linhas preexistentes serão atualizadas. Se falso, essas linhas serão inseridas.

- `MergeAction` – String UTF-8 correspondente a Custom string pattern #58.

  Especifica uma ação de mesclagem. Valores válidos: `simple`, `custom`. Se for simples, o comportamento de mesclagem será definido por `MergeWhenMatched` e `MergeWhenNotMatched`. Se for personalizado, será definido por `MergeClause`.

- `MergeWhenMatched` – String UTF-8 correspondente a Custom string pattern #58.

  Especifica como resolver registros que correspondam a dados preexistentes durante a mesclagem. Valores válidos: `update`, `delete`.

- `MergeWhenNotMatched` – String UTF-8 correspondente a Custom string pattern #58.

  Especifica como processar registros que não correspondem a dados preexistentes durante a mesclagem. Valores válidos: `insert`, `none`.

- `MergeClause` – String UTF-8.

  Uma instrução SQL que especifica um comportamento de mesclagem personalizado.

- `StagingTable` – String UTF-8.

  O nome de uma tabela de preparação usada ao executar `merge` ou fazer o upsert das ações `append`. Os dados são gravados nessa tabela e, em seguida, movidos para a `table` por uma pós-ação gerada.

- `SelectedColumns`: um array de objetos Opção.

  Especifica as colunas combinadas para identificar um registro ao detectar correspondências para mesclagens e upserts. Uma lista de estruturas com as chaves `value`, `label` e `description`. Cada estrutura descreve uma coluna.

- `AutoPushdown` – Booleano.

  Especifica se o pushdown de consultas está habilitado. Se o pushdown estiver habilitado, quando uma consulta for executada no Spark, se for possível fazer pushdown de parte da consulta para o servidor do Snowflake, isso ocorrerá. Isso melhora a performance de algumas consultas.

- `TableSchema`: um array de objetos Opção.

Define manualmente o esquema de destino para o nó. Uma lista de estruturas com as chaves `value`, `label` e `description`. Cada estrutura define uma coluna.

Estrutura SnowflakeSource

Especifica uma fonte de dados do Snowflake.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome da fonte de dados do Snowflake.
- `Data` – Obrigatório: um objeto SnowflakeNodeData.

  Configuração da fonte de dados do Snowflake.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica esquemas definidos pelo usuário para seus dados de saída.

Estrutura SnowflakeTarget

Especifica um destino do Snowflake.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome do destino do Snowflake.
- `Data` – Obrigatório: um objeto SnowflakeNodeData.

  Especifica os dados do nó de destino do Snowflake.
- `Inputs`: uma matriz de strings UTF-8, com não menos que 1 nem mais que 1 string.

  Os nós que são entradas para o destino de dados.

Estrutura ConnectorDataSource

Especifica uma fonte gerada com opções de conexão padrão.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome desse nó de origem.
- `ConnectionType` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O `connectionType`, conforme fornecido à biblioteca AWS Glue subjacente. Esse tipo de nó é compatível com os seguintes tipos de conexão:
  - `opensearch`
  - `azuresql`
  - `azurecosmos`
  - `bigquery`
  - `saphana`
  - `teradata`
  - `vertica`
- `Data`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um mapa que especifica as opções de conexão para o nó. É possível encontrar opções de conexão padrão para o tipo de conexão correspondente na seção Parâmetros de conexão da documentação do AWS Glue.
- `OutputSchemas`: um array de objetos GlueSchema.

  Especifica o esquema de dados para esta fonte.

Estrutura ConnectorDataTarget

Especifica um destino gerado com opções de conexão padrão.

Campos

- `Name` – Obrigatório: string UTF-8, correspondente a Custom string pattern #61.

  O nome desse nó de destino.

- `ConnectionType` – Obrigatório: string UTF-8, correspondente a Custom string pattern #59.

  O `connectionType`, conforme fornecido à biblioteca AWS Glue subjacente. Esse tipo de nó é compatível com os seguintes tipos de conexão:

  - `opensearch`
  - `azuresql`
  - `azurecosmos`
  - `bigquery`
  - `saphana`
  - `teradata`
  - `vertica`
- `Data`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um mapa que especifica as opções de conexão para o nó. É possível encontrar opções de conexão padrão para o tipo de conexão correspondente na seção Parâmetros de conexão da documentação do AWS Glue.
- `Inputs`: uma matriz de strings UTF-8, com não menos que 1 nem mais que 1 string.

  Os nós que são entradas para o destino de dados.

Estrutura RecipeStep

Uma etapa de fórmula usada em um nó de fórmula de preparação de dados do AWS Glue Studio.

Campos

- `Action` – Obrigatório: um objeto RecipeAction.

  A ação de transformação da etapa de fórmula.
- `ConditionExpressions`: um array de objetos ConditionExpression.

  Expressões de condição para a etapa de fórmula.

Estrutura RecipeAction

Ações definidas no nó da fórmula de preparação de dados do AWS Glue Studio.

Campos

- `Operation`: obrigatório: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #54.

  A operação da ação da fórmula.

- `Parameters` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes, correspondente a Custom string pattern #55.

  Cada chave é uma string UTF-8, podendo ter entre 1 e 32.768 bytes.

  Os parâmetros da ação da fórmula.

Estrutura ConditionExpression

Expressão de condição definida no nó da fórmula de preparação de dados do AWS Glue Studio.

Campos

- `Condition`: obrigatório: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #54.

  A condição da expressão de condição.

- `Value`: string UTF-8, com no máximo 1.024 bytes.

  O valor da expressão de condição.

- `TargetColumn` (obrigatório): string UTF-8, podendo ter entre 1 e 1.024 bytes.

  A coluna de destino das expressões de condição.

API de trabalhos

A API de trabalhos descreve os tipos de dados de trabalhos e contém APIs para operar com trabalhos, execuções de trabalhos e acionadores no AWS Glue.

Tópicos

- Tarefas
- Execuções de trabalhos
- Acionadores

Tarefas

A API de trabalhos descreve os tipos de dados e a API relacionada à criação, atualização, exclusão ou previsualização de trabalhos no AWS Glue.

Tipos de dados

- Estrutura Job
- Estrutura ExecutionProperty
- Estrutura NotificationProperty
- Estrutura JobCommand
- Estrutura ConnectionsList
- Estrutura JobUpdate
- Estrutura SourceControlDetails

Estrutura Job

Especifica uma definição de trabalho.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome que você atribui a esta definição de trabalho.
- `JobMode` – String UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

Um modo que descreve como um trabalho foi criado. Os valores válidos são:

- `SCRIPT`: o trabalho foi criado usando o editor de scripts do AWS Glue Studio.
- `VISUAL`: o trabalho foi criado usando o editor visual do AWS Glue Studio.
- `NOTEBOOK`: o trabalho foi criado usando um caderno de sessões interativas.

Quando o campo `JobMode` está ausente ou é nulo, `SCRIPT` é atribuído como o valor padrão.

- `JobRunQueuingEnabled` – Booleano.

  Especifica se o enfileiramento da execução de trabalhos está habilitado para as execuções desse trabalho.

  Um valor "verdadeiro" significa que o enfileiramento da execução de trabalhos está habilitado para a execução do trabalho. Se o valor for "falso" ou não estiver preenchido, as execuções do trabalho não serão consideradas para enfileiramento.

  Se esse campo não corresponder ao valor definido na execução do trabalho, o valor do campo de execução do trabalho será usado.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do trabalho.

- `LogUri` – String UTF-8.

  Este campo está reservado para uso futuro.

- `Role` – String UTF-8.

  O nome ou o nome de recurso da Amazon (ARN) da função do IAM associada a esta trabalho.

- `CreatedOn` – Timestamp.

  A hora e a data em que esta definição de trabalho foi criada.

- `LastModifiedOn` – Timestamp.

  O último momento em que esta definição de trabalho foi modificada.

- `ExecutionProperty` – Um objeto ExecutionProperty.

  Um `ExecutionProperty` que especifica o número máximo de execuções simultâneas permitidas para o trabalho.

- `Command` – Um objeto JobCommand.

  O `JobCommand` que executa esse trabalho.

- `DefaultArguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Os argumentos padrão para toda execução desse trabalho, especificados como pares de nome-valor.

  Aqui, é possível especificar os argumentos que seu próprio script de execução de trabalho consome, além dos argumentos que o AWS Glue consome.

  Os argumentos do trabalho podem ser registrados em log. Não transmita segredos em texto simples como argumentos. Recupere os segredos de uma conexão do AWS Glue, AWS Secrets Manager ou outro mecanismo de gerenciamento de segredo se pretender mantê-los dentro do trabalho.

  Para obter informações sobre como especificar e consumir seus próprios argumentos de trabalho, consulte o tópico Chamar APIs do AWS Glue em Python no guia do desenvolvedor.

  Para obter informações sobre os argumentos que podem ser fornecidos a esse campo ao configurar trabalhos do Spark, consulte o tópico Parâmetros especiais usados pelo AWS Glue no guia do desenvolvedor.

  Para obter informações sobre os argumentos que você pode fornecer a esse campo ao configurar trabalhos do Ray, consulte o tópico Using job parameters in Ray jobs no guia do desenvolvedor.

- `NonOverridableArguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Argumentos para esse trabalho que não são substituídos ao fornecer argumentos de trabalho na execução de um trabalho, especificados como pares de nome-valor.

- `Connections` – Um objeto ConnectionsList.

  As conexões usadas no trabalho.

- `MaxRetries` – Número (íntegro).

  O número máximo de novas tentativas desse trabalho após a falha de um JobRun.

- `AllocatedCapacity` – Número (íntegro).

  Este campo está obsoleto. Use `MaxCapacity` em vez disso.

  O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas em execuções desse trabalho. É possível alocar um mínimo de 2 DPUs; o padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite do trabalho em minutos. Este é o tempo máximo durante o qual uma execução de trabalho pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`.

  Os trabalhos devem ter valores de tempo limite inferiores a 7 dias ou 10.080 minutos. Caso contrário, os trabalhos gerarão uma exceção.

  Quando o valor é deixado em branco, o tempo limite padrão é de 2.880 minutos.

  Quaisquer trabalhos do AWS Glue existentes que tinham um valor de tempo limite maior que 7 dias serão padronizados para 7 dias. Por exemplo, se você especificou um tempo limite de 20 dias para um trabalho em lote, ele será interrompido no 7º dia.

  Para trabalhos de streaming, se você tiver configurado uma janela de manutenção, ela será reiniciada durante a janela de manutenção após 7 dias.

- `MaxCapacity` – Número (duplo).

  Para trabalhos do Glue versão 1.0 ou anterior, usando o tipo de operador padrão, é o número de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando esse trabalho for executado. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  Para trabalhos do Glue versão 2.0 ou posterior, você não pode um `Maximum capacity`. Em vez disso, você deve especificar um `Worker type` e o `Number of workers`.

Não defina `MaxCapacity` se estiver usando `WorkerType` e `NumberOfWorkers`.

O valor que pode ser alocado para `MaxCapacity` depende se você está executando um trabalho de shell do Python, um trabalho de ETL do Apache Spark ou um trabalho de ETL de streaming do Apache Spark:

- Ao especificar um trabalho de shell do Python (`JobCommand.Name`="pythonshell"), será possível alocar 0,0625 ou 1 DPU. O padrão é 0,0625 DPU.
- Ao especificar um trabalho de ETL do Apache Spark (`JobCommand.Name`="glueetl") ou um trabalho de ETL de streaming do Apache Spark (`JobCommand.Name`="gluestreaming"), é possível alocar de 2 a 100 DPUs. O padrão é de 10 DPUs. Esse tipo de trabalho não pode ter uma alocação de DPU fracionada.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando um trabalho é executado. Aceita um valor de G.1X, G.2X, G.4X, G.8X ou G.025X para trabalhos do Spark. Aceita o valor Z.2X para trabalhos do Ray.

  - Para o tipo de operador `G.1X`, cada operador é mapeado em 1 DPU (4 vCPU, 16 GB de memória) com 94 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.2X`, cada operador é mapeado em 2 DPU (8 vCPU, 32 GB de memória) com 138 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.4X`, cada operador é mapeado em 4 DPU (16 vCPU, 64 GB de memória) com 256 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Estes tipos de operadores estão disponíveis apenas para trabalhos Spark ETL do AWS Glue versão 3.0 ou posteriores nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (N. da Califórnia), Oeste dos EUA (Oregon), Ásia-Pacífico (Mumbai), Ásia-Pacífico (Seul), Ásia-Pacífico (Singapura), Ásia-Pacífico (Sydney), Ásia-Pacífico (Tóquio), Canadá (Central), Europa (Frankfurt), Europa (Irlanda), Europa (Londres), Europa (Espanha), Europa (Estocolmo) e América do Sul (São Paulo).

  - Para o tipo de operador `G.8X`, cada operador é mapeado em 8 DPU (32 vCPU, 128 GB de memória) com 512 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior, nas mesmas regiões da AWS compatíveis com o tipo de operador `G.4X`.
  - Para o tipo de operador `G.025X`, cada operador é mapeado para 0,25 DPU (2 vCPU, 4 GB de memória) com 84 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos de streaming de baixo volume. Esse tipo de operador só está disponível para trabalhos de streaming do AWS Glue versão 3.0 ou posterior.
  - Para o tipo de operador `Z.2X`, cada operador é mapeado em 2 M-DPU (8 vCPUs, 64 GB de memória) com 128 GB de disco e fornece até 8 operadores do Ray baseados no autoscaler.
- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando um trabalho é executado.
- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com esse trabalho.
- `NotificationProperty` – Um objeto NotificationProperty.

  Especifica propriedades de configuração de uma notificação de trabalho.
- `Running` – Booleano.

  Este campo está reservado para uso futuro.
- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Nas tarefas do Spark, `GlueVersion` determina as versões do Apache Spark e do Python que o AWS Glue disponibiliza em um trabalho. A versão do Python indica a versão compatível com trabalhos do tipo Spark.

  Os trabalhos de Ray devem definir `GlueVersion` como `4.0` ou mais. Porém, as versões do Ray, do Python e das bibliotecas adicionais disponíveis no seu trabalho do Ray são determinadas pelo parâmetro `Runtime` do comando Job.

Para obter mais informações sobre as versões disponíveis do AWS Glue e as versões correspondentes do Spark e do Python, consulte Versão do Glue no guia do desenvolvedor.

Os trabalhos criados sem especificar uma versão do Glue usam como padrão o Glue 0.9.

- `CodeGenConfigurationNodes` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #58.

  Cada valor é um objeto CodeGenConfigurationNode A.

  A representação de um gráfico acíclico direcionado no qual tanto o componente visual do Glue Studio quanto a geração de código do Glue Studio são baseados.

- `ExecutionClass`: string UTF-8, inferior a 16 bytes de comprimento (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica se o trabalho é executado com uma classe de execução padrão ou flexível. A classe de execução padrão é ideal para workloads sensíveis ao tempo que exigem a inicialização rápida de trabalhos e recursos dedicados.

  A classe de execução flexível é adequada para trabalhos insensíveis ao tempo, cujos horários de início e conclusão podem variar.

  Somente trabalhos com o AWS Glue versão 3.0 e posterior e o tipo de comando `glueetl` terão permissão para definir `ExecutionClass` como `FLEX`. A classe de execução flexível está disponível para trabalhos do Spark.

- `SourceControlDetails` – Um objeto SourceControlDetails.

  Os detalhes de uma configuração de controle de origem para um trabalho, permitindo a sincronização de artefatos de trabalho de ou para um repositório remoto.

- `MaintenanceWindow` – String UTF-8 correspondente a Custom string pattern #34.

  Esse campo especifica um dia da semana e uma hora para uma janela de manutenção para trabalhos de streaming. O AWS Glue realiza periodicamente atividades de manutenção. Durante essas janelas de manutenção, o AWS Glue precisará reiniciar seus trabalhos de streaming.

  O AWS Glue reiniciará o trabalho dentro de 3 horas da janela de manutenção especificada. Por exemplo, se você configurar a janela de manutenção para segunda-feira às 10h (GMT), seus trabalhos serão reiniciados entre 10h (GMT) e 13h (GMT).

- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado ao trabalho.

Estrutura ExecutionProperty

Uma propriedade de execução de um trabalho.

Campos

- `MaxConcurrentRuns` – Número (íntegro).

  O número máximo de execuções simultâneas permitidas para o trabalho. O padrão é um. Um erro será retornado quando este limite for atingido. O valor máximo que pode ser especificado é controlado por um limite de serviço.

Estrutura NotificationProperty

Especifica propriedades de configuração de uma notificação.

Campos

- `NotifyDelayAfter` – Número (inteiro), pelo menos 1.

  Depois que a execução de um trabalho for iniciada, o número de minutos a esperar antes de enviar uma notificação de atraso de execução de trabalho.

Estrutura JobCommand

Especifica o código executado quando um trabalho é executado.

Campos

- `Name` – String UTF-8.

  O nome do comando de trabalho. Para um trabalho de ETL do Apache Spark, ele deve ser `glueetl`. Para um trabalho de shell do Python, ele deve ser `pythonshell`. Para um trabalho de ETL de streaming do Apache Spark, ele deve ser `gluestreaming`. Para um trabalho do Ray, isso deve ser `glueray`.

- `ScriptLocation`: string UTF-8, não superior a 400.000 bytes de comprimento.

  Especifica o caminho do Amazon Simple Storage Service (Amazon S3) para um script que executa um trabalho.

- `PythonVersion` – String UTF-8 correspondente a Custom string pattern #48.

  A versão de Python que está em uso para executar um trabalho de shell em Python. Os valores permitidos são 2 ou 3.

- `Runtime`: string UTF-8, com no máximo 64 bytes de comprimento, correspondendo a Custom string pattern #33.

  Em trabalhos do Ray, Runtime é usado para especificar as versões do Ray, do Python e das bibliotecas adicionais disponíveis no ambiente. Esse campo não é usado em outros tipos de trabalho. Para obter os valores do ambiente de runtime compatíveis, consulte Ambientes de runtime do Ray compatíveis no Guia do desenvolvedor do AWS Glue.

Estrutura ConnectionsList

Especifica as conexões usadas por um trabalho.

Campos

- `Connections`: uma matriz de strings UTF-8, no máximo mil strings.

  Uma lista das conexões usadas pelo trabalho.

Estrutura JobUpdate

Especifica as informações usadas para atualizar uma definição de trabalho existente. A definição de trabalho anterior é totalmente substituída por essa informação.

Campos

- `JobMode` – String UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

  Um modo que descreve como um trabalho foi criado. Os valores válidos são:

  - `SCRIPT`: o trabalho foi criado usando o editor de scripts do AWS Glue Studio.
  - `VISUAL`: o trabalho foi criado usando o editor visual do AWS Glue Studio.
  - `NOTEBOOK`: o trabalho foi criado usando um caderno de sessões interativas.

Quando o campo `JobMode` está ausente ou é nulo, `SCRIPT` é atribuído como o valor padrão.

- `JobRunQueuingEnabled` – Booleano.

  Especifica se o enfileiramento da execução de trabalhos está habilitado para as execuções desse trabalho.

  Um valor "verdadeiro" significa que o enfileiramento da execução de trabalhos está habilitado para a execução do trabalho. Se o valor for "falso" ou não estiver preenchido, as execuções do trabalho não serão consideradas para enfileiramento.

  Se esse campo não corresponder ao valor definido na execução do trabalho, o valor do campo de execução do trabalho será usado.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Descrição do trabalho que está sendo definido.

- `LogUri` – String UTF-8.

  Este campo está reservado para uso futuro.

- `Role` – String UTF-8.

  O nome ou o nome de recurso da Amazon (ARN) da função do IAM associada a esse trabalho (obrigatório).

- `ExecutionProperty` – Um objeto ExecutionProperty.

  Um `ExecutionProperty` que especifica o número máximo de execuções simultâneas permitidas para o trabalho.

- `Command` – Um objeto JobCommand.

  O `JobCommand` que executa esse trabalho (obrigatório).

- `DefaultArguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Os argumentos padrão para toda execução desse trabalho, especificados como pares de nome-valor.

Aqui, é possível especificar os argumentos que seu próprio script de execução de trabalho consome, além dos argumentos que o AWS Glue consome.

Os argumentos do trabalho podem ser registrados em log. Não transmita segredos em texto simples como argumentos. Recupere os segredos de uma conexão do AWS Glue, AWS Secrets Manager ou outro mecanismo de gerenciamento de segredo se pretender mantê-los dentro do trabalho.

Para obter informações sobre como especificar e consumir seus próprios argumentos de trabalho, consulte o tópico Chamar APIs do AWS Glue em Python no guia do desenvolvedor.

Para obter informações sobre os argumentos que podem ser fornecidos a esse campo ao configurar trabalhos do Spark, consulte o tópico Parâmetros especiais usados pelo AWS Glue no guia do desenvolvedor.

Para obter informações sobre os argumentos que você pode fornecer a esse campo ao configurar trabalhos do Ray, consulte o tópico Using job parameters in Ray jobs no guia do desenvolvedor.

- `NonOverridableArguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Argumentos para esse trabalho que não são substituídos ao fornecer argumentos de trabalho na execução de um trabalho, especificados como pares de nome-valor.

- `Connections` – Um objeto ConnectionsList.

  As conexões usadas no trabalho.

- `MaxRetries` – Número (íntegro).

  O número máximo de novas tentativas desse trabalho em caso de falha.

- `AllocatedCapacity` – Número (íntegro).

  Este campo está obsoleto. Use `MaxCapacity` em vez disso.

  O número de unidades de processamento de dados (DPUs) do AWS Glue a serem alocadas para esse trabalho. É possível alocar um mínimo de 2 DPUs; o padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs

e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite do trabalho em minutos. Este é o tempo máximo durante o qual uma execução de trabalho pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`.

  Os trabalhos devem ter valores de tempo limite inferiores a 7 dias ou 10.080 minutos. Caso contrário, os trabalhos gerarão uma exceção.

  Quando o valor é deixado em branco, o tempo limite padrão é de 2.880 minutos.

  Quaisquer trabalhos do AWS Glue existentes que tinham um valor de tempo limite maior que 7 dias serão padronizados para 7 dias. Por exemplo, se você especificou um tempo limite de 20 dias para um trabalho em lote, ele será interrompido no 7º dia.

  Para trabalhos de streaming, se você tiver configurado uma janela de manutenção, ela será reiniciada durante a janela de manutenção após 7 dias.

- `MaxCapacity` – Número (duplo).

  Para trabalhos do Glue versão 1.0 ou anterior, usando o tipo de operador padrão, é o número de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando esse trabalho for executado. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  Para trabalhos do Glue versão 2.0+, você não pode especificar uma `Maximum capacity`. Em vez disso, você deve especificar um `Worker type` e o `Number of workers`.

  Não defina `MaxCapacity` se estiver usando `WorkerType` e `NumberOfWorkers`.

  O valor que pode ser alocado para `MaxCapacity` depende se você está executando um trabalho de shell do Python, um trabalho de ETL do Apache Spark ou um trabalho de ETL de streaming do Apache Spark:

  - Ao especificar um trabalho de shell do Python (`JobCommand.Name`="pythonshell"), será possível alocar 0,0625 ou 1 DPU. O padrão é 0,0625 DPU.
  - Ao especificar um trabalho de ETL do Apache Spark (`JobCommand.Name`="glueetl") ou um trabalho de ETL de streaming do Apache Spark (`JobCommand.Name`="gluestreaming"), é

possível alocar de 2 a 100 DPUs. O padrão é de 10 DPUs. Esse tipo de trabalho não pode ter uma alocação de DPU fracionada.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando um trabalho é executado. Aceita um valor de G.1X, G.2X, G.4X, G.8X ou G.025X para trabalhos do Spark. Aceita o valor Z.2X para trabalhos do Ray. Para obter mais informações, consulte Definir propriedades de trabalho para trabalhos do Spark.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando um trabalho é executado.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com esse trabalho.

- `NotificationProperty` – Um objeto NotificationProperty.

  Especifica as propriedades de configuração de uma notificação de trabalho.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Nas tarefas do Spark, `GlueVersion` determina as versões do Apache Spark e do Python que o AWS Glue disponibiliza em um trabalho. A versão do Python indica a versão compatível com trabalhos do tipo Spark.

  Os trabalhos de Ray devem definir `GlueVersion` como `4.0` ou mais. Porém, as versões do Ray, do Python e das bibliotecas adicionais disponíveis no seu trabalho do Ray são determinadas pelo parâmetro `Runtime` do comando Job.

  Para obter mais informações sobre as versões disponíveis do AWS Glue e as versões correspondentes do Spark e do Python, consulte Versão do Glue no guia do desenvolvedor.

  Os trabalhos criados sem especificar uma versão do Glue usam como padrão o Glue 0.9.

- `CodeGenConfigurationNodes` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #58.

Cada valor é um objeto CodeGenConfigurationNode A.

A representação de um gráfico acíclico direcionado no qual tanto o componente visual do Glue Studio quanto a geração de código do Glue Studio são baseados.

- `ExecutionClass`: string UTF-8, inferior a 16 bytes de comprimento (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica se o trabalho é executado com uma classe de execução padrão ou flexível. A classe de execução padrão é ideal para workloads sensíveis ao tempo que exigem a inicialização rápida de trabalhos e recursos dedicados.

  A classe de execução flexível é adequada para trabalhos insensíveis ao tempo, cujos horários de início e conclusão podem variar.

  Somente trabalhos com o AWS Glue versão 3.0 e posterior e o tipo de comando `glueetl` terão permissão para definir `ExecutionClass` como `FLEX`. A classe de execução flexível está disponível para trabalhos do Spark.

- `SourceControlDetails` – Um objeto SourceControlDetails.

  Os detalhes de uma configuração de controle de origem para um trabalho, permitindo a sincronização de artefatos de trabalho de ou para um repositório remoto.

- `MaintenanceWindow` – String UTF-8 correspondente a Custom string pattern #34.

  Esse campo especifica um dia da semana e uma hora para uma janela de manutenção para trabalhos de streaming. O AWS Glue realiza periodicamente atividades de manutenção. Durante essas janelas de manutenção, o AWS Glue precisará reiniciar seus trabalhos de streaming.

  O AWS Glue reiniciará o trabalho dentro de 3 horas da janela de manutenção especificada. Por exemplo, se você configurar a janela de manutenção para segunda-feira às 10h (GMT), seus trabalhos serão reiniciados entre 10h (GMT) e 13h (GMT).

- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado ao trabalho.

Estrutura SourceControlDetails

Os detalhes de uma configuração de controle de origem para um trabalho, permitindo a sincronização de artefatos de trabalho de ou para um repositório remoto.

Campos

- `Provider`: string UTF-8 (valores válidos: `GITHUB` | `AWS_CODE_COMMIT`).

  O provedor do repositório remoto.
- `Repository`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  O nome do repositório remoto que contém os artefatos do trabalho.
- `Owner`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  O proprietário do repositório remoto que contém os artefatos do trabalho.
- `Branch`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  Uma ramificação opcional no repositório remoto.
- `Folder`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  Uma pasta opcional no repositório remoto.
- `LastCommitId`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  O último ID de confirmação no repositório remoto.
- `LastSyncTimestamp`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  A data e a hora em que a última sincronização de trabalho foi realizada.
- `AuthStrategy`: string UTF-8 (valores válidos: `PERSONAL_ACCESS_TOKEN` | `AWS_SECRETS_MANAGER`).

  O tipo de autenticação, que pode ser um token de autenticação armazenado no AWS Secrets Manager ou um token de acesso pessoal.
- `AuthToken`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  O valor de um token de autorização.

Operações

- Ação CreateJob (Python: create_job)
- Ação UpdateJob (Python: update_job)
- Ação GetJob (Python: get_job)
- Ação GetJobs (Python: get_jobs)
- Ação DeleteJob (Python: delete_job)
- Ação ListJobs (Python: list_jobs)
- Ação BatchGetJobs (Python: batch_get_jobs)

Ação CreateJob (Python: create_job)

Cria uma nova definição de trabalho.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome que você atribui a esta definição de trabalho. Ele deve ser exclusivo na sua conta da .
- `JobMode` – String UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

  Um modo que descreve como um trabalho foi criado. Os valores válidos são:

  - `SCRIPT`: o trabalho foi criado usando o editor de scripts do AWS Glue Studio.
  - `VISUAL`: o trabalho foi criado usando o editor visual do AWS Glue Studio.
  - `NOTEBOOK`: o trabalho foi criado usando um caderno de sessões interativas.

  Quando o campo `JobMode` está ausente ou é nulo, `SCRIPT` é atribuído como o valor padrão.
- `JobRunQueuingEnabled` – Booleano.

  Especifica se o enfileiramento da execução de trabalhos está habilitado para as execuções desse trabalho.

  Um valor "verdadeiro" significa que o enfileiramento da execução de trabalhos está habilitado para a execução do trabalho. Se o valor for "falso" ou não estiver preenchido, as execuções do trabalho não serão consideradas para enfileiramento.

Se esse campo não corresponder ao valor definido na execução do trabalho, o valor do campo de execução do trabalho será usado.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Descrição do trabalho que está sendo definido.

- `LogUri` – String UTF-8.

  Este campo está reservado para uso futuro.

- `Role` – Obrigatório: string UTF-8.

  O nome ou o nome de recurso da Amazon (ARN) da função do IAM associada a esta trabalho.

- `ExecutionProperty` – Um objeto ExecutionProperty.

  Um `ExecutionProperty` que especifica o número máximo de execuções simultâneas permitidas para o trabalho.

- `Command` – Obrigatório: um objeto JobCommand.

  O `JobCommand` que executa esse trabalho.

- `DefaultArguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Os argumentos padrão para toda execução desse trabalho, especificados como pares de nome-valor.

  Aqui, é possível especificar os argumentos que seu próprio script de execução de trabalho consome, além dos argumentos que o AWS Glue consome.

  Os argumentos do trabalho podem ser registrados em log. Não transmita segredos em texto simples como argumentos. Recupere os segredos de uma conexão do AWS Glue, AWS Secrets Manager ou outro mecanismo de gerenciamento de segredo se pretender mantê-los dentro do trabalho.

  Para obter informações sobre como especificar e consumir seus próprios argumentos de trabalho, consulte o tópico Chamar APIs do AWS Glue em Python no guia do desenvolvedor.

Para obter informações sobre os argumentos que podem ser fornecidos a esse campo ao configurar trabalhos do Spark, consulte o tópico Parâmetros especiais usados pelo AWS Glue no guia do desenvolvedor.

Para obter informações sobre os argumentos que você pode fornecer a esse campo ao configurar trabalhos do Ray, consulte o tópico Using job parameters in Ray jobs no guia do desenvolvedor.

- `NonOverridableArguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Argumentos para esse trabalho que não são substituídos ao fornecer argumentos de trabalho na execução de um trabalho, especificados como pares de nome-valor.

- `Connections` – Um objeto ConnectionsList.

  As conexões usadas no trabalho.

- `MaxRetries` – Número (íntegro).

  O número máximo de novas tentativas desse trabalho em caso de falha.

- `AllocatedCapacity` – Número (íntegro).

  Esse parâmetro está suspenso. Use `MaxCapacity` em vez disso.

  O número de unidades de processamento de dados (DPUs) do AWS Glue a serem alocadas para esse trabalho. É possível alocar um mínimo de 2 DPUs; o padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite do trabalho em minutos. Este é o tempo máximo durante o qual uma execução de trabalho pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`.

  Os trabalhos devem ter valores de tempo limite inferiores a 7 dias ou 10.080 minutos. Caso contrário, os trabalhos gerarão uma exceção.

  Quando o valor é deixado em branco, o tempo limite padrão é de 2.880 minutos.

Quaisquer trabalhos do AWS Glue existentes que tinham um valor de tempo limite maior que 7 dias serão padronizados para 7 dias. Por exemplo, se você especificou um tempo limite de 20 dias para um trabalho em lote, ele será interrompido no 7º dia.

Para trabalhos de streaming, se você tiver configurado uma janela de manutenção, ela será reiniciada durante a janela de manutenção após 7 dias.

- `MaxCapacity` – Número (duplo).

  Para trabalhos do Glue versão 1.0 ou anterior, usando o tipo de operador padrão, é o número de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando esse trabalho for executado. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  Para trabalhos do Glue versão 2.0+, você não pode especificar uma `Maximum capacity`. Em vez disso, você deve especificar um `Worker type` e o `Number of workers`.

  Não defina `MaxCapacity` se estiver usando `WorkerType` e `NumberOfWorkers`.

  O valor que pode ser alocado para `MaxCapacity` depende se você está executando um trabalho de shell do Python, um trabalho de ETL do Apache Spark ou um trabalho de ETL de streaming do Apache Spark:

  - Ao especificar um trabalho de shell do Python (`JobCommand.Name`="pythonshell"), será possível alocar 0,0625 ou 1 DPU. O padrão é 0,0625 DPU.
  - Ao especificar um trabalho de ETL do Apache Spark (`JobCommand.Name`="glueetl") ou um trabalho de ETL de streaming do Apache Spark (`JobCommand.Name`="gluestreaming"), é possível alocar de 2 a 100 DPUs. O padrão é de 10 DPUs. Esse tipo de trabalho não pode ter uma alocação de DPU fracionada.
- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com esse trabalho.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

As tags a serem usadas com essa tarefa. Você pode usar tags para limitar o acesso à tarefa. Para obter mais informações sobre tags no AWS Glue, consulte Tags da AWS no AWS Glue no guia do desenvolvedor.

- `NotificationProperty` – Um objeto NotificationProperty.

  Especifica propriedades de configuração de uma notificação de trabalho.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Nas tarefas do Spark, `GlueVersion` determina as versões do Apache Spark e do Python que o AWS Glue disponibiliza em um trabalho. A versão do Python indica a versão compatível com trabalhos do tipo Spark.

  Os trabalhos de Ray devem definir `GlueVersion` como `4.0` ou mais. Porém, as versões do Ray, do Python e das bibliotecas adicionais disponíveis no seu trabalho do Ray são determinadas pelo parâmetro `Runtime` do comando Job.

  Para obter mais informações sobre as versões disponíveis do AWS Glue e as versões correspondentes do Spark e do Python, consulte Versão do Glue no guia do desenvolvedor.

  Os trabalhos criados sem especificar uma versão do Glue usam como padrão o Glue 0.9.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando um trabalho é executado.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando um trabalho é executado. Aceita um valor de G.1X, G.2X, G.4X, G.8X ou G.025X para trabalhos do Spark. Aceita o valor Z.2X para trabalhos do Ray.

  - Para o tipo de operador `G.1X`, cada operador é mapeado em 1 DPU (4 vCPU, 16 GB de memória) com 94 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.2X`, cada operador é mapeado em 2 DPU (8 vCPU, 32 GB de memória) com 138 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo

de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.

- Para o tipo de operador `G.4X`, cada operador é mapeado em 4 DPU (16 vCPU, 64 GB de memória) com 256 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Estes tipos de operadores estão disponíveis apenas para trabalhos Spark ETL do AWS Glue versão 3.0 ou posteriores nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (N. da Califórnia), Oeste dos EUA (Oregon), Ásia-Pacífico (Mumbai), Ásia-Pacífico (Seul), Ásia-Pacífico (Singapura), Ásia-Pacífico (Sydney), Ásia-Pacífico (Tóquio), Canadá (Central), Europa (Frankfurt), Europa (Irlanda), Europa (Londres), Europa (Espanha), Europa (Estocolmo) e América do Sul (São Paulo).
- Para o tipo de operador `G.8X`, cada operador é mapeado em 8 DPU (32 vCPU, 128 GB de memória) com 512 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior, nas mesmas regiões da AWS compatíveis com o tipo de operador `G.4X`.
- Para o tipo de operador `G.025X`, cada operador é mapeado para 0,25 DPU (2 vCPU, 4 GB de memória) com 84 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos de streaming de baixo volume. Esse tipo de operador só está disponível para trabalhos de streaming do AWS Glue versão 3.0 ou posterior.
- Para o tipo de operador `Z.2X`, cada operador é mapeado em 2 M-DPU (8 vCPUs, 64 GB de memória) com 128 GB de disco e fornece até 8 operadores do Ray baseados no autoscaler.

- `CodeGenConfigurationNodes` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 que corresponde a Custom string pattern #58.

  Cada valor é um objeto CodeGenConfigurationNode A.

  A representação de um gráfico acíclico direcionado no qual tanto o componente visual do Glue Studio quanto a geração de código do Glue Studio são baseados.

- `ExecutionClass`: string UTF-8, inferior a 16 bytes de comprimento (valores válidos: `FLEX=""` | `STANDARD=""`).

Indica se o trabalho é executado com uma classe de execução padrão ou flexível. A classe de execução padrão é ideal para workloads sensíveis ao tempo que exigem a inicialização rápida de trabalhos e recursos dedicados.

A classe de execução flexível é adequada para trabalhos insensíveis ao tempo, cujos horários de início e conclusão podem variar.

Somente trabalhos com o AWS Glue versão 3.0 e posterior e o tipo de comando `glueetl` terão permissão para definir `ExecutionClass` como `FLEX`. A classe de execução flexível está disponível para trabalhos do Spark.

- `SourceControlDetails` – Um objeto SourceControlDetails.

  Os detalhes de uma configuração de controle de origem para um trabalho, permitindo a sincronização de artefatos de trabalho de ou para um repositório remoto.

- `MaintenanceWindow` – String UTF-8 correspondente a Custom string pattern #34.

  Esse campo especifica um dia da semana e uma hora para uma janela de manutenção para trabalhos de streaming. O AWS Glue realiza periodicamente atividades de manutenção. Durante essas janelas de manutenção, o AWS Glue precisará reiniciar seus trabalhos de streaming.

  O AWS Glue reiniciará o trabalho dentro de 3 horas da janela de manutenção especificada. Por exemplo, se você configurar a janela de manutenção para segunda-feira às 10h (GMT), seus trabalhos serão reiniciados entre 10h (GMT) e 13h (GMT).

- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado ao trabalho.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome exclusivo que foi fornecido para esta definição de trabalho.

Erros

- `InvalidInputException`
- `IdempotentParameterMismatchException`
- `AlreadyExistsException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

Ação UpdateJob (Python: update_job)

Atualiza uma definição de trabalho existente. A definição de trabalho anterior é totalmente substituída por essa informação.

Solicitação

- `JobName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome da definição de trabalho a ser atualizada.
- `JobUpdate` – Obrigatório: um objeto JobUpdate.

  Especifica os valores com os quais a definição de trabalho será atualizada. A configuração não especificada é removida ou redefinida para os valores padrão.
- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado ao trabalho.

Resposta

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Retorna o nome da definição de trabalho atualizada.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Ação GetJob (Python: get_job)

Recupera uma definição de trabalho existente.

Solicitação

- `JobName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da definição de trabalho a ser recuperada.

Resposta

- `Job` – Um objeto Trabalho.

  A definição de trabalho solicitada.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetJobs (Python: get_jobs)

Recupera todas as definições de trabalho atuais.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo da resposta.

Resposta

- `Jobs`: um array de objetos Trabalho.

  Uma lista de definições de trabalho.
- `NextToken` – String UTF-8.

  Um token de continuação, caso algumas definições de trabalho ainda não tenham sido retornadas.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação DeleteJob (Python: delete_job)

Exclui uma definição de trabalho especificada. Se a definição de trabalho não for encontrada, nenhuma exceção será gerada.

Solicitação

- `JobName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da definição de trabalho a ser excluída.

Resposta

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da definição de trabalho que foi excluída.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação ListJobs (Python: list_jobs)

Recupera os nomes de todos os recursos do trabalho nessa conta da AWS ou os recursos com a tag especificada. Essa operação permite que você veja quais recursos estão disponíveis em sua conta e seus nomes.

Essa operação aceita o campo `Tags` opcional, que pode ser usado como um filtro na resposta, para que recursos com tags possam ser recuperados como um grupo. Se você optar por usar a filtragem por tags, apenas os recursos com a tag serão recuperados.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo de uma lista a ser retornada.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Especifica apenas o retorno desses recursos com tags.

Resposta

- `JobNames` – Uma matriz de strings UTF-8.

  Os nomes de todos os trabalhos na conta ou os trabalhos com as tags especificadas.
- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não contiver a métrica mais recente disponível.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação BatchGetJobs (Python: batch_get_jobs)

Retorna uma lista de metadados do recurso para uma lista de nomes de trabalho. Depois de chamar a operação `ListJobs`, você pode chamar essa operação para acessar os dados aos quais você recebeu permissões. Essa operação oferece suporte a todas as permissões do IAM, incluindo condições de permissão que usam tags.

Solicitação

- `JobNames`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de nomes de trabalho, que podem ser os nomes retornados da operação `ListJobs`.

Resposta

- `Jobs`: um array de objetos Trabalho.

  Uma lista de definições de trabalho.
- `JobsNotFound` – Uma matriz de strings UTF-8.

  Uma lista de nomes de trabalho não encontrados.

Erros

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Execuções de trabalhos

A API de execuções de trabalhos descreve os tipos de dados e a API relacionada para iniciar, interromper ou visualizar execuções de trabalhos e redefinir marcações de trabalhos no AWS Glue. O histórico de execução de trabalhos pode ser acessado por 90 dias para seu fluxo de trabalho e execução de trabalhos.

Tipos de dados

- Estrutura JobRun
- Estrutura Predecessor
- Estrutura JobBookmarkEntry
- Estrutura BatchStopJobRunSuccessfulSubmission
- Estrutura BatchStopJobRunError
- Estrutura NotificationProperty

Estrutura JobRun

Contém informações sobre uma execução de trabalho.

Campos

- `Id` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID dessa execução de trabalho.
- `Attempt` – Número (íntegro).

  O número de tentativas para execução deste trabalho.
- `PreviousRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O ID da execução anterior deste trabalho. Por exemplo, o `JobRunId` especificado na ação `StartJobRun`.

- `TriggerName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do gatilho que iniciou esta execução de trabalho.

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da definição de trabalho que está sendo usada nesta execução.

- `JobMode` – String UTF-8 (valores válidos: `SCRIPT=""` | `VISUAL=""` | `NOTEBOOK=""`).

  Um modo que descreve como um trabalho foi criado. Os valores válidos são:

  - `SCRIPT`: o trabalho foi criado usando o editor de scripts do AWS Glue Studio.
  - `VISUAL`: o trabalho foi criado usando o editor visual do AWS Glue Studio.
  - `NOTEBOOK`: o trabalho foi criado usando um caderno de sessões interativas.

  Quando o campo `JobMode` está ausente ou é nulo, `SCRIPT` é atribuído como o valor padrão.

- `JobRunQueuingEnabled` – Booleano.

  Especifica se o enfileiramento da execução de trabalhos está habilitado para a execução do trabalho.

  Um valor "verdadeiro" significa que o enfileiramento da execução de trabalhos está habilitado para as execuções do trabalho. Se o valor for "falso" ou não estiver preenchido, a execução do trabalho não será considerada para enfileiramento.

- `StartedOn` – Timestamp.

  A data e a hora em que a execução deste trabalho foi iniciada.

- `LastModifiedOn` – Timestamp.

  A hora em que a execução desse trabalho foi modificada.

- `CompletedOn` – Timestamp.

  A data e a hora em que a execução desse trabalho foi concluída.

- `JobRunState`: string UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

  O estado atual da execução do trabalho. Para obter mais informações sobre os status de trabalhos que foram terminados de forma anormal, consulte Status de execução de trabalhos do AWS Glue.

- `Arguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Os argumentos de trabalho associados a esta execução. Para essa execução de tarefa, eles substituem os argumentos padrão definidos na própria definição de tarefa.

  Aqui, é possível especificar os argumentos que seu próprio script de execução de trabalho consome, além dos argumentos que o AWS Glue consome.

  Os argumentos do trabalho podem ser registrados em log. Não transmita segredos em texto simples como argumentos. Recupere os segredos de uma conexão do AWS Glue, AWS Secrets Manager ou outro mecanismo de gerenciamento de segredo se pretender mantê-los dentro do trabalho.

  Para obter informações sobre como especificar e consumir seus próprios argumentos de trabalho, consulte o tópico Chamar APIs do AWS Glue em Python no guia do desenvolvedor.

  Para obter informações sobre os argumentos que podem ser fornecidos a esse campo ao configurar trabalhos do Spark, consulte o tópico Parâmetros especiais usados pelo AWS Glue no guia do desenvolvedor.

  Para obter informações sobre os argumentos que podem ser fornecidos a esse campo ao configurar trabalhos do Ray, consulte o tópico Uso de parâmetros de trabalho em trabalhos do Ray no guia do desenvolvedor.

- `ErrorMessage` – String UTF-8.

  Uma mensagem de erro associada à execução deste trabalho.

- `PredecessorRuns`: um array de objetos Predecessor.

  Uma lista de predecessores para a execução deste trabalho.

- `AllocatedCapacity` – Número (íntegro).

Este campo está obsoleto. Use `MaxCapacity` em vez disso.

O número de unidades de processamento de dados (DPUs) do AWS Glue atribuídas a esse JobRun. É possível atribuir de 2 a 100 DPUs, e o padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

- `ExecutionTime` – Número (íntegro).

  A quantidade de tempo (em segundos) em que o trabalho executado consumiu recursos.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite de `JobRun` em minutos. Este é o tempo máximo durante o qual uma execução de trabalho pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. Esse valor substitui o valor de tempo limite definido no trabalho principal.

  Os trabalhos devem ter valores de tempo limite inferiores a 7 dias ou 10.080 minutos. Caso contrário, os trabalhos gerarão uma exceção.

  Quando o valor é deixado em branco, o tempo limite padrão é de 2.880 minutos.

  Quaisquer trabalhos do AWS Glue existentes que tinham um valor de tempo limite maior que 7 dias serão padronizados para 7 dias. Por exemplo, se você especificou um tempo limite de 20 dias para um trabalho em lote, ele será interrompido no 7º dia.

  Para trabalhos de streaming, se você tiver configurado uma janela de manutenção, ela será reiniciada durante a janela de manutenção após 7 dias.

- `MaxCapacity` – Número (duplo).

  Para trabalhos do Glue versão 1.0 ou anterior, usando o tipo de operador padrão, é o número de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando esse trabalho for executado. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  Para trabalhos do Glue versão 2.0+, você não pode especificar uma `Maximum capacity`. Em vez disso, você deve especificar um `Worker type` e o `Number of workers`.

  Não defina `MaxCapacity` se estiver usando `WorkerType` e `NumberOfWorkers`.

O valor que pode ser alocado para `MaxCapacity` depende se você está executando um trabalho de shell do Python, um trabalho de ETL do Apache Spark ou um trabalho de ETL de streaming do Apache Spark:

- Ao especificar um trabalho de shell do Python (`JobCommand.Name`="pythonshell"), será possível alocar 0,0625 ou 1 DPU. O padrão é 0,0625 DPU.
- Ao especificar um trabalho de ETL do Apache Spark (`JobCommand.Name`="glueetl") ou um trabalho de ETL de streaming do Apache Spark (`JobCommand.Name`="gluestreaming"), é possível alocar de 2 a 100 DPUs. O padrão é de 10 DPUs. Esse tipo de trabalho não pode ter uma alocação de DPU fracionada.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando um trabalho é executado. Aceita um valor de G.1X, G.2X, G.4X, G.8X ou G.025X para trabalhos do Spark. Aceita o valor Z.2X para trabalhos do Ray.

  - Para o tipo de operador `G.1X`, cada operador é mapeado em 1 DPU (4 vCPU, 16 GB de memória) com 94 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.2X`, cada operador é mapeado em 2 DPU (8 vCPU, 32 GB de memória) com 138 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.4X`, cada operador é mapeado em 4 DPU (16 vCPU, 64 GB de memória) com 256 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Singapura), Ásia-Pacífico (Sydney), Ásia-Pacífico (Tóquio), Canadá (Central), Europa (Frankfurt), Europa (Irlanda) e Europa (Estocolmo).
  - Para o tipo de operador `G.8X`, cada operador é mapeado em 8 DPU (32 vCPU, 128 GB de memória) com 512 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL

do Spark no AWS Glue versão 3.0 ou posterior, nas mesmas regiões da AWS compatíveis com o tipo de operador `G.4X`.

- Para o tipo de operador `G.025X`, cada operador é mapeado para 0,25 DPU (2 vCPU, 4 GB de memória) com 84 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos de streaming de baixo volume. Esse tipo de operador só está disponível para trabalhos de streaming do AWS Glue versão 3.0 ou posterior.
- Para o tipo de operador `Z.2X`, cada operador é mapeado em 2 M-DPU (8 vCPUs, 64 GB de memória) com 128 GB de disco e fornece até 8 operadores do Ray baseados no autoscaler.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando um trabalho é executado.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com a execução desse trabalho.

- `LogGroupName` – String UTF-8.

  O nome do grupo de logs para registro seguro, que pode ser criptografado no lado do servidor no Amazon CloudWatch usando o AWS KMS. Esse nome pode ser `/aws-glue/jobs/` e, nesse caso, a criptografia padrão é `NONE`. Se você adicionar o nome de um perfil e o nome de `SecurityConfiguration` (em outras palavras, `/aws-glue/jobs-yourRoleName-yourSecurityConfigurationName/`), essa configuração de segurança será usada para criptografar o grupo de logs.

- `NotificationProperty` – Um objeto NotificationProperty.

  Especifica propriedades de configuração de uma notificação de execução de trabalho.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Nas tarefas do Spark, `GlueVersion` determina as versões do Apache Spark e do Python que o AWS Glue disponibiliza em um trabalho. A versão do Python indica a versão compatível com trabalhos do tipo Spark.

  Os trabalhos de Ray devem definir `GlueVersion` como `4.0` ou mais. Porém, as versões do Ray, do Python e das bibliotecas adicionais disponíveis no seu trabalho do Ray são determinadas pelo parâmetro `Runtime` do comando Job.

Para obter mais informações sobre as versões disponíveis do AWS Glue e as versões correspondentes do Spark e do Python, consulte Versão do Glue no guia do desenvolvedor.

Os trabalhos criados sem especificar uma versão do Glue usam como padrão o Glue 0.9.

- `DPUSeconds` – Número (duplo).

  Esse campo pode ser preenchido para execuções de trabalhos com classes de execução `FLEX` ou quando o Auto Scaling está habilitado e representa o tempo total de execução de um executor durante o ciclo de vida de uma execução de trabalho em segundos, multiplicado por um fator de DPU (1 para operadores `G.1X`, 2 para operadores `G.2X` e 0,25 para operadores `G.025X`). Esse valor pode ser diferente de `executionEngineRuntime` * `MaxCapacity`, como no caso de trabalhos do Auto Scaling, pois o número de executores em execução em um determinado momento pode ser menor que `MaxCapacity`. Portanto, é possível que o valor de `DPUSeconds` seja menor que `executionEngineRuntime` * `MaxCapacity`.

- `ExecutionClass`: string UTF-8, inferior a 16 bytes de comprimento (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica se o trabalho é executado com uma classe de execução padrão ou flexível. A classe de execução padrão é ideal para workloads sensíveis ao tempo que exigem a inicialização rápida de trabalhos e recursos dedicados.

  A classe de execução flexível é adequada para trabalhos insensíveis ao tempo, cujos horários de início e conclusão podem variar.

  Somente trabalhos com o AWS Glue versão 3.0 e posterior e o tipo de comando `glueetl` terão permissão para definir `ExecutionClass` como `FLEX`. A classe de execução flexível está disponível para trabalhos do Spark.

- `MaintenanceWindow` – String UTF-8 correspondente a Custom string pattern #34.

  Esse campo especifica um dia da semana e uma hora para uma janela de manutenção para trabalhos de streaming. O AWS Glue realiza periodicamente atividades de manutenção. Durante essas janelas de manutenção, o AWS Glue precisará reiniciar seus trabalhos de streaming.

  O AWS Glue reiniciará o trabalho dentro de 3 horas da janela de manutenção especificada. Por exemplo, se você configurar a janela de manutenção para segunda-feira às 10h (GMT), seus trabalhos serão reiniciados entre 10h (GMT) e 13h (GMT).

- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado à execução do trabalho.
- `StateDetail`: string UTF-8, não superior a 400.000 bytes de comprimento.

  Esse campo contém detalhes referentes ao estado da execução de um trabalho. O campo é anulável.

  Por exemplo, quando a execução de um trabalho está em um estado "EM ESPERA" como resultado da fila de execução de um trabalho, o campo contém o motivo pelo qual a execução do trabalho está nesse estado.

Estrutura Predecessor

Uma execução de trabalho usada no predicado de um gatilho condicional que a acionou.

Campos

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da definição de trabalho usada pela execução do trabalho antecessor.
- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da execução de trabalho predecessor.

Estrutura JobBookmarkEntry

Define um ponto em que um trabalho pode retomar o processamento.

Campos

- `JobName` – String UTF-8.

  O nome do trabalho em questão.
- `Version` – Número (íntegro).

  A versão do trabalho.

- `Run` – Número (íntegro).

  O número do ID de execução.
- `Attempt` – Número (íntegro).

  O número do ID de tentativa.
- `PreviousRunId` – String UTF-8.

  O identificador de execução exclusivo associado à execução do trabalho anterior.
- `RunId` – String UTF-8.

  O número do ID de execução.
- `JobBookmark` – String UTF-8.

  O próprio marcador.

Estrutura BatchStopJobRunSuccessfulSubmission

Registra uma solicitação bem-sucedido para interromper um `JobRun` especificado.

Campos

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da definição de trabalho usada na execução do trabalho que foi interrompida.
- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O `JobRunId` da execução de trabalho que foi interrompida.

Estrutura BatchStopJobRunError

Registra um erro que ocorreu ao tentar interromper uma execução de trabalho especificada.

Campos

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O nome da definição de trabalho usada na execução do trabalho em questão.

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O `JobRunId` da execução do trabalho em questão.

- `ErrorDetail` – Um objeto ErrorDetail.

  Especifica detalhes sobre o erro encontrado.

Estrutura NotificationProperty

Especifica propriedades de configuração de uma notificação.

Campos

- `NotifyDelayAfter` – Número (inteiro), pelo menos 1.

  Depois que a execução de um trabalho for iniciada, o número de minutos a esperar antes de enviar uma notificação de atraso de execução de trabalho.

Operações

- Ação StartJobRun (Python: start_job_run)
- Ação BatchStopJobRun (Python: batch_stop_job_run)
- Ação GetJobRun (Python: get_job_run)
- Ação GetJobRuns (Python: get_job_runs)
- Ação GetJobBookmark (Python: get_job_bookmark)
- Ação GetJobBookmarks (Python: get_job_bookmarks)
- Ação ResetJobBookmark (Python: reset_job_bookmark)

Ação StartJobRun (Python: start_job_run)

Inicia uma execução de trabalho usando uma definição de trabalho.

Solicitação

- `JobName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da definição de trabalho que será usada.

- `JobRunQueuingEnabled` – Booleano.

  Especifica se o enfileiramento da execução de trabalhos está habilitado para a execução do trabalho.

  Um valor "verdadeiro" significa que o enfileiramento da execução de trabalhos está habilitado para as execuções do trabalho. Se o valor for "falso" ou não estiver preenchido, a execução do trabalho não será considerada para enfileiramento.

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de um `JobRun` anterior para tentar novamente.

- `Arguments` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Os argumentos de trabalho associados a esta execução. Para essa execução de tarefa, eles substituem os argumentos padrão definidos na própria definição de tarefa.

  Aqui, é possível especificar os argumentos que seu próprio script de execução de trabalho consome, além dos argumentos que o AWS Glue consome.

  Os argumentos do trabalho podem ser registrados em log. Não transmita segredos em texto simples como argumentos. Recupere os segredos de uma conexão do AWS Glue, AWS Secrets Manager ou outro mecanismo de gerenciamento de segredo se pretender mantê-los dentro do trabalho.

  Para obter informações sobre como especificar e consumir seus próprios argumentos de trabalho, consulte o tópico Chamar APIs do AWS Glue em Python no guia do desenvolvedor.

Para obter informações sobre os argumentos que podem ser fornecidos a esse campo ao configurar trabalhos do Spark, consulte o tópico Parâmetros especiais usados pelo AWS Glue no guia do desenvolvedor.

Para obter informações sobre os argumentos que podem ser fornecidos a esse campo ao configurar trabalhos do Ray, consulte o tópico Uso de parâmetros de trabalho em trabalhos do Ray no guia do desenvolvedor.

- `AllocatedCapacity` – Número (íntegro).

  Este campo está obsoleto. Use `MaxCapacity` em vez disso.

  O número de unidades de processamento de dados (DPUs) do AWS Glue a serem atribuídas a esse JobRun. É possível alocar um mínimo de 2 DPUs. O padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite de `JobRun` em minutos. Este é o tempo máximo durante o qual uma execução de trabalho pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. Esse valor substitui o valor de tempo limite definido no trabalho principal.

  Os trabalhos devem ter valores de tempo limite inferiores a 7 dias ou 10.080 minutos. Caso contrário, os trabalhos gerarão uma exceção.

  Quando o valor é deixado em branco, o tempo limite padrão é de 2.880 minutos.

  Quaisquer trabalhos do AWS Glue existentes que tinham um valor de tempo limite maior que 7 dias serão padronizados para 7 dias. Por exemplo, se você especificou um tempo limite de 20 dias para um trabalho em lote, ele será interrompido no 7º dia.

  Para trabalhos de streaming, se você tiver configurado uma janela de manutenção, ela será reiniciada durante a janela de manutenção após 7 dias.

- `MaxCapacity` – Número (duplo).

  Para trabalhos do Glue versão 1.0 ou anterior, usando o tipo de operador padrão, é o número de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando esse trabalho for executado. Uma DPU é uma medida relativa do poder de processamento que

consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

Para trabalhos do Glue versão 2.0+, você não pode especificar uma `Maximum capacity`. Em vez disso, você deve especificar um `Worker type` e o `Number of workers`.

Não defina `MaxCapacity` se estiver usando `WorkerType` e `NumberOfWorkers`.

O valor que pode ser alocado para `MaxCapacity` depende se você está executando um trabalho de shell do Python, um trabalho de ETL do Apache Spark ou um trabalho de ETL de streaming do Apache Spark:

- Ao especificar um trabalho de shell do Python (`JobCommand.Name`="pythonshell"), será possível alocar 0,0625 ou 1 DPU. O padrão é 0,0625 DPU.
- Ao especificar um trabalho de ETL do Apache Spark (`JobCommand.Name`="glueetl") ou um trabalho de ETL de streaming do Apache Spark (`JobCommand.Name`="gluestreaming"), é possível alocar de 2 a 100 DPUs. O padrão é de 10 DPUs. Esse tipo de trabalho não pode ter uma alocação de DPU fracionada.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com a execução desse trabalho.

- `NotificationProperty` – Um objeto NotificationProperty.

  Especifica propriedades de configuração de uma notificação de execução de trabalho.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando um trabalho é executado. Aceita um valor de G.1X, G.2X, G.4X, G.8X ou G.025X para trabalhos do Spark. Aceita o valor Z.2X para trabalhos do Ray.

  - Para o tipo de operador `G.1X`, cada operador é mapeado em 1 DPU (4 vCPU, 16 GB de memória) com 94 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.2X`, cada operador é mapeado em 2 DPU (8 vCPU, 32 GB de memória) com 138 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo

de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.

- Para o tipo de operador `G.4X`, cada operador é mapeado em 4 DPU (16 vCPU, 64 GB de memória) com 256 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Singapura), Ásia-Pacífico (Sydney), Ásia-Pacífico (Tóquio), Canadá (Central), Europa (Frankfurt), Europa (Irlanda) e Europa (Estocolmo).
- Para o tipo de operador `G.8X`, cada operador é mapeado em 8 DPU (32 vCPU, 128 GB de memória) com 512 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior, nas mesmas regiões da AWS compatíveis com o tipo de operador `G.4X`.
- Para o tipo de operador `G.025X`, cada operador é mapeado para 0,25 DPU (2 vCPU, 4 GB de memória) com 84 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos de streaming de baixo volume. Esse tipo de operador só está disponível para trabalhos de streaming do AWS Glue versão 3.0 ou posterior.
- Para o tipo de operador `Z.2X`, cada operador é mapeado em 2 M-DPU (8 vCPUs, 64 GB de memória) com 128 GB de disco e fornece até 8 operadores do Ray baseados no autoscaler.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando um trabalho é executado.

- `ExecutionClass`: string UTF-8, inferior a 16 bytes de comprimento (valores válidos: `FLEX=""` | `STANDARD=""`).

  Indica se o trabalho é executado com uma classe de execução padrão ou flexível. A classe de execução padrão é ideal para workloads sensíveis ao tempo que exigem a inicialização rápida de trabalhos e recursos dedicados.

  A classe de execução flexível é adequada para trabalhos insensíveis ao tempo, cujos horários de início e conclusão podem variar.

Somente trabalhos com o AWS Glue versão 3.0 e posterior e o tipo de comando `glueetl` terão permissão para definir `ExecutionClass` como `FLEX`. A classe de execução flexível está disponível para trabalhos do Spark.

- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado à execução do trabalho.

Resposta

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID atribuído a esta execução de trabalho.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentRunsExceededException`

Ação BatchStopJobRun (Python: batch_stop_job_run)

Interrompe uma ou mais execuções de trabalho para uma definição de trabalho determinada.

Solicitação

- `JobName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da definição de trabalho para a qual as execuções de trabalho são interrompidas.

- `JobRunIds` – Obrigatório: uma matriz de strings UTF-8, no mínimo 1 ou mais de 25 strings.

Uma lista dos `JobRunIds` que devem ser interrompidos para essa definição de trabalho.

Resposta

- `SuccessfulSubmissions`: um array de objetos BatchStopJobRunSuccessfulSubmission.

  Uma lista dos JobRuns que foram enviados com sucesso para interrupção.
- `Errors`: um array de objetos BatchStopJobRunError.

  Uma lista dos erros que foram encontrados durante a tentativa de interrupção de `JobRuns`, incluindo o `JobRunId` para o qual cada erro foi encontrado e os detalhes do erro.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetJobRun (Python: get_job_run)

Recupera os metadados para uma execução de trabalho específica. O histórico de execução de trabalhos fica disponível por 365 dias para seu fluxo de trabalho e para a execução do trabalho.

Solicitação

- `JobName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome da definição de trabalho em execução.
- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da execução de trabalho.
- `PredecessorsIncluded` – Booleano.

  True, se uma lista de execuções antecessoras for retornada.

Resposta

- `JobRun` – Um objeto JobRun.

  Os metadados solicitados da execução de trabalho.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetJobRuns (Python: get_job_runs)

Recupera os metadados para todas as execuções de uma determinada definição de trabalho.

`GetJobRuns` retorna as execuções da tarefa em ordem cronológica, com as tarefas mais recentes primeiro.

Solicitação

- `JobName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da definição de trabalho para a qual todas as execuções de trabalho são recuperadas.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.
- `MaxResults`: número (inteiro) não inferior a 1 nem superior a 200.

  O tamanho máximo da resposta.

Resposta

- `JobRuns`: um array de objetos JobRun.

  Uma lista de objetos de metadados de execução de trabalho.

- `NextToken` – String UTF-8.

  Um token de continuação, se todas as execuções de trabalho solicitadas não tiverem sido retornadas.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetJobBookmark (Python: get_job_bookmark)

Retorna informações sobre uma entrada de marcador de trabalho.

Para obter mais informações sobre como habilitar e usar marcadores de trabalho, consulte:

- Rastrear dados processados usando marcadores de trabalho
- Parâmetros de trabalho usados pelo AWS Glue
- Estrutura de trabalhos

Solicitação

- `JobName` – Obrigatório: string UTF-8.

  O nome do trabalho em questão.
- `Version` – Número (íntegro).

  A versão do trabalho.
- `RunId` – String UTF-8.

  O identificador de execução exclusivo associado à execução desse trabalho.

Resposta

- `JobBookmarkEntry` – Um objeto JobBookmarkEntry.

Uma estrutura que define um ponto em que um trabalho pode retomar o processamento.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ValidationException`

Ação GetJobBookmarks (Python: get_job_bookmarks)

Retorna informações sobre as entradas de marcador de trabalho. A ordem da lista é em números de versão decrescentes.

Para obter mais informações sobre como habilitar e usar marcadores de trabalho, consulte:

- Rastrear dados processados usando marcadores de trabalho
- Parâmetros de trabalho usados pelo AWS Glue
- Estrutura de trabalhos

Solicitação

- `JobName` – Obrigatório: string UTF-8.

  O nome do trabalho em questão.
- `MaxResults` – Número (íntegro).

  O tamanho máximo da resposta.
- `NextToken` – Número (íntegro).

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `JobBookmarkEntries`: um array de objetos JobBookmarkEntry.

Uma lista de entradas de marcador de trabalho que define um ponto em que um trabalho pode retomar o processamento.

- `NextToken` – Número (íntegro).

  Um token de continuação, que terá um valor de 1 se todas as entradas forem retornadas ou > 1 se nem todas as execuções solicitadas forem retornadas.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação ResetJobBookmark (Python: reset_job_bookmark)

Redefine uma entrada de marcador.

Para obter mais informações sobre como habilitar e usar marcadores de trabalho, consulte:

- Rastrear dados processados usando marcadores de trabalho
- Parâmetros de trabalho usados pelo AWS Glue
- Estrutura de trabalhos

Solicitação

- `JobName` – Obrigatório: string UTF-8.

  O nome do trabalho em questão.

- `RunId` – String UTF-8.

  O identificador de execução exclusivo associado à execução desse trabalho.

Resposta

- `JobBookmarkEntry` – Um objeto JobBookmarkEntry.

A redefinição da entrada de marcador.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Acionadores

A API de acionadores descreve os tipos de dados e a API relacionada à criação, atualização ou exclusão, e início e interrupção, de acionadores de trabalho no AWS Glue.

Tipos de dados

- Estrutura de acionador
- Estrutura TriggerUpdate
- Estrutura Predicate
- Estrutura Condition
- Estrutura Action
- Estrutura EventBatchingCondition

Estrutura de acionador

As informações sobre um determinado gatilho.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do gatilho.
- `WorkflowName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O nome do fluxo de trabalho associado ao gatilho.

- `Id` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Reservado para uso futuro.

- `Type` – String UTF-8 (valores válidos: `SCHEDULED` | `CONDITIONAL` | `ON_DEMAND` | `EVENT`).

  O tipo de gatilho.

- `State` – String UTF-8 (valores válidos: `CREATING` | `CREATED` | `ACTIVATING` | `ACTIVATED` | `DEACTIVATING` | `DEACTIVATED` | `DELETING` | `UPDATING`).

  O estado atual do gatilho do trabalho.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição desse gatilho.

- `Schedule` – String UTF-8.

  Uma expressão `cron` usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers. Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.

- `Actions`: um array de objetos Ação.

  As ações iniciadas por esse gatilho.

- `Predicate` – Um objeto Predicado.

  O predicado deste gatilho, que define quando ele disparará.

- `EventBatchingCondition` – Um objeto EventBatchingCondition.

  Condição de lote que deve ser atendida (número especificado de eventos recebidos ou janela de tempo de lote expirada) antes que o acionador do evento do EventBridge dispare.

Estrutura TriggerUpdate

Uma estrutura usada para fornecer as informações necessárias para atualizar um gatilho. Este objeto atualiza a definição do gatilho anterior, substituindo-a completamente.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Reservado para uso futuro.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição desse gatilho.
- `Schedule` – String UTF-8.

  Uma expressão `cron` usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers. Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.
- `Actions`: um array de objetos Ação.

  As ações iniciadas por esse gatilho.
- `Predicate` – Um objeto Predicado.

  O predicado deste gatilho, que define quando ele disparará.
- `EventBatchingCondition` – Um objeto EventBatchingCondition.

  Condição de lote que deve ser atendida (número especificado de eventos recebidos ou janela de tempo de lote expirada) antes que o acionador do evento do EventBridge dispare.

Estrutura Predicate

Define o predicado do gatilho, que determina quando ele é acionado.

Campos

- `Logical`: string UTF-8 (valores válidos: `AND` | `ANY`).

  Um campo opcional se apenas uma condição estiver listada. Se várias condições estiverem listadas, esse campo será obrigatório.
- `Conditions`: uma matriz de objetos Condição, não mais de 500 estruturas.

  Uma lista das condições que determinam quando o gatilho será acionado.

Estrutura Condition

Define em que condição um gatilho será acionado.

Campos

- `LogicalOperator` – String UTF-8 (valores válidos: `EQUALS`).

  Um operador lógico.
- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do trabalho cujo `JobRuns` essa condição se aplica e na qual esse gatilho aguardará.
- `State`: string UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

  O estado da condição. No momento, os únicos estados de trabalho que um trigger pode escutar são `SUCCEEDED`, `STOPPED`, `FAILED` e `TIMEOUT`. Os únicos estados de crawler que um trigger pode escutar são `SUCCEEDED`, `FAILED` e `CANCELLED`.
- `CrawlerName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do crawler ao qual essa condição se aplica.
- `CrawlState` – String UTF-8 (valores válidos: `RUNNING` | `CANCELLING` | `CANCELLED` | `SUCCEEDED` | `FAILED` | `ERROR`).

  O estado do crawler ao qual essa condição se aplica.

Estrutura Action

Define uma ação a ser iniciada por um gatilho.

Campos

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um trabalho a ser executado.
- `Arguments` – Um array de mapa dos pares de valor-chave.

Cada chave é uma sequência de caracteres UTF-8.

Cada valor é uma sequência de caracteres UTF-8.

Os argumentos de tarefa usados ao acionar esse trigger. Para essa execução de tarefa, eles substituem os argumentos padrão definidos na própria definição de tarefa.

Aqui, é possível especificar os argumentos que seu próprio script de execução de trabalho consome, além dos argumentos que o AWS Glue consome.

Para obter informações sobre como especificar e consumir seus próprios argumentos de trabalho, consulte o tópico Chamar APIs do AWS Glue em Python no guia do desenvolvedor.

Para obter informações sobre os pares de chave-valor que o AWS Glue consome para configurar o trabalho, consulte o tópico Parâmetros especiais usados pelo AWS Glue no guia do desenvolvedor.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite de `JobRun` em minutos. Este é o tempo máximo durante o qual uma execução de trabalho pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. Isso substitui o valor de tempo limite definido no trabalho principal.

  Os trabalhos devem ter valores de tempo limite inferiores a 7 dias ou 10.080 minutos. Caso contrário, os trabalhos gerarão uma exceção.

  Quando o valor é deixado em branco, o tempo limite padrão é de 2.880 minutos.

  Quaisquer trabalhos do AWS Glue existentes que tinham um valor de tempo limite maior que 7 dias serão padronizados para 7 dias. Por exemplo, se você especificou um tempo limite de 20 dias para um trabalho em lote, ele será interrompido no 7º dia.

  Para trabalhos de streaming, se você tiver configurado uma janela de manutenção, ela será reiniciada durante a janela de manutenção após 7 dias.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com essa ação.

- `NotificationProperty` – Um objeto NotificationProperty.

Especifica propriedades de configuração de uma notificação de execução de trabalho.

- `CrawlerName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do crawler que será usado com essa ação.

Estrutura EventBatchingCondition

Condição de lote que deve ser atendida (número especificado de eventos recebidos ou janela de tempo de lote expirada) antes que o acionador do evento do EventBridge dispare.

Campos

- `BatchSize`: obrigatório: número (inteiro), não menos do que 1 ou superior a 100.

  Número de eventos que devem ser recebidos do Amazon EventBridge antes que o acionador do evento do EventBridge dispare.
- `BatchWindow`: número (inteiro), não menos do que 1 ou superior a 900.

  Janela de tempo em segundos após a qual o acionador do evento do EventBridge dispara. A janela é iniciada quando o primeiro evento é recebido.

Operações

- Ação CreateTrigger (Python: create_trigger)
- Ação StartTrigger (Python: start_trigger)
- Ação GetTrigger (Python: get_trigger)
- Ação GetTriggers (Python: get_triggers)
- Ação UpdateTrigger (Python: update_trigger)
- Ação StopTrigger (Python: stop_trigger)
- Ação DeleteTrigger (Python: delete_trigger)
- Ação ListTriggers (Python: list_triggers)
- Ação BatchGetTriggers (Python: batch_get_triggers)

Ação CreateTrigger (Python: create_trigger)

Cria um novo gatilho.

Os argumentos do trabalho podem ser registrados em log. Não transmita segredos em texto simples como argumentos. Recupere os segredos de uma conexão do AWS Glue, AWS Secrets Manager ou outro mecanismo de gerenciamento de segredos se pretender mantê-los dentro do trabalho.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do gatilho.
- `WorkflowName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do fluxo de trabalho associado ao gatilho.
- `Type`: obrigatório: string UTF-8 (valores válidos: `SCHEDULED` | `CONDITIONAL` | `ON_DEMAND` | `EVENT`).

  O tipo do novo gatilho.
- `Schedule` – String UTF-8.

  Uma expressão `cron` usada para especificar a programação (consulte Programações baseadas em hora para tarefas e crawlers. Por exemplo, para executar algo todos os dias às 12h15 UTC, especifique: `cron(15 12 * * ? *)`.

  Esse campo é obrigatório quando o tipo do gatilho é SCHEDULED.
- `Predicate` – Um objeto Predicado.

  Um predicado para especificar quando o novo gatilho será disparado.

  Esse campo é obrigatório quando o tipo do gatilho é `CONDITIONAL`.
- `Actions` – Obrigatório: uma matriz de objetos Ação.

  As ações iniciadas por esse gatilho quando ele é disparado.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

Uma descrição do novo gatilho.

- `StartOnCreation` – Booleano.

  Defina como `true` para iniciar os gatilhos `SCHEDULED` e `CONDITIONAL` na criação. True (Verdadeiro) não é compatível com gatilhos `ON_DEMAND`.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags a serem usadas com esse trigger. Você pode usar tags para limitar o acesso ao trigger. Para obter mais informações sobre tags no AWS Glue, consulte Tags da AWS no AWS Glue no guia do desenvolvedor.

- `EventBatchingCondition` – Um objeto EventBatchingCondition.

  Condição de lote que deve ser atendida (número especificado de eventos recebidos ou janela de tempo de lote expirada) antes que o acionador do evento do EventBridge dispare.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do gatilho.

Erros

- `AlreadyExistsException`
- `EntityNotFoundException`
- `InvalidInputException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

Ação StartTrigger (Python: start_trigger)

Inicia um gatilho existente. Consulte Acionar tarefas para obter informações sobre como diferentes tipos de gatilho são acionados.

Solicitação

- Name: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do gatilho a ser iniciado.

Resposta

- Name – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do gatilho iniciado.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentRunsExceededException`

Ação GetTrigger (Python: get_trigger)

Recupera a definição de um gatilho.

Solicitação

- Name: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do gatilho a ser recuperado.

Resposta

- `Trigger` – Um objeto Trigger.

  A definição de gatilho solicitada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetTriggers (Python: get_triggers)

Obtém todos os gatilhos associados a um trabalho.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

- `DependentJobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do trabalho para o qual recuperar gatilhos. O gatilho que pode iniciar esse trabalho será retornado e, se ele não existir, todos os gatilhos serão retornados.

- `MaxResults`: número (inteiro) não inferior a 1 nem superior a 200.

  O tamanho máximo da resposta.

Resposta

- `Triggers`: um array de objetos Trigger.

  Uma lista de gatilhos para o trabalho especificado.

- `NextToken` – String UTF-8.

Um token de continuação, se todos os gatilhos solicitados ainda não tiverem sido retornados.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação UpdateTrigger (Python: update_trigger)

Atualiza uma definição do gatilho.

Os argumentos do trabalho podem ser registrados em log. Não transmita segredos em texto simples como argumentos. Recupere os segredos de uma conexão do AWS Glue, AWS Secrets Manager ou outro mecanismo de gerenciamento de segredos se pretender mantê-los dentro do trabalho.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do gatilho a ser atualizado.
- `TriggerUpdate` – Obrigatório: um objeto TriggerUpdate.

  Os novos valores para atualização do gatilho.

Resposta

- `Trigger` – Um objeto Trigger.

  A definição de gatilho resultante.

Erros

- `InvalidInputException`
- `InternalServiceException`

- `EntityNotFoundException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Ação StopTrigger (Python: stop_trigger)

Interrompe um gatilho especificado.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do gatilho a ser interrompido.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do gatilho interrompido.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Ação DeleteTrigger (Python: delete_trigger)

Exclui um gatilho especificado. Se o gatilho não for encontrado, nenhuma exceção será lançada.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do gatilho a ser excluído.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do gatilho excluído.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Ação ListTriggers (Python: list_triggers)

Recupera os nomes de todos os recursos de acionador nessa conta da AWS ou os recursos com a tag especificada. Essa operação permite que você veja quais recursos estão disponíveis em sua conta e seus nomes.

Essa operação aceita o campo `Tags` opcional, que pode ser usado como um filtro na resposta, para que recursos com tags possam ser recuperados como um grupo. Se você optar por usar a filtragem por tags, apenas os recursos com a tag serão recuperados.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `DependentJobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O nome do trabalho para o qual recuperar gatilhos. O gatilho que pode iniciar esse trabalho é retornado. Se esse gatilho não existir, todos os gatilhos serão retornados.

- `MaxResults`: número (inteiro) não inferior a 1 nem superior a 200.

  O tamanho máximo de uma lista a ser retornada.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Especifica apenas o retorno desses recursos com tags.

Resposta

- `TriggerNames` – Uma matriz de strings UTF-8.

  Os nomes de todos os gatilhos na conta ou os gatilhos com as tags especificadas.

- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não contiver a métrica mais recente disponível.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação BatchGetTriggers (Python: batch_get_triggers)

Retorna uma lista de metadados de recurso para uma lista de nomes de gatilho. Depois de chamar a operação `ListTriggers`, você pode chamar essa operação para acessar os dados aos quais você recebeu permissões. Essa operação oferece suporte a todas as permissões do IAM, incluindo condições de permissão que usam tags.

Solicitação

- `TriggerNames`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de nomes de gatilho, que podem ser os nomes retornados pela operação `ListTriggers`.

Resposta

- `Triggers`: um array de objetos Trigger.

  Uma lista das definições de gatilho.
- `TriggersNotFound` – Uma matriz de strings UTF-8.

  Uma lista de nomes de gatilhos não encontrados.

Erros

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

APIs de integração no AWS Glue

Tipos de dados

- Estrutura da integração
- Estrutura de IntegrationConfig
- Estrutura IntegrationPartition
- Estrutura IntegrationError
- Estrutura IntegrationFilter
- Estrutura InboundIntegration
- Estrutura SourceProcessingProperties
- Estrutura TargetProcessingProperties
- Estrutura SourceTableConfig

- Estrutura TargetTableConfig

Estrutura da integração

Descreve uma integração ETL zero.

Campos

- `SourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da origem da integração.
- `TargetArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do destino da integração.
- `Description`: string UTF-8 com no máximo 1.000 bytes de comprimento e correspondente a Custom string pattern #12.

  Uma descrição da integração.
- `IntegrationName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Um nome exclusivo para a integração.
- `IntegrationArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da integração.
- `KmsKeyId`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O ARN de uma chave do KMS usada para criptografar o canal.
- `AdditionalEncryptionContext` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um conjunto opcional de pares chave-valor não secretas que contém informações contextuais adicionais para criptografia. Isso só pode ser fornecido se `KMSKeyId` for fornecido.
- `Tags`: um array de objetos Tag.

Metadados atribuídos ao recurso que consiste em uma lista de pares chave-valor.

- `Status`: obrigatório: string UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  Os possíveis status são:

  - CREATING: a integração está sendo criada.
  - ACTIVE: a criação da integração foi bem-sucedida.
  - MODIFYING: a integração está sendo modificada.
  - FAILED: a criação da integração falhou.
  - DELETING: a integração está sendo excluída.
  - SYNCING: a integração está sincronizando.
  - NEEDS_ATTENTION: a integração precisa de atenção, como sincronização.
- `CreateTime`: obrigatório: carimbo de data e hora.

  A hora em que a integração foi criada (UTC).
- `IntegrationConfig` – Um objeto IntegrationConfig.

  As propriedades associadas à integração.
- `Errors`: um array de objetos IntegrationError.

  Uma lista de erros associados à integração.
- `DataFilter`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Seleciona tabelas de origem para a integração usando a sintaxe do filtro Maxwell.

Estrutura de IntegrationConfig

As propriedades associadas à integração.

Campos

- `RefreshInterval` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Especifica a frequência com que as extrações do CDC (Change Data Capture) ou as cargas incrementais devem ocorrer. Esse parâmetro fornece flexibilidade para alinhar a taxa de atualização com seus padrões específicos de atualização de dados, considerações de carga

do sistema e metas de otimização de performance. O incremento de tempo pode ser definido de 15 minutos a 8.640 minutos (seis dias). Atualmente só é compatível com a criação de `RefreshInterval`.

- `SourceProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Uma coleção de pares de chave-valor que especificam propriedades adicionais para a fonte de integração. Essas propriedades fornecem opções de configuração que podem ser usadas para personalizar o comportamento da fonte ODB durante as operações de integração de dados.

Estrutura IntegrationPartition

Uma estrutura que descreve como os dados são particionados no destino.

Campos

- `FieldName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome do campo usado para particionar dados no destino. Evite usar colunas que tenham valores exclusivos para cada linha (por exemplo, "LastModifiedTimestamp", "SystemModTimeStamp") como a coluna de partição. Essas colunas não são adequadas para particionamento porque criam um grande número de partições pequenas, o que pode causar problemas de performance.
- `FunctionSpec` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Especifica a função usada para particionar dados no destino. O único valor aceito para esse parâmetro é "identity" (string). A função "identity" garante que o particionamento de dados no destino siga o mesmo esquema da origem. Em outras palavras, a estrutura de particionamento dos dados da origem é preservada no destino.
- `ConversionSpec` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Especifica o formato de timestamp dos dados da fonte. Os valores válidos são:
  - `epoch_sec`: timestamp da era Unix em segundos
  - `epoch_milli`: timetstamp da era Unix em milissegundos
  - `iso`: timestamp no formato ISO 8601

> **Note**
>
> Especifique `ConversionSpec` apenas ao usar funções de partição baseadas em timestamp (ano, mês, dia ou hora). AWS Glue O Zero-ETL usa esse parâmetro para transformar corretamente os dados da fonte no formato de timestamp antes do particionamento.
> Não use colunas de alta cardinalidade com a função de partição `identity`. Colunas de alta cardinalidade incluem:
>
> - Chaves primárias
> - Campos de timestamp (como `LastModifiedTimestamp`, `CreatedDate`)
> - Timestamps gerados pelo sistema
>
> O uso de colunas de alta cardinalidade com particionamento baseado em identidade cria muitas pequenas partições, o que pode degradar significativamente o desempenho de ingestão.

Estrutura IntegrationError

Um erro associado a uma integração ETL zero.

Campos

- `ErrorCode` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O código associado a este erro.
- `ErrorMessage`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Uma mensagem descrevendo o erro.

Estrutura IntegrationFilter

Um filtro que pode ser usado ao invocar uma solicitação `DescribeIntegrations`.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

O nome do filtro.

- `Values` – Uma matriz de strings UTF-8.

  Uma lista de valores de filtro.

Estrutura InboundIntegration

Uma estrutura para uma integração que grava dados em um recurso.

Campos

- `SourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do recurso de origem para a integração.

- `TargetArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do recurso de destino para a integração.

- `IntegrationArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da integração ETL zero.

- `Status`: obrigatório: string UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  Os possíveis status são:

  - CREATING: a integração está sendo criada.
  - ACTIVE: a criação da integração foi bem-sucedida.
  - MODIFYING: a integração está sendo modificada.
  - FAILED: a criação da integração falhou.
  - DELETING: a integração está sendo excluída.
  - SYNCING: a integração está sincronizando.
  - NEEDS_ATTENTION: a integração precisa de atenção, como sincronização.

- `CreateTime`: obrigatório: carimbo de data e hora.

  A hora em que a integração foi criada (UTC).

- `IntegrationConfig` – Um objeto IntegrationConfig.

As propriedades associadas à integração.

- `Errors`: um array de objetos IntegrationError.

  Uma lista de erros associados à integração.

Estrutura SourceProcessingProperties

As propriedades do recurso associadas à origem da integração.

Campos

- `RoleArn` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O perfil do IAM para acessar a conexão ao AWS Glue.

Estrutura TargetProcessingProperties

As propriedades do recurso associadas ao destino da integração.

Campos

- `RoleArn` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O perfil do IAM para acessar o banco de dados do AWS Glue.
- `KmsArn`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O ARN da chave do KMS usada para criptografia.
- `ConnectionName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  A conexão de rede do AWS Glue para configurar o trabalho do AWS Glue em execução na VPC do cliente.
- `EventBusArn`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O ARN de um barramento de eventos do Eventbridge para receber a notificação do status da integração.

Estrutura SourceTableConfig

Propriedades usadas pela perna de origem para processar dados da origem.

Campos

- `Fields` – Uma matriz de strings UTF-8.

  Uma lista de campos usados para filtragem em nível de coluna. Atualmente incompatível.

- `FilterPredicate` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Uma cláusula de condição usada para filtragem em nível de linha. Atualmente incompatível.

- `PrimaryKey` – Uma matriz de strings UTF-8.

  Forneça o conjunto de chaves primárias para essa tabela. Atualmente compatível especificamente para entidades `Entity0f` do SAP, mediante solicitação. Entre em contato com o AWS Support para disponibilizar esse recurso.

- `RecordUpdateField` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Campo incremental extração baseado em timestamp. Atualmente incompatível.

Estrutura TargetTableConfig

Propriedades usadas pela perna de destino para particionar os dados no destino.

Campos

- `UnnestSpec` – String UTF-8 (valores válidos: `TOPLEVEL` | `FULL` | `NOUNNEST`).

  Especifica como os objetos aninhados são nivelados em elementos de nível superior. Os valores válidos são: "TOPLEVEL", "FULL" ou "NOUNNEST".

- `PartitionSpec`: um array de objetos IntegrationPartition.

  Determina o layout do arquivo no destino.

- `TargetTableName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome opcional de uma tabela de destino.

Operações

- Ação CreateIntegration action (Python: create_integration)
- Ação ModifyIntegration (Python: modify_integration)
- Ação DescribeIntegrations (Python: describe_integrations)
- Ação DeleteIntegration (Python: delete_integration)
- Ação DescribeInboundIntegrations (Python: describe_inbound_integrations)
- Ação CreateIntegrationTableProperties (Python: create_integration_table_properties)
- Ação UpdateIntegrationTableProperties (Python: update_integration_table_properties)
- Ação GetIntegrationTableProperties (Python: get_integration_table_properties)
- Ação DeleteIntegrationTableProperties (Python: delete_integration_table_properties)
- Ação CreateIntegrationResourceProperty (Python: create_integration_resource_property)
- Ação UpdateIntegrationResourceProperty (Python: update_integration_resource_property)
- Ação GetIntegrationResourceProperty (Python: get_integration_resource_property)
- Ação UntagResource (Python: untag_resource)
- Ação ListTagsForResource (Python: list_tags_for_resource)

Ação CreateIntegration action (Python: create_integration)

Cria uma integração ETL zero na conta do chamador entre dois recursos com nomes do recurso da Amazon (ARNs): `SourceArn` e `TargetArn`.

Solicitação

- `IntegrationName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Um nome exclusivo para uma integração no AWS Glue.
- `SourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do recurso de origem para a integração.
- `TargetArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do recurso de destino para a integração.

- `Description`: string UTF-8 com no máximo 1.000 bytes de comprimento e correspondente a Custom string pattern #12.

  Uma descrição da integração.

- `DataFilter`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Seleciona tabelas de origem para a integração usando a sintaxe do filtro Maxwell.

- `KmsKeyId`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O ARN de uma chave do KMS usada para criptografar o canal.

- `AdditionalEncryptionContext` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um conjunto opcional de pares chave-valor não secretas que contém informações contextuais adicionais para criptografia. Isso só pode ser fornecido se `KMSKeyId` for fornecido.

- `Tags`: um array de objetos Tag.

  Metadados atribuídos ao recurso que consiste em uma lista de pares chave-valor.

- `IntegrationConfig` – Um objeto IntegrationConfig.

  As definições de configuração.

Resposta

- `SourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do recurso de origem para a integração.

- `TargetArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do recurso de destino para a integração.

- `IntegrationName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Um nome exclusivo para uma integração no AWS Glue.

- `Description`: string UTF-8 com no máximo 1.000 bytes de comprimento e correspondente a Custom string pattern #12.

  Uma descrição da integração.

- `IntegrationArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da integração criada.

- `KmsKeyId`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O ARN de uma chave do KMS usada para criptografar o canal.

- `AdditionalEncryptionContext` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um conjunto opcional de pares chave-valor não secretas que contém informações contextuais adicionais para criptografia.

- `Tags`: um array de objetos Tag.

  Metadados atribuídos ao recurso que consiste em uma lista de pares chave-valor.

- `Status`: obrigatório: string UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  O status da integração que está sendo criada.

  Os possíveis status são:

  - CREATING: a integração está sendo criada.
  - ACTIVE: a criação da integração foi bem-sucedida.
  - MODIFYING: a integração está sendo modificada.
  - FAILED: a criação da integração falhou.
  - DELETING: a integração está sendo excluída.
  - SYNCING: a integração está sincronizando.
  - NEEDS_ATTENTION: a integração precisa de atenção, como sincronização.

- `CreateTime`: obrigatório: carimbo de data e hora.

A hora em que a integração foi criada (UTC).

- `Errors`: um array de objetos IntegrationError.

  Uma lista de erros associados à criação da integração.

- `DataFilter`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Seleciona tabelas de origem para a integração usando a sintaxe do filtro Maxwell.

- `IntegrationConfig` – Um objeto IntegrationConfig.

  As definições de configuração.

Erros

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `IntegrationConflictOperationFault`
- `IntegrationQuotaExceededFault`
- `KMSKeyNotAccessibleFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `ResourceNumberLimitExceededException`
- `InvalidInputException`

Ação ModifyIntegration (Python: modify_integration)

Modifica uma integração ETL zero na conta do chamador.

Solicitação

- `IntegrationIdentifier`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

O nome do recurso da Amazon (ARN) da integração.

- `Description`: string UTF-8 com no máximo 1.000 bytes de comprimento e correspondente a Custom string pattern #12.

  Uma descrição da integração.

- `DataFilter`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Seleciona tabelas de origem para a integração usando a sintaxe do filtro Maxwell.

- `IntegrationName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Um nome exclusivo para uma integração no AWS Glue.

Resposta

- `SourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da origem da integração.

- `TargetArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do destino da integração.

- `IntegrationName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  Um nome exclusivo para uma integração no AWS Glue.

- `Description`: string UTF-8 com no máximo 1.000 bytes de comprimento e correspondente a Custom string pattern #12.

  Uma descrição da integração.

- `IntegrationArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da integração.

- `KmsKeyId`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O ARN de uma chave do KMS usada para criptografar o canal.

- `AdditionalEncryptionContext` – Um array de mapa dos pares de valor-chave.

Cada chave é uma sequência de caracteres UTF-8.

Cada valor é uma sequência de caracteres UTF-8.

Um conjunto opcional de pares chave-valor não secretas que contém informações contextuais adicionais para criptografia.

- `Tags`: um array de objetos Tag.

  Metadados atribuídos ao recurso que consiste em uma lista de pares chave-valor.

- `Status`: obrigatório: string UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  O status da integração que está sendo modificada.

  Os possíveis status são:

  - CREATING: a integração está sendo criada.
  - ACTIVE: a criação da integração foi bem-sucedida.
  - MODIFYING: a integração está sendo modificada.
  - FAILED: a criação da integração falhou.
  - DELETING: a integração está sendo excluída.
  - SYNCING: a integração está sincronizando.
  - NEEDS_ATTENTION: a integração precisa de atenção, como sincronização.

- `CreateTime`: obrigatório: carimbo de data e hora.

  A hora em que a integração foi criada (UTC).

- `Errors`: um array de objetos IntegrationError.

  Uma lista de erros associados à modificação da integração.

- `DataFilter`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Seleciona tabelas de origem para a integração usando a sintaxe do filtro Maxwell.

Erros

- `ValidationException`
- `AccessDeniedException`

- `InternalServerException`
- `IntegrationNotFoundFault`
- `IntegrationConflictOperationFault`
- `InvalidIntegrationStateFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `InvalidStateException`
- `InvalidInputException`

Ação DescribeIntegrations (Python: describe_integrations)

A API é usada para recuperar uma lista de integrações.

Solicitação

- `IntegrationIdentifier` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da integração.
- `Marker` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Um valor que indica o ponto de partida do próximo conjunto de registros de resposta em uma solicitação subsequente.
- `MaxRecords` – Número (íntegro).

  O número total de itens para retornar na saída.
- `Filters`: um array de objetos IntegrationFilter.

  Uma lista de chaves e valores para filtrar os resultados. As chaves aceitas são "Status", "IntegrationName" e "SourceArn". IntegrationName está limitado a apenas um valor.

Resposta

- `Integrations`: um array de objetos Integração.

  Uma lista de integrações ETL zero.

- `Marker` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Um valor que indica o ponto de partida do próximo conjunto de registros de resposta em uma solicitação subsequente.

Erros

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `IntegrationNotFoundFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação DeleteIntegration (Python: delete_integration)

Exclui a integração ETL zero especificada.

Solicitação

- `IntegrationIdentifier`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da integração.

Resposta

- `SourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da origem da integração.
- `TargetArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN do destino da integração.
- `IntegrationName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

Um nome exclusivo para uma integração no AWS Glue.

- `Description`: string UTF-8 com no máximo 1.000 bytes de comprimento e correspondente a Custom string pattern #12.

  Uma descrição da integração.

- `IntegrationArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da integração.

- `KmsKeyId`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  O ARN de uma chave do KMS usada para criptografar o canal.

- `AdditionalEncryptionContext` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um conjunto opcional de pares chave-valor não secretas que contém informações contextuais adicionais para criptografia.

- `Tags`: um array de objetos Tag.

  Metadados atribuídos ao recurso que consiste em uma lista de pares chave-valor.

- `Status`: obrigatório: string UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `MODIFYING` | `FAILED` | `DELETING` | `SYNCING` | `NEEDS_ATTENTION`).

  O status da integração que está sendo excluída.

  Os possíveis status são:

  - CREATING: a integração está sendo criada.
  - ACTIVE: a criação da integração foi bem-sucedida.
  - MODIFYING: a integração está sendo modificada.
  - FAILED: a criação da integração falhou.
  - DELETING: a integração está sendo excluída.
  - SYNCING: a integração está sincronizando.
  - NEEDS_ATTENTION: a integração precisa de atenção, como sincronização.

- `CreateTime`: obrigatório: carimbo de data e hora.

  A hora em que a integração foi criada (UTC).

- `Errors`: um array de objetos IntegrationError.

  Uma lista de erros associados à integração.

- `DataFilter`: string UTF-8 com no mínimo 1 e no máximo 2.048 bytes de comprimento.

  Seleciona tabelas de origem para a integração usando a sintaxe do filtro Maxwell.

Erros

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `IntegrationNotFoundFault`
- `IntegrationConflictOperationFault`
- `InvalidIntegrationStateFault`
- `EntityNotFoundException`
- `InternalServiceException`
- `ConflictException`
- `InvalidStateException`
- `InvalidInputException`

Ação DescribeInboundIntegrations (Python: describe_inbound_integrations)

Retorna uma lista de integrações de entrada para a integração especificada.

Solicitação

- `IntegrationArn` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da integração.

- `Marker` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

Um token para especificar onde iniciar a paginação. Esse é o marcador de uma resposta anteriormente truncada.

- `MaxRecords` – Número (íntegro).

  O número total de itens para retornar na saída.

- `TargetArn` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) do recurso de destino na integração.

Resposta

- `InboundIntegrations`: um array de objetos InboundIntegration.

  Uma lista de integrações de entrada.

- `Marker` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  Um valor que indica o ponto de partida do próximo conjunto de registros de resposta em uma solicitação subsequente.

Erros

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `IntegrationNotFoundFault`
- `TargetResourceNotFound`
- `OperationNotSupportedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação CreateIntegrationTableProperties (Python: create_integration_table_properties)

Essa API é usada para fornecer propriedades de substituição opcionais para as tabelas que precisam ser replicadas. Essas propriedades podem incluir propriedades de filtragem e particionamento das tabelas de origem e de destino. Para definir as propriedades de origem e destino, a mesma API precisa ser invocada com o ARN da conexão do AWS Glue como `ResourceArn` com `SourceTableConfig` e o ARN do banco de dados do AWS Glue como `ResourceArn` com `TargetTableConfig`, respectivamente.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da tabela de destino para a qual devem ser criadas propriedades de tabelas de integração. Atualmente, essa API é compatível apenas com a criação de propriedades de tabelas de integração para tabelas de destino, e o ARN fornecido deve ser o ARN da tabela de destino no AWS Glue Data Catalog. A compatibilidade com a criação de propriedades de tabelas de integração para conexões de origem (usando o ARN da conexão) ainda não foi implementada e será adicionada em uma versão futura.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome da tabela a ser replicada.
- `SourceTableConfig` – Um objeto SourceTableConfig.

  Uma estrutura para a configuração da tabela de origem. Consulte a estrutura `SourceTableConfig` para ver a lista de propriedades de fontes compatíveis.
- `TargetTableConfig` – Um objeto TargetTableConfig.

  Uma estrutura para a configuração da tabela de destino.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação UpdateIntegrationTableProperties (Python: update_integration_table_properties)

Essa API é usada para fornecer propriedades de substituição opcionais para as tabelas que precisam ser replicadas. Essas propriedades podem incluir propriedades de filtragem e particionamento das tabelas de origem e de destino. Para definir as propriedades de origem e destino, a mesma API precisa ser invocada com o ARN da conexão do AWS Glue como `ResourceArn` com `SourceTableConfig` e o ARN do banco de dados do AWS Glue como `ResourceArn` com `TargetTableConfig`, respectivamente.

A substituição será refletida em todas as integrações usando o mesmo `ResourceArn` e a mesma tabela de origem.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome da tabela a ser replicada.
- `SourceTableConfig` – Um objeto SourceTableConfig.

  Uma estrutura para a configuração da tabela de origem.
- `TargetTableConfig` – Um objeto TargetTableConfig.

Uma estrutura para a configuração da tabela de destino.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação GetIntegrationTableProperties (Python: get_integration_table_properties)

Essa API é usada para recuperar propriedades de substituição opcionais para as tabelas que precisam ser replicadas. Essas propriedades podem incluir propriedades de filtragem e partição das tabelas de origem e de destino.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da tabela de destino para a qual devem ser recuperadas as propriedades de tabelas de integração. Atualmente, essa API é compatível apenas a recuperação de propriedades de tabelas de integração para tabelas de destino, e o ARN fornecido deve ser o ARN da tabela de destino no AWS Glue Data Catalog. A compatibilidade com a recuperação de propriedades de tabelas de integração para conexões de origem (usando o ARN da conexão) ainda não foi implementada e será adicionada em uma versão futura.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

O nome da tabela a ser replicada.

Resposta

- `ResourceArn` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome do recurso da Amazon (ARN) da tabela de destino para a qual devem ser recuperadas as propriedades de tabelas de integração. Atualmente, essa API é compatível apenas a recuperação de propriedades de tabelas de integração para tabelas de destino, e o ARN fornecido deve ser o ARN da tabela de destino no AWS Glue Data Catalog. A compatibilidade com a recuperação de propriedades de tabelas de integração para conexões de origem (usando o ARN da conexão) ainda não foi implementada e será adicionada em uma versão futura.
- `TableName` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O nome da tabela a ser replicada.
- `SourceTableConfig` – Um objeto SourceTableConfig.

  Uma estrutura para a configuração da tabela de origem.
- `TargetTableConfig` – Um objeto TargetTableConfig.

  Uma estrutura para a configuração da tabela de destino.

Erros

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação DeleteIntegrationTableProperties (Python: delete_integration_table_properties)

Exclui as propriedades de tabela que foram criadas para as tabelas que precisam ser replicadas.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.
- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O nome da tabela a ser replicada.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `ValidationException`
- `AccessDeniedException`
- `ResourceNotFoundException`
- `InternalServerException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação CreateIntegrationResourceProperty (Python: create_integration_resource_property)

Essa API pode ser usada para configurar a `ResourceProperty` da conexão do AWS Glue (para a origem) ou o ARN do banco de dados do AWS Glue (para o destino). Essas propriedades podem incluir o perfil para acessar a conexão ou o banco de dados. Para definir as propriedades de

origem e destino, a mesma API precisa ser invocada com o ARN da conexão do AWS Glue como `ResourceArn` com `SourceProcessingProperties` e o ARN do banco de dados do AWS Glue como `ResourceArn` com `TargetProcessingProperties`, respectivamente.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.
- `SourceProcessingProperties` – Um objeto SourceProcessingProperties.

  As propriedades do recurso associadas à origem da integração.
- `TargetProcessingProperties` – Um objeto TargetProcessingProperties.

  As propriedades do recurso associadas ao destino da integração.

Resposta

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.
- `SourceProcessingProperties` – Um objeto SourceProcessingProperties.

  As propriedades do recurso associadas à origem da integração.
- `TargetProcessingProperties` – Um objeto TargetProcessingProperties.

  As propriedades do recurso associadas ao destino da integração.

Erros

- `ValidationException`
- `AccessDeniedException`
- `ConflictException`
- `InternalServerException`
- `ResourceNotFoundException`

- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação UpdateIntegrationResourceProperty (Python: update_integration_resource_property)

Essa API pode ser usada para atualizar a `ResourceProperty` da conexão do AWS Glue (para a origem) ou o ARN do banco de dados do AWS Glue (para o destino). Essas propriedades podem incluir o perfil para acessar a conexão ou o banco de dados. Como o mesmo recurso pode ser usado em várias integrações, a atualização das propriedades do recurso afetará todas as integrações que o usam.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.
- `SourceProcessingProperties` – Um objeto SourceProcessingProperties.

  As propriedades do recurso associadas à origem da integração.
- `TargetProcessingProperties` – Um objeto TargetProcessingProperties.

  As propriedades do recurso associadas ao destino da integração.

Resposta

- `ResourceArn` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.
- `SourceProcessingProperties` – Um objeto SourceProcessingProperties.

  As propriedades do recurso associadas à origem da integração.
- `TargetProcessingProperties` – Um objeto TargetProcessingProperties.

  As propriedades do recurso associadas ao destino da integração.

Erros

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `ResourceNotFoundException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação GetIntegrationResourceProperty (Python: get_integration_resource_property)

Essa API é usada para atualizar a `ResourceProperty` da conexão do AWS Glue (para a origem) ou o ARN do banco de dados do AWS Glue (para o destino)

Solicitação

- `ResourceArn`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.

Resposta

- `ResourceArn` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  O ARN da conexão da origem ou o ARN do banco de dados do destino.
- `SourceProcessingProperties` – Um objeto SourceProcessingProperties.

  As propriedades do recurso associadas à origem da integração.
- `TargetProcessingProperties` – Um objeto TargetProcessingProperties.

  As propriedades do recurso associadas ao destino da integração.

Erros

- `ValidationException`
- `AccessDeniedException`
- `InternalServerException`
- `ResourceNotFoundException`
- `EntityNotFoundException`
- `InternalServiceException`
- `InvalidInputException`

Ação UntagResource (Python: untag_resource)

Remove as tags especificadas de um recurso de integração.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do recurso de integração.
- `TagsToRemove`: obrigatório: uma matriz de strings UTF-8, no máximo 50 strings.

  Uma lista das tags de metadados a serem removidas do recurso.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `ResourceNotFoundException`

Ação ListTagsForResource (Python: list_tags_for_resource)

Lista as tags de metadados atribuídas ao recurso especificado.

Solicitação

- `ResourceARN`: obrigatório: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O ARN do recurso.

Resposta

- `Tags`: uma matriz de objetos Tag, não mais do que dez estruturas.

  Uma lista de tags.

Erros

- `ResourceNotFoundException`

Exceções

- Estrutura ResourceNotFoundException
- Estrutura InternalServiceException
- Estrutura IntegrationAlreadyExistsFault
- Estrutura IntegrationConflictOperationFault
- Estrutura IntegrationQuotaExceededFault
- Estrutura KMSKeyNotAccessibleFault
- Estrutura IntegrationNotFoundFault
- Estrutura TargetResourceNotFound
- Estrutura InvalidIntegrationStateFault

Estrutura ResourceNotFoundException

Não foi possível encontrar o recurso.

Campos

- `Message` – String UTF-8.

Uma mensagem descrevendo o problema.

Estrutura InternalServiceException

Ocorreu um erro interno do servidor.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura IntegrationAlreadyExistsFault

A integração especificada já existe.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura IntegrationConflictOperationFault

A operação solicitada está em conflito com outra operação.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura IntegrationQuotaExceededFault

Os dados processados por meio da sua integração excederam sua cota.

Campos

- `Message` – String UTF-8.

Uma mensagem descrevendo o problema.

Estrutura KMSKeyNotAccessibleFault

A chave do KMS especificada não está acessível.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura IntegrationNotFoundFault

Não foi possível encontrar a integração especificada.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura TargetResourceNotFound

Não foi possível encontrar o recurso de destino.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura InvalidIntegrationStateFault

A integração está em um estado inválido.

Campos

- `Message` – String UTF-8.

Uma mensagem descrevendo o problema.

Sessões API interativas

A API de sessões interativas descreve a API do AWS Glue relacionada ao uso de sessões interativas do AWS Glue para criar e testar scripts de extração, transformação e carregamento (ETL) para a integração de dados.

Tipos de dados

- Estrutura Session
- Estrutura SessionCommand
- Estrutura Statement
- Estrutura StatementOutput
- Estrutura StatementOutputData
- Estrutura ConnectionsList

Estrutura Session

O período em que um ambiente do runtime remoto do Spark está sendo executado.

Campos

- `Id` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da sessão.
- `CreatedOn` – Timestamp.

  A data e a hora em que a sessão foi criada.
- `Status` – String UTF-8 (valores válidos: `PROVISIONING` | `READY` | `FAILED` | `TIMEOUT` | `STOPPING` | `STOPPED`).

  O status da sessão.
- `ErrorMessage`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

A mensagem de erro exibida durante a sessão.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A descrição da sessão.

- `Role` – String UTF-8, superior a 20 e inferior a 2048 bytes de comprimento, correspondente a Custom string pattern #30.

  O nome ou nome de recurso da Amazon (ARN) da função do IAM associada à sessão.

- `Command` – Um objeto SessionCommand.

  O comando Object.Consulte SessionCommand.

- `DefaultArguments` – Uma matriz de mapas de pares de valores-chave, não mais de 75 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes, correspondente a Custom string pattern #31.

  Cada valor é uma string UTF-8, com comprimento não superior a 4096 bytes, correspondente a URI address multi-line string pattern.

  Um array de mapa dos pares de valor-chave. O máximo é de 75 pares.

- `Connections` – Um objeto ConnectionsList.

  O número de conexões usadas para a sessão.

- `Progress` – Número (duplo).

  O andamento da execução do código da sessão.

- `MaxCapacity` – Número (duplo).

  O número de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando o trabalho for executado. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura SecurityConfiguration a ser usada com a sessão.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  A versão AWS Glue determina as versões do Apache Spark e do Python compatíveis com o AWS Glue. O GlueVersion deve ser maior que 2.0.

- `DataAccessId` - String UTF-8, não menos do que 1 ou superior a 36 bytes de comprimento.

  O ID de acesso a dados da sessão.

- `PartitionId` - String UTF-8, não menos do que 1 ou superior a 36 bytes de comprimento.

  O ID da partição da sessão.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `WorkerType` para usar na sessão.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando uma sessão é executada. Aceita um valor de `G.1X`, `G.2X`, `G.4X` ou `G.8X` para sessões do Spark. Aceita o valor `Z.2X` para sessões do Ray.

- `CompletedOn` – Timestamp.

  A data e a hora em que a execução desse trabalho foi concluída.

- `ExecutionTime` – Número (duplo).

  O tempo total durante o qual a sessão foi executada.

- `DPUSeconds` – Número (duplo).

  As DPUs consumidas pela sessão (fórmula: ExecutionTime * MaxCapacity).

- `IdleTimeout` – Número (íntegro).

  O número de minutos de natividade até esgotar o tempo limite da sessão.

- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado à sessão.

Estrutura SessionCommand

O `SessionCommand` que executa esse trabalho.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Especifica o nome do SessionCommand. Pode ser “glueetl” ou “glueestreaming”.
- `PythonVersion` – String UTF-8 correspondente a Custom string pattern #48.

  Especifica a versão usada do Python. A versão do Python indica a versão compatível com trabalhos do tipo Spark.

Estrutura Statement

A declaração ou solicitação para que uma ação específica ocorra em uma sessão.

Campos

- `Id` – Número (íntegro).

  O ID da instrução.
- `Code` – String UTF-8.

  O código de execução da instrução.
- `State` – String UTF-8 (valores válidos: `WAITING` | `RUNNING` | `AVAILABLE` | `CANCELLING` | `CANCELLED` | `ERROR`).

  O estado enquanto a solicitação é acionada.
- `Output` – Um objeto StatementOutput.

  A saída em JSON.
- `Progress` – Número (duplo).

  O progresso da execução do código.
- `StartedOn` – Número (extenso).

A hora e a data unix em que a definição de trabalho foi iniciada.

- `CompletedOn` – Número (extenso).

  A hora e a data unix em que a definição de trabalho foi concluída.

Estrutura StatementOutput

O resultado da execução de código no formato JSON.

Campos

- `Data` – Um objeto StatementOutputData.

  O resultado da execução de código.

- `ExecutionCount` – Número (íntegro).

  A contagem de execução da saída.

- `Status` – String UTF-8 (valores válidos: `WAITING` | `RUNNING` | `AVAILABLE` | `CANCELLING` | `CANCELLED` | `ERROR`).

  O status da saída do código de execução.

- `ErrorName` – String UTF-8.

  O nome do erro na saída.

- `ErrorValue` – String UTF-8.

  O valor de erro da saída.

- `Traceback` – Uma matriz de strings UTF-8.

  O traceback da saída.

Estrutura StatementOutputData

O resultado da execução de código no formato JSON.

Campos

- `TextPlain` – String UTF-8.

O resultado da execução do código no formato de texto.

Estrutura ConnectionsList

Especifica as conexões usadas por um trabalho.

Campos

- `Connections`: uma matriz de strings UTF-8, no máximo mil strings.

  Uma lista das conexões usadas pelo trabalho.

Operações

- Ação CreateSession (Python: create_session)
- Ação StopSession (Python: stop_session)
- Ação DeleteSession (Python: delete_session)
- Ação GetSession (Python: get_session)
- Ação ListSessions (Python: list_sessions)
- Ação RunStatement (Python: run_statement)
- Ação CancelStatement (Python: cancel_statement)
- Ação GetStatement (Python: get_statement)
- Ação ListStatations (Python: list_statements)

Ação CreateSession (Python: create_session)

Cria uma nova sessão..

Solicitação

Solicitação para criar uma nova sessão.

- `Id`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da solicitação de sessão.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A descrição da sessão.

- `Role` – Obrigatório: string UTF-8, não inferior a 20 ou superior a 2048 bytes de comprimento, correspondendo a Custom string pattern #30.

  O ARN da função do &IAM

- `Command` – Obrigatório: um objeto SessionCommand.

  O `SessionCommand` que executa esse trabalho.

- `Timeout` – Número (inteiro), pelo menos 1.

  O número de minutos até esgotar o tempo limite da sessão. O valor padrão para trabalhos de ETL no Spark é 48 horas, equivalente a 2.880 minutos. Consulte a documentação para outros tipos de trabalho.

- `IdleTimeout` – Número (inteiro), pelo menos 1.

  O número de minutos de natividade até esgotar o tempo limite da sessão. O padrão para trabalhos de ETL do Spark é o valor do tempo limite. Consulte a documentação para outros tipos de trabalho.

- `DefaultArguments` – Uma matriz de mapas de pares de valores-chave, não mais de 75 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes, correspondente a Custom string pattern #31.

  Cada valor é uma string UTF-8, com comprimento não superior a 4096 bytes, correspondente a URI address multi-line string pattern.

  Um array de mapa dos pares de valor-chave. O máximo é de 75 pares.

- `Connections` – Um objeto ConnectionsList.

  O número de conexões usadas para a sessão.

- `MaxCapacity` – Número (duplo).

  O número de unidades de processamento de dados (DPUs) do AWS Glue que poderão ser alocadas quando o trabalho for executado. Uma DPU é uma medida relativa do poder de

processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `WorkerType` para usar na sessão.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando um trabalho é executado. Aceita um valor de G.1X, G.2X, G.4X ou G.8X para trabalhos do Spark. Aceita o valor Z.2X para cadernos do Ray.

  - Para o tipo de operador `G.1X`, cada operador é mapeado em 1 DPU (4 vCPU, 16 GB de memória) com 94 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.2X`, cada operador é mapeado em 2 DPU (8 vCPU, 32 GB de memória) com 138 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para workloads, como transformações de dados, uniões e consultas, para oferecer uma maneira escalável e econômica de executar a maioria dos trabalhos.
  - Para o tipo de operador `G.4X`, cada operador é mapeado em 4 DPU (16 vCPU, 64 GB de memória) com 256 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior nas seguintes regiões da AWS: Leste dos EUA (Ohio), Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Singapura), Ásia-Pacífico (Sydney), Ásia-Pacífico (Tóquio), Canadá (Central), Europa (Frankfurt), Europa (Irlanda) e Europa (Estocolmo).
  - Para o tipo de operador `G.8X`, cada operador é mapeado em 8 DPU (32 vCPU, 128 GB de memória) com 512 GB de disco e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos cujas workloads contêm as transformações, agregações, uniões e consultas mais exigentes. Esse tipo de operador está disponível somente para trabalhos de ETL do Spark no AWS Glue versão 3.0 ou posterior, nas mesmas regiões da AWS compatíveis com o tipo de operador `G.4X`.
  - Para o tipo de operador `Z.2X`, cada operador é mapeado em 2 M-DPU (8 vCPUs, 64 GB de memória) com 128 GB de disco e fornece até 8 operadores do Ray baseados no autoscaler.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura SecurityConfiguration a ser usada com a sessão.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  A versão AWS Glue determina as versões do Apache Spark e do Python compatíveis com o AWS Glue. O GlueVersion deve ser maior que 2.0.

- `DataAccessId` - String UTF-8, não menos do que 1 ou superior a 36 bytes de comprimento.

  O ID de acesso a dados da sessão.

- `PartitionId` - String UTF-8, não menos do que 1 ou superior a 36 bytes de comprimento.

  O ID da partição da sessão.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  O mapa dos pares de valores-chave (tags) pertencentes à sessão.

- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação.

- `ProfileName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um perfil de uso do AWS Glue associado à sessão.

Resposta

- `Session` – Um objeto Sessão.

  Retorna o objeto de sessão na resposta.

Erros

- `AccessDeniedException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`

Ação StopSession (Python: stop_session)

Interrompa a sessão.

Solicitação

- `Id`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da sessão a ser interrompida.
- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação.

Resposta

- `Id` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Retorna o ID da sessão interrompida.

Erros

- `AccessDeniedException`

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`
- `ConcurrentModificationException`

Ação DeleteSession (Python: delete_session)

Exclui a sessão.

Solicitação

- `Id`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da sessão a ser excluído.
- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  O nome da origem da solicitação de sessão de exclusão.

Resposta

- `Id` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Retorna o ID da sessão excluída.

Erros

- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`
- `ConcurrentModificationException`

Ação GetSession (Python: get_session)

Recupera a sessão.

Solicitação

- `Id`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da sessão.
- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação.

Resposta

- `Session` – Um objeto Sessão.

  O objeto de sessão é retornado na resposta.

Erros

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação ListSessions (Python: list_sessions)

Recupere uma lista de sessões.

Solicitação

- `NextToken`: string UTF-8, não superior a 400.000 bytes de comprimento.

  O token para o próximo conjunto de resultados ou nulo se não houver mais resultados.

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Tags pertencentes à sessão.

- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação.

Resposta

- `Ids` – Uma matriz de strings UTF-8.

  Retorna o ID da sessão.

- `Sessions`: um array de objetos Sessão.

  Retorna o objeto de sessão.

- `NextToken`: string UTF-8, não superior a 400.000 bytes de comprimento.

  O token para o próximo conjunto de resultados ou nulo se não houver mais resultados.

Erros

- `AccessDeniedException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação RunStatement (Python: run_statement)

Executa a instrução.

Solicitação

- `SessionId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da sessão da instrução a ser executado.
- `Code`: Obrigatório: string UTF-8, não superior a 68000 bytes de comprimento.

  O código da instrução a ser executado.
- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação.

Resposta

- `Id` – Número (íntegro).

  Retorna o ID da instrução que foi executada.

Erros

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`
- `ResourceNumberLimitExceededException`
- `IllegalSessionStateException`

Ação CancelStatement (Python: cancel_statement)

Cancela a instrução.

Solicitação

- `SessionId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da sessão da instrução a ser cancelado.
- `Id`: obrigatório: número (inteiro).

  O ID da instrução a ser cancelado.
- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação para cancelar a instrução.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`

Ação GetStatement (Python: get_statement)

Recupera a instrução.

Solicitação

- `SessionId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da sessão da instrução.

- `Id`: obrigatório: número (inteiro).

  O ID da instrução.

- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação.

Resposta

- `Statement` – Um objeto Declaração.

  Recupera a instrução.

Erros

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`

Ação ListStatations (Python: list_statements)

Lista as instruções para a sessão.

Solicitação

- `SessionId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da sessão das instruções.

- `RequestOrigin`: string UTF-8 com no mínimo 1 e no máximo 128 bytes de comprimento e correspondente a Custom string pattern #31.

  A origem da solicitação para listar instruções.

- `NextToken`: string UTF-8, não superior a 400.000 bytes de comprimento.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `Statements`: um array de objetos Declaração.

  Retorna a lista de instruções.
- `NextToken`: string UTF-8, não superior a 400.000 bytes de comprimento.

  Um token de continuação, se nem todas as instruções ainda tiverem sido retornadas.

Erros

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `IllegalSessionStateException`

API de endpoints de desenvolvimento

A API Development endpoints descreve a API do AWS Glue relacionada a testes com uso de um DevEndpoint personalizado.

Tipos de dados

- Estrutura DevEndpoint
- Estrutura DevEndpointCustomLibraries

Estrutura DevEndpoint

Um endpoint de desenvolvimento no qual um desenvolvedor pode depurar scripts de extração, transformação e carregamento (ETL) remotamente.

Campos

- `EndpointName` – String UTF-8.

  O nome da `DevEndpoint`.

- `RoleArn` – String UTF-8 correspondente a AWS IAM ARN string pattern.

  O nome de recurso da Amazon (ARN) da função do IAM usada nesse `DevEndpoint`.

- `SecurityGroupIds` – Uma matriz de strings UTF-8.

  Uma lista dos identificadores de grupo de segurança usados neste `DevEndpoint`.

- `SubnetId` – String UTF-8.

  O ID de sub-rede para esse `DevEndpoint`.

- `YarnEndpointAddress` – String UTF-8.

  O endereço do endpoint YARN usado por este `DevEndpoint`.

- `PrivateAddress` – String UTF-8.

  Um endereço IP privado para acessar o `DevEndpoint` em uma VPC se o `DevEndpoint` for criado dentro de um. O campo `PrivateAddress` está presente somente quando você cria o `DevEndpoint` na VPC.

- `ZeppelinRemoteSparkInterpreterPort` – Número (íntegro).

  A porta Apache Zeppelin para o intérprete Apache Spark remoto.

- `PublicAddress` – String UTF-8.

  O endereço IP público usado por esse `DevEndpoint`. O campo `PublicAddress` está presente somente quando você cria uma nuvem privada não virtual (VPC) `DevEndpoint`.

- `Status` – String UTF-8.

  O status atual deste `DevEndpoint`.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido alocado para o endpoint de desenvolvimento. Aceita um valor de Standard (Padrão), G.1X ou G.2X.

- Para o tipo de operador `Standard`, cada operador fornece 4 vCPU, 16 GB de memória e um disco de 50 GB e 2 executores por operador.
- Para o tipo de operador `G.1X`, cada operador é mapeado para 1 DPU (4 vCPU, 16 GB de memória, disco de 64 GB), e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória.
- Para o tipo de operador `G.2X`, cada operador é mapeado para 2 DPU (8 vCPU, 32 GB de memória, disco de 128 GB), e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória.

Problema conhecido: quando um endpoint de desenvolvimento é criado com a configuração `WorkerType` `G.2X`, os drivers do Spark para o endpoint de desenvolvimento são executados em 4 vCPUs, 16 GB de memória e um disco de 64 GB.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  A versão do Glue determina as versões do Apache Spark e do Python compatíveis com o AWS Glue. A versão do Python indica a versão compatível para executar seus scripts de ETL em endpoints de desenvolvimento.

  Para obter mais informações sobre as versões disponíveis do AWS Glue e as versões correspondentes do Spark e do Python, consulte Versão do Glue no guia do desenvolvedor.

  Os endpoints de desenvolvimento criados sem especificar uma versão do Glue usam como padrão o Glue 0.9.

  É possível especificar uma versão do suporte do Python para endpoints de desenvolvimento usando o parâmetro `Arguments` nas APIs `UpdateDevEndpoint` ou `CreateDevEndpoint`. Se nenhum argumento for fornecido, a versão usará o Python 2 como padrão.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de um `workerType` definido que são alocados para o endpoint de desenvolvimento.

  O número máximo de operadores que você pode definir são 299 para `G.1X` e 149 para `G.2X`.

- `NumberOfNodes` – Número (íntegro).

  O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para esse `DevEndpoint`.

- `AvailabilityZone` – String UTF-8.

  A zona de disponibilidade da AWS onde esse `DevEndpoint` está localizado.

- `VpcId` – String UTF-8.

  O ID da nuvem privada virtual (VPC) usada por esse `DevEndpoint`.

- `ExtraPythonLibsS3Path` – String UTF-8.

  Os caminhos para um ou mais bibliotecas Python em um bucket do Amazon S3 que deve ser carregado no seu `DevEndpoint`. Vários valores devem ser caminhos completos separados por uma vírgula.

  > **Note**
  >
  > Você pode usar apenas bibliotecas Python puras com um `DevEndpoint`. Bibliotecas que contam com extensões C, como a biblioteca de análise de dados Python 8pandas, não são compatíveis no momento.

- `ExtraJarsS3Path` – String UTF-8.

  Os caminhos para um ou mais arquivos `.jar` do Java em um bucket do S3 que deve ser carregado no `DevEndpoint`.

  > **Note**
  >
  > Você pode usar apenas bibliotecas Java/Scala com um `DevEndpoint`.

- `FailureReason` – String UTF-8.

  O motivo da falha atual neste `DevEndpoint`.

- `LastUpdateStatus` – String UTF-8.

  O status da última atualização.

- `CreatedTimestamp` – Timestamp.

  O momento em que este DevEndpoint foi criado.

- `LastModifiedTimestamp` – Timestamp.

  O momento em que esse `DevEndpoint` foi modificado pela última vez.

- `PublicKey` – String UTF-8.

  A chave pública a ser usada por esse `DevEndpoint` para autenticação. Este atributo é fornecido para compatibilidade com versões anteriores, pois o atributo recomendado para uso são chaves públicas.

- `PublicKeys` – Uma matriz de strings UTF-8, no máximo 5 strings.

  Uma lista de chaves públicas a serem usadas pelos `DevEndpoints` para autenticação. O uso desse atributo é preferido em vez de uma única chave pública, pois as chaves públicas permitem que você tenha uma chave privada diferente por cliente.

  > **Note**
  >
  > Se você tiver criado um endpoint com uma chave pública, deverá remover essa chave para poder definir uma lista de chaves públicas. Chame a operação da API `UpdateDevEndpoint` com o conteúdo da chave pública no atributo `deletePublicKeys` e a lista de novas chaves no atributo `addPublicKeys`.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com esse `DevEndpoint`.

- `Arguments`: uma matriz de mapa dos pares de chave-valor, não mais do que 100 pares.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  Um mapa de argumentos usados para configurar o `DevEndpoint`.

  Os argumentos válidos são:

  - `"--enable-glue-datacatalog": ""`

  É possível especificar uma versão do suporte do Python para endpoints de desenvolvimento usando o parâmetro `Arguments` nas APIs `UpdateDevEndpoint` ou `CreateDevEndpoint`. Se nenhum argumento for fornecido, a versão usará o Python 2 como padrão.

Estrutura DevEndpointCustomLibraries

Bibliotecas personalizadas a serem carregadas em um endpoint de desenvolvimento.

Campos

- `ExtraPythonLibsS3Path` – String UTF-8.

  Os caminhos para uma ou mais bibliotecas Python em um bucket do Amazon Simple Storage Service (Amazon S3) que devem ser carregadas no `DevEndpoint`. Vários valores devem ser caminhos completos separados por uma vírgula.

  > **Note**
  >
  > Você pode usar apenas bibliotecas Python puras com um `DevEndpoint`. Bibliotecas que contam com extensões C, como a biblioteca de análise de dados Python 8pandas, não são compatíveis no momento.

- `ExtraJarsS3Path` – String UTF-8.

  Os caminhos para um ou mais arquivos `.jar` do Java em um bucket do S3 que deve ser carregado no `DevEndpoint`.

  > **Note**
  >
  > Você pode usar apenas bibliotecas Java/Scala com um `DevEndpoint`.

Operações

- Ação CreateDevEndpoint (Python: create_dev_endpoint)
- Ação UpdateDevEndpoint (Python: update_dev_endpoint)
- Ação DeleteDevEndpoint (Python: delete_dev_endpoint)
- Ação GetDevEndpoint (Python: get_dev_endpoint)
- Ação GetDevEndpoints (Python: get_dev_endpoints)
- Ação BatchGetDevEndpoints (Python: batch_get_dev_endpoints)
- Ação ListDevEndpoints (Python: list_dev_endpoints)

Ação CreateDevEndpoint (Python: create_dev_endpoint)

Cria um endpoint de desenvolvimento.

Solicitação

- `EndpointName` – Obrigatório: string UTF-8.

  O nome a ser atribuído ao novo `DevEndpoint`.

- `RoleArn` – Obrigatório: string UTF-8, correspondente a AWS IAM ARN string pattern.

  A função do IAM para o `DevEndpoint`.

- `SecurityGroupIds` – Uma matriz de strings UTF-8.

  IDs dos grupos de segurança a serem usados pelo novo `DevEndpoint`.

- `SubnetId` – String UTF-8.

  O ID de sub-rede para o novo `DevEndpoint` a ser usado.

- `PublicKey` – String UTF-8.

  A chave pública a ser usada por esse `DevEndpoint` para autenticação. Este atributo é fornecido para compatibilidade com versões anteriores, pois o atributo recomendado para uso são chaves públicas.

- `PublicKeys` – Uma matriz de strings UTF-8, no máximo 5 strings.

  Uma lista de chaves públicas a serem usadas pelos endpoints de desenvolvimento para autenticação. O uso desse atributo é preferido em vez de uma única chave pública, pois as chaves públicas permitem que você tenha uma chave privada diferente por cliente.

  > **Note**
  >
  > Se você tiver criado um endpoint com uma chave pública, deverá remover essa chave para poder definir uma lista de chaves públicas. Chame a API `UpdateDevEndpoint` com o conteúdo da chave pública no atributo `deletePublicKeys` e a lista de novas chaves no atributo `addPublicKeys`.

- `NumberOfNodes` – Número (íntegro).

O número de unidades de processamento de dados (DPUs) do AWS Glue a serem alocadas para esse `DevEndpoint`.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido alocado para o endpoint de desenvolvimento. Aceita um valor de Standard (Padrão), G.1X ou G.2X.

  - Para o tipo de operador `Standard`, cada operador fornece 4 vCPU, 16 GB de memória e um disco de 50 GB e 2 executores por operador.
  - Para o tipo de operador `G.1X`, cada operador é mapeado para 1 DPU (4 vCPU, 16 GB de memória, disco de 64 GB), e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória.
  - Para o tipo de operador `G.2X`, cada operador é mapeado para 2 DPU (8 vCPU, 32 GB de memória, disco de 128 GB), e fornece 1 executor por operador. Recomendamos esse tipo de operador para trabalhos com uso intensivo de memória.

  Problema conhecido: quando um endpoint de desenvolvimento é criado com a configuração `WorkerType` `G.2X`, os drivers do Spark para o endpoint de desenvolvimento são executados em 4 vCPUs, 16 GB de memória e um disco de 64 GB.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  A versão do Glue determina as versões do Apache Spark e do Python compatíveis com o AWS Glue. A versão do Python indica a versão compatível para executar seus scripts de ETL em endpoints de desenvolvimento.

  Para obter mais informações sobre as versões disponíveis do AWS Glue e as versões correspondentes do Spark e do Python, consulte Versão do Glue no guia do desenvolvedor.

  Os endpoints de desenvolvimento criados sem especificar uma versão do Glue usam como padrão o Glue 0.9.

  É possível especificar uma versão do suporte do Python para endpoints de desenvolvimento usando o parâmetro `Arguments` nas APIs `UpdateDevEndpoint` ou `CreateDevEndpoint`. Se nenhum argumento for fornecido, a versão usará o Python 2 como padrão.

- `NumberOfWorkers` – Número (íntegro).

O número de operadores de um `workerType` definido que são alocados para o endpoint de desenvolvimento.

O número máximo de operadores que você pode definir são 299 para `G.1X` e 149 para `G.2X`.

- `ExtraPythonLibsS3Path` – String UTF-8.

  Os caminhos para um ou mais bibliotecas Python em um bucket do Amazon S3 que deve ser carregado no seu `DevEndpoint`. Vários valores devem ser caminhos completos separados por uma vírgula.

  > **Note**
  >
  > Você pode usar apenas bibliotecas Python puras com um `DevEndpoint`. Bibliotecas que contam com extensões C, como a biblioteca de análise de dados Python pandas, ainda não são compatíveis.

- `ExtraJarsS3Path` – String UTF-8.

  Os caminhos para um ou mais arquivos `.jar` do Java em um bucket do S3 que deve ser carregado no `DevEndpoint`.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com esse `DevEndpoint`.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags a serem usadas com esse DevEndpoint. Você pode usar tags para limitar o acesso ao DevEndpoint. Para obter mais informações sobre tags no AWS Glue, consulte Tags da AWS no AWS Glue no guia do desenvolvedor.

- `Arguments`: uma matriz de mapa dos pares de chave-valor, não mais do que 100 pares.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

Um mapa de argumentos usados para configurar o `DevEndpoint`.

Resposta

- `EndpointName` – String UTF-8.

  O nome atribuído ao novo `DevEndpoint`.

- `Status` – String UTF-8.

  O status atual do novo `DevEndpoint`.

- `SecurityGroupIds` – Uma matriz de strings UTF-8.

  Os grupos de segurança atribuídos ao novo `DevEndpoint`.

- `SubnetId` – String UTF-8.

  O ID de sub-rede atribuído ao novo `DevEndpoint`.

- `RoleArn` – String UTF-8 correspondente a AWS IAM ARN string pattern.

  O nome de recurso da Amazon (ARN) da função atribuída ao novo `DevEndpoint`.

- `YarnEndpointAddress` – String UTF-8.

  O endereço do endpoint YARN usado por esse `DevEndpoint`.

- `ZeppelinRemoteSparkInterpreterPort` – Número (íntegro).

  A porta Apache Zeppelin para o intérprete Apache Spark remoto.

- `NumberOfNodes` – Número (íntegro).

  O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para esse DevEndpoint.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido alocado para o endpoint de desenvolvimento. Deve ser um valor de Standard (Padrão), G.1X ou G.2X.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

A versão do Glue determina as versões do Apache Spark e do Python compatíveis com o AWS Glue. A versão do Python indica a versão compatível para executar seus scripts de ETL em endpoints de desenvolvimento.

Para obter mais informações sobre as versões disponíveis do AWS Glue e as versões correspondentes do Spark e do Python, consulte Versão do Glue no guia do desenvolvedor.

- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de um `workerType` definido que são alocados para o endpoint de desenvolvimento.

- `AvailabilityZone` – String UTF-8.

  A zona de disponibilidade da AWS onde esse `DevEndpoint` está localizado.

- `VpcId` – String UTF-8.

  O ID da nuvem privada virtual (VPC) usada por esse `DevEndpoint`.

- `ExtraPythonLibsS3Path` – String UTF-8.

  Os caminhos para um ou mais bibliotecas Python em um bucket do S3 que será carregado no `DevEndpoint`.

- `ExtraJarsS3Path` – String UTF-8.

  Os caminhos para um ou mais arquivos `.jar` do Java em um bucket do S3 que será carregado no `DevEndpoint`.

- `FailureReason` – String UTF-8.

  O motivo da falha atual neste `DevEndpoint`.

- `SecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da estrutura de `SecurityConfiguration` a ser usada com esse `DevEndpoint`.

- `CreatedTimestamp` – Timestamp.

  O momento em que esse `DevEndpoint` foi criado.

- `Arguments`: uma matriz de mapa dos pares de chave-valor, não mais do que 100 pares.

  Cada chave é uma sequência de caracteres UTF-8.

Cada valor é uma sequência de caracteres UTF-8.

O mapa de argumentos usados para configurar esse `DevEndpoint`.

Os argumentos válidos são:

- `"--enable-glue-datacatalog": ""`

É possível especificar uma versão do suporte do Python para endpoints de desenvolvimento usando o parâmetro `Arguments` nas APIs `UpdateDevEndpoint` ou `CreateDevEndpoint`. Se nenhum argumento for fornecido, a versão usará o Python 2 como padrão.

Erros

- `AccessDeniedException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`
- `ResourceNumberLimitExceededException`

Ação UpdateDevEndpoint (Python: update_dev_endpoint)

Atualiza um endpoint de desenvolvimento especificado.

Solicitação

- `EndpointName` – Obrigatório: string UTF-8.

  O nome do `DevEndpoint` a ser atualizado.

- `PublicKey` – String UTF-8.

  A chave pública a ser usada pelo `DevEndpoint`.

- `AddPublicKeys` – Uma matriz de strings UTF-8, no máximo 5 strings.

A lista de chaves públicas a serem usadas pelo `DevEndpoint`.

- `DeletePublicKeys` – Uma matriz de strings UTF-8, no máximo 5 strings.

  A lista de chaves públicas a serem excluídas do `DevEndpoint`.

- `CustomLibraries` – Um objeto DevEndpointCustomLibraries.

  Bibliotecas personalizadas Python ou Java a serem carregadas no `DevEndpoint`.

- `UpdateEtlLibraries` – Booleano.

  `True`, se a lista de bibliotecas personalizadas a serem carregadas no endpoint de desenvolvimento precisarem ser atualizadas, ou `False`, caso contrário.

- `DeleteArguments` – Uma matriz de strings UTF-8.

  A lista de chaves de argumentos a serem excluídos do mapa de argumentos usado para configurar o `DevEndpoint`.

- `AddArguments`: uma matriz de mapa dos pares de chave-valor, não mais do que 100 pares.

  Cada chave é uma sequência de caracteres UTF-8.

  Cada valor é uma sequência de caracteres UTF-8.

  O mapa de argumentos para adicionar o mapa de argumentos usado para configurar o `DevEndpoint`.

  Os argumentos válidos são:

  - `"--enable-glue-datacatalog": ""`

  É possível especificar uma versão do suporte do Python para endpoints de desenvolvimento usando o parâmetro `Arguments` nas APIs `UpdateDevEndpoint` ou `CreateDevEndpoint`. Se nenhum argumento for fornecido, a versão usará o Python 2 como padrão.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `ValidationException`

Ação DeleteDevEndpoint (Python: delete_dev_endpoint)

Exclui um endpoint de desenvolvimento especificado.

Solicitação

- `EndpointName` – Obrigatório: string UTF-8.

  O nome da `DevEndpoint`.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação GetDevEndpoint (Python: get_dev_endpoint)

Recupera informações sobre um endpoint de desenvolvimento especificado.

> **Note**
>
> Quando você cria um endpoint de desenvolvimento em uma nuvem privada virtual (VPC), o AWS Glue retorna apenas um endereço IP privado e o campo do endereço IP público campo

não é preenchido. Quando você cria um endpoint de desenvolvimento não seja da VPC, o AWS Glue retorna somente um endereço IP público.

Solicitação

- `EndpointName` – Obrigatório: string UTF-8.

  Nome do `DevEndpoint` para o qual recuperar informações.

Resposta

- `DevEndpoint` – Um objeto DevEndpoint.

  Uma definição de `DevEndpoint`.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação GetDevEndpoints (Python: get_dev_endpoints)

Recupera todos os endpoints de desenvolvimento nessa conta da AWS.

> **Note**
>
> Quando você cria um endpoint de desenvolvimento em uma nuvem privada virtual (VPC), o AWS Glue retorna apenas um endereço IP privado, e o campo do endereço IP público campo não é preenchido. Quando você cria um endpoint de desenvolvimento não seja da VPC, o AWS Glue retorna somente um endereço IP público.

Solicitação

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

O tamanho máximo das informações a serem retornadas.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `DevEndpoints`: um array de objetos DevEndpoint.

  Uma lista de definições de `DevEndpoint`.
- `NextToken` – String UTF-8.

  Um token de continuação, caso nem todas as definições de `DevEndpoint` tenham sido retornadas ainda.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação BatchGetDevEndpoints (Python: batch_get_dev_endpoints)

Retorna uma lista de metadados de recurso para uma lista de nomes de endpoints de desenvolvimento. Depois de chamar a operação `ListDevEndpoints`, você pode chamar essa operação para acessar os dados aos quais você recebeu permissões. Essa operação oferece suporte a todas as permissões do IAM, incluindo condições de permissão que usam tags.

Solicitação

- `customerAccountId` – String UTF-8.

  O ID da conta da AWS.
- `DevEndpointNames` – Obrigatório: uma matriz de strings UTF-8, no mínimo 1 ou mais de 25 strings.

Uma lista de nomes de `DevEndpoint`, que podem ser os nomes retornados da operação `ListDevEndpoint`.

Resposta

- `DevEndpoints`: um array de objetos DevEndpoint.

  Uma lista de definições de `DevEndpoint`.
- `DevEndpointsNotFound`: uma matriz de strings UTF-8, não menos do que 1 ou superior a 25 strings.

  Uma lista de `DevEndpoints` não encontrados.

Erros

- `AccessDeniedException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação ListDevEndpoints (Python: list_dev_endpoints)

Recupera os nomes de todos os recursos do `DevEndpoint` nessa conta da AWS ou os recursos com a tag especificada. Essa operação permite que você veja quais recursos estão disponíveis em sua conta e seus nomes.

Essa operação aceita o campo `Tags` opcional, que pode ser usado como um filtro na resposta, para que recursos com tags possam ser recuperados como um grupo. Se você optar por usar a filtragem por tags, apenas os recursos com a tag serão recuperados.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

O tamanho máximo de uma lista a ser retornada.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Especifica apenas o retorno desses recursos com tags.

Resposta

- `DevEndpointNames` – Uma matriz de strings UTF-8.

  Os nomes de cada `DevEndpoint` na conta de cada `DevEndpoint` com as tags especificadas.
- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não contiver a métrica mais recente disponível.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Registro de esquemas

A API de registro de esquemas descreve os tipos de dados e a API relacionada ao trabalho com esquemas no AWS Glue.

Tipos de dados

- Estrutura RegistryId
- Estrutura RegistryListItem
- Estrutura MetadataInfo
- Estrutura OtherMetadataValueListItem

- Estrutura SchemaListItem
- Estrutura SchemaVersionListItem
- Estrutura MetadataKeyValuePair
- Estrutura SchemaVersionErrorItem
- Estrutura ErrorDetails
- Estrutura SchemaVersionNumber
- Estrutura SchemaId

Estrutura RegistryId

Uma estrutura de wrapper que pode conter o nome de registro e o nome do recurso da Amazon (ARN).

Campos

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  Nome do registro. Usado apenas para pesquisa. Um de `RegistryArn` ou `RegistryName` tem de ser fornecido.
- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  ARN do registro a ser atualizado. Um de `RegistryArn` ou `RegistryName` tem de ser fornecido.

Estrutura RegistryListItem

Uma estrutura que contém os detalhes de um registro.

Campos

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro.
- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

O nome de recurso da Amazon (ARN) do registro.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do registro.

- `Status`: string UTF-8 (valores válidos: `AVAILABLE` | `DELETING`).

  O status do registro.

- `CreatedTime` – String UTF-8.

  A data em que o registro foi criado.

- `UpdatedTime` – String UTF-8.

  A data em que o registro foi atualizado.

Estrutura MetadataInfo

Uma estrutura que contém informações de metadados para uma versão do esquema.

Campos

- `MetadataValue`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #14.

  O valor correspondente da chave de metadados.

- `CreatedTime` – String UTF-8.

  A hora em que a entrada foi criada.

- `OtherMetadataValueList`: um array de objetos OtherMetadataValueListItem.

  Outros metadados pertencentes à mesma chave de metadados.

Estrutura OtherMetadataValueListItem

Uma estrutura que contém outros metadados para uma versão do esquema pertencente à mesma chave de metadados.

Campos

- `MetadataValue`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #14.

  O valor correspondente da chave de metadados para os outros metadados pertencentes à mesma chave de metadados.
- `CreatedTime` – String UTF-8.

  A hora em que a entrada foi criada.

Estrutura SchemaListItem

Um objeto que contém detalhes mínimos para um esquema.

Campos

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro em que o esquema reside.
- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema.
- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do esquema.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição para o esquema.
- `SchemaStatus` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  O status do esquema.
- `CreatedTime` – String UTF-8.

  A data e a hora em que o esquema foi criado.

- `UpdatedTime` – String UTF-8.

  A data e a hora em que o esquema foi atualizado.

Estrutura SchemaVersionListItem

Um objeto que contém os detalhes sobre uma versão do esquema.

Campos

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do esquema.

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O identificador exclusivo da versão do esquema.

- `VersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.

- `Status` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  O status da versão do esquema.

- `CreatedTime` – String UTF-8.

  A data e hora em que a versão do esquema foi criada.

Estrutura MetadataKeyValuePair

Uma estrutura que contém um par de chave-valor para metadados.

Campos

- `MetadataKey`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #14.

  Uma chave de metadados.

- `MetadataValue`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #14.

  O valor correspondente de uma chave de metadados.

Estrutura SchemaVersionErrorItem

Um objeto que contém os detalhes de erro de uma operação em uma versão do esquema.

Campos

- `VersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.
- `ErrorDetails` – Um objeto ErrorDetails.

  Os detalhes do erro para a versão do esquema.

Estrutura ErrorDetails

Um objeto que contém detalhes do erro.

Campos

- `ErrorCode` – String UTF-8.

  O código de erro para um erro.
- `ErrorMessage` – String UTF-8.

  A mensagem de erro para um erro.

Estrutura SchemaVersionNumber

Uma estrutura que contém as informações da versão do esquema.

Campos

- `LatestVersion` – Booleano.

  A versão mais recente disponível para o esquema.

- `VersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.

Estrutura SchemaId

O ID exclusivo do esquema no registro de esquemas do AWS Glue.

Campos

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.
- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.
- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro do esquema que contém o esquema.

Operações

- Ação CreateRegistry (Python: create_registry)
- Ação CreateSchema (Python: create_esquema)
- Ação GetSchema (Python: get_schema)
- Ação ListSchemaVersions (Python: list_schema_versions)
- Ação GetSchemaVersion (Python: get_schema_version)
- Ação GetSchemaVersionsDiff (Python: get_schema_versions_diff)
- Ação ListRegistries (Python: list_registries)
- Ação ListSchemas (Python: list_schemas)
- Ação RegisterSchemaVersion (Python: register_schema_version)

- Ação UpdateSchema (Python: update_schema)
- Ação CheckSchemaVersionValidity (Python: check_schema_version_validity)
- Ação UpdateRegistry (Python: update_registry)
- Ação GetSchemaByDefinition (Python: get_schema_by_definition)
- Ação GetRegistry (Python: get_registry)
- Ação PutSchemaVersionMetadata (Python: put_schema_version_metadata)
- Ação QuerySchemaVersionMetadata (Python: query_schema_version_metadata)
- Ação RemoveSchemaVersionMetadata (Python: remove_schema_version_metadata)
- Ação DeleteRegistry (Python: delete_registry)
- Ação DeleteSchema (Python: delete_schema)
- Ação DeleteSchemaVersions (Python: delete_schema_versions)

Ação CreateRegistry (Python: create_registry)

Cria um novo registro que pode ser usado para armazenar uma coleção de esquemas.

Solicitação

- `RegistryName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Custom string pattern #45.

  Nome do esquema a ser criado com comprimento máximo de 255 e que só pode conter letras, números, hífen, sublinhado, sinal de dólar ou cerquilha. Sem espaço em branco
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do registro. Se a descrição não for fornecida, não haverá nenhum valor padrão para esse campo.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Tags da AWS que contêm um par de chave-valor e podem ser pesquisadas por console, linha de comando ou API.

Resposta

- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do registro recém-criado.

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do registro.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags do registro.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`
- `InternalServiceException`

Ação CreateSchema (Python: create_esquema)

Cria um novo conjunto de esquemas e registra a definição do esquema. Retorna um erro se o conjunto de esquemas já existir sem realmente registrar a versão.

Quando o conjunto de esquemas é criado, um ponto de verificação de versão é definido para a primeira versão. O modo de compatibilidade “DISABLED” (Desabilitado) restringe a adição de versões adicionais do esquema após a primeira versão. Para todos os outros modos de compatibilidade, a validação das configurações de compatibilidade será aplicada somente a partir da segunda versão em diante, quando a API do `RegisterSchemaVersion` for usada.

Quando esta API é chamada sem um `RegistryId`, isso cria uma entrada para um “default-registry” (registro padrão) nas tabelas de banco de dados do registro, se ela ainda não estiver presente.

Solicitação

- `RegistryId` – Um objeto RegistryId.

  Esta é uma forma de wrapper para conter os campos de identidade do registro. Se essa propriedade não for definida, o registro padrão será usado. O formato do ARN para a mesma propriedade será: `arn:aws:glue:us-east-2:<customer id>:registry/default-registry:random-5-letter-id`.
- `SchemaName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Custom string pattern #45.

  Nome do esquema a ser criado com comprimento máximo de 255, e só pode conter letras, números, hífen, sublinhado, sinal de dólar ou marca de hash. Sem espaço em branco
- `DataFormat` – Obrigatório: string UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  O formato de dados da definição do esquema. No momento, há suporte a `AVRO`, `JSON` e `PROTOBUF`.
- `Compatibility` – String UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  O modo de compatibilidade do esquema. Os valores possíveis são:
  - NONE (Nenhum): nenhum modo de compatibilidade se aplica. Você pode usar essa opção em cenários de desenvolvimento ou se você não souber o modo de compatibilidade que deseja aplicar aos esquemas. Qualquer nova versão adicionada será aceita sem ser submetida a uma verificação de compatibilidade.
  - DISABLED (Desabilitado): esta opção de compatibilidade impede o versionamento de um esquema específico. Você pode usar essa opção para evitar versionamentos futuros de um esquema.

  - BACKWARD (Anterior): esta opção de compatibilidade é recomendada, pois permite que os receptores de dados leiam a versão atual e uma anterior do esquema. Isso significa que, por exemplo, uma nova versão do esquema não pode descartar campos de dados ou alterar o tipo desses campos, portanto, eles não podem ser lidos pelos leitores usando a versão anterior.
  - BACKWARD_ALL (Todas as anteriores): esta opção de compatibilidade é recomendada, pois permite que os receptores de dados leiam a versão atual e todas as anteriores do esquema. Você pode usar essa opção quando precisar excluir campos ou adicionar campos opcionais e verificar a compatibilidade com todas as versões anteriores do esquema.
  - FORWARD (Próxima): esta opção de compatibilidade permite que os receptores de dados leiam a versão atual e uma próxima do esquema, mas não necessariamente versões posteriores. Você pode usar essa opção quando precisar adicionar campos ou excluir campos opcionais, mas apenas verificar a compatibilidade com a última versão do esquema.
  - FORWARD_ALL (Todas as próximas): esta opção de compatibilidade permite que os receptores de dados leiam dados gravados pelos produtores de qualquer novo esquema registrado. Você pode usar essa opção quando precisar adicionar campos ou excluir campos opcionais e verificar a compatibilidade com todas as versões anteriores do esquema.
  - FULL (Completo): esta opção de compatibilidade permite que os receptores de dados leiam dados gravados por produtores usando a versão anterior ou seguinte do esquema, mas não necessariamente versões anteriores ou posteriores. Você pode usar essa opção quando precisar adicionar ou remover campos opcionais, mas apenas verificar a compatibilidade com a última versão do esquema.
  - FULL_ALL (Completo total): esta opção de compatibilidade permite que os receptores de dados leiam dados gravados por produtores usando todas as versões de esquema anteriores. Você pode usar essa opção quando precisar adicionar ou remover campos opcionais e verificar a compatibilidade com todas as versões anteriores do esquema.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição opcional do esquema. Se a descrição não for fornecida, não haverá nenhum valor padrão automático para esse campo.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

Tags da AWS que contêm um par de chave-valor e podem ser pesquisadas por console, linha de comando ou API. Se especificado, segue o padrão tags-on-create da AWS.

- `SchemaDefinition`: string UTF-8, não menos do que 1 ou superior a 170.000 bytes de comprimento, correspondente a Custom string pattern #13.

  A definição do esquema usando a configuração `DataFormat` para `SchemaName`.

Resposta

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro.

- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do registro.

- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema.

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do esquema.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do esquema, se especificado quando criado.

- `DataFormat` – String UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  O formato de dados da definição do esquema. No momento, há suporte a `AVRO`, `JSON` e `PROTOBUF`.

- `Compatibility` – String UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  O modo de compatibilidade do esquema.

- `SchemaCheckpoint`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do ponto de verificação (a última vez que o modo de compatibilidade foi alterado).
- `LatestSchemaVersion`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  A versão mais recente do esquema associado à definição do esquema retornado.
- `NextSchemaVersion`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  A próxima versão do esquema associado à definição do esquema retornado.
- `SchemaStatus` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  O status do esquema.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags do esquema.
- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O identificador exclusivo da primeira versão do esquema.
- `SchemaVersionStatus` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  O status da primeira versão do esquema criada.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `AlreadyExistsException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

- `InternalServiceException`

Ação GetSchema (Python: get_schema)

Descreve o esquema especificado em detalhes.

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  É uma estrutura de wrapper para conter campos de identidade de esquema. A estrutura contém:

  - SchemaId$SchemaArno: o nome do recurso da Amazon (ARN) do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.
  - SchemaId$SchemaName: o nome do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.

Resposta

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro.
- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do registro.
- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema.
- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do esquema.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do esquema, se especificado quando criado

- `DataFormat` – String UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  O formato de dados da definição do esquema. No momento, há suporte a `AVRO`, `JSON` e `PROTOBUF`.

- `Compatibility` – String UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  O modo de compatibilidade do esquema.

- `SchemaCheckpoint`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do ponto de verificação (a última vez que o modo de compatibilidade foi alterado).

- `LatestSchemaVersion`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  A versão mais recente do esquema associado à definição do esquema retornado.

- `NextSchemaVersion`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  A próxima versão do esquema associado à definição do esquema retornado.

- `SchemaStatus` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  O status do esquema.

- `CreatedTime` – String UTF-8.

  A data e a hora em que o esquema foi criado.

- `UpdatedTime` – String UTF-8.

  A data e a hora em que o esquema foi atualizado.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

Ação ListSchemaVersions (Python: list_schema_versions)

Retorna uma lista de versões de esquema que você criou, com informações mínimas. As versões do esquema no status Deleted (Excluído) não serão incluídas nos resultados. Resultados vazios serão retornados, se não houver versões de esquema disponíveis.

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  É uma estrutura de wrapper para conter campos de identidade de esquema. A estrutura contém:

  - SchemaId$SchemaArno: o nome do recurso da Amazon (ARN) do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.
  - SchemaId$SchemaName: o nome do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.
- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 100.

  O número máximo de resultados exigidos por página. Se o valor não for fornecido, esse valor será definido por padrão como 25 por página.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `Schemas`: um array de objetos SchemaVersionListItem.

  Uma matriz de objetos `SchemaVersionList` contendo detalhes de cada versão do esquema.
- `NextToken` – String UTF-8.

  Um token de continuação para paginação da lista de tokens retornada, retornado se o segmento atual da lista não for o último.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`

- `InternalServiceException`

Ação GetSchemaVersion (Python: get_schema_version)

Obtém o esquema especificado por seu ID exclusivo atribuído quando uma versão do esquema é criada ou registrada. As versões do esquema no status Deleted (Excluído) não serão incluídas nos resultados.

Solicitação

- `SchemaId` – Um objeto SchemaId.

  É uma estrutura de wrapper para conter campos de identidade de esquema. A estrutura contém:

  - SchemaId$SchemaArno: o nome do recurso da Amazon (ARN) do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.
  - SchemaId$SchemaName: o nome do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.
- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O `SchemaVersionId` da versão do esquema. Esse campo é obrigatório para buscar pelo ID do esquema. Esse ou o wrapper `SchemaId` tem que ser fornecido.
- `SchemaVersionNumber` – Um objeto SchemaVersionNumber.

  O número da versão do esquema.

Resposta

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O `SchemaVersionId` da versão do esquema.
- `SchemaDefinition`: string UTF-8, não menos do que 1 ou superior a 170.000 bytes de comprimento, correspondente a Custom string pattern #13.

  A definição do esquema para o ID do esquema.
- `DataFormat` – String UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

O formato de dados da definição do esquema. No momento, há suporte a `AVRO`, `JSON` e `PROTOBUF`.

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do esquema.
- `VersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.
- `Status` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  O status da versão do esquema.
- `CreatedTime` – String UTF-8.

  A data e hora em que a versão do esquema foi criada.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

Ação GetSchemaVersionsDiff (Python: get_schema_versions_diff)

Obtém a diferença de versão do esquema no tipo de diferença especificado entre duas versões de esquema armazenadas no registro de esquema.

Essa API permite comparar duas versões de esquema entre duas definições sob o mesmo esquema.

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  É uma estrutura de wrapper para conter campos de identidade de esquema. A estrutura contém:
  - SchemaId$SchemaArno: o nome do recurso da Amazon (ARN) do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.

  - SchemaId$SchemaName: o nome do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.
- `FirstSchemaVersionNumber` – Obrigatório: um objeto SchemaVersionNumber.

  A primeira das duas versões de esquema a serem comparadas.
- `SecondSchemaVersionNumber` – Obrigatório: um objeto SchemaVersionNumber.

  A segunda das duas versões de esquema a serem comparadas.
- `SchemaDiffType`: obrigatório: string UTF-8 (valores válidos: `SYNTAX_DIFF`).

  Refere-se a `SYNTAX_DIFF`, que é o tipo de comparação atualmente suportado.

Resposta

- `Diff`: string UTF-8, não menos do que 1 ou superior a 340.000 bytes de comprimento, correspondente a Custom string pattern #13.

  A diferença entre esquemas como uma string no formato JsonPatch.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`

Ação ListRegistries (Python: list_registries)

Retorna uma lista de registros que você criou, com informações mínimas de registro. Registros no status `Deleting` não serão incluídos nos resultados. Resultados vazios serão retornados, se não houver registros disponíveis.

Solicitação

- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 100.

O número máximo de resultados exigidos por página. Se o valor não for fornecido, esse valor será definido por padrão como 25 por página.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `Registries`: um array de objetos RegistryListItem.

  Uma matriz de objetos `RegistryDetailedListItem` contendo detalhes mínimos de cada registro.

- `NextToken` – String UTF-8.

  Um token de continuação para paginação da lista de tokens retornada, retornado se o segmento atual da lista não for o último.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`

Ação ListSchemas (Python: list_schemas)

Retorna uma lista de esquemas com detalhes mínimos. Esquemas no status Deleting (Exclusão) não serão incluídos nos resultados. Resultados vazios serão retornados, se não houver esquemas disponíveis.

Quando o `RegistryId` não for fornecido, todos os esquemas nos registros serão parte da resposta da API.

Solicitação

- `RegistryId` – Um objeto RegistryId.

Uma estrutura de wrapper que pode conter o nome de registro e o nome do recurso da Amazon (ARN).

- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 100.

  O número máximo de resultados exigidos por página. Se o valor não for fornecido, esse valor será definido por padrão como 25 por página.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `Schemas`: um array de objetos SchemaListItem.

  Uma matriz de objetos `SchemaListItem` contendo detalhes de cada esquema.

- `NextToken` – String UTF-8.

  Um token de continuação para paginação da lista de tokens retornada, retornado se o segmento atual da lista não for o último.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

Ação RegisterSchemaVersion (Python: register_schema_version)

Adiciona uma nova versão ao esquema existente. Retorna um erro se a nova versão do esquema não atender aos requisitos de compatibilidade do conjunto de esquemas. Essa API não criará um novo conjunto de esquemas e retornará um erro 404 se o conjunto de esquemas ainda não estiver presente no registro de esquema.

Se essa for a primeira definição de esquema a ser registrada no registro de esquema, essa API armazenará a versão do esquema e retornará imediatamente. Caso contrário, essa chamada

tem o potencial de ser executada por mais tempo do que outras operações graças aos modos de compatibilidade. Você pode chamar a API `GetSchemaVersion` com o `SchemaVersionId` para conferir os modos de compatibilidade.

Se a mesma definição de esquema já estiver armazenada no registro de esquema como uma versão, o ID do esquema existente será retornado ao autor da chamada.

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  É uma estrutura de wrapper para conter campos de identidade de esquema. A estrutura contém:

  - SchemaId$SchemaArno: o nome do recurso da Amazon (ARN) do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.
  - SchemaId$SchemaName: o nome do esquema. `SchemaArn` ou `SchemaName` e `RegistryName` devem ser fornecidos.
- `SchemaDefinition`: obrigatório: string UTF-8, não menos do que 1 ou superior a 170.000 bytes de comprimento, correspondente a Custom string pattern #13.

  A definição do esquema usando a configuração `DataFormat` para o `SchemaName`.

Resposta

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID exclusivo que representa a versão desse esquema.
- `VersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  A versão desse esquema (apenas para fluxo de sincronização, caso esta seja a primeira versão).
- `Status` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  O status da versão do esquema.

Erros

- `InvalidInputException`
- `AccessDeniedException`

- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`
- `InternalServiceException`

Ação UpdateSchema (Python: update_schema)

Atualiza a descrição, a configuração de compatibilidade ou o ponto de verificação de versão de um conjunto de esquemas.

Para atualizar a configuração de compatibilidade, a chamada não validará a compatibilidade para todo o conjunto de versões de esquema com a nova configuração de compatibilidade. Se o valor para `Compatibility` for fornecido, o `VersionNumber` (um ponto de verificação) também será necessário. A API validará o número de versão do ponto de verificação para fins de consistência.

Se o valor para `VersionNumber` (ponto de verificação) for fornecido, `Compatibility` será opcional e isso poderá ser usado para definir/redefinir um ponto de verificação para o esquema.

Essa atualização ocorrerá somente se o esquema estiver no estado AVAILABLE (Disponível).

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  É uma estrutura de wrapper para conter campos de identidade de esquema. A estrutura contém:

  - SchemaId$SchemaArno: o nome do recurso da Amazon (ARN) do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.
  - SchemaId$SchemaName: o nome do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.
- `SchemaVersionNumber` – Um objeto SchemaVersionNumber.

  Número de versão necessário para criar o ponto de verificação. Um de `VersionNumber` ou `Compatibility` tem de ser fornecido.
- `Compatibility` – String UTF-8 (valores válidos: `NONE` | `DISABLED` | `BACKWARD` | `BACKWARD_ALL` | `FORWARD` | `FORWARD_ALL` | `FULL` | `FULL_ALL`).

  A nova configuração de compatibilidade do esquema.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A nova descrição do esquema.

Resposta

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do esquema.

- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema.

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro que contém o esquema.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConcurrentModificationException`
- `InternalServiceException`

Ação CheckSchemaVersionValidity (Python: check_schema_version_validity)

Valida o esquema fornecido. Essa chamada não tem efeitos colaterais, ela simplesmente valida usando o esquema fornecido que usa `DataFormat` como o formato. Como ela não usa um nome de conjunto de esquemas, nenhuma verificação de compatibilidade é realizada.

Solicitação

- `DataFormat` – Obrigatório: string UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  O formato de dados da definição do esquema. No momento, há suporte a `AVRO`, `JSON` e `PROTOBUF`.
- `SchemaDefinition`: obrigatório: string UTF-8, não menos do que 1 ou superior a 170.000 bytes de comprimento, correspondente a Custom string pattern #13.

  A definição do esquema que deve ser validado.

Resposta

- `Valid` – Booleano.

  Retorna true, se o esquema for válido, e false, caso contrário.
- `Error`: string UTF-8, não menos do que 1 ou superior a 5.000 bytes de comprimento.

  Uma mensagem de erro de falha de validação.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `InternalServiceException`

Ação UpdateRegistry (Python: update_registry)

Atualiza um registro existente que é usado para armazenar uma coleção de esquemas. As propriedades atualizadas se relacionam com o registro e não modificam nenhum dos esquemas dentro dele.

Solicitação

- `RegistryId` – Obrigatório: um objeto RegistryId.

  Esta é uma estrutura de wrapper que pode conter o nome de registro e o nome do recurso da Amazon (ARN).

- `Description`: obrigatório: string de descrição, inferior a 2.048 bytes de comprimento, correspondente a URI address multi-line string pattern.

  Uma descrição do registro. Se a descrição não for fornecida, esse campo não será atualizado.

Resposta

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro atualizado.
- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do registro atualizado.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `ConcurrentModificationException`
- `InternalServiceException`

Ação GetSchemaByDefinition (Python: get_schema_by_definition)

Recupera um esquema pela `SchemaDefinition`. A definição de esquema é enviada para o registro de esquema, canonizada e com hash. Se o hash for correspondido dentro do escopo do `SchemaName` ou ARN (ou o registro padrão, se nenhum for fornecido), os metadados desse esquema serão retornados. Caso contrário, um erro 404 ou NotFound (não encontrado) é retornado. As versões do esquema no status `Deleted` não serão incluídas nos resultados.

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  É uma estrutura de wrapper para conter campos de identidade de esquema. A estrutura contém:

  - SchemaId$SchemaArno: o nome do recurso da Amazon (ARN) do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.
  - SchemaId$SchemaName: o nome do esquema. Um de `SchemaArn` ou `SchemaName` tem de ser fornecido.
- `SchemaDefinition`: obrigatório: string UTF-8, não menos do que 1 ou superior a 170.000 bytes de comprimento, correspondente a Custom string pattern #13.

  A definição do esquema para a qual os detalhes do esquema são necessários.

Resposta

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID do esquema da versão do esquema.
- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do esquema.
- `DataFormat` – String UTF-8 (valores válidos: `AVRO` | `JSON` | `PROTOBUF`).

  O formato de dados da definição do esquema. No momento, há suporte a `AVRO`, `JSON` e `PROTOBUF`.
- `Status` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `FAILURE` | `DELETING`).

  O status da versão do esquema.
- `CreatedTime` – String UTF-8.

  A data e a hora em que o esquema foi criado.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

Ação GetRegistry (Python: get_registry)

Descreve o registro especificado em detalhes.

Solicitação

- `RegistryId` – Obrigatório: um objeto RegistryId.

  Esta é uma estrutura de wrapper que pode conter o nome de registro e o nome do recurso da Amazon (ARN).

Resposta

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro.

- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do registro.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do registro.

- `Status`: string UTF-8 (valores válidos: `AVAILABLE` | `DELETING`).

  O status do registro.

- `CreatedTime` – String UTF-8.

  A data e a hora em que o registro foi criado.

- `UpdatedTime` – String UTF-8.

  A data e a hora em que o registro foi atualizado.

Erros

- `InvalidInputException`

- `AccessDeniedException`
- `EntityNotFoundException`
- `InternalServiceException`

Ação PutSchemaVersionMetadata (Python: put_schema_version_metadata)

Insere o par de chave-valor de metadados para um ID de versão de esquema especificado. Um máximo de dez pares de chave-valor será permitido por versão do esquema. Eles podem ser adicionados em uma ou mais chamadas.

Solicitação

- `SchemaId` – Um objeto SchemaId.

  O ID exclusivo do esquema.
- `SchemaVersionNumber` – Um objeto SchemaVersionNumber.

  O número da versão do esquema.
- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID de versão exclusivo da versão do esquema.
- `MetadataKeyValue` – Obrigatório: um objeto MetadataKeyValuePair.

  O valor correspondente da chave de metadados.

Resposta

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do esquema.
- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema.
- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

O nome do registro.

- `LatestVersion` – Booleano.

  A versão mais recente do esquema.

- `VersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID de versão exclusivo da versão do esquema.

- `MetadataKey`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #14.

  A chave de metadados.

- `MetadataValue`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #14.

  O valor da chave de metadados.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `AlreadyExistsException`
- `EntityNotFoundException`
- `ResourceNumberLimitExceededException`

Ação QuerySchemaVersionMetadata (Python: query_schema_version_metadata)

Consultas para obter as informações de metadados da versão do esquema.

Solicitação

- `SchemaId` – Um objeto SchemaId.

Uma estrutura de wrapper que pode conter o nome do esquema e o nome do recurso da Amazon (ARN).

- `SchemaVersionNumber` – Um objeto SchemaVersionNumber.

  O número da versão do esquema.

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID de versão exclusivo da versão do esquema.

- `MetadataList`: um array de objetos MetadataKeyValuePair.

  Pesquisa os pares de chave-valor para metadados. Se eles não forem fornecidos, todas as informações de metadados serão buscadas.

- `MaxResults`: número (inteiro), não menos do que 1 ou superior a 50.

  O número máximo de resultados exigidos por página. Se o valor não for fornecido, esse valor será definido por padrão como 25 por página.

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma chamada de continuação.

Resposta

- `MetadataInfoMap` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes, correspondente a Custom string pattern #14.

  Cada valor é um objeto MetadataInfo A.

  Um mapa de uma chave de metadados e valores associados.

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID de versão exclusivo da versão do esquema.

- `NextToken` – String UTF-8.

Um token de continuação para paginação da lista de tokens retornada, retornado se o segmento atual da lista não for o último.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`

Ação RemoveSchemaVersionMetadata (Python: remove_schema_version_metadata)

Remove um par de chave-valor dos metadados de versão do esquema para o ID de versão do esquema especificado.

Solicitação

- `SchemaId` – Um objeto SchemaId.

  Uma estrutura de wrapper que pode conter o nome do esquema e o nome do recurso da Amazon (ARN).
- `SchemaVersionNumber` – Um objeto SchemaVersionNumber.

  O número da versão do esquema.
- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID de versão exclusivo da versão do esquema.
- `MetadataKeyValue` – Obrigatório: um objeto MetadataKeyValuePair.

  O valor da chave de metadados.

Resposta

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

O nome de recurso da Amazon (ARN) do esquema.

- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema.

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro.

- `LatestVersion` – Booleano.

  A versão mais recente do esquema.

- `VersionNumber`: número (inteiro longo), não menos do que 1 ou superior a 100.000.

  O número da versão do esquema.

- `SchemaVersionId`: string UTF-8, não menos do que 36 ou superior a 36 bytes de comprimento, correspondente a Custom string pattern #44.

  O ID da versão para a versão do esquema.

- `MetadataKey`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #14.

  A chave de metadados.

- `MetadataValue`: string UTF-8, não menos do que 1 ou superior a 256 bytes de comprimento, correspondente a Custom string pattern #14.

  O valor da chave de metadados.

Erros

- `InvalidInputException`
- `AccessDeniedException`
- `EntityNotFoundException`

Ação DeleteRegistry (Python: delete_registry)

Exclui todo o registro, incluindo esquema e todas as suas versões. Para obter o status da operação de exclusão, é possível chamar a API `GetRegistry` após a chamada assíncrona. Excluir um registro desativará todas as operações online para ele, como as APIs `UpdateRegistry`, `CreateSchema`, `UpdateSchema` e `RegisterSchemaVersion`.

Solicitação

- `RegistryId` – Obrigatório: um objeto RegistryId.

  Esta é uma estrutura de wrapper que pode conter o nome de registro e o nome do recurso da Amazon (ARN).

Resposta

- `RegistryName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do registro sendo excluído.

- `RegistryArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do registro a ser excluído.

- `Status`: string UTF-8 (valores válidos: `AVAILABLE` | `DELETING`).

  O status do registro. Uma operação bem-sucedida retornará o status `Deleting`.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ConcurrentModificationException`

Ação DeleteSchema (Python: delete_schema)

Exclui todo o conjunto de esquemas, incluindo o conjunto de esquemas e todas as suas versões. Para obter o status da operação de exclusão, é possível chamar a API `GetSchema` após a chamada assíncrona. Excluir um registro desativará todas as operações online para ele, como as APIs `GetSchemaByDefinition` e `RegisterSchemaVersion`.

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  Esta é uma estrutura de wrapper que pode conter o nome do esquema e o nome do recurso da Amazon (ARN).

Resposta

- `SchemaArn`: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do esquema sendo excluído.
- `SchemaName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #45.

  O nome do esquema sendo excluído.
- `Status` – String UTF-8 (valores válidos: `AVAILABLE` | `PENDING` | `DELETING`).

  O status do esquema.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ConcurrentModificationException`

Ação DeleteSchemaVersions (Python: delete_schema_versions)

Remove versões do esquema especificado. Um número de versão ou intervalo pode ser fornecido. Se o modo de compatibilidade proibir a exclusão de uma versão que é necessária, como BACKWARDS_FULL, um erro será retornado. Chamar a API `GetSchemaVersions` após essa chamada listará o status das versões excluídas.

Quando o intervalo de números de versão contiver a versão de ponto de verificação, a API retornará um conflito 409 e não prosseguirá com a exclusão. Primeiro, é preciso remover o ponto de verificação usando a API `DeleteSchemaCheckpoint` antes de usar essa API.

Não é possível utilizar a API `DeleteSchemaVersions` para excluir a primeira versão do esquema no conjunto de esquemas. A primeira versão do esquema só pode ser excluída pela API `DeleteSchema`. Essa operação também excluirá os `SchemaVersionMetadata` anexados nas versões do esquema. Exclusões irreversíveis serão impostas no banco de dados.

Se o modo de compatibilidade proibir a exclusão de uma versão que é necessária, como BACKWARDS_FULL, um erro será retornado.

Solicitação

- `SchemaId` – Obrigatório: um objeto SchemaId.

  Esta é uma estrutura de wrapper que pode conter o nome do esquema e o nome do recurso da Amazon (ARN).

- `Versions`: obrigatório: string UTF-8, não menos do que 1 ou superior a 100.000 bytes de comprimento, correspondente a Custom string pattern #15.

  Pode ser fornecido um intervalo de versões que pode ser do formato:

  - um único número de versão, 5
  - um intervalo, 5-8: exclui as versões 5, 6, 7 e 8

Resposta

- `SchemaVersionErrors`: um array de objetos SchemaVersionErrorItem.

  Uma lista de objetos `SchemaVersionErrorItem`, cada um contendo uma versão de esquema e erro.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `AccessDeniedException`
- `ConcurrentModificationException`

Fluxos de trabalho

A API de fluxos de trabalho descreve os tipos de dados e a API relacionados à criação, atualização ou exibição de fluxos de trabalho no AWS Glue. O histórico de execução de trabalhos pode ser acessado por 90 dias para seu fluxo de trabalho e execução de trabalhos.

Tipos de dados

- Estrutura JobNodeDetails
- Estrutura CrawlerNodeDetails
- Estrutura TriggerNodeDetails
- Estrutura Crawl
- Estrutura Node
- Estrutura Edge
- Estrutura Workflow
- Estrutura WorkflowGraph
- Estrutura WorkflowRun
- Estrutura WorkflowRunStatistics
- Estrutura StartingEventBatchCondition
- Estrutura Blueprint
- Estrutura BlueprintDetails
- Estrutura LastActiveDefinition
- Estrutura BlueprintRun

Estrutura JobNodeDetails

Os detalhes de um nó de tarefa presente no fluxo de trabalho.

Campos

- `JobRuns`: um array de objetos JobRun.

  As informações da execução da tarefa representada pelo nó de tarefa.

Estrutura CrawlerNodeDetails

Os detalhes de um nó de crawler presente no fluxo de trabalho.

Campos

- `Crawls`: um array de objetos Crawl.

  Uma lista de monitoramentos representados pelo nó de monitoramento.

Estrutura TriggerNodeDetails

Os detalhes de um nó de gatilho presente no fluxo de trabalho.

Campos

- `Trigger` – Um objeto Trigger.

  As informações do gatilho representado pelo nó de gatilho.

Estrutura Crawl

Os detalhes de um monitoramento no fluxo de trabalho

Campos

- `State` – String UTF-8 (valores válidos: `RUNNING` | `CANCELLING` | `CANCELLED` | `SUCCEEDED` | `FAILED` | `ERROR`).

  O estado do crawler.

- `StartedOn` – Timestamp.

  A data e a hora em que o monitoramento foi iniciado.

- `CompletedOn` – Timestamp.

  A data e a hora em que o monitoramento foi concluído.

- `ErrorMessage`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A mensagem de erro associada ao crawl.

- `LogGroup`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Log group string pattern.

  O grupo de logs associado ao crawl.

- `LogStream`: string UTF-8 com no mínimo 1 e no máximo 512 bytes de comprimento e correspondente a Log-stream string pattern.

  O fluxo de logs associado ao rastreamento.

Estrutura Node

Um nó representa um componente AWS Glue (acionador, crawler ou trabalho) em um gráfico de fluxo de trabalho.

Campos

- `Type` – String UTF-8 (valores válidos: `CRAWLER` | `JOB` | `TRIGGER`).

  O tipo de componente do AWS Glue representado pelo nó.

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do componente do AWS Glue representado pelo nó.

- `UniqueId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID exclusivo atribuído ao nó no fluxo de trabalho.

- `TriggerDetails` – Um objeto TriggerNodeDetails.

Detalhes do gatilho quando o nó representa um gatilho.

- `JobDetails` – Um objeto JobNodeDetails.

  Detalhes da tarefa quando o nó representa uma tarefa.

- `CrawlerDetails` – Um objeto CrawlerNodeDetails.

  Detalhes do crawler quando o nó representa um crawler.

Estrutura Edge

Uma borda representa uma conexão direta entre dois componentes do AWS Glue que fazem parte do fluxo de trabalho ao qual a borda pertence.

Campos

- `SourceId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O exclusivo do nó no fluxo de trabalho onde a borda é iniciada.

- `DestinationId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O exclusivo do nó no fluxo de trabalho onde a borda é finalizada.

Estrutura Workflow

Um fluxo de trabalho é uma colação de vários trabalhos e crawlers do AWS Glue dependentes, que são executados para concluir uma tarefa de ETL complexa. Um fluxo de trabalho gerencia a execução e o monitoramento de todos os seus trabalhos e crawlers.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do fluxo de trabalho.

- `Description` – String UTF-8.

Uma descrição do fluxo de trabalho.

- `DefaultRunProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma sequência de caracteres UTF-8.

  Um conjunto de propriedades a serem usadas como parte de cada execução do fluxo de trabalho. As propriedades de execução são disponibilizadas para cada trabalho no fluxo de trabalho. Um trabalho pode modificar as propriedades dos próximos trabalhos no fluxo.

- `CreatedOn` – Timestamp.

  A data e a hora em que o fluxo de trabalho foi criado.

- `LastModifiedOn` – Timestamp.

  A data e a hora em que o fluxo de trabalho foi modificado pela última vez.

- `LastRun` – Um objeto WorkflowRun.

  As informações sobre a última execução do fluxo de trabalho.

- `Graph` – Um objeto WorkflowGraph.

  O gráfico que representa todos os componentes do AWS Glue que pertencem ao fluxo de trabalho como nós e conexões direcionadas entre eles como bordas.

- `CreationStatus` – String UTF-8 (valores válidos: `CREATING` | `CREATED` | `CREATION_FAILED`).

  O status de criação do fluxo de trabalho.

- `MaxConcurrentRuns` – Número (íntegro).

  Você pode usar esse parâmetro para evitar várias atualizações indesejadas de dados, para controlar custos ou, em alguns casos, evitar que exceda o número máximo de execuções simultâneas de qualquer um dos trabalhos do componente. Se você deixar esse parâmetro em branco, não haverá limite para o número de execuções de fluxo de trabalho simultâneas.

- `BlueprintDetails` – Um objeto BlueprintDetails.

  Essa estrutura indica os detalhes do blueprint do qual esse fluxo de trabalho específico foi criado.

Estrutura WorkflowGraph

Um gráfico de fluxo de trabalho representa o fluxo de trabalho completo que contém todos os componentes do AWS Glue presentes no fluxo de trabalho e todas as conexões direcionadas entre eles.

Campos

- `Nodes`: um array de objetos Nó.

  Uma lista dos componentes do AWS Glue que pertencem ao fluxo de trabalho representados como nós.
- `Edges`: um array de objetos Borda.

  Uma lista de todas as conexões direcionadas entre os nós que pertencem ao fluxo de trabalho.

Estrutura WorkflowRun

Uma execução de fluxo de trabalho é uma execução de um fluxo de trabalho que fornece todas as informações do runtime.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome do fluxo de trabalho que foi executado.
- `WorkflowRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID dessa execução de fluxo de trabalho.
- `PreviousRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da execução do fluxo de trabalho anterior.
- `WorkflowRunProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

Cada valor é uma sequência de caracteres UTF-8.

As propriedades da execução do fluxo de trabalho que foram definidas durante a execução.

- `StartedOn` – Timestamp.

  A data e a hora em que a execução do fluxo de trabalho foi iniciada.

- `CompletedOn` – Timestamp.

  A data e a hora em que a execução do fluxo de trabalho foi concluída.

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `COMPLETED` | `STOPPING` | `STOPPED` | `ERROR`).

  O status da execução do fluxo de trabalho.

- `ErrorMessage` – String UTF-8.

  Essa mensagem de erro descreve qualquer erro que possa ter ocorrido ao iniciar a execução do fluxo de trabalho. Atualmente, a única mensagem de erro é “Concurrent runs exceeded for workflow: `foo`” (Execuções simultâneas excedidas para fluxo de trabalho: foo).

- `Statistics` – Um objeto WorkflowRunStatistics.

  As estatísticas da execução.

- `Graph` – Um objeto WorkflowGraph.

  O gráfico que representa todos os componentes do AWS Glue que pertencem ao fluxo de trabalho como nós e conexões direcionadas entre eles como bordas.

- `StartingEventBatchCondition` – Um objeto StartingEventBatchCondition.

  A condição do lote que iniciou a execução do fluxo de trabalho.

Estrutura WorkflowRunStatistics

As estatísticas da execução do fluxo de trabalho fornecem estatísticas sobre a execução do fluxo de trabalho.

Campos

- `TotalActions` – Número (íntegro).

  O número total de ações na execução do fluxo de trabalho.

- `TimeoutActions` – Número (íntegro).

  O número total de ações que atingiram o tempo limite.

- `FailedActions` – Número (íntegro).

  O número total de ações que falharam.

- `StoppedActions` – Número (íntegro).

  O número total de ações que foram interrompidas.

- `SucceededActions` – Número (íntegro).

  O número total de ações que foram bem-sucedidas.

- `RunningActions` – Número (íntegro).

  O número total de ações no estado de execução.

- `ErroredActions` – Número (íntegro).

  Indica a contagem de execuções de trabalho no estado ERROR (ERRO) na execução do fluxo de trabalho.

- `WaitingActions` – Número (íntegro).

  Indica a contagem de execuções de trabalho no estado WAITING (AGUARDANDO) na execução do fluxo de trabalho.

Estrutura StartingEventBatchCondition

A condição do lote que iniciou a execução do fluxo de trabalho. Ou o número de eventos no tamanho do lote chegou, caso em que o membro BatchSize é diferente de zero, ou a janela do lote expirou, caso em que o membro BatchWindow é diferente de zero.

Campos

- `BatchSize` – Número (íntegro).

  Número de eventos no lote.

- `BatchWindow` – Número (íntegro).

  Duração da janela do lote em segundos.

Estrutura Blueprint

Os detalhes de um blueprint.

Campos

- `Name`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #31.

  O nome do blueprint.

- `Description`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  A descrição do blueprint.

- `CreatedOn` – Timestamp.

  A data e a hora em que o blueprint foi registrado.

- `LastModifiedOn` – Timestamp.

  A data e a hora em que o blueprint foi modificado pela última vez.

- `ParameterSpec`: string UTF-8, não menos do que 1 ou superior a 131.072 bytes de comprimento.

  Uma string JSON que indica a lista de especificações de parâmetros para o blueprint.

- `BlueprintLocation` – String UTF-8.

  Especifica o caminho no Amazon S3 onde o blueprint é publicado.

- `BlueprintServiceLocation` – String UTF-8.

  Especifica um caminho no Amazon S3 onde o blueprint é copiado quando você chama `CreateBlueprint/UpdateBlueprint` para registrá-lo no AWS Glue.

- `Status` – String UTF-8 (valores válidos: `CREATING` | `ACTIVE` | `UPDATING` | `FAILED`).

  O status do registro do blueprint.

  - Creating (Criando): o registro do blueprint está em andamento.
  - Active (Ativo): o blueprint foi registrado com sucesso.
  - Updating (Atualizando): uma atualização para o registro do blueprint está em andamento.
  - Failed (Falha): falha no registro do blueprint.

- `ErrorMessage` – String UTF-8.

Uma mensagem de erro.

- `LastActiveDefinition` – Um objeto LastActiveDefinition.

  Quando há várias versões de um blueprint e a versão mais recente apresenta alguns erros, esse atributo indica a última definição do blueprint bem-sucedida que está disponível com o serviço.

Estrutura BlueprintDetails

Os detalhes de um blueprint.

Campos

- `BlueprintName`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #31.

  O nome do blueprint.
- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução desse blueprint.

Estrutura LastActiveDefinition

Quando há várias versões de um blueprint e a versão mais recente apresenta alguns erros, esse atributo indica a última definição do blueprint bem-sucedida que está disponível com o serviço.

Campos

- `Description`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  A descrição do blueprint.
- `LastModifiedOn` – Timestamp.

  A data e a hora em que o blueprint foi modificado pela última vez.
- `ParameterSpec`: string UTF-8, não menos do que 1 ou superior a 131.072 bytes de comprimento.

  Uma string JSON que especifica os parâmetros para o blueprint.
- `BlueprintLocation` – String UTF-8.

Especifica um caminho no Amazon S3 em que o blueprint é publicado pelo desenvolvedor do AWS Glue.

- `BlueprintServiceLocation` – String UTF-8.

  Especifica um caminho no Amazon S3 onde o esquema é copiado quando você cria ou atualiza o esquema.

Estrutura BlueprintRun

Os detalhes de uma execução de blueprint.

Campos

- `BlueprintName`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #31.

  O nome do blueprint.

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução para essa execução de blueprint.

- `WorkflowName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de um fluxo de trabalho criado como resultado de uma execução bem-sucedida do blueprint. Se uma execução de blueprint tiver um erro, não haverá um fluxo de trabalho criado.

- `State` – String UTF-8 (valores válidos: `RUNNING` | `SUCCEEDED` | `FAILED` | `ROLLING_BACK`).

  O estado da execução do blueprint. Os valores possíveis são:

  - Running (Executando): a execução do blueprint está em andamento.
  - Succeeded (Êxito): a execução do blueprint foi concluída com êxito.
  - Failed (Falha): a execução do blueprint falhou e a reversão está concluída.
  - Rolling Back (Revertendo): a execução do blueprint falhou e a reversão está em andamento.

- `StartedOn` – Timestamp.

  A data e a hora em que a execução do blueprint foi iniciada.

- `CompletedOn` – Timestamp.

  A data e a hora em que a execução do blueprint foi concluída.

- `ErrorMessage` – String UTF-8.

  Indica os erros que são vistos durante a execução do blueprint.

- `RollbackErrorMessage` – String UTF-8.

  Se houver erros ao criar as entidades de um fluxo de trabalho, tentamos reverter as entidades criadas até esse ponto e excluí-las. Esse atributo indica os erros vistos ao tentar excluir as entidades que foram criadas.

- `Parameters`: string UTF-8, não menos do que 1 ou superior a 131.072 bytes de comprimento.

  Os parâmetros do blueprint como uma string. Você terá que fornecer um valor para cada chave exigida pela especificação do parâmetro, que é definida em `Blueprint$ParameterSpec`.

- `RoleArn` – String UTF-8, superior a 1 e inferior a 1024 bytes de comprimento, correspondente a Custom string pattern #30.

  O ARN do perfil. Essa função será assumida pelo produto AWS Glue e será usada para criar o fluxo de trabalho e outras entidades de um fluxo de trabalho.

Operações

- Ação CreateWorkflow (Python: create_workflow)
- Ação UpdateWorkflow (Python: update_workflow)
- Ação DeleteWorkflow (Python: delete_workflow)
- Ação GetWorkflow (Python: get_workflow)
- Ação ListWorkflows (Python: list_workflows)
- Ação BatchGetWorkflows (Python: batch_get_workflows)
- Ação GetWorkflowRun (Python: get_workflow_run)
- Ação GetWorkflowRuns (Python: get_workflow_runs)
- Ação GetWorkflowRunProperties (Python: get_workflow_run_properties)
- Ação PutWorkflowRunProperties (Python: put_workflow_run_properties)
- Ação CreateBlueprint (Python: create_blueprint)
- Ação UpdateBlueprint (Python: update_blueprint)

- Ação DeleteBlueprint (Python: delete_blueprint)
- Ação ListBlueprints (Python: list_blueprints)
- Ação BatchGetBlueprints (Python: batch_get_blueprints)
- Ação StartBlueprintRun (Python: start_blueprint_run)
- Ação GetBlueprintRun (Python: get_blueprint_run)
- Ação GetBlueprintRuns (Python: get_blueprint_runs)
- Ação StartWorkflowRun (Python: start_workflow_run)
- Ação StopWorkflowRun (Python: stop_workflow_run)
- Ação ResumeWorkflowRun (Python: resume_workflow_run)

Ação CreateWorkflow (Python: create_workflow)

Cria uma nova workload.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome a ser atribuído ao fluxo de trabalho. Ele deve ser exclusivo na conta.
- `Description`: string UTF-8, com no máximo 120 mil bytes.

  Uma descrição do fluxo de trabalho.
- `DefaultRunProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma sequência de caracteres UTF-8.

  Um conjunto de propriedades a serem usadas como parte de cada execução do fluxo de trabalho.

  As propriedades de execução podem ser registradas em log. Evite fornecer segredos em texto simples e não criptografado como propriedades. Caso necessite utilizá-los no decorrer da execução do fluxo de trabalho, recupere-os de uma Conexão do AWS Glue, do AWS Secrets Manager ou de outro mecanismo de gerenciamento de segredos.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

As tags a serem usadas com esse fluxo de trabalho.

- `MaxConcurrentRuns` – Número (íntegro).

  Você pode usar esse parâmetro para evitar várias atualizações indesejadas de dados, para controlar custos ou, em alguns casos, evitar que exceda o número máximo de execuções simultâneas de qualquer um dos trabalhos do componente. Se você deixar esse parâmetro em branco, não haverá limite para o número de execuções de fluxo de trabalho simultâneas.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do fluxo de trabalho que foi fornecido como parte da solicitação.

Erros

- `AlreadyExistsException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `ConcurrentModificationException`

Ação UpdateWorkflow (Python: update_workflow)

Atualiza um fluxo de trabalho existente.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

Nome do fluxo de trabalho a ser atualizado.

- `Description`: string UTF-8, com no máximo 120 mil bytes.

  A descrição do fluxo de trabalho.

- `DefaultRunProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma sequência de caracteres UTF-8.

  Um conjunto de propriedades a serem usadas como parte de cada execução do fluxo de trabalho.

  As propriedades de execução podem ser registradas em log. Evite fornecer segredos em texto simples e não criptografado como propriedades. Caso necessite utilizá-los no decorrer da execução do fluxo de trabalho, recupere-os de uma Conexão do AWS Glue, do AWS Secrets Manager ou de outro mecanismo de gerenciamento de segredos.

- `MaxConcurrentRuns` – Número (íntegro).

  Você pode usar esse parâmetro para evitar várias atualizações indesejadas de dados, para controlar custos ou, em alguns casos, evitar que exceda o número máximo de execuções simultâneas de qualquer um dos trabalhos do componente. Se você deixar esse parâmetro em branco, não haverá limite para o número de execuções de fluxo de trabalho simultâneas.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do fluxo de trabalho que foi especificado na entrada.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

- `ConcurrentModificationException`

Ação DeleteWorkflow (Python: delete_workflow)

Exclui um fluxo de trabalho.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do fluxo de trabalho a ser excluído.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Nome do fluxo de trabalho especificado na entrada.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentModificationException`

Ação GetWorkflow (Python: get_workflow)

Recupera metadados de recurso para um fluxo de trabalho.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do fluxo de trabalho a ser recuperado.
- `IncludeGraph` – Booleano.

Especifica se um gráfico será incluído ao retornar os metadados do recurso do fluxo de trabalho.

Resposta

- `Workflow` – Um objeto Fluxo de trabalho.

  Os metadados de recurso para o fluxo de trabalho.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação ListWorkflows (Python: list_workflows)

Lista nomes de fluxos de trabalho criados na conta.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `MaxResults`: número (inteiro), não inferior a 1 nem superior a 25.

  O tamanho máximo de uma lista a ser retornada.

Resposta

- `Workflows`: uma matriz de strings UTF-8, não menos do que 1 ou superior a 25 strings.

  Lista de nomes de fluxos de trabalho na conta.
- `NextToken` – String UTF-8.

  Um token de continuação, caso nem todos os nomes de fluxos de trabalho tenham sido retornados.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação BatchGetWorkflows (Python: batch_get_workflows)

Retorna uma lista de metadados de recurso para uma lista de nomes de fluxos de trabalho. Depois de chamar a operação `ListWorkflows`, você pode chamar essa operação para acessar os dados aos quais você recebeu permissões. Essa operação oferece suporte a todas as permissões do IAM, incluindo condições de permissão que usam tags.

Solicitação

- `Names` – Obrigatório: uma matriz de strings UTF-8, no mínimo 1 ou mais de 25 strings.

  Uma lista de nomes de fluxos de trabalho, que podem ser os nomes retornados pela operação `ListWorkflows`.
- `IncludeGraph` – Booleano.

  Especifica se um gráfico será incluído ao retornar os metadados do recurso do fluxo de trabalho.

Resposta

- `Workflows`: uma matriz de objetos Fluxo de trabalho, não menos do que 1 ou superior a 25 estruturas.

  Uma lista de metadados do recurso do fluxo de trabalho.
- `MissingWorkflows`: uma matriz de strings UTF-8, não menos do que 1 ou superior a 25 strings.

  Uma lista de nomes de fluxos de trabalho não encontrados.

Erros

- `InternalServiceException`
- `OperationTimeoutException`

- `InvalidInputException`

Ação GetWorkflowRun (Python: get_workflow_run)

Recupera os metadados de determinada execução do fluxo de trabalho. O histórico de execução de trabalhos pode ser acessado por 90 dias para seu fluxo de trabalho e execução de trabalhos.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do fluxo de trabalho em execução.
- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da execução do fluxo de trabalho.
- `IncludeGraph` – Booleano.

  Especifica se deve incluir o gráfico do fluxo de trabalho como resposta ou não.

Resposta

- `Run` – Um objeto WorkflowRun.

  Os metadados da execução do fluxo de trabalho solicitados.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetWorkflowRuns (Python: get_workflow_runs)

Recupera os metadados de todas as execuções de determinado fluxo de trabalho.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do fluxo de trabalho cujos metadados de execuções devem ser retornados.
- `IncludeGraph` – Booleano.

  Especifica se deve incluir o gráfico do fluxo de trabalho como resposta ou não.
- `NextToken` – String UTF-8.

  O tamanho máximo da resposta.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de execuções do fluxo de trabalho a serem incluídas na resposta.

Resposta

- `Runs`: uma matriz de objetos WorkflowRun, não menos do que 1 ou superior a 1.000 estruturas.

  Uma lista de objetos de metadados da execução do fluxo de trabalho.
- `NextToken` – String UTF-8.

  Um token de continuação, se todas as execuções do fluxo de trabalho solicitadas não tiverem sido retornadas.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação GetWorkflowRunProperties (Python: get_workflow_run_properties)

Recupera as propriedades de execução do fluxo de trabalho que foram definidas durante a execução.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do fluxo de trabalho que foi executado.

- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da execução do fluxo de trabalho cujas propriedades deveriam ser retornadas.

Resposta

- `RunProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma sequência de caracteres UTF-8.

  As propriedades da execução do fluxo de trabalho que foram definidas durante a execução especificada.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação PutWorkflowRunProperties (Python: put_workflow_run_properties)

Coloca as propriedades da execução do fluxo de trabalho especificadas para determinada execução do fluxo de trabalho. Se uma propriedade já existir para a execução especificada, ela substituirá o valor. Caso contrário, a propriedade será adicionada às propriedades existentes.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome do fluxo de trabalho que foi executado.

- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da execução do fluxo de trabalho para o qual as propriedades de execução deveriam ser atualizadas.

- `RunProperties`: obrigatório: uma matriz de mapa dos pares de chave-valor.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma sequência de caracteres UTF-8.

  As propriedades para colocar a execução especificada.

  As propriedades de execução podem ser registradas em log. Evite fornecer segredos em texto simples e não criptografado como propriedades. Caso necessite utilizá-los no decorrer da execução do fluxo de trabalho, recupere-os de uma Conexão do AWS Glue, do AWS Secrets Manager ou de outro mecanismo de gerenciamento de segredos.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `AlreadyExistsException`
- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

- `ConcurrentModificationException`

Ação CreateBlueprint (Python: create_blueprint)

Regista um blueprint com o AWS Glue.

Solicitação

- `Name`: obrigatório: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #31.

  O nome do blueprint.
- `Description`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  Uma descrição do blueprint.
- `BlueprintLocation`: obrigatório: string UTF-8, não menos do que 1 ou superior a 8.192 bytes de comprimento, correspondente a Custom string pattern #32.

  Especifica um caminho no Amazon S3 em que o blueprint é publicado.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags a serem aplicadas a esse blueprint.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Retorna o nome do blueprint que foi registrado.

Erros

- `AlreadyExistsException`
- `InvalidInputException`

- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

Ação UpdateBlueprint (Python: update_blueprint)

Atualiza um blueprint registrado.

Solicitação

- `Name`: obrigatório: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #31.

  O nome do blueprint.
- `Description`: string UTF-8, não menos do que 1 ou superior a 512 bytes de comprimento.

  Uma descrição do blueprint.
- `BlueprintLocation`: obrigatório: string UTF-8, não menos do que 1 ou superior a 8.192 bytes de comprimento, correspondente a Custom string pattern #32.

  Especifica um caminho no Amazon S3 em que o blueprint é publicado.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Retorna o nome do blueprint que foi atualizado.

Erros

- `EntityNotFoundException`
- `ConcurrentModificationException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

- `IllegalBlueprintStateException`

Ação DeleteBlueprint (Python: delete_blueprint)

Exclui um blueprint existente.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do blueprint a ser excluído.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Retorna o nome do blueprint que foi excluído.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação ListBlueprints (Python: list_blueprints)

Lista todos os nomes de blueprints em uma conta.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `MaxResults`: número (inteiro), não inferior a 1 nem superior a 25.

  O tamanho máximo de uma lista a ser retornada.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Filtra a lista por uma tag de recurso da AWS.

Resposta

- `Blueprints` – Uma matriz de strings UTF-8.

  Lista de nomes de blueprints na conta.
- `NextToken` – String UTF-8.

  Um token de continuação, se nem todos os nomes de blueprints sejam retornados.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação BatchGetBlueprints (Python: batch_get_blueprints)

Recupera informações sobre uma lista de blueprints.

Solicitação

- `Names` – Obrigatório: uma matriz de strings UTF-8, no mínimo 1 ou mais de 25 strings.

  Uma lista de nomes de blueprints.
- `IncludeBlueprint` – Booleano.

  Especifica se deve incluir o blueprint na resposta ou não.
- `IncludeParameterSpec` – Booleano.

  Especifica se deve incluir os parâmetros para o blueprint, como uma string JSON, na resposta ou não.

Resposta

- `Blueprints`: um array de objetos Blueprint.

  Retorna uma lista de blueprints como um objeto `Blueprints`.
- `MissingBlueprints` – Uma matriz de strings UTF-8.

  Retorna uma lista de `BlueprintNames` que não foram encontrados.

Erros

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação StartBlueprintRun (Python: start_blueprint_run)

Inicia uma nova execução do blueprint especificado.

Solicitação

- `BlueprintName`: obrigatório: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #31.

  O nome do blueprint.
- `Parameters`: string UTF-8, não menos do que 1 ou superior a 131.072 bytes de comprimento.

  Especifica os parâmetros como um objeto `BlueprintParameters`.
- `RoleArn` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 1024 bytes de comprimento, correspondente a Custom string pattern #30.

  Especifica a função do IAM usada para criar o fluxo de trabalho.

Resposta

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O ID de execução para essa execução de blueprint.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`
- `EntityNotFoundException`
- `IllegalBlueprintStateException`

Ação GetBlueprintRun (Python: get_blueprint_run)

Recupera os detalhes de uma execução de bluetprint.

Solicitação

- `BlueprintName`: obrigatório: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #31.

  O nome do blueprint.
- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID de execução do blueprint que você deseja recuperar.

Resposta

- `BlueprintRun` – Um objeto BlueprintRun.

  Informa um objeto `BlueprintRun`.

Erros

- `EntityNotFoundException`
- `InternalServiceException`

- `OperationTimeoutException`

Ação GetBlueprintRuns (Python: get_blueprint_runs)

Recupera os detalhes das execuções de blueprint para um blueprint especificado.

Solicitação

- `BlueprintName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do blueprint.
- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo de uma lista a ser retornada.

Resposta

- `BlueprintRuns`: um array de objetos BlueprintRun.

  Retorna uma lista de objetos `BlueprintRun`.
- `NextToken` – String UTF-8.

  Um token de continuação, se nem todas as execuções de blueprint solicitadas forem retornadas.

Erros

- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`

Ação StartWorkflowRun (Python: start_workflow_run)

Inicia uma nova execução do fluxo de trabalho especificado.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do fluxo de trabalho a ser iniciado.
- `RunProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma sequência de caracteres UTF-8.

  As propriedades de execução de fluxo de trabalho para a nova execução de fluxo de trabalho.

  As propriedades de execução podem ser registradas em log. Evite fornecer segredos em texto simples e não criptografado como propriedades. Caso necessite utilizá-los no decorrer da execução do fluxo de trabalho, recupere-os de uma Conexão do AWS Glue, do AWS Secrets Manager ou de outro mecanismo de gerenciamento de segredos.

Resposta

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um ID para a nova execução.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

- `ConcurrentRunsExceededException`

Ação StopWorkflowRun (Python: stop_workflow_run)

Interrompe a execução do fluxo de trabalho especificada.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do fluxo de trabalho a ser interrompido.
- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da execução do fluxo de trabalho a ser interrompida.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `IllegalWorkflowStateException`

Ação ResumeWorkflowRun (Python: resume_workflow_run)

Reinicia os nós selecionados de uma execução de fluxo de trabalho anterior parcialmente concluída e retoma a execução do fluxo de trabalho. Os nós selecionados e todos os nós downstream a eles são executados.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do fluxo de trabalho a ser retomado.
- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da execução do fluxo de trabalho a ser retomada.
- `NodeIds`: obrigatório: uma matriz de strings UTF-8.

  Uma lista de IDs de nó daqueles que você deseja reiniciar. Os nós que devem ser reiniciados devem ter uma tentativa de execução na execução original.

Resposta

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O novo ID atribuído à execução do fluxo de trabalho retomada. Cada retomada de uma execução de fluxo de trabalho terá um novo ID de execução.
- `NodeIds` – Uma matriz de strings UTF-8.

  Uma lista de IDs dos nós que foram realmente reiniciados.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `InternalServiceException`
- `OperationTimeoutException`
- `ConcurrentRunsExceededException`
- `IllegalWorkflowStateException`

Perfis de uso

A API de perfis de uso descreve os tipos de dados e API relacionados à criação, atualização ou exibição de fluxos de trabalho no AWS Glue.

Tipos de dados

- Estrutura ProfileConfiguration
- Estrutura ConfigurationObject
- Estrutura UsageProfileDefinition

Estrutura ProfileConfiguration

Especifica os valores de trabalho e sessão que um administrador configura em um perfil de uso do AWS Glue.

Campos

- `SessionConfiguration` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 255 bytes, correspondente a Single-line string pattern.

  Cada valor é um objeto ConfigurationObject A.

  Um mapa de chave-valor de configuração para sessões do AWS Glue.
- `JobConfiguration` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 255 bytes, correspondente a Single-line string pattern.

  Cada valor é um objeto ConfigurationObject A.

  Um mapa de chave-valor de configuração para trabalhos do AWS Glue.

Estrutura ConfigurationObject

Especifica os valores que um administrador define para cada parâmetro de trabalho ou sessão configurado em um perfil de uso do AWS Glue.

Campos

- `DefaultValue`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #35.

  Um valor padrão para o parâmetro.

- `AllowedValues` – Uma matriz de strings UTF-8.

  Uma lista dos valores permitidos para o parâmetro.

- `MinValue`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #35.

  Um valor mínimo permitido para o parâmetro.

- `MaxValue`: string UTF-8, não menos do que 1 ou superior a 128 bytes de comprimento, correspondente a Custom string pattern #35.

  Um valor máximo permitido para o parâmetro.

Estrutura UsageProfileDefinition

Descreve um perfil de uso do AWS Glue.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do perfil do usuário.

- `Description` – String de descrição, inferior a 2048 bytes de comprimento, correspondente a URI address multi-line string pattern.

  Uma descrição do perfil de uso.

- `CreatedOn` – Timestamp.

  A data e a hora em que o perfil de uso foi criado.

- `LastModifiedOn` – Timestamp.

  A data e a hora em que o perfil de uso foi modificado pela última vez.

Operações

- Ação CreateUsageProfile (Python: create_usage_profile)
- Ação GetUsageProfile (Python: get_usage_profile)
- Ação UpdateUsageProfile (Python: update_usage_profile)
- Ação DeleteUsageProfile (Python: delete_usage_profile)
- Ação ListUsageProfiles (Python: list_usage_profiles)

Ação CreateUsageProfile (Python: create_usage_profile)

Cria um perfil de uso do AWS Glue.

Solicitação

- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do perfil do usuário.
- `Description` – String de descrição, inferior a 2048 bytes de comprimento, correspondente a URI address multi-line string pattern.

  Uma descrição do perfil de uso.
- `Configuration` – Obrigatório: um objeto ProfileConfiguration.

  Um objeto `ProfileConfiguration` que especifica os valores do trabalho e da sessão para o perfil.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Uma lista de tags aplicadas ao perfil de uso.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O nome do perfil de uso que foi criado.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `OperationNotSupportedException`

Ação GetUsageProfile (Python: get_usage_profile)

Recupera informações sobre o perfil de uso do AWS Glue especificado.

Solicitação

- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do perfil de uso a ser recuperado.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do perfil do usuário.
- `Description` – String de descrição, inferior a 2048 bytes de comprimento, correspondente a URI address multi-line string pattern.

  Uma descrição do perfil de uso.
- `Configuration` – Um objeto ProfileConfiguration.

  Um objeto `ProfileConfiguration` que especifica os valores do trabalho e da sessão para o perfil.

- `CreatedOn` – Timestamp.

  A data e a hora em que o perfil de uso foi criado.

- `LastModifiedOn` – Timestamp.

  A data e a hora em que o perfil de uso foi modificado pela última vez.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `OperationNotSupportedException`

Ação UpdateUsageProfile (Python: update_usage_profile)

Atualiza um perfil de uso do AWS Glue.

Solicitação

- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do perfil do usuário.

- `Description` – String de descrição, inferior a 2048 bytes de comprimento, correspondente a URI address multi-line string pattern.

  Uma descrição do perfil de uso.

- `Configuration` – Obrigatório: um objeto ProfileConfiguration.

  Um objeto `ProfileConfiguration` que especifica os valores do trabalho e da sessão para o perfil.

Resposta

- Name – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do perfil de uso que foi atualizado.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `OperationNotSupportedException`
- `ConcurrentModificationException`

Ação DeleteUsageProfile (Python: delete_usage_profile)

Exclui o perfil de uso do AWS Glue especificado.

Solicitação

- Name – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do perfil de uso a ser excluído.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

- `OperationNotSupportedException`

Ação ListUsageProfiles (Python: list_usage_profiles)

Liste todos os perfis de uso do AWS Glue.

Solicitação

- `NextToken`: string UTF-8, não superior a 400.000 bytes de comprimento.

  Um token de continuação, incluído se esta for uma chamada de continuação.
- `MaxResults`: número (inteiro) não inferior a 1 nem superior a 200.

  O número máximo de perfis de uso a serem retornados em uma única resposta.

Resposta

- `Profiles` – Uma matriz de objetos UsageProfileDefinition.

  Uma lista de objetos do perfil de uso (`UsageProfileDefinition`).
- `NextToken`: string UTF-8, não superior a 400.000 bytes de comprimento.

  Um token de continuação, presente se o segmento de lista atual não for o último.

Erros

- `InternalServiceException`
- `OperationTimeoutException`
- `InvalidInputException`
- `OperationNotSupportedException`

API de machine learning

A API Machine learning descreve os tipos de dados de machine learning e inclui a API para criar, excluir ou atualizar uma transformação, ou iniciar a execução de uma tarefa de machine learning.

Tipos de dados

- Estrutura TransformParameters
- Estrutura EvaluationMetrics
- Estrutura MLTransform
- Estrutura FindMatchesParameters
- Estrutura FindMatchesMetrics
- Estrutura ConfusionMatrix
- Estrutura GlueTable
- Estrutura TaskRun
- Estrutura TransformFilterCriteria
- Estrutura TransformSortCriteria
- Estrutura TaskRunFilterCriteria
- Estrutura TaskRunSortCriteria
- Estrutura TaskRunProperties
- Estrutura FindMatchesTaskRunProperties
- Estrutura ImportLabelsTaskRunProperties
- Estrutura ExportLabelsTaskRunProperties
- Estrutura LabelingSetGenerationTaskRunProperties
- Estrutura SchemaColumn
- Estrutura TransformEncryption
- Estrutura MLUserDataEncryption
- Estrutura ColumnImportance

Estrutura TransformParameters

Os parâmetros de algoritmo específicos associados à transformação de machine learning.

Campos

- `TransformType`: obrigatório: string UTF-8 (valores válidos: `FIND_MATCHES`).

  O tipo de transformação de machine learning.

Para obter informações sobre os tipos de transformações de machine learning, consulte Criação de transformações para machine learning.

- `FindMatchesParameters` – Um objeto FindMatchesParameters.

  Os parâmetros do algoritmo de busca de correspondências.

Estrutura EvaluationMetrics

As métricas de avaliação fornecem uma estimativa da qualidade da transformação de machine learning.

Campos

- `TransformType`: obrigatório: string UTF-8 (valores válidos: `FIND_MATCHES`).

  O tipo de transformação de machine learning.
- `FindMatchesMetrics` – Um objeto FindMatchesMetrics.

  As métricas de avaliação do algoritmo de busca de correspondências.

Estrutura MLTransform

Uma estrutura para a transformação de machine learning.

Campos

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de transformação exclusivo gerado para a transformação de machine learning. É garantido que o ID será único e não mudará.
- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome definido pelo usuário para a transformação de machine learning. Não é garantido que os nomes serão únicos, e poderão ser trocados a qualquer momento.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

Um texto de descrição de formato longo e definido pelo usuário para a transformação de machine learning. Não é garantido que as descrições serão únicas, e elas poderão mudar a qualquer momento.

- `Status` – String UTF-8 (valores válidos: `NOT_READY` | `READY` | `DELETING`).

  O status atual da transformação de machine learning.

- `CreatedOn` – Timestamp.

  Um carimbo de data/hora. A data e hora em que essa transformação de machine learning foi criada.

- `LastModifiedOn` – Timestamp.

  Um carimbo de data/hora. O último momento em que essa transformação de machine learning foi modificada.

- `InputRecordTables`: uma matriz de objetos GlueTable, não mais do que dez estruturas.

  Uma lista de definições de tabela do AWS Glue usadas pela transformação.

- `Parameters` – Um objeto TransformParameters.

  Um objeto `TransformParameters`. Você pode usar parâmetros para ajustar (personalizar) o comportamento da transformação de machine learning, especificando quais dados ela aprenderá e sua preferência sobre vários tradeoffs (como precisão vs. revocação, ou acurácia vs. custo).

- `EvaluationMetrics` – Um objeto EvaluationMetrics.

  Um objeto `EvaluationMetrics`. As métricas de avaliação fornecem uma estimativa da qualidade da transformação de machine learning.

- `LabelCount` – Número (íntegro).

  Um identificador de contagem para rotular arquivos gerados pelo AWS Glue para essa transformação. À medida que você cria uma transformação melhor, é possível fazer download, rotular e fazer upload do arquivo de rotulamento de maneira interativa.

- `Schema`: uma matriz de objetos SchemaColumn, não mais de 100 estruturas.

  Um mapa de pares de chave-valor representando as colunas e os tipos de dados que podem ser executados em relação a essa transformação. Tem um limite superior de 100 colunas.

- `Role` – String UTF-8.

O nome ou o nome de recurso da Amazon (ARN) da função do IAM com as permissões necessárias. As permissões necessárias incluem as permissões de função de serviço do AWS Glue para recursos do AWS Glue e as permissões do Amazon S3 exigidas pela transformação.

- Essa função precisa de permissões de função de serviço do AWS Glue para conceder o acesso aos recursos no AWS Glue. Consulte Anexar uma política aos usuários do IAM que acessam o AWS Glue.
- Essa função precisa de permissão para suas origens, seus destinos, seu diretório temporário, seus scripts e quaisquer bibliotecas do Amazon Simple Storage Service (Amazon S3) usadas pela execução de tarefa nessa transformação.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Este valor determina com qual versão de AWS Glue essa transformação de machine learning é compatível. O Glue 1.0 é recomendado para a maioria dos clientes. Se o valor não for definido, a compatibilidade com o Glue 0.9 será definida como padrão. Para obter mais informações, consulte Versões do AWS Glue no guia do desenvolvedor.

- `MaxCapacity` – Número (duplo).

  O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para execuções de tarefas para essa transformação. Você pode alocar de 2 a 100 DPUs. O padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  `MaxCapacity` é uma opção mutuamente exclusiva com `NumberOfWorkers` e `WorkerType`.

  - Se `NumberOfWorkers` ou `WorkerType` estiver definido, `MaxCapacity` não poderá ser definido.
  - Se `MaxCapacity` estiver definido, nem `NumberOfWorkers` e nem `WorkerType` poderá ser definido.
  - Se `WorkerType` estiver definido, `NumberOfWorkers` será necessário (e vice-versa).
  - `MaxCapacity` e `NumberOfWorkers` devem ser pelo menos 1.

  Quando o campo `WorkerType` é definido como um valor diferente de `Standard`, o campo `MaxCapacity` é definido automaticamente e se torna somente leitura.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido alocado quando uma tarefa dessa transformação é executada. Aceita um valor de Standard (Padrão), G.1X ou G.2X.

  - Para o tipo de operador `Standard`, cada operador fornece 4 vCPU, 16 GB de memória e um disco de 50 GB e 2 executores por operador.
  - Para o tipo de operador `G.1X`, cada operador fornece 4 vCPU, 16 GB de memória e um disco e 64 GB, 1 executor por operador.
  - Para o tipo de operador `G.2X`, cada operador fornece 8 vCPU, 32 GB de memória e um disco de 128 GB e 1 executor por operador.

  `MaxCapacity` é uma opção mutuamente exclusiva com `NumberOfWorkers` e `WorkerType`.

  - Se `NumberOfWorkers` ou `WorkerType` estiver definido, `MaxCapacity` não poderá ser definido.
  - Se `MaxCapacity` estiver definido, nem `NumberOfWorkers` e nem `WorkerType` poderá ser definido.
  - Se `WorkerType` estiver definido, `NumberOfWorkers` será necessário (e vice-versa).
  - `MaxCapacity` e `NumberOfWorkers` devem ser pelo menos 1.
- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de um `workerType` definido alocados quando uma tarefa da transformação é executada.

  Se `WorkerType` estiver definido, `NumberOfWorkers` será necessário (e vice-versa).
- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite em minutos da transformação de machine learning.
- `MaxRetries` – Número (íntegro).

  O número máximo de novas tentativas após uma falha de transformação `MLTaskRun` de machine learning.
- `TransformEncryption` – Um objeto TransformEncryption.

As configurações de criptografia em repouso da transformação que se aplicam ao acesso aos dados do usuário. As transformações de machine learning podem acessar dados do usuário criptografados no Amazon S3 usando o KMS.

Estrutura FindMatchesParameters

Os parâmetros para configurar a transformação de localização de correspondências.

Campos

- `PrimaryKeyColumnName` – String UTF-8, superior a 1 e inferior a 1024 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de uma coluna que identifica exclusivamente as linhas na tabela de origem. Usado para ajudar a identificar os registros correspondentes.

- `PrecisionRecallTradeoff`: número (double), no máximo 1,0.

  O valor selecionado ao ajustar a transformação para um equilíbrio entre precisão e revocação. Um valor de 0.5 significa que não há preferência; um valor de 1.0 significa um desvio puramente para precisão, e um valor de 0.0 significa um desvio para revocação. Como este é um tradeoff, escolher valores próximos a 1.0 significa uma revocação muito baixa, e escolher valores próximos a 0.0 resulta em uma precisão muito baixa.

  A métrica de precisão indica a frequência com que seu modelo está correto ao prever uma correspondência.

  A métrica de revocação indica, para uma correspondência real, com que frequência seu modelo prevê a correspondência.

- `AccuracyCostTradeoff`: número (double), no máximo 1,0.

  O valor selecionado ao ajustar sua transformação para um equilíbrio entre acurácia e custo. Um valor de 0.5 significa que o sistema equilibra as preocupações de acurácia e o custo. Um valor de 1.0 significa um desvio puramente para a acurácia, o que normalmente resulta em um custo mais alto, que é, às vezes, substancialmente superior. Um valor de 0.0 significa um desvio puramente para o custo, o que resulta em uma transformação `FindMatches` menos precisa e que é, às vezes, uma acurácia inaceitável.

A acurácia mede quão bem a transformação encontra verdadeiros positivos e verdadeiros negativos. Aumentar a acurácia exige mais recursos de máquina e eleva os custos. Mas isso também resulta em um aumento da revocação.

O custo avalia o número de recursos de computação, ou seja, o dinheiro, consumidos para executar a transformação.

- `EnforceProvidedLabels` – Booleano.

  O valor para ativar/desativar a forçar a saída para corresponder aos rótulos fornecidos por usuários. Se o valor for `True`, a transformação `find matches` forçará a saída para corresponder aos rótulos fornecidos. Os resultados substituem os resultados de confluência normal. Se o valor for `False`, a transformação `find matches` não garantirá que todos os rótulos fornecidos serão respeitados, e os resultados contarão com o modelo treinado.

  Observe que definir esse valor como true pode aumentar o tempo de execução do trabalho.

Estrutura FindMatchesMetrics

As métricas de avaliação do algoritmo de busca de correspondências. A qualidade da transformação de machine learning é avaliada fazendo com que sua transformação preveja algumas correspondências e comparando os resultados com correspondências conhecidas do mesmo conjunto de dados. As métricas de qualidade são baseadas em um subconjunto dos seus dados, para que eles não sejam precisos.

Campos

- `AreaUnderPRCurve`: número (double), no máximo 1,0.

  A área sob a curva de precisão/revocação (AUPRC) é um único número único que mede a qualidade geral da transformação, que é independente da escolha feita em precisão vs. revocação. Valores mais altos indicam que você tem um tradeoff de precisão vs. revocação mais atrativo.

  Para obter mais informações, consulte Precisão e revocação na Wikipédia.

- `Precision`: número (double), no máximo 1,0.

A métrica de precisão indica a frequência com que sua transformação está correta ao prever uma correspondência. Especificamente, avalia quão bem a transformação encontra verdadeiros positivos do total possível de verdadeiros positivos.

Para obter mais informações, consulte Precisão e revocação na Wikipédia.

- `Recall`: número (double), no máximo 1,0.

  A métrica de revocação indica, para uma correspondência real, com que frequência sua transformação prevê a correspondência. Especificamente, avalia quão bem a transformação encontra verdadeiros positivos do total de registros nos dados de origem.

  Para obter mais informações, consulte Precisão e revocação na Wikipédia.

- `F1`: número (double), no máximo 1,0.

  O F1 máximo indica a acurácia da transformação entre 0 e 1, onde 1 é a melhor acurácia.

  Para obter mais informações, consulte F1 score na Wikipédia.

- `ConfusionMatrix` – Um objeto ConfusionMatrix.

  A matriz de confusão mostra o que sua transformação está prevendo com precisão, e quais tipos de erros está cometendo.

  Para obter mais informações, consulte Confusion Matrix na Wikipédia.

- `ColumnImportances`: uma matriz de objetos ColumnImportance, não mais de 100 estruturas.

  Uma lista de estruturas `ColumnImportance` contendo métricas de importância de coluna, classificadas em ordem de importância decrescente.

Estrutura ConfusionMatrix

A matriz de confusão mostra o que sua transformação está prevendo com precisão, e quais tipos de erros está cometendo.

Para obter mais informações, consulte Confusion Matrix na Wikipédia.

Campos

- `NumTruePositives` – Número (extenso).

O número de correspondências nos dados que a transformação encontrou corretamente, na matriz de confusão da sua transformação.

- `NumFalsePositives` – Número (extenso).

  O número de não correspondências nos dados que a transformação incorretamente classificou como correspondências, na matriz de confusão da sua transformação.

- `NumTrueNegatives` – Número (extenso).

  O número de não correspondências nos dados que a transformação rejeitou corretamente, na matriz de confusão da sua transformação.

- `NumFalseNegatives` – Número (extenso).

  O número de correspondências nos dados que a transformação não encontrou, na matriz de confusão da sua transformação.

Estrutura GlueTable

O banco de dados e a tabela no AWS Glue Data Catalog usados para os dados de entrada ou saída.

Campos

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados no AWS Glue Data Catalog.

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela no AWS Glue Data Catalog.

- `CatalogId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um identificador exclusivo para o AWS Glue Data Catalog.

- `ConnectionName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da conexão com o AWS Glue Data Catalog.

- `AdditionalOptions`: uma matriz de mapas de pares chave-valor, não menos que 1 o não mais que 10 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 255 bytes, correspondente a Single-line string pattern.

  Cada valor é uma string de descrição, com não mais de 2048 de comprimento, correspondo a URI address multi-line string pattern.

  Opções adicionais para a tabela. Atualmente, duas chaves são compatíveis:

  - `pushDownPredicate`: para filtrar por partições sem a necessidade de listar e ler todos os arquivos do conjunto de dados.
  - `catalogPartitionPredicate`: para usar a remoção de partições do lado do servidor usando índices de partição no AWS Glue Data Catalog.

Estrutura TaskRun

Os parâmetros de amostragem associados à transformação de machine learning.

Campos

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da transformação

- `TaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo para a execução dessa tarefa.

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status atual da execução de tarefa solicitada.

- `LogGroupName` – String UTF-8.

  Os nomes do grupo de log para proteger os registros, associados a essa execução de tarefa.

- `Properties` – Um objeto TaskRunProperties.

Especifica as propriedades de configuração associadas à execução de tarefa.

- `ErrorString` – String UTF-8.

  A lista de strings de erros associadas a essa execução de tarefa.

- `StartedOn` – Timestamp.

  A data e a hora em que essa execução de tarefa iniciou.

- `LastModifiedOn` – Timestamp.

  O último momento em que a execução de tarefa foi atualizada.

- `CompletedOn` – Timestamp.

  O último momento em que a execução de tarefa foi finalizada.

- `ExecutionTime` – Número (íntegro).

  A quantidade de tempo (em segundos) em que a tarefa executada consumiu recursos.

Estrutura TransformFilterCriteria

Os critérios usado para filtrar as transformações de machine learning.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome de transformação exclusivo usado para filtrar as transformações de machine learning.

- `TransformType` – String UTF-8 (valores válidos: `FIND_MATCHES`).

  O tipo de transformação de machine learning usado para filtrar as transformações de machine learning.

- `Status` – String UTF-8 (valores válidos: `NOT_READY` | `READY` | `DELETING`).

  Filtra a lista de transformações de machine learning pelo último status conhecido das transformações (para indicar se uma transformação pode ser usada ou não). Um dos "NOT_READY", "READY" ou "DELETING".

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Este valor determina com qual versão de AWS Glue essa transformação de machine learning é compatível. O Glue 1.0 é recomendado para a maioria dos clientes. Se o valor não for definido, a compatibilidade com o Glue 0.9 será definida como padrão. Para obter mais informações, consulte Versões do AWS Glue no guia do desenvolvedor.
- `CreatedBefore` – Timestamp.

  A data e hora antes de as transformações serem criadas.
- `CreatedAfter` – Timestamp.

  A data e hora depois de as transformações serem criadas.
- `LastModifiedBefore` – Timestamp.

  Filtro da última modificação das transformações antes dessa data.
- `LastModifiedAfter` – Timestamp.

  Filtro da última modificação das transformações depois dessa data.
- `Schema`: uma matriz de objetos SchemaColumn, não mais de 100 estruturas.

  Filtros dos conjuntos de dados com um esquema específico. O objeto `Map<Column, Type>` é uma matriz de pares de chave-valor que representa o esquema que essa transformação aceita, em que `Column` é o nome de uma coluna, e `Type` é o tipo dos dados como um número inteiro ou uma string. Tem um limite superior de 100 colunas.

Estrutura TransformSortCriteria

Os critérios de classificação associados à transformação de machine learning.

Campos

- `Column` – obrigatório: string UTF-8 (valores válidos: `NAME` | `TRANSFORM_TYPE` | `STATUS` | `CREATED` | `LAST_MODIFIED`).

  A coluna a ser usada nos critérios de classificação que estão associados à transformação de machine learning.
- `SortDirection` – Obrigatório: string UTF-8 (valores válidos: `DESCENDING` | `ASCENDING`).

A direção da classificação a ser usada nos critérios de classificação associados à transformação de machine learning.

Estrutura TaskRunFilterCriteria

Os critérios usados para filtrar a execução de tarefa para a transformação de machine learning.

Campos

- `TaskRunType` – String UTF-8 (valores válidos: `EVALUATION` | `LABELING_SET_GENERATION` | `IMPORT_LABELS` | `EXPORT_LABELS` | `FIND_MATCHES`).

  O tipo da tarefa executada.

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status atual da tarefa executada.

- `StartedBefore` – Timestamp.

  Filtra as execuções de tarefas iniciadas antes dessa data.

- `StartedAfter` – Timestamp.

  Filtra as execuções de tarefas iniciadas após essa data.

Estrutura TaskRunSortCriteria

Os critérios de classificação usados para classificar a lista de execuções de tarefas para a transformação de machine learning.

Campos

- `Column` – Obrigatório: string UTF-8 (valores válidos: `TASK_RUN_TYPE` | `STATUS` | `STARTED`).

  A coluna que será usada para classificar a lista de execuções de tarefas para a transformação de machine learning.

- `SortDirection` – Obrigatório: string UTF-8 (valores válidos: `DESCENDING` | `ASCENDING`).

A direção de classificação que será usada para classificar a lista de execuções de tarefas para a transformação de machine learning.

Estrutura TaskRunProperties

As propriedades de configuração para a execução de tarefa.

Campos

- `TaskType` – String UTF-8 (valores válidos: `EVALUATION` | `LABELING_SET_GENERATION` | `IMPORT_LABELS` | `EXPORT_LABELS` | `FIND_MATCHES`).

  O tipo da tarefa executada.
- `ImportLabelsTaskRunProperties` – Um objeto ImportLabelsTaskRunProperties.

  As propriedades de configuração para uma execução de tarefa de rótulos de importação.
- `ExportLabelsTaskRunProperties` – Um objeto ExportLabelsTaskRunProperties.

  As propriedades de configuração para uma execução de tarefa de rótulos de exportação.
- `LabelingSetGenerationTaskRunProperties` – Um objeto LabelingSetGenerationTaskRunProperties.

  As propriedades de configuração para execução de tarefa de geração de conjunto de rótulos.
- `FindMatchesTaskRunProperties` – Um objeto FindMatchesTaskRunProperties.

  As propriedades de configuração de uma execução de tarefa de busca de correspondências.

Estrutura FindMatchesTaskRunProperties

Especifica as propriedades de configuração de uma execução de tarefa de busca de correspondências.

Campos

- `JobId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do trabalho da execução de tarefa de busca de correspondências.

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome atribuído ao trabalho da execução de tarefa de busca de correspondências.

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da execução de trabalho para a execução de tarefa de busca de correspondências

Estrutura ImportLabelsTaskRunProperties

Especifica as propriedades de configuração para uma execução de tarefa de importação de rótulos.

Campos

- `InputS3Path` – String UTF-8.

  O caminho do Amazon Simple Storage Service (Amazon S3) para onde você importará os rótulos.

- `Replace` – Booleano.

  Indica se você deve substituir os rótulos existentes.

Estrutura ExportLabelsTaskRunProperties

Especifica as propriedades de configuração para uma execução de tarefa de exportação de rótulos.

Campos

- `OutputS3Path` – String UTF-8.

  O caminho do Amazon Simple Storage Service (Amazon S3) de onde você exportará os rótulos.

Estrutura LabelingSetGenerationTaskRunProperties

Especifica as propriedades de configuração para execução de tarefa de geração de conjunto de rótulos.

Campos

- `OutputS3Path` – String UTF-8.

  O caminho do Amazon Simple Storage Service (Amazon S3) de onde você irá gerar o conjunto de rótulos.

Estrutura SchemaColumn

Um par de chave-valor representando a coluna e o tipo de dado que podem ser executados em relação a essa transformação. O parâmetro `Schema` do `MLTransform` pode conter até 100 dessas estruturas.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 1024 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da coluna.

- `DataType` – String UTF-8 com comprimento não superior a 131.072 bytes, correspondente a Single-line string pattern.

  O tipo de dados na coluna.

Estrutura TransformEncryption

As configurações de criptografia em repouso da transformação que se aplicam ao acesso aos dados do usuário. As transformações de machine learning podem acessar dados do usuário criptografados no Amazon S3 usando o KMS.

Além disso, rótulos importados e transformações treinadas agora podem ser criptografados usando uma chave KMS fornecida pelo cliente.

Campos

- `MlUserDataEncryption` – Um objeto MLUserDataEncryption.

  Um objeto `MLUserDataEncryption` que contém o modo de criptografia e o ID da chave do KMS fornecida pelo cliente.

- `TaskRunSecurityConfigurationName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança.

Estrutura MLUserDataEncryption

As configurações de criptografia em repouso da transformação que se aplicam ao acesso aos dados do usuário.

Campos

- `MlUserDataEncryptionMode` – Obrigatório: string UTF-8 (valores válidos: `DISABLED` | `SSE-KMS="SSEKMS"`).

  O modo de criptografia aplicado aos dados do usuário. Os valores válidos são:

  - DISABLED: a criptografia está desativada
  - SSEKMS: uso de criptografia no lado do servidor com o AWS Key Management Service (SSE-KMS) para dados do usuário armazenados no Amazon S3.
- `KmsKeyId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da chave do KMS fornecida pelo cliente.

Estrutura ColumnImportance

Uma estrutura que contém o nome e a pontuação de importância de uma coluna.

A importância da coluna ajuda você a entender como as colunas contribuem para o seu modelo, identificando quais delas em seus registros são mais usadas para fazer a correspondência.

Campos

- `ColumnName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome de uma coluna.
- `Importance`: número (double), no máximo 1,0.

A pontuação de importância da coluna, como um valor decimal.

Operações

- Ação CreateMLTransform (Python: create_ml_transform)
- Ação UpdateMLTransform (Python: update_ml_transform)
- Ação DeleteMLTransform (Python: delete_ml_transform)
- Ação GetMLTransform (Python: get_ml_transform)
- Ação GetMLTransforms (Python: get_ml_transforms)
- Ação ListMLTransforms (Python: list_ml_transforms)
- Ação StartMLEvaluationTaskRun (Python: start_ml_evaluation_task_run)
- Ação StartMLLabelingSetGenerationTaskRun (Python: start_ml_labeling_set_generation_task_run)
- Ação GetMLTaskRun (Python: get_ml_task_run)
- Ação GetMLTaskRuns (Python: get_ml_task_runs)
- Ação CancelMLTaskRun (Python: cancel_ml_task_run)
- Ação StartExportLabelsTaskRun (Python: start_export_labels_task_run)
- Ação StartImportLabelsTaskRun (Python: start_import_labels_task_run)

Ação CreateMLTransform (Python: create_ml_transform)

Cria uma transformação de machine learning do AWS Glue. Essa operação cria a transformação e todos os parâmetros necessários para treiná-la.

Chame esta operação como a primeira etapa no processo de usar uma transformação de machine learning (como a transformação `FindMatches`) para a desduplicação de dados. Você pode fornecer uma `Description`, adicional, além dos parâmetros que você quer usar para seu algoritmo.

Você também deve especificar determinados parâmetros para as tarefas que o AWS Glue executa em seu nome como parte do aprendizado com seus dados e para criação de uma transformação de machine learning de alta qualidade. Esses parâmetros incluem `Role` e, opcionalmente, `AllocatedCapacity`, `Timeout` e `MaxRetries`. Para obter mais informações, consulte Tarefas.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome exclusivo que você atribui à transformação quando a cria.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição da transformação de machine learning que está sendo definida. O padrão é uma string vazia.

- `InputRecordTables` - obrigatório: uma matriz de objetos GlueTable, não mais que dez estruturas.

  Uma lista de definições de tabela do AWS Glue usadas pela transformação.

- `Parameters` – Obrigatório: um objeto TransformParameters.

  Os parâmetros do algoritmo específicos para o tipo de transformação utilizado. Dependente condicionalmente do tipo de transformação.

- `Role` – Obrigatório: string UTF-8.

  O nome ou o nome de recurso da Amazon (ARN) da função do IAM com as permissões necessárias. As permissões necessárias incluem as permissões de função de serviço do AWS Glue para recursos do AWS Glue e as permissões do Amazon S3 exigidas pela transformação.

  - Essa função precisa de permissões de função de serviço do AWS Glue para conceder o acesso aos recursos no AWS Glue. Consulte Anexar uma política aos usuários do IAM que acessam o AWS Glue.
  - Essa função precisa de permissão para suas origens, seus destinos, seu diretório temporário, seus scripts e quaisquer bibliotecas do Amazon Simple Storage Service (Amazon S3) usadas pela execução de tarefa nessa transformação.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Este valor determina com qual versão de AWS Glue essa transformação de machine learning é compatível. O Glue 1.0 é recomendado para a maioria dos clientes. Se o valor não for definido, a compatibilidade com o Glue 0.9 será definida como padrão. Para obter mais informações, consulte Versões do AWS Glue no guia do desenvolvedor.

- `MaxCapacity` – Número (duplo).

  O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para execuções de tarefas para essa transformação. Você pode alocar de 2 a 100 DPUs. O padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  `MaxCapacity` é uma opção mutuamente exclusiva com `NumberOfWorkers` e `WorkerType`.

  - Se `NumberOfWorkers` ou `WorkerType` estiver definido, `MaxCapacity` não poderá ser definido.
  - Se `MaxCapacity` estiver definido, nem `NumberOfWorkers` e nem `WorkerType` poderá ser definido.
  - Se `WorkerType` estiver definido, `NumberOfWorkers` será necessário (e vice-versa).
  - `MaxCapacity` e `NumberOfWorkers` devem ser pelo menos 1.

  Quando o campo `WorkerType` é definido como um valor diferente de `Standard`, o campo `MaxCapacity` é definido automaticamente e se torna somente leitura.

  Quando o campo `WorkerType` é definido como um valor diferente de `Standard`, o campo `MaxCapacity` é definido automaticamente e se torna somente leitura.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando uma tarefa é executada. Aceita um valor de Standard (Padrão), G.1X ou G.2X.

  - Para o tipo de operador `Standard`, cada operador fornece 4 vCPU, 16 GB de memória e um disco de 50 GB e 2 executores por operador.
  - Para o tipo de operador `G.1X`, cada operador fornece 4 vCPU, 16 GB de memória e um disco e 64 GB, 1 executor por operador.
  - Para o tipo de operador `G.2X`, cada operador fornece 8 vCPU, 32 GB de memória e um disco de 128 GB e 1 executor por operador.

  `MaxCapacity` é uma opção mutuamente exclusiva com `NumberOfWorkers` e `WorkerType`.

  - Se `NumberOfWorkers` ou `WorkerType` estiver definido, `MaxCapacity` não poderá ser definido.

  - Se `MaxCapacity` estiver definido, nem `NumberOfWorkers` e nem `WorkerType` poderá ser definido.
  - Se `WorkerType` estiver definido, `NumberOfWorkers` será necessário (e vice-versa).
  - `MaxCapacity` e `NumberOfWorkers` devem ser pelo menos 1.
- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando uma tarefa é executada.

  Se `WorkerType` estiver definido, `NumberOfWorkers` será necessário (e vice-versa).
- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite da execução de tarefa para essa transformação, em minutos. Esse é o tempo máximo durante o qual uma execução de tarefa para essa transformação pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).
- `MaxRetries` – Número (íntegro).

  O número máximo de vezes de novas tentativas dessa transformação após uma execução de tarefa falhar.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags a serem usadas com essa transformação de machine learning. É possível usar tags para limitar o acesso à transformação de machine learning. Para obter mais informações sobre tags no AWS Glue, consulte Tags da AWS no AWS Glue no guia do desenvolvedor.
- `TransformEncryption` – Um objeto TransformEncryption.

  As configurações de criptografia em repouso da transformação que se aplicam ao acesso aos dados do usuário. As transformações de machine learning podem acessar dados do usuário criptografados no Amazon S3 usando o KMS.

Resposta

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um identificador exclusivo gerado para a transformação.

Erros

- `AlreadyExistsException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `AccessDeniedException`
- `ResourceNumberLimitExceededException`
- `IdempotentParameterMismatchException`

Ação UpdateMLTransform (Python: update_ml_transform)

Atualiza uma transformação de machine learning existente. Chame esta operação para ajustar os parâmetros do algoritmo para atingir resultados melhores.

Depois de chamar essa operação, você pode chamar a operação `StartMLEvaluationTaskRun` para avaliar se os novos parâmetros alcançaram seus objetivos (como melhoria da qualidade da sua transformação de machine learning ou geração de um custo mais eficiente).

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Um identificador exclusivo gerado quando a transformação foi criada.
- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome exclusivo que você atribuiu à transformação quando a criou.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição da transformação. O padrão é uma string vazia.

- `Parameters` – Um objeto TransformParameters.

  Os parâmetros de configuração específicos para o tipo de transformação (algoritmo) usado. Dependente condicionalmente do tipo de transformação.

- `Role` – String UTF-8.

  O nome ou o nome de recurso da Amazon (ARN) da função do IAM com as permissões necessárias.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Este valor determina com qual versão de AWS Glue essa transformação de machine learning é compatível. O Glue 1.0 é recomendado para a maioria dos clientes. Se o valor não for definido, a compatibilidade com o Glue 0.9 será definida como padrão. Para obter mais informações, consulte Versões do AWS Glue no guia do desenvolvedor.

- `MaxCapacity` – Número (duplo).

  O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para execuções de tarefas para essa transformação. Você pode alocar de 2 a 100 DPUs. O padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  Quando o campo `WorkerType` é definido como um valor diferente de `Standard`, o campo `MaxCapacity` é definido automaticamente e se torna somente leitura.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando uma tarefa é executada. Aceita um valor de Standard (Padrão), G.1X ou G.2X.

  - Para o tipo de operador `Standard`, cada operador fornece 4 vCPU, 16 GB de memória e um disco de 50 GB e 2 executores por operador.

  - Para o tipo de operador `G.1X`, cada operador fornece 4 vCPU, 16 GB de memória e um disco e 64 GB, 1 executor por operador.
  - Para o tipo de operador `G.2X`, cada operador fornece 8 vCPU, 32 GB de memória e um disco de 128 GB e 1 executor por operador.
- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando uma tarefa é executada.
- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite para uma tarefa executar essa transformação em minutos. Esse é o tempo máximo durante o qual uma execução de tarefa para essa transformação pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).
- `MaxRetries` – Número (íntegro).

  O número máximo de vezes de novas tentativas dessa transformação após uma execução de tarefa falhar.

Resposta

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo para a transformação que foi atualizada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `AccessDeniedException`

Ação DeleteMLTransform (Python: delete_ml_transform)

Exclui uma transformação de machine learning do AWS Glue. As transformações de machine learning são um tipo especial de transformação que usa machine learning para aprender os detalhes da transformação que será realizada pelo aprendizado com exemplos fornecidos por humanos. Essas transformações são então salvas pelo AWS Glue. Se você não precisar mais de uma transformação, pode excluí-la chamando `DeleteMLTransforms`. No entanto, qualquer trabalho do AWS Glue que ainda faça referência à transformação excluída não terá mais êxito.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação que será excluída.

Resposta

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da transformação que foi excluída.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetMLTransform (Python: get_ml_transform)

Obtém um artefato de transformação de machine learning do AWS Glue e todos os seus metadados correspondentes. As transformações de machine learning são um tipo especial de transformação que usa machine learning para aprender os detalhes da transformação que será realizada pelo aprendizado com exemplos fornecidos por humanos. Essas transformações são então salvas pelo AWS Glue. Você pode recuperar os metadados chamando `GetMLTransform`.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação, gerado no momento em que a transformação é criada.

Resposta

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da transformação, gerado no momento em que a transformação é criada.
- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome exclusivo atribuído à transformação quando ela foi criada.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição da transformação.
- `Status` – String UTF-8 (valores válidos: `NOT_READY` | `READY` | `DELETING`).

  O último status conhecido da transformação (para indicar se pode ser usada ou não). Um dos "NOT_READY", "READY" ou "DELETING".
- `CreatedOn` – Timestamp.

  A data e a hora em que a transformação foi criada.
- `LastModifiedOn` – Timestamp.

  A data e a hora em que a transformação foi modificada pela última vez.
- `InputRecordTables`: uma matriz de objetos GlueTable, não mais do que dez estruturas.

  Uma lista de definições de tabela do AWS Glue usadas pela transformação.
- `Parameters` – Um objeto TransformParameters.

  Os parâmetros de configuração específicos para o algoritmo usado.
- `EvaluationMetrics` – Um objeto EvaluationMetrics.

As métricas de avaliação mais recentes.

- `LabelCount` – Número (íntegro).

  O número de rótulos disponíveis para essa transformação.

- `Schema`: uma matriz de objetos SchemaColumn, não mais de 100 estruturas.

  O objeto `Map<Column, Type>` que representa o esquema aceito por essa transformação. Tem um limite superior de 100 colunas.

- `Role` – String UTF-8.

  O nome ou o nome de recurso da Amazon (ARN) da função do IAM com as permissões necessárias.

- `GlueVersion` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #47.

  Este valor determina com qual versão de AWS Glue essa transformação de machine learning é compatível. O Glue 1.0 é recomendado para a maioria dos clientes. Se o valor não for definido, a compatibilidade com o Glue 0.9 será definida como padrão. Para obter mais informações, consulte Versões do AWS Glue no guia do desenvolvedor.

- `MaxCapacity` – Número (duplo).

  O número de unidades de processamento de dados (DPUs) do AWS Glue alocadas para execuções de tarefas para essa transformação. Você pode alocar de 2 a 100 DPUs. O padrão é 10. Uma DPU é uma medida relativa do poder de processamento que consiste em uma capacidade computacional de 4 vCPUs e 16 GB de memória. Para obter mais informações, consulte a página de definição de preços do AWS Glue.

  Quando o campo `WorkerType` é definido como um valor diferente de `Standard`, o campo `MaxCapacity` é definido automaticamente e se torna somente leitura.

- `WorkerType` – String UTF-8 (valores válidos: `Standard=""` | `G.1X=""` | `G.2X=""` | `G.025X=""` | `G.4X=""` | `G.8X=""` | `Z.2X=""`).

  O tipo de operador predefinido que é alocado quando uma tarefa é executada. Aceita um valor de Standard (Padrão), G.1X ou G.2X.

  - Para o tipo de operador `Standard`, cada operador fornece 4 vCPU, 16 GB de memória e um disco de 50 GB e 2 executores por operador.

  - Para o tipo de operador `G.1X`, cada operador fornece 4 vCPU, 16 GB de memória e um disco e 64 GB, 1 executor por operador.
  - Para o tipo de operador `G.2X`, cada operador fornece 8 vCPU, 32 GB de memória e um disco de 128 GB e 1 executor por operador.
- `NumberOfWorkers` – Número (íntegro).

  O número de operadores de determinado `workerType` que são alocados quando uma tarefa é executada.
- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite para uma tarefa executar essa transformação em minutos. Esse é o tempo máximo durante o qual uma execução de tarefa para essa transformação pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).
- `MaxRetries` – Número (íntegro).

  O número máximo de vezes de novas tentativas dessa transformação após uma execução de tarefa falhar.
- `TransformEncryption` – Um objeto TransformEncryption.

  As configurações de criptografia em repouso da transformação que se aplicam ao acesso aos dados do usuário. As transformações de machine learning podem acessar dados do usuário criptografados no Amazon S3 usando o KMS.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetMLTransforms (Python: get_ml_transforms)

Obtém uma lista filtrável e classificável de transformações de machine learning do AWS Glue existentes. As transformações de machine learning são um tipo especial de transformação que usa machine learning para aprender os detalhes da transformação que será realizada pelo aprendizado

com exemplos fornecidos por humanos. Essas transformações são então salvas pelo AWS Glue e você pode recuperar os metadados delas chamando `GetMLTransforms`.

Solicitação

- `NextToken` – String UTF-8.

  Um token paginado para equilibrar os resultados.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.
- `Filter` – Um objeto TransformFilterCriteria.

  Os critérios da transformação de filtros
- `Sort` – Um objeto TransformSortCriteria.

  Os critérios de classificação.

Resposta

- `Transforms` – Obrigatório: uma matriz de objetos MLTransform.

  Uma lista de transformações de machine learning.
- `NextToken` – String UTF-8.

  Um token de paginação, se houver mais resultados disponíveis.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação ListMLTransforms (Python: list_ml_transforms)

Recupera uma lista classificável e filtrável de transformações de machine learning do AWS Glue existentes nesta conta da AWS ou os recursos com a tag especificada. Essa operação aceita o

campo `Tags` opcional, que pode ser usado como um filtro das respostas, para que recursos com tags possam ser recuperados como um grupo. Se você optar por usar a filtragem por tags, apenas os recursos com as tags serão recuperados.

Solicitação

- `NextToken` – String UTF-8.

  Um token de continuação, se esta for uma solicitação de continuação.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O tamanho máximo de uma lista a ser retornada.
- `Filter` – Um objeto TransformFilterCriteria.

  Os `TransformFilterCriteria` usados para filtrar as transformações de machine learning.
- `Sort` – Um objeto TransformSortCriteria.

  Os `TransformSortCriteria` usados para classificar as transformações de machine learning.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais do que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Especifica apenas o retorno desses recursos com tags.

Resposta

- `TransformIds`: obrigatório: uma matriz de strings UTF-8.

  Os identificadores de todas as transformações de machine learning na conta, ou as transformações de machine learning com as tags especificadas.
- `NextToken` – String UTF-8.

  Um token de continuação, se a lista retornada não contiver a métrica mais recente disponível.

Erros

- `EntityNotFoundException`

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação StartMLEvaluationTaskRun (Python: start_ml_evaluation_task_run)

Inicia uma tarefa para estimar a qualidade da transformação.

Quando você fornece conjuntos de rótulos como exemplos de verdade, o machine learning do AWS Glue usa esses exemplos para aprender com eles. Os outros rótulos são usados como um teste para estimar a qualidade.

Retorna o identificador exclusivo da execução. Você pode chamar `GetMLTaskRun` para obter mais informações sobre as estatísticas de `EvaluationTaskRun`.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.

Resposta

- `TaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo associado a essa execução.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConcurrentRunsExceededException`
- `MLTransformNotReadyException`

Ação StartMLLabelingSetGenerationTaskRun (Python: start_ml_labeling_set_generation_task_run)

Inicia o fluxo de trabalho de aprendizado ativo da sua transformação de machine learning para melhorar a qualidade da transformação gerando conjuntos de dados e adicionando rótulos.

Quando `StartMLLabelingSetGenerationTaskRun` estiver concluído, o AWS Glue terá gerado um “conjunto de rótulos” ou um conjunto de questões para serem respondidas por humanos.

No caso da transformação `FindMatches`, essas perguntas são do tipo: "Qual é a maneira correta para agrupar essas linhas em grupos compostos inteiramente por registros correspondentes?"

Depois que o processo de rotulação finalizar, você poderá fazer upload dos seus rótulos com uma chamada para `StartImportLabelsTaskRun`. Depois de `StartImportLabelsTaskRun` terminar, todas as execuções futuras da transformação de machine learning usarão os rótulos novos e melhorados para executar uma transformação de maior qualidade.

Observação: o perfil usado para gravar o conjunto de rótulos gerado no `OutputS3Path` é o perfil associado à transformação de machine learning, especificado na API `CreateMLTransform`.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.
- `OutputS3Path` – Obrigatório: string UTF-8.

  O caminho do Amazon Simple Storage Service (Amazon S3) de onde você gera o conjunto de rótulos.

Resposta

- `TaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da execução associado a essa execução de tarefa.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConcurrentRunsExceededException`

Ação GetMLTaskRun (Python: get_ml_task_run)

Obtém os detalhes de uma execução de tarefa em uma transformação de machine learning. As execuções de tarefas de machine learning são tarefas assíncronas executadas pelo AWS Glue em seu nome como parte de vários fluxos de trabalho de machine learning. Você pode verificar as estatísticas de qualquer execução de tarefa chamando `GetMLTaskRun` com o `TaskRunID` e o `TransformID` da sua transformação principal.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.
- `TaskRunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da tarefa executada.

Resposta

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da tarefa executada.
- `TaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status da execução dessa tarefa.
- `LogGroupName` – String UTF-8.

  Os nomes dos grupos de logs associados à execução de tarefa.
- `Properties` – Um objeto TaskRunProperties.

  A lista de propriedades associadas à execução de tarefa.
- `ErrorString` – String UTF-8.

  As strings de erro associadas à execução de tarefa.
- `StartedOn` – Timestamp.

  A data e hora em que essa execução de tarefa foi iniciada.
- `LastModifiedOn` – Timestamp.

  A data e hora em que essa execução de tarefa foi modificada pela última vez.
- `CompletedOn` – Timestamp.

  A data e hora em que essa execução de tarefa foi finalizada.
- `ExecutionTime` – Número (íntegro).

  A quantidade de tempo (em segundos) em que a tarefa executada consumiu recursos.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetMLTaskRuns (Python: get_ml_task_runs)

Obtém uma lista de execuções para a transformação de machine learning. As execuções de tarefas de machine learning são tarefas assíncronas executadas pelo AWS Glue em seu nome como parte

de vários fluxos de trabalho de machine learning. Você pode obter uma lista de execuções de tarefa de machine learning filtrável e classificável chamando `GetMLTaskRuns` com o `TransformID` da transformação principal e outros parâmetros opcionais conforme documentados nesta seção.

Essa operação retorna uma lista com de execuções históricas e deve ser paginada.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.
- `NextToken` – String UTF-8.

  Um token de paginação dos resultados. O padrão é vazio.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.
- `Filter` – Um objeto TaskRunFilterCriteria.

  Os critérios de filtro, na estrutura `TaskRunFilterCriteria`, da execução de tarefa.
- `Sort` – Um objeto TaskRunSortCriteria.

  Os critérios de classificação, na estrutura `TaskRunSortCriteria`, da execução de tarefa.

Resposta

- `TaskRuns`: um array de objetos TaskRun.

  Uma lista de execuções de tarefa que são associadas a transformação.
- `NextToken` – String UTF-8.

  Um token de paginação, se houver mais resultados disponíveis.

Erros

- `EntityNotFoundException`
- `InvalidInputException`

- `OperationTimeoutException`
- `InternalServiceException`

Ação CancelMLTaskRun (Python: cancel_ml_task_run)

Cancela (interrompe) a execução de uma tarefa. As execuções de tarefas de machine learning são tarefas assíncronas executadas pelo AWS Glue em seu nome como parte de vários fluxos de trabalho de machine learning. Você pode cancelar uma execução de tarefa de machine learning a qualquer momento chamando `CancelMLTaskRun` com um `TransformID` de transformação principal da execução de tarefa e o `TaskRunId` da execução de tarefa.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.
- `TaskRunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Um identificador exclusivo para a tarefa executada.

Resposta

- `TransformId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.
- `TaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da tarefa executada.
- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status dessa execução.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação StartExportLabelsTaskRun (Python: start_export_labels_task_run)

Inicia uma tarefa assíncrona para exportar todos os dados rotulados para uma determinada transformação. Essa tarefa é a única chamada de API relacionada ao rótulo e não faz parte do fluxo de trabalho típico de aprendizado ativo. Normalmente, você usa `StartExportLabelsTaskRun` quando quer trabalhar com todos os rótulos existentes ao mesmo tempo, por exemplo, quando deseja excluir ou alterar rótulos que foram enviados como verdade anteriormente. Esta operação de API aceita o `TransformId` do qual você deseja exportar rótulos e um caminho do Amazon Simple Storage Service (Amazon S3) para onde exportá-los. A operação retorna um `TaskRunId`. Você pode verificar o status da sua tarefa chamando a API `GetMLTaskRun`.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.
- `OutputS3Path` – Obrigatório: string UTF-8.

  O caminho do Amazon S3 para onde você exportará os rótulos.

Resposta

- `TaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da tarefa executada.

Erros

- `EntityNotFoundException`

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação StartImportLabelsTaskRun (Python: start_import_labels_task_run)

Permite que você forneça rótulos adicionais (exemplos de verdade) para serem usados no ensino da transformação de machine learning e na melhoria da qualidade. Essa operação de API é geralmente usada como parte do fluxo de aprendizagem ativo que começa com a chamada `StartMLLabelingSetGenerationTaskRun` e que, em última análise, resulta em melhorar a qualidade da sua transformação de machine learning.

Quando `StartMLLabelingSetGenerationTaskRun` terminar, o machine learning do AWS Glue terá gerado várias questões para serem respondidas por humanos. (Responder a essas perguntas é muitas vezes chamado de "rotulamento" nos fluxos de machine learning). No caso da transformação `FindMatches`, essas perguntas são do tipo: "Qual é a maneira correta para agrupar essas linhas em grupos compostos inteiramente por registros correspondentes?" Após o término do processo de rotulamento, os usuários carregam suas respostas/rótulos com uma chamada para `StartImportLabelsTaskRun`. Depois que `StartImportLabelsTaskRun` terminar, todas as execuções futuras da transformação de machine learning usarão os rótulos novos e melhorados para executar uma transformação de maior qualidade.

Por padrão, `StartMLLabelingSetGenerationTaskRun` aprende continuamente e combina todos os rótulos do seu upload, a não ser que você defina `Replace` como true. Se você definir `Replace` como true, `StartImportLabelsTaskRun` exclui e esquece todos os rótulos previamente submetidos e aprende somente com o conjunto exato que você carregar. Substituir rótulos pode ser útil se você perceber que fez um upload incorreto de rótulos anteriormente e acredita que eles estão causando um efeito negativo na qualidade da transformação.

Você pode verificar o status da sua execução de tarefa chamando a operação `GetMLTaskRun`.

Solicitação

- `TransformId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador exclusivo da transformação de machine learning.
- `InputS3Path` – Obrigatório: string UTF-8.

O caminho do Amazon Simple Storage Service (Amazon S3) para onde você importará os rótulos.

- `ReplaceAllLabels` – Booleano.

  Indica se você deve substituir os rótulos existentes.

Resposta

- `TaskRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador exclusivo da tarefa executada.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`
- `InternalServiceException`

API Data Quality API

A API Data Quality descreve os tipos de dados de qualidade dos dados e inclui a API para criar, excluir ou atualizar conjuntos de dados, execuções e avaliações de qualidade de dados.

Tipos de dados

- Estrutura DataSource
- Estrutura DataQualityRulesetListDetails
- Estrutura DataQualityTargetTable
- Estrutura DataQualityRulesetEvaluationRunDescription
- Estrutura DataQualityRulesetEvaluationRunFilter
- Estrutura DataQualityEvaluationRunAdditionalRunOptions
- Estrutura DataQualityRuleRecommendationRunDescription

- Estrutura DataQualityRuleRecommendationRunFilter
- Estrutura DataQualityResult
- Estrutura DataQualityAnalyzerResult
- Estrutura DataQualityObservation
- Estrutura MetricBasedObservation
- Estrutura DataQualityMetricValues
- Estrutura DataQualityRuleResult
- Estrutura DataQualityResultDescription
- Estrutura DataQualityResultFilterCriteria
- Estrutura DataQualityRulesetFilterCriteria
- Estrutura DataQualityAggregatedMetrics
- Estrutura StatisticAnotation
- Estrutura TimestampedInclusionAnnotation
- Estrutura AnnotationError
- Estrutura DatapointInclusionAnnotation
- Lista StatisticSummaryList
- Estrutura StatisticSummary
- Estrutura RunIdentifier
- Estrutura StatisticModelResult

Estrutura DataSource

Uma fonte de dados (uma tabela do AWS Glue) para a qual você deseja resultados de qualidade de dados.

Campos

- `GlueTable` – Obrigatório: um objeto GlueTable.

  Uma tabela do AWS Glue.

Estrutura DataQualityRulesetListDetails

Descreve um conjunto de regras de qualidade de dados retornado por `GetDataQualityRuleset`.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do conjunto de regras de qualidade de dados.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do conjunto de regras de qualidade de dados.

- `CreatedOn` – Timestamp.

  A data e hora da criação do conjunto de regras de qualidade de dados.

- `LastModifiedOn` – Timestamp.

  A data e hora da modificação do conjunto de regras de qualidade de dados.

- `TargetTable` – Um objeto DataQualityTargetTable.

  Um objeto que representa uma tabela do AWS Glue.

- `RecommendationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Quando um conjunto de regras foi criado de execução de uma recomendação, esse ID de execução é gerado para vincular os dois.

- `RuleCount` – Número (íntegro).

  O número de regras no conjunto de regras.

Estrutura DataQualityTargetTable

Um objeto que representa uma tabela do AWS Glue.

Campos

- `TableName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome da tabela AWS Glue.

- `DatabaseName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do banco de dados em que a tabela do AWS Glue existe.
- `CatalogId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do catálogo onde a tabela AWS Glue se encontra.

Estrutura DataQualityRulesetEvaluationRunDescription

Descreve o resultado da avaliação de um conjunto de regras de qualidade de dados.

Campos

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.
- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status dessa execução.
- `StartedOn` – Timestamp.

  A data e a hora de início da execução.
- `DataSource` – Um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada à execução.

Estrutura DataQualityRulesetEvaluationRunFilter

Os critérios de filtro.

Campos

- `DataSource` – Obrigatório: um objeto DataSource.

  Filtrar com base em uma fonte de dados (uma tabela do AWS Glue) associada à execução.

- `StartedBefore` – Timestamp.

  Filtrar os resultados por execuções iniciadas antes desse horário.

- `StartedAfter` – Timestamp.

  Filtrar os resultados por execuções iniciadas depois desse horário.

Estrutura DataQualityEvaluationRunAdditionalRunOptions

Opções adicionais de execução que você pode especificar para uma execução de avaliação.

Campos

- `CloudWatchMetricsEnabled` – Booleano.

  Se as métricas do CloudWatch devem ou não ser habilitadas.

- `ResultsS3Prefix` – String UTF-8.

  Prefixo para o Amazon S3 para armazenar resultados.

- `CompositeRuleEvaluationMethod`: string UTF-8 (valores válidos: `COLUMN` | `ROW`).

  Definir o método de avaliação para regras compostas no conjunto de regras como ROW/COLUMN

Estrutura DataQualityRuleRecommendationRunDescription

Descreve o resultado da avaliação de uma recomendação de regra de qualidade de dados.

Campos

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status dessa execução.

- `StartedOn` – Timestamp.

A data e hora em que essa execução foi iniciada.

- `DataSource` – Um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada à execução da recomendação.

Estrutura DataQualityRuleRecommendationRunFilter

Um filtro para listar as execuções de recomendação de qualidade de dados.

Campos

- `DataSource` – Obrigatório: um objeto DataSource.

  Filtrar com base em uma fonte de dados especificada (tabela do AWS Glue).

- `StartedBefore` – Timestamp.

  Filtrar com base na hora dos resultados iniciados antes do horário fornecido.

- `StartedAfter` – Timestamp.

  Filtrar com base na hora dos resultados iniciados depois do horário fornecido.

Estrutura DataQualityResult

Descreve um resultado de qualidade de dados.

Campos

- `ResultId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um ID de resultado exclusivo para o resultado de qualidade dos dados.

- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil para o resultado de qualidade dos dados.

- `Score`: número (double), no máximo 1,0.

Uma pontuação de qualidade de dados agregada. Representa a razão de regras que foram aproadas para o número total de regras.

- `DataSource` – Um objeto DataSource.

  A tabela associada ao resultado de qualidade dos dados, se houver.

- `RulesetName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do conjunto de regras associado ao resultado de qualidade de dados.

- `EvaluationContext` – String UTF-8.

  No contexto de um trabalho no AWS Glue Studio, cada nó na tela normalmente recebe algum tipo de nome e os nós de qualidade de dados terão nomes. No caso de vários nós, o `evaluationContext` pode diferenciar os nós.

- `StartedOn` – Timestamp.

  A data e hora de início dessa execução de qualidade de dados.

- `CompletedOn` – Timestamp.

  A data e hora de conclusão dessa execução de qualidade de dados.

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do trabalho associado ao resultado de qualidade dos dados, se houver.

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução de trabalho associado ao resultado de qualidade dos dados, se houver.

- `RulesetEvaluationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução exclusivo para a avaliação do conjunto de regras para esse resultado de qualidade de dados.

- `RuleResults`: uma matriz de objetos DataQualityRuleResult, não mais de 2.000 estruturas.

  Uma lista de objetos do `DataQualityRuleResult` representando os resultados de cada regra.

- `AnalyzerResults`: uma matriz de objetos DataQualityAnalyzerResult, não mais de 2.000 estruturas.

  Uma lista de objetos `DataQualityAnalyzerResult` representando os resultados de cada analisador.
- `Observations` – Uma matriz de DataQualityObservation objetos, não mais de 50 estruturas.

  Uma lista de objetos `DataQualityObservation` representando as observações geradas após a avaliação das regras e dos analisadores.
- `AggregatedMetrics` – Um objeto DataQualityAggregatedMetrics.

  Um resumo dos objetos `DataQualityAggregatedMetrics` mostrando as contagens totais de linhas e regras processadas, incluindo suas estatísticas de aprovação/reprovação com base nos resultados no nível de linha.

Estrutura DataQualityAnalyzerResult

Descreve o resultado da avaliação de um analisador de qualidade de dados.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do analisador de qualidade de dados.
- `Description`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a URI address multi-line string pattern.

  Uma descrição do analisador de qualidade de dados.
- `EvaluationMessage`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a URI address multi-line string pattern.

  Uma mensagem de avaliação.
- `EvaluatedMetrics` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é um número (duplo).

Um mapa das métricas associadas à avaliação do analisador.

Estrutura DataQualityObservation

Descreve a observação gerada após a avaliação das regras e dos analisadores.

Campos

- `Description`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a URI address multi-line string pattern.

  Uma descrição da observação de qualidade de dados.
- `MetricBasedObservation` – Um objeto MetricBasedObservation.

  Um objeto do tipo `MetricBasedObservation` que representa a observação com base nas métricas de qualidade de dados avaliadas.

Estrutura MetricBasedObservation

Descreve a observação baseada em métricas gerada com base nas métricas de qualidade de dados avaliadas.

Campos

- `MetricName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da métrica de qualidade de dados usada para gerar a observação.
- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística.
- `MetricValues` – Um objeto DataQualityMetricValues.

  Um objeto do tipo `DataQualityMetricValues` que representa a análise do valor da métrica de qualidade de dados.
- `NewRules` – Uma matriz de strings UTF-8.

Uma lista de novas regras de qualidade de dados geradas como parte da observação com base no valor da métrica de qualidade de dados.

Estrutura DataQualityMetricValues

Descreve o valor da métrica de qualidade de dados de acordo com a análise de dados históricos.

Campos

- `ActualValue` – Número (duplo).

  O valor real da métrica de qualidade de dados.
- `ExpectedValue` – Número (duplo).

  O valor esperado da métrica de qualidade de dados de acordo com a análise de dados históricos.
- `LowerLimit` – Número (duplo).

  O limite inferior do valor da métrica de qualidade de dados de acordo com a análise de dados históricos.
- `UpperLimit` – Número (duplo).

  O limite superior do valor da métrica de qualidade de dados de acordo com a análise de dados históricos.

Estrutura DataQualityRuleResult

Descreve o resultado da avaliação de uma regra de qualidade de dados.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da regra de qualidade de dados.
- `Description`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a URI address multi-line string pattern.

  Uma descrição da regras de qualidade de dados.

- `EvaluationMessage`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a URI address multi-line string pattern.

  Uma mensagem de avaliação.

- `Result` – String UTF-8 (valores válidos: `PASS` | `FAIL` | `ERROR`).

  Um status de aprovação ou reprovação da regra.

- `EvaluatedMetrics` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é um número (duplo).

  Um mapa das métricas associadas à avaliação da regra.

- `EvaluatedRule`: string UTF-8 com comprimento máximo de 2.048 bytes e correspondente a URI address multi-line string pattern.

  A regra avaliada.

- `RuleMetrics` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é um número (duplo).

  Um mapa contendo métricas associadas à avaliação da regra com base nos resultados no nível de linha.

Estrutura DataQualityResultDescription

Descreve um resultado de qualidade de dados.

Campos

- `ResultId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de resultado exclusivo para esse resultado de qualidade dos dados.

- `DataSource` – Um objeto DataSource.

  O nome da tabela associada ao resultado de qualidade dos dados.
- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do trabalho associado ao resultado de qualidade dos dados.
- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução de trabalho associado ao resultado de qualidade dos dados.
- `StartedOn` – Timestamp.

  A hora de início da execução desse resultado de qualidade de dados.

Estrutura DataQualityResultFilterCriteria

Critérios usados para retornar resultados de qualidade de dados.

Campos

- `DataSource` – Um objeto DataSource.

  Filtrar os resultados pela fonte de dados especificada. Por exemplo, recuperar todos os resultados de uma tabela do AWS Glue.
- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Filtrar os resultados pelo nome de trabalho especificado.
- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Filtrar os resultados pelo ID e execução de trabalho especificado.
- `StartedAfter` – Timestamp.

  Filtrar os resultados por execuções iniciadas depois desse horário.
- `StartedBefore` – Timestamp.

  Filtrar os resultados por execuções iniciadas antes desse horário.

Estrutura DataQualityRulesetFilterCriteria

Os critérios usados para filtrar conjuntos de regras de qualidade de dados.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome dos critérios de filtro do conjunto de regras.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  A descrição dos critérios de filtro do conjunto de regras.
- `CreatedBefore` – Timestamp.

  Filtrar por conjuntos de regras criados antes dessa data.
- `CreatedAfter` – Timestamp.

  Filtrar por conjuntos de regras criados depois dessa data.
- `LastModifiedBefore` – Timestamp.

  Filtrar por conjuntos de dados modificados antes dessa data.
- `LastModifiedAfter` – Timestamp.

  Filtrar por conjuntos de dados modificados depois dessa data.
- `TargetTable` – Um objeto DataQualityTargetTable.

  O nome e o nome do banco de dados da tabela de destino.

Estrutura DataQualityAggregatedMetrics

Um resumo de métricas mostrando as contagens totais de linhas e regras processadas, incluindo suas estatísticas de aprovação/reprovação com base nos resultados no nível de linha.

Campos

- `TotalRowsProcessed` – Número (duplo).

O número total de linhas que foram processadas durante a avaliação da qualidade dos dados.

- `TotalRowsPassed` – Número (duplo).

  O número total de linhas que passaram por todas as regras aplicáveis de qualidade de dados.

- `TotalRowsFailed` – Número (duplo).

  O número total de linhas que falharam em uma ou mais regras de qualidade de dados.

- `TotalRulesProcessed` – Número (duplo).

  O número total de regras de qualidade de dados que foram avaliadas.

- `TotalRulesPassed` – Número (duplo).

  O número total de regras de qualidade de dados que foram aprovadas em seus critérios de avaliação.

- `TotalRulesFailed` – Número (duplo).

  O número total de regras de qualidade de dados que foram reprovadas em seus critérios de avaliação.

Estrutura StatisticAnotation

Uma anotação estatística.

Campos

- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil.

- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística.

- `StatisticRecorded0n` – Timestamp.

  O carimbo de data e hora de quando a estatística anotada foi registrada.

- `InclusionAnnotation` – Um objeto TimestampedInclusionAnnotation.

A anotação de inclusão aplicada à estatística.

Estrutura TimestampedInclusionAnnotation

Uma anotação de inclusão com data e hora.

Campos

- `Value`: string UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  O valor da anotação de inclusão.
- `LastModifiedOn` – Timestamp.

  O carimbo de data e hora da última modificação da anotação de inclusão.

Estrutura AnnotationError

Uma anotação com falha.

Campos

- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil da anotação com falha.
- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística da anotação com falha.
- `FailureReason`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  O motivo pelo qual a anotação falhou.

Estrutura DatapointInclusionAnnotation

Uma anotação de inclusão.

Campos

- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil de qualidade de dados ao qual a estatística pertence.
- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística.
- `InclusionAnnotation`: string UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  O valor da anotação de inclusão a ser aplicado à estatística.

Lista StatisticSummaryList

Uma lista de `StatisticSummary`.

Uma matriz de objetos StatisticSummary.

Uma lista de `StatisticSummary`.

Estrutura StatisticSummary

Informações resumidas sobre uma estatística.

Campos

- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística.
- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil.
- `RunIdentifier` – Um objeto RunIdentifier.

  O identificador da execução.

- `StatisticName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Custom string pattern #16.

  O nome da estatística.

- `DoubleValue` – Número (duplo).

  O valor da estatística.

- `EvaluationLevel` – String UTF-8 (valores válidos: `Dataset="DATASET"` | `Column="COLUMN"` | `Multicolumn="MULTICOLUMN"`).

  O nível de avaliação da estatística. Valores possíveis: `Dataset`, `Column`, `Multicolumn`.

- `ColumnsReferenced` – Uma matriz de strings UTF-8.

  A lista de colunas referenciadas pela estatística.

- `ReferencedDatasets` – Uma matriz de strings UTF-8.

  A lista de conjuntos de dados referenciados pela estatística.

- `StatisticProperties` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é uma string de descrição, com não mais de 2048 de comprimento, correspondo a URI address multi-line string pattern.

  Uma `StatisticPropertiesMap`, que contém uma `NameString` e uma `DescriptionString`

- `RecordedOn` – Timestamp.

  O carimbo de data e hora de quando a estatística foi registrada.

- `InclusionAnnotation` – Um objeto TimestampedInclusionAnnotation.

  A anotação de inclusão da estatística.

Estrutura RunIdentifier

Um identificador de execução.

Campos

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da execução.

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da execução do trabalho.

Estrutura StatisticModelResult

O resultado do modelo estatístico.

Campos

- `LowerBound` – Número (duplo).

  O limite inferior.

- `UpperBound` – Número (duplo).

  O limite superior.

- `PredictedValue` – Número (duplo).

  O valor previsto

- `ActualValue` – Número (duplo).

  O valor real.

- `Date` – Timestamp.

  A data.

- `InclusionAnnotation`: string UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  A anotação de inclusão.

Operações

- Ação StartDataQualityRulesetEvaluationRun (Python: start_data_quality_ruleset_evaluation_run)
- Ação CancelDataQualityRulesetEvaluationRun (Python: cancel_data_quality_ruleset_evaluation_run)
- Ação GetDataQualityRulesetEvaluationRun (Python: get_data_quality_ruleset_evaluation_run)
- Ação ListDataQualityRulesetEvaluationRuns (Python: list_data_quality_ruleset_evaluation_runs)
- Ação StartDataQualityRuleRecommendationRun (Python: start_data_quality_rule_recommendation_run)
- Ação CancelDataQualityRuleRecommendationRun (Python: cancel_data_quality_rule_recommendation_run)
- Ação GetDataQualityRuleRecommendationRun (Python: get_data_quality_rule_recommendation_run)
- Ação ListDataQualityRuleRecommendationRuns (Python: list_data_quality_rule_recommendation_runs)
- Ação GetDataQualityResult (Python: get_data_quality_result)
- Ação BatchGetDataQualityResult (Python: batch_get_data_quality_result)
- Ação ListDataQualityResults (Python: list_data_quality_results)
- Ação CreateDataQualityRuleset (Python: create_data_quality_ruleset)
- Ação DeleteDataQualityRuleset (Python: delete_data_quality_ruleset)
- Ação GetDataQualityRuleset (Python: get_data_quality_ruleset)
- Ação ListDataQualityRulesets (Python: list_data_quality_rulesets)
- Ação UpdateDataQualityRuleset (Python: update_data_quality_ruleset)
- Ação ListDataQualityStatistics (Python: list_data_quality_statistics)
- Estrutura TimestampFilter
- Estrutura CreateDataQualityRulesetRequest
- Estrutura GetDataQualityRulesetResponse
- Estrutura GetDataQualityResultResponse
- Estrutura StartDataQualityRuleRecommendationRunRequest
- Estrutura GetDataQualityRuleRecommendationRunResponse
- Ação BatchPutDataQualityStatisticAnnotation (Python: batch_put_data_quality_statistic_annotation)

- Ação GetDataQualityModel (Python: get_data_quality_model)
- Ação GetDataQualityModelResult (Python: get_data_quality_model_result)
- Ação ListDataQualityStatisticAnnotations (Python: list_data_quality_statistic_annotations)
- Ação PutDataQualityProfileAnnotation (Python: put_data_quality_profile_annotation)

Ação StartDataQualityRulesetEvaluationRun (Python: start_data_quality_ruleset_evaluation_run)

Depois que você tem uma definição de conjunto de regras (recomendado ou seu própria conjunto), você chama essa operação para avaliar o conjunto de regras em relação a uma fonte de dados (tabela do AWS Glue). A avaliação calcula os resultados que você pode recuperar com a API `GetDataQualityResult`.

Solicitação

- `DataSource` – Obrigatório: um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada a essa execução.
- `Role` – Obrigatório: string UTF-8.

  Um perfil do IAM fornecido para criptografar os resultados da execução.
- `NumberOfWorkers` – Número (íntegro).

  O número de processadores do `G.1X` a serem usados na execução. O padrão é 5.
- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite em minutos para uma execução. Esse é o tempo máximo durante o qual uma execução pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).
- `ClientToken` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Usado para idempotência e é recomendado que seja definido como um ID aleatório (como um UUID) para evitar criar ou iniciar várias instâncias do mesmo recurso.
- `AdditionalRunOptions` – Um objeto DataQualityEvaluationRunAdditionalRunOptions.

  Opções adicionais de execução que você pode especificar para uma execução de avaliação.

- `RulesetNames` - obrigatório: uma matriz de strings UTF-8, não menos que 1 ou mais que 10 strings.

  Uma lista de nomes de conjuntos de regras.

- `AdditionalDataSources` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é um objeto DataSource A.

  Um mapa de strings de referência para fontes de dados adicionais que você pode especificar para uma execução de avaliação.

Resposta

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

Erros

- `InvalidInputException`
- `EntityNotFoundException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ConflictException`

Ação CancelDataQualityRulesetEvaluationRun (Python: cancel_data_quality_ruleset_evaluation_run)

Cancela uma execução em que um conjunto de regras está sendo avaliado em relação a uma fonte de dados.

Solicitação

- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetDataQualityRulesetEvaluationRun (Python: get_data_quality_ruleset_evaluation_run)

Cancela uma execução específica em que um conjunto de regras está sendo avaliado em relação a uma fonte de dados.

Solicitação

- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

Resposta

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

- `DataSource` – Um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada a essa avaliação.

- `Role` – String UTF-8.

  Um perfil do IAM fornecido para criptografar os resultados da execução.

- `NumberOfWorkers` – Número (íntegro).

  O número de processadores do `G.1X` a serem usados na execução. O padrão é 5.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite em minutos para uma execução. Esse é o tempo máximo durante o qual uma execução pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).

- `AdditionalRunOptions` – Um objeto DataQualityEvaluationRunAdditionalRunOptions.

  Opções adicionais de execução que você pode especificar para uma execução de avaliação.

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status dessa execução.

- `ErrorString` – String UTF-8.

  As strings de erro associadas à execução.

- `StartedOn` – Timestamp.

  A data e hora em que essa execução foi iniciada.

- `LastModifiedOn` – Timestamp.

  Um carimbo de data/hora. O último ponto em que essa recomendação de regra de qualidade de dados foi executada foi modificado.

- `CompletedOn` – Timestamp.

  A data e hora de conclusão dessa execução.

- `ExecutionTime` – Número (íntegro).

  A quantidade de tempo (em segundos) durante a qual a execução consumiu recursos.

- `RulesetNames`: uma matriz de strings UTF-8, não menos que 1 ou mais que 10 strings.

Uma lista de nomes de conjuntos de regras para a execução. Atualmente, este parâmetro pode ter apenas um nome de conjunto de regras.

- `ResultIds`: uma matriz de strings UTF-8, não menos que 1 ou mais que 10 strings.

  Uma lista de IDs de resultado para os resultados de qualidade de dados da execução.

- `AdditionalDataSources` – Um array de mapa dos pares de valor-chave.

  Cada chave é uma string UTF-8 com no mínimo 1 e e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Cada valor é um objeto DataSource A.

  Um mapa de strings de referência para fontes de dados adicionais que você pode especificar para uma execução de avaliação.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação ListDataQualityRulesetEvaluationRuns (Python: list_data_quality_ruleset_evaluation_runs)

Lista todas as execuções que atendem aos critérios de filtro, em que um conjunto de regras é avaliado em relação a uma fonte de dados.

Solicitação

- `Filter` – Um objeto DataQualityRulesetEvaluationRunFilter.

  Os critérios de filtro.

- `NextToken` – String UTF-8.

  Um token paginado para equilibrar os resultados.

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.

Resposta

- `Runs`: um array de objetos DataQualityRulesetEvaluationRunDescription.

  Uma lista de objetos `DataQualityRulesetEvaluationRunDescription` que representam execuções de conjuntos de regras de qualidade de dados.
- `NextToken` – String UTF-8.

  Um token de paginação, se houver mais resultados disponíveis.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação StartDataQualityRuleRecommendationRun (Python: start_data_quality_rule_recommendation_run)

Inicia uma execução de recomendação que é usada para gerar regras quando você não sabe quais regras escrever. AWS Glue A Data Quality analisa os dados e gera recomendações para um possível conjunto de regras. Em seguida, você pode fazer a triagem do conjunto de regras e modificar o conjunto de regras gerado de acordo com sua preferência.

As execuções de recomendação são excluídas automaticamente após 90 dias.

Solicitação

A solicitação de recomendação da regra de qualidade dos dados.

- `DataSource` – Obrigatório: um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada a essa execução.
- `Role` – Obrigatório: string UTF-8.

Um perfil do IAM fornecido para criptografar os resultados da execução.

- `NumberOfWorkers` – Número (íntegro).

  O número de processadores do `G.1X` a serem usados na execução. O padrão é 5.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite em minutos para uma execução. Esse é o tempo máximo durante o qual uma execução pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).

- `CreatedRulesetName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome para o conjunto de regras.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

- `ClientToken` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Usado para idempotência e é recomendado que seja definido como um ID aleatório (como um UUID) para evitar criar ou iniciar várias instâncias do mesmo recurso.

Resposta

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

- `ConflictException`

Ação CancelDataQualityRuleRecommendationRun (Python: cancel_data_quality_rule_recommendation_run)

Cancela a execução da recomendação especificada que estava sendo usada para gerar regras.

Solicitação

- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetDataQualityRuleRecommendationRun (Python: get_data_quality_rule_recommendation_run)

Obtém a execução da recomendação especificada que estava sendo usada para gerar regras.

Solicitação

- `RunId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

Resposta

A resposta para a execução de recomendação da regra de qualidade dos dados.

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.
- `DataSource` – Um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada a essa execução.
- `Role` – String UTF-8.

  Um perfil do IAM fornecido para criptografar os resultados da execução.
- `NumberOfWorkers` – Número (íntegro).

  O número de processadores do `G.1X` a serem usados na execução. O padrão é 5.
- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite em minutos para uma execução. Esse é o tempo máximo durante o qual uma execução pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).
- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status dessa execução.
- `ErrorString` – String UTF-8.

  As strings de erro associadas à execução.
- `StartedOn` – Timestamp.

  A data e hora em que essa execução foi iniciada.
- `LastModifiedOn` – Timestamp.

  Um carimbo de data/hora. O último ponto em que essa recomendação de regra de qualidade de dados foi executada foi modificado.
- `CompletedOn` – Timestamp.

  A data e hora de conclusão dessa execução.

- `ExecutionTime` – Número (íntegro).

  A quantidade de tempo (em segundos) durante a qual a execução consumiu recursos.

- `RecommendedRuleset`: string UTF-8, não menos do que 1 ou mais de 65536 bytes de comprimento.

  Quando uma execução de recomendação de regra inicial é concluída, ela cria um conjunto de regras recomendado. Esse membro tem essas regras no formato Data Quality Definition Language (DQDL).

- `CreatedRulesetName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do conjunto de regras que foi criado pela execução.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação ListDataQualityRuleRecommendationRuns (Python: list_data_quality_rule_recommendation_runs)

Lista as execuções de recomendações que atendem aos critérios do filtro.

Solicitação

- `Filter` – Um objeto DataQualityRuleRecommendationRunFilter.

  Os critérios de filtro.

- `NextToken` – String UTF-8.

Um token paginado para equilibrar os resultados.

- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.

Resposta

- `Runs`: um array de objetos DataQualityRuleRecommendationRunDescription.

  Uma lista dos objetos `DataQualityRuleRecommendationRunDescription`.
- `NextToken` – String UTF-8.

  Um token de paginação, se houver mais resultados disponíveis.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetDataQualityResult (Python: get_data_quality_result)

Recupera o resultado de uma avaliação da regra de qualidade de dados.

Solicitação

- `ResultId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Um ID de resultado exclusivo para o resultado de qualidade dos dados.

Resposta

A resposta para o resultado de qualidade dos dados.

- `ResultId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

Um ID de resultado exclusivo para o resultado de qualidade dos dados.

- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil para o resultado de qualidade dos dados.

- `Score`: número (double), no máximo 1,0.

  Uma pontuação de qualidade de dados agregada. Representa a razão de regras que foram aproadas para o número total de regras.

- `DataSource` – Um objeto DataSource.

  A tabela associada ao resultado de qualidade dos dados, se houver.

- `RulesetName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do conjunto de regras associado ao resultado de qualidade de dados.

- `EvaluationContext` – String UTF-8.

  No contexto de um trabalho no AWS Glue Studio, cada nó na tela normalmente recebe algum tipo de nome e os nós de qualidade de dados terão nomes. No caso de vários nós, o `evaluationContext` pode diferenciar os nós.

- `StartedOn` – Timestamp.

  A data e hora de início da execução desse resultado de qualidade de dados.

- `CompletedOn` – Timestamp.

  A data e hora de conclusão da execução desse resultado de qualidade de dados.

- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do trabalho associado ao resultado de qualidade dos dados, se houver.

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução de trabalho associado ao resultado de qualidade dos dados, se houver.

- `RulesetEvaluationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O ID de execução exclusivo associado à avaliação do conjunto de regras.

- `RuleResults`: uma matriz de objetos DataQualityRuleResult, não mais de 2.000 estruturas.

  Uma lista de objetos do `DataQualityRuleResult` representando os resultados de cada regra.

- `AnalyzerResults`: uma matriz de objetos DataQualityAnalyzerResult, não mais de 2.000 estruturas.

  Uma lista de objetos `DataQualityAnalyzerResult` representando os resultados de cada analisador.

- `Observations` – Uma matriz de DataQualityObservation objetos, não mais de 50 estruturas.

  Uma lista de objetos `DataQualityObservation` representando as observações geradas após a avaliação das regras e dos analisadores.

- `AggregatedMetrics` – Um objeto DataQualityAggregatedMetrics.

  Um resumo dos objetos `DataQualityAggregatedMetrics` mostrando as contagens totais de linhas e regras processadas, incluindo suas estatísticas de aprovação/reprovação com base nos resultados no nível de linha.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `EntityNotFoundException`

Ação BatchGetDataQualityResult (Python: batch_get_data_quality_result)

Recupera uma lista de resultados de qualidade de dados para os IDs de resultados especificados.

Solicitação

- `ResultIds` - obrigatório: uma matriz de strings UTF-8, não menos que 1 ou mais que 100 strings.

  Uma lista de IDs de resultado exclusivas para os resultados de qualidade dos dados.

Resposta

- `Results` – Obrigatório: uma matriz de objetos DataQualityResult.

  Uma lista de objetos `DataQualityResult` que representam os resultados de qualidade dos dados.
- `ResultsNotFound`: uma matriz de strings UTF-8, não menos que 1 ou mais que 100 strings.

  Uma lista de IDs de resultados para os quais resultados não foram encontrados.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação ListDataQualityResults (Python: list_data_quality_results)

Retorna todos os resultados de execução de qualidade de dados para sua conta.

Solicitação

- `Filter` – Um objeto DataQualityResultFilterCriteria.

  Os critérios de filtro.
- `NextToken` – String UTF-8.

  Um token paginado para equilibrar os resultados.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.

Resposta

- `Results` – Obrigatório: uma matriz de objetos DataQualityResultDescription.

  Uma lista dos objetos `DataQualityResultDescription`.
- `NextToken` – String UTF-8.

Um token de paginação, se houver mais resultados disponíveis.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação CreateDataQualityRuleset (Python: create_data_quality_ruleset)

Cria um conjunto de regras de qualidade de dados com regras DQDL aplicadas a uma tabela do AWS Glue especificada.

Você cria o conjunto de regras usando a Data Quality Definition Language (DQDL). Para obter mais informações, consulte o Guia do desenvolvedor do AWS Glue.

Solicitação

Uma solicitação para criar um conjunto de regras de qualidade de dados

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Um nome exclusivo para o conjunto de regras de qualidade de dados.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do conjunto de regras de qualidade de dados.
- `Ruleset` - obrigatório: string UTF-8, não menos que 1 ou mais que 65.536 bytes de comprimento.

  Um conjunto de regras em Data Quality Definition Language (DQDL). Para obter mais informações, consulte o Guia do desenvolvedor do AWS Glue.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

Uma lista de tags aplicadas ao conjunto de regras de qualidade de dados.

- `TargetTable` – Um objeto DataQualityTargetTable.

  Uma tabela de destino associada ao conjunto de regras de qualidade de dados.

- `RecommendationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um ID de execução exclusivo para a execução da recomendação.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

- `ClientToken` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Usado para idempotência e é recomendado que seja definido como um ID aleatório (como um UUID) para evitar criar ou iniciar várias instâncias do mesmo recurso.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome exclusivo para o conjunto de regras de qualidade de dados.

Erros

- `InvalidInputException`
- `AlreadyExistsException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

Ação DeleteDataQualityRuleset (Python: delete_data_quality_ruleset)

Exclui um conjunto de regras de qualidade de dados.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Um nome para o conjunto de regras de qualidade de dados.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetDataQualityRuleset (Python: get_data_quality_ruleset)

Retorna um conjunto de regras existente por identificador ou um nome.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do grupo de regras.

Resposta

Retorna a resposta do conjunto de regras de qualidade de dados.

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do grupo de regras.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição da predefinição.

- `Ruleset`: string UTF-8, não menos do que 1 ou mais de 65536 bytes de comprimento.

  Um conjunto de regras em Data Quality Definition Language (DQDL). Para obter mais informações, consulte o Guia do desenvolvedor do AWS Glue.

- `TargetTable` – Um objeto DataQualityTargetTable.

  O nome e o nome do banco de dados da tabela de destino.

- `CreatedOn` – Timestamp.

  Um carimbo de data/hora. A hora e a data de criação desse conjunto de regras de qualidade de dados.

- `LastModifiedOn` – Timestamp.

  Um carimbo de data/hora. O último ponto em que esse conjunto de regras de qualidade de dados foi modificado.

- `RecommendationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Quando um conjunto de regras foi criado de execução de uma recomendação, esse ID de execução é gerado para vincular os dois.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

Erros

- `EntityNotFoundException`

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação ListDataQualityRulesets (Python: list_data_quality_rulesets)

Retorna uma lista paginada dos conjuntos de regras para a lista de tabelas do AWS Glue especificadas.

Solicitação

- `NextToken` – String UTF-8.

  Um token paginado para equilibrar os resultados.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados.
- `Filter` – Um objeto DataQualityRulesetFilterCriteria.

  Os critérios de filtro.
- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Uma lista de tags de pares chave-valor.

Resposta

- `Rulesets`: um array de objetos DataQualityRulesetListDetails.

  Uma lista paginada dos conjuntos de regras para a lista de tabelas do AWS Glue especificadas.
- `NextToken` – String UTF-8.

  Um token de paginação, se houver mais resultados disponíveis.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação UpdateDataQualityRuleset (Python: update_data_quality_ruleset)

Atualiza o conjunto de regras de qualidade de dados especificado.

Solicitação

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O nome do conjunto de regras de qualidade de dados.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição da predefinição.
- `Ruleset`: string UTF-8, não menos do que 1 ou mais de 65536 bytes de comprimento.

  Um conjunto de regras em Data Quality Definition Language (DQDL). Para obter mais informações, consulte o Guia do desenvolvedor do AWS Glue.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do conjunto de regras de qualidade de dados.
- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição da predefinição.
- `Ruleset`: string UTF-8, não menos do que 1 ou mais de 65536 bytes de comprimento.

Um conjunto de regras em Data Quality Definition Language (DQDL). Para obter mais informações, consulte o Guia do desenvolvedor do AWS Glue.

Erros

- `EntityNotFoundException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`
- `ResourceNumberLimitExceededException`

Ação ListDataQualityStatistics (Python: list_data_quality_statistics)

Recupera uma lista de estatísticas de qualidade dos dados.

Solicitação

- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística.
- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil.
- `TimestampFilter` – Um objeto TimestampFilter.

  Um filtro de carimbo de data e hora.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados nesta solicitação.
- `NextToken` – String UTF-8.

  Um token de paginação para solicitar a próxima página de resultados.

Resposta

- `Statistics`: um array de objetos StatisticSummary.

  O `StatisticSummaryList`.
- `NextToken` – String UTF-8.

  Um token de paginação para solicitar a próxima página de resultados.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

Estrutura TimestampFilter

Um filtro de carimbo de data e hora.

Campos

- `RecordedBefore` – Timestamp.

  O registro de data e hora antes do qual as estatísticas devem ser incluídas nos resultados.
- `RecordedAfter` – Timestamp.

  O registro de data e hora após o qual as estatísticas devem ser incluídas nos resultados.

Estrutura CreateDataQualityRulesetRequest

Uma solicitação para criar um conjunto de regras de qualidade de dados

Campos

- `Name`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Um nome exclusivo para o conjunto de regras de qualidade de dados.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição do conjunto de regras de qualidade de dados.

- `Ruleset` - obrigatório: string UTF-8, não menos que 1 ou mais que 65.536 bytes de comprimento.

  Um conjunto de regras em Data Quality Definition Language (DQDL). Para obter mais informações, consulte o Guia do desenvolvedor do AWS Glue.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Uma lista de tags aplicadas ao conjunto de regras de qualidade de dados.

- `TargetTable` – Um objeto DataQualityTargetTable.

  Uma tabela de destino associada ao conjunto de regras de qualidade de dados.

- `RecommendationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um ID de execução exclusivo para a execução da recomendação.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

- `ClientToken` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Usado para idempotência e é recomendado que seja definido como um ID aleatório (como um UUID) para evitar criar ou iniciar várias instâncias do mesmo recurso.

Estrutura GetDataQualityRulesetResponse

Retorna a resposta do conjunto de regras de qualidade de dados.

Campos

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do grupo de regras.

- `Description`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma descrição da predefinição.

- `Ruleset`: string UTF-8, não menos do que 1 ou mais de 65536 bytes de comprimento.

  Um conjunto de regras em Data Quality Definition Language (DQDL). Para obter mais informações, consulte o Guia do desenvolvedor do AWS Glue.

- `TargetTable` – Um objeto DataQualityTargetTable.

  O nome e o nome do banco de dados da tabela de destino.

- `CreatedOn` – Timestamp.

  Um carimbo de data/hora. A hora e a data de criação desse conjunto de regras de qualidade de dados.

- `LastModifiedOn` – Timestamp.

  Um carimbo de data/hora. O último ponto em que esse conjunto de regras de qualidade de dados foi modificado.

- `RecommendationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Quando um conjunto de regras foi criado de execução de uma recomendação, esse ID de execução é gerado para vincular os dois.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

Estrutura GetDataQualityResultResponse

A resposta para o resultado de qualidade dos dados.

Campos

- `ResultId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um ID de resultado exclusivo para o resultado de qualidade dos dados.
- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil para o resultado de qualidade dos dados.
- `Score`: número (double), no máximo 1,0.

  Uma pontuação de qualidade de dados agregada. Representa a razão de regras que foram aproadas para o número total de regras.
- `DataSource` – Um objeto DataSource.

  A tabela associada ao resultado de qualidade dos dados, se houver.
- `RulesetName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do conjunto de regras associado ao resultado de qualidade de dados.
- `EvaluationContext` – String UTF-8.

  No contexto de um trabalho no AWS Glue Studio, cada nó na tela normalmente recebe algum tipo de nome e os nós de qualidade de dados terão nomes. No caso de vários nós, o `evaluationContext` pode diferenciar os nós.
- `StartedOn` – Timestamp.

  A data e hora de início da execução desse resultado de qualidade de dados.
- `CompletedOn` – Timestamp.

  A data e hora de conclusão da execução desse resultado de qualidade de dados.
- `JobName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O nome do trabalho associado ao resultado de qualidade dos dados, se houver.

- `JobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução de trabalho associado ao resultado de qualidade dos dados, se houver.

- `RulesetEvaluationRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID de execução exclusivo associado à avaliação do conjunto de regras.

- `RuleResults`: uma matriz de objetos DataQualityRuleResult, não mais de 2.000 estruturas.

  Uma lista de objetos do `DataQualityRuleResult` representando os resultados de cada regra.

- `AnalyzerResults`: uma matriz de objetos DataQualityAnalyzerResult, não mais de 2.000 estruturas.

  Uma lista de objetos `DataQualityAnalyzerResult` representando os resultados de cada analisador.

- `Observations` – Uma matriz de DataQualityObservation objetos, não mais de 50 estruturas.

  Uma lista de objetos `DataQualityObservation` representando as observações geradas após a avaliação das regras e dos analisadores.

- `AggregatedMetrics` – Um objeto DataQualityAggregatedMetrics.

  Um resumo dos objetos `DataQualityAggregatedMetrics` mostrando as contagens totais de linhas e regras processadas, incluindo suas estatísticas de aprovação/reprovação com base nos resultados no nível de linha.

Estrutura StartDataQualityRuleRecommendationRunRequest

A solicitação de recomendação da regra de qualidade dos dados.

Campos

- `DataSource` – Obrigatório: um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada a essa execução.

- `Role` – Obrigatório: string UTF-8.

Um perfil do IAM fornecido para criptografar os resultados da execução.

- `NumberOfWorkers` – Número (íntegro).

  O número de processadores do `G.1X` a serem usados na execução. O padrão é 5.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite em minutos para uma execução. Esse é o tempo máximo durante o qual uma execução pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).

- `CreatedRulesetName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome para o conjunto de regras.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

- `ClientToken` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Usado para idempotência e é recomendado que seja definido como um ID aleatório (como um UUID) para evitar criar ou iniciar várias instâncias do mesmo recurso.

Estrutura GetDataQualityRuleRecommendationRunResponse

A resposta para a execução de recomendação da regra de qualidade dos dados.

Campos

- `RunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O identificador de execução único associado a essa execução.

- `DataSource` – Um objeto DataSource.

  A fonte de dados (uma tabela do AWS Glue) associada a essa execução.

- `Role` – String UTF-8.

  Um perfil do IAM fornecido para criptografar os resultados da execução.

- `NumberOfWorkers` – Número (íntegro).

  O número de processadores do `G.1X` a serem usados na execução. O padrão é 5.

- `Timeout` – Número (inteiro), pelo menos 1.

  O tempo limite em minutos para uma execução. Esse é o tempo máximo durante o qual uma execução pode consumir recursos antes de ser encerrada e entrar no status `TIMEOUT`. O padrão é 2.880 minutos (48 horas).

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `FINISHED` | `FAILED` | `PENDING_EXECUTION` | `TIMED_OUT` | `CANCELING` | `CANCELED` | `RECEIVED_BY_TASKRUNNER`).

  O status dessa execução.

- `ErrorString` – String UTF-8.

  As strings de erro associadas à execução.

- `StartedOn` – Timestamp.

  A data e hora em que essa execução foi iniciada.

- `LastModifiedOn` – Timestamp.

  Um carimbo de data/hora. O último ponto em que essa recomendação de regra de qualidade de dados foi executada foi modificado.

- `CompletedOn` – Timestamp.

  A data e hora de conclusão dessa execução.

- `ExecutionTime` – Número (íntegro).

  A quantidade de tempo (em segundos) durante a qual a execução consumiu recursos.

- `RecommendedRuleset`: string UTF-8, não menos do que 1 ou mais de 65536 bytes de comprimento.

  Quando uma execução de recomendação de regra inicial é concluída, ela cria um conjunto de regras recomendado. Esse membro tem essas regras no formato Data Quality Definition Language (DQDL).

- `CreatedRulesetName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do conjunto de regras que foi criado pela execução.

- `DataQualitySecurityConfiguration` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome da configuração de segurança criada com a opção de criptografia de qualidade dos dados.

Ação BatchPutDataQualityStatisticAnnotation (Python: batch_put_data_quality_statistic_annotation)

Anote os pontos de dados ao longo do tempo para obter uma estatística específica de qualidade dos dados.

Solicitação

- `InclusionAnnotations` – Obrigatório: uma matriz de objetos DatapointInclusionAnnotation.

  Uma lista de `DatapointInclusionAnnotation`.

- `ClientToken` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Token cliente.

Resposta

- `FailedInclusionAnnotations`: um array de objetos AnnotationError.

  Uma lista de `AnnotationError`.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

- `ResourceNumberLimitExceededException`

Ação GetDataQualityModel (Python: get_data_quality_model)

Recupere o status de treinamento do modelo com mais informações (CompletedOn, StartedOn, FailureReason).

Solicitação

- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística.
- `ProfileId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do perfil.

Resposta

- `Status` – String UTF-8 (valores válidos: `RUNNING` | `SUCCEEDED` | `FAILED`).

  O status do treinamento de modelo de qualidade dos dados.
- `StartedOn` – Timestamp.

  A data e hora em que o treinamento de modelo de qualidade dos dados começou.
- `CompletedOn` – Timestamp.

  O carimbo de data e hora de quando o treinamento do modelo de qualidade dos dados foi concluído.
- `FailureReason` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O motivo da falha no treinamento.

Erros

- `EntityNotFoundException`

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação GetDataQualityModelResult (Python: get_data_quality_model_result)

Recupere as previsões de uma estatística para um determinado ID de perfil.

Solicitação

- `StatisticId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID da estatística.
- `ProfileId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do perfil.

Resposta

- `CompletedOn` – Timestamp.

  O carimbo de data e hora de quando o treinamento do modelo de qualidade dos dados foi concluído.
- `Model`: um array de objetos StatisticModelResult.

  Uma lista de `StatisticModelResult`

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Ação ListDataQualityStatisticAnnotations (Python: list_data_quality_statistic_annotations)

Recupere anotações para uma estatística de qualidade dos dados.

Solicitação

- `StatisticId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da estatística.
- `ProfileId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID do perfil.
- `TimestampFilter` – Um objeto TimestampFilter.

  Um filtro de carimbo de data e hora.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

  O número máximo de resultados a serem retornados nesta solicitação.
- `NextToken` – String UTF-8.

  Um token de paginação para recuperar o próximo conjunto de resultados.

Resposta

- `Annotations`: um array de objetos StatisticAnnotation.

  Uma lista de `StatisticAnnotation` aplicadas à estatística
- `NextToken` – String UTF-8.

  Um token de paginação para recuperar o próximo conjunto de resultados.

Erros

- `InvalidInputException`
- `InternalServiceException`

Ação PutDataQualityProfileAnnotation (Python: put_data_quality_profile_annotation)

Anote todos os pontos de dados de um perfil.

Solicitação

- `ProfileId`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  O ID do perfil de monitoramento da qualidade dos dados a ser anotado.
- `InclusionAnnotation` – Obrigatório: string UTF-8 (valores válidos: `INCLUDE` | `EXCLUDE`).

  O valor da anotação de inclusão a ser aplicado ao perfil.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `EntityNotFoundException`
- `InvalidInputException`
- `InternalServiceException`

API de detecção de dados sigilosos

A API Sensitive data detection descreve as APIs usadas para detectar dados confidenciais nas colunas e linhas de seus dados estruturados.

Tipos de dados

- Estrutura CustomEntityType

Estrutura CustomEntityType

Um objeto que representa um padrão personalizado para detectar dados sigilosos nas colunas e linhas dos dados estruturados.

Campos

- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome para o padrão personalizado que permite que ele seja recuperado ou excluído posteriormente. Esse nome deve ser exclusivo por conta AWS.
- `RegexString` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  Uma string de expressão regular usada para detectar dados sigilosos em um padrão personalizado.
- `ContextWords`: uma matriz de strings UTF-8, não menos que 1 ou mais que 20 strings.

  Uma lista de palavras de contexto. Se nenhuma dessas palavras de contexto for encontrada nas proximidades da expressão regular, os dados não serão detectados como dados sigilosos.

  Se nenhuma palavra de contexto for passada, apenas uma expressão regular será marcada.

Operações

- Ação CreateCustomEntityType (Python: create_custom_entity_type)
- Ação DeleteCustomEntityType (Python: delete_custom_entity_type)
- Ação GetCustomEntityType (Python: get_custom_entity_type)
- Ação BatchGetCustomEntityTypes (Python: batch_get_custom_entity_types)
- Ação ListCustomEntityTypes (Python: list_custom_entity_types)

Ação CreateCustomEntityType (Python: create_custom_entity_type)

Cria um padrão personalizado usado para detectar dados sigilosos nas colunas e linhas dos dados estruturados.

Cada padrão personalizado criado especifica uma expressão regular e uma lista opcional de palavras de contexto. Se nenhuma palavra de contexto for passada, apenas uma expressão regular será marcada.

Solicitação

- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  Um nome para o padrão personalizado que permite que ele seja recuperado ou excluído posteriormente. Esse nome deve ser exclusivo por conta AWS.

- `RegexString` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  Uma string de expressão regular usada para detectar dados sigilosos em um padrão personalizado.

- `ContextWords`: uma matriz de strings UTF-8, não menos que 1 ou mais que 20 strings.

  Uma lista de palavras de contexto. Se nenhuma dessas palavras de contexto for encontrada nas proximidades da expressão regular, os dados não serão detectados como dados sigilosos.

  Se nenhuma palavra de contexto for passada, apenas uma expressão regular será marcada.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Uma lista de tags aplicadas ao tipo de entidade personalizada.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do padrão personalizado que você criou.

Erros

- `AccessDeniedException`
- `AlreadyExistsException`
- `IdempotentParameterMismatchException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`
- `ResourceNumberLimitExceededException`

Ação DeleteCustomEntityType (Python: delete_custom_entity_type)

Exclui um padrão personalizado especificando seu nome.

Solicitação

- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do padrão personalizado que você deseja excluir.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do padrão personalizado que você excluiu.

Erros

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação GetCustomEntityType (Python: get_custom_entity_type)

Recupera os detalhes de um padrão personalizado especificando o nome do mesmo.

Solicitação

- `Name` – Obrigatório: string UTF-8, no mínimo 1 ou mais de 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do padrão personalizado que você deseja recuperar.

Resposta

- `Name` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O nome do padrão personalizado que você recuperou.
- `RegexString` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  Uma string de expressão regular usada para detectar dados sigilosos em um padrão personalizado.
- `ContextWords`: uma matriz de strings UTF-8, não menos que 1 ou mais que 20 strings.

  Uma lista de palavras de contexto, se especificada quando você criou o padrão personalizado. Se nenhuma dessas palavras de contexto for encontrada nas proximidades da expressão regular, os dados não serão detectados como dados sigilosos.

Erros

- `EntityNotFoundException`
- `AccessDeniedException`
- `InternalServiceException`
- `InvalidInputException`
- `OperationTimeoutException`

Ação BatchGetCustomEntityTypes (Python: batch_get_custom_entity_types)

Recupera os detalhes dos padrões personalizados especificados por uma lista de nomes.

Solicitação

- `Names`: obrigatório: uma matriz de strings UTF-8, não menos de 1 ou mais de 50 strings.

  Uma lista de nomes dos padrões personalizados que você deseja recuperar.

Resposta

- `CustomEntityTypes` – Uma matriz de objetos CustomEntityType.

  Lista de objetos `CustomEntityType` que representam os padrões personalizados que foram criados.
- `CustomEntityTypesNotFound` - Uma matriz de strings UTF-8, não menos que 1 ou mais que 50 strings.

  Uma lista dos nomes de padrões personalizados que não foram encontrados.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`

Ação ListCustomEntityTypes (Python: list_custom_entity_types)

Lista todos os padrões personalizados que foram criados.

Solicitação

- `NextToken` – String UTF-8.

  Um token paginado para equilibrar os resultados.
- `MaxResults` – Número (inteiro), superior a 1 ou mais que 1000.

O número máximo de resultados a serem retornados.

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  Uma lista de tags de pares chave-valor.

Resposta

- `CustomEntityTypes` – Uma matriz de objetos CustomEntityType.

  Lista de objetos `CustomEntityType` que representam os padrões personalizados.
- `NextToken` – String UTF-8.

  Um token de paginação, se houver mais resultados disponíveis.

Erros

- `InvalidInputException`
- `OperationTimeoutException`
- `InternalServiceException`

Marcação de APIs no AWS Glue

Tipos de dados

- Estrutura Tag

Estrutura Tag

O objeto `Tag` representa um rótulo que pode ser atribuído a um recurso da AWS. Cada tag consiste de uma chave e um valor opcional, que podem ser definidos.

Para obter mais informações sobre tags e como controlar o acesso aos recursos no AWS Glue, consulte Marcações da AWS no AWS Glue) e Especificação de ARNs de recurso no AWS Glue no guia do desenvolvedor.

Campos

- `key` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  A chave de tags. A chave é necessária ao criar uma tag em um objeto. A chave diferencia maiúsculas de minúsculas e não deve conter o prefixo aws.
- `value` – String UTF-8 com comprimento não superior a 256 bytes.

  O valor da tag. O valor é opcional ao criar uma tag em um objeto. O valor diferencia maiúsculas de minúsculas e não deve conter o prefixo aws.

Operações

- Ação TagResource (Python: tag_resource)
- Ação UntagResource (Python: untag_resource)
- Ação GetTags (Python: get_tags)

Ação TagResource (Python: tag_resource)

Adiciona etiquetas a um recurso. Uma tag é um rótulo que pode ser atribuído a um recurso da AWS. No AWS Glue, apenas determinados recursos podem ser marcados. Para obter informações sobre quais recursos podem ser marcados, consulte Tags da AWS no AWS Glue.

Além das permissões de marcação para chamar APIs relacionadas a tags, você também precisa da permissão `glue:GetConnection` para chamar APIs de marcação em conexões e da permissão `glue:GetDatabase` para chamar APIs de marcação em bancos de dados.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O ARN do recurso do AWS Glue ao qual se deseja adicionar as tags. Para obter mais informações sobre ARNs de recurso do AWS Glue, consulte o padrão de string de ARN do AWS Glue.

- `TagsToAdd`: obrigatório: uma matriz de mapa dos pares de chave-valor, no máximo 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags a serem adicionadas a esse recurso.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `ResourceNotFoundException`

Ação UntagResource (Python: untag_resource)

Remove as tags especificadas de um recurso de integração.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome do recurso da Amazon (ARN) do recurso de integração.
- `TagsToRemove`: obrigatório: uma matriz de strings UTF-8, no máximo 50 strings.

  Uma lista das tags de metadados a serem removidas do recurso.

Resposta

- Nenhum parâmetro de resposta.

Erros

- `ResourceNotFoundException`

Ação GetTags (Python: get_tags)

Recupera uma lista de tags associadas a um recurso.

Solicitação

- `ResourceArn`: obrigatório: string UTF-8, não menos do que 1 ou superior a 10.240 bytes de comprimento, correspondente a Custom string pattern #49.

  O nome de recurso da Amazon (ARN) do recurso para o qual deseja recuperar as tags.

Resposta

- `Tags`: uma matriz de mapa dos pares de chave-valor, não mais que 50 pares.

  Cada chave é uma string UTF-8, com comprimento entre 1 e 128 bytes.

  Cada valor é uma string UTF-8, inferior a 256 bytes de comprimento.

  As tags solicitadas.

Erros

- `InvalidInputException`
- `InternalServiceException`
- `OperationTimeoutException`
- `EntityNotFoundException`

Tipos de dados comuns

Tipos de dados comuns descrevem os diversos tipos de dados comuns no AWS Glue.

Estrutura Tag

O objeto `Tag` representa um rótulo que pode ser atribuído a um recurso da AWS. Cada tag consiste de uma chave e um valor opcional, que podem ser definidos.

Para obter mais informações sobre tags e como controlar o acesso aos recursos no AWS Glue, consulte Marcações da AWS no AWS Glue) e Especificação de ARNs de recurso no AWS Glue no guia do desenvolvedor.

Campos

- `key` – String UTF-8, superior a 1 e inferior a 128 bytes de comprimento.

  A chave de tags. A chave é necessária ao criar uma tag em um objeto. A chave diferencia maiúsculas de minúsculas e não deve conter o prefixo aws.
- `value` – String UTF-8 com comprimento não superior a 256 bytes.

  O valor da tag. O valor é opcional ao criar uma tag em um objeto. O valor diferencia maiúsculas de minúsculas e não deve conter o prefixo aws.

Estrutura DecimalNumber

Contém um valor numérico em formato decimal.

Campos

- `UnscaledValue`: obrigatório: blob.

  O valor numérico não escalado.
- `Scale`: obrigatório: número (inteiro).

  A escala que determina a posição do ponto decimal no valor não escalado.

Estrutura ErrorDetail

Contém detalhes sobre um erro.

Campos

- `ErrorCode` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O código associado a este erro.

- `ErrorMessage`: string de descrição com no máximo 2.048 bytes de comprimento e correspondente a URI address multi-line string pattern.

  Uma mensagem descrevendo o erro.

Estrutura PropertyPredicate

Define um predicado de propriedade.

Campos

- `Key`: string Value com no mínimo 1 e no máximo 1.024 bytes de comprimento.

  A chave da propriedade.
- `Value`: string Value com no mínimo 1 e no máximo 1.024 bytes de comprimento.

  O valor da propriedade.
- `Comparator` – String UTF-8 (valores válidos: `EQUALS` | `GREATER_THAN` | `LESS_THAN` | `GREATER_THAN_EQUALS` | `LESS_THAN_EQUALS`).

  O comparador costumava comparar esta propriedade com outras.

Estrutura ResourceUri

Os URIs para recursos de função.

Campos

- `ResourceType` – String UTF-8 (valores válidos: `JAR` | `FILE` | `ARCHIVE`).

  O tipo de recurso.
- `Uri` – URI (Uniform Resource Identifier), maior que 1 ou maior que 1024 bytes de comprimento, correspondente a URI address multi-line string pattern.

  O URI para acessar o recurso.

Estrutura ColumnStatistics

Representa as estatísticas de nível de coluna geradas para uma tabela ou partição.

Campos

- `ColumnName`: obrigatório: string UTF-8 com no mínimo 1 e no máximo 255 bytes de comprimento e correspondente a Single-line string pattern.

  Nome da coluna à qual as estatísticas pertencem.

- `ColumnType`: obrigatório: nome do tipo, no máximo 20.000 bytes de comprimento, correspondente a Single-line string pattern.

  O tipo de dados da coluna.

- `AnalyzedTime`: obrigatório: carimbo de data e hora.

  O carimbo de data e hora do momento em que as estatísticas da coluna foram geradas.

- `StatisticsData` – Obrigatório: um objeto ColumnStatisticsData.

  Um objeto `ColumnStatisticData` que contém os valores de dados de estatísticas.

Estrutura ColumnStatisticsError

Encapsula um objeto `ColumnStatistics` que tenha falhado e o motivo da falha.

Campos

- `ColumnStatistics` – Um objeto ColumnStatistics.

  As `ColumnStatistics` da coluna.

- `Error` – Um objeto ErrorDetail.

  Uma mensagem de erro com o motivo da falha de uma operação.

Estrutura ColumnError

Encapsula um nome de coluna que tenha falhado e o motivo da falha.

Campos

- `ColumnName` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

O nome da coluna que falhou.

- `Error` – Um objeto ErrorDetail.

  Uma mensagem de erro com o motivo da falha de uma operação.

Estrutura ColumnStatisticsData

Contém os tipos individuais de dados de estatísticas de coluna. Apenas um objeto de dados deve ser definido e indicado pelo atributo `Type`.

Campos

- `Type`: obrigatório: string UTF-8 (valores válidos: `BOOLEAN` | `DATE` | `DECIMAL` | `DOUBLE` | `LONG` | `STRING` | `BINARY`).

  O tipo de dados de estatísticas de coluna.
- `BooleanColumnStatisticsData` – Um objeto BooleanColumnStatisticsData.

  Dados de estatísticas de coluna booleanos.
- `DateColumnStatisticsData` – Um objeto DateColumnStatisticsData.

  Dados de estatísticas de coluna de data.
- `DecimalColumnStatisticsData` – Um objeto DecimalColumnStatisticsData.

  Dados de estatísticas de coluna decimais. UnscaledValues internos são objetos binários codificados na Base64 que armazenam representações big-endian de complemento de dois do valor da decimal sem escala.
- `DoubleColumnStatisticsData` – Um objeto DoubleColumnStatisticsData.

  Dados de estatísticas de coluna double.
- `LongColumnStatisticsData` – Um objeto LongColumnStatisticsData.

  Dados de estatísticas de coluna inteiros longos.
- `StringColumnStatisticsData` – Um objeto StringColumnStatisticsData.

  Dados de estatísticas de coluna de string.
- `BinaryColumnStatisticsData` – Um objeto BinaryColumnStatisticsData.

Dados de estatísticas de coluna binários.

Estrutura BooleanColumnStatisticsData

Define estatísticas de coluna suportadas para colunas de dados booleanos.

Campos

- `NumberOfTrues`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores true na coluna.
- `NumberOfFalses`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores false na coluna.
- `NumberOfNulls`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores nulos na coluna.

Estrutura DateColumnStatisticsData

Define estatísticas de coluna suportadas para colunas de dados de carimbo de data e hora.

Campos

- `MinimumValue` – Timestamp.

  O valor mais baixo na coluna.
- `MaximumValue` – Timestamp.

  O valor mais alto na coluna.
- `NumberOfNulls`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores nulos na coluna.
- `NumberOfDistinctValues`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores distintos em uma coluna.

Estrutura DecimalColumnStatisticsData

Define estatísticas de coluna suportadas para colunas de dados de números de ponto fixo.

Campos

- `MinimumValue` – Um objeto DecimalNumber.

  O valor mais baixo na coluna.
- `MaximumValue` – Um objeto DecimalNumber.

  O valor mais alto na coluna.
- `NumberOfNulls`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores nulos na coluna.
- `NumberOfDistinctValues`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores distintos em uma coluna.

Estrutura DoubleColumnStatisticsData

Define estatísticas de coluna suportadas para colunas de dados de números de ponto flutuante.

Campos

- `MinimumValue` – Número (duplo).

  O valor mais baixo na coluna.
- `MaximumValue` – Número (duplo).

  O valor mais alto na coluna.
- `NumberOfNulls`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores nulos na coluna.
- `NumberOfDistinctValues`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores distintos em uma coluna.

Estrutura LongColumnStatisticsData

Define estatísticas de coluna suportadas para colunas de dados inteiros.

Campos

- `MinimumValue` – Número (extenso).

  O valor mais baixo na coluna.
- `MaximumValue` – Número (extenso).

  O valor mais alto na coluna.
- `NumberOfNulls`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores nulos na coluna.
- `NumberOfDistinctValues`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores distintos em uma coluna.

Estrutura StringColumnStatisticsData

Define estatísticas de coluna suportadas para valores de dados de sequência de caracteres.

Campos

- `MaximumLength`: obrigatório: número (inteiro longo), no máximo nenhum.

  O tamanho da string mais longa na coluna.
- `AverageLength`: obrigatório: número (double), no máximo nenhum.

  O comprimento médio da string na coluna.
- `NumberOfNulls`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores nulos na coluna.
- `NumberOfDistinctValues`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores distintos em uma coluna.

Estrutura BinaryColumnStatisticsData

Define estatísticas de coluna suportadas para valores de dados de sequência de bits.

Campos

- `MaximumLength`: obrigatório: número (inteiro longo), no máximo nenhum.

  O tamanho da sequência de bits mais longa na coluna.
- `AverageLength`: obrigatório: número (double), no máximo nenhum.

  O comprimento médio da sequência de bits na coluna.
- `NumberOfNulls`: obrigatório: número (inteiro longo), no máximo nenhum.

  O número de valores nulos na coluna.

Padrões de string

A API usa as seguintes expressões regulares para definir o que é conteúdo válido para vários membros e parâmetros de string:

- Single-line string pattern – `"[\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\t]*"`
- Padrão de string com várias linhas de endereço URI – `"[\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\r\n\t]*"`
- Um padrão de string Logstash Grok – `"[\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\r\t]*"`
- Padrão de string do identificador – `"[A-Za-z_][A-Za-z0-9_]*"`
- Padrão de string do ARN da AWS IAM – `"arn:aws:iam::\d{12}:role/.*"`
- Versão do padrão de string – `"^[a-zA-Z0-9-_]+$"`
- Padrão de string do grupo de logs – `"[\.\-_/#A-Za-z0-9]+"`
- Padrão de string do stream de logs – `"[^:*]*"`
- Padrão de string personalizado n.º 10: “`[a-zA-Z0-9-_]+`”
- Padrão de string personalizado n.º 11: “`[-a-zA-Z0-9+=/:_]*`”
- Padrão de string personalizado n.º 12: “`[\S\s]*`”

- Padrão de string personalizado n.º 13: “`.*\S.*`”
- Padrão de string personalizado n.º 14: “`[a-zA-Z0-9-=._/@]+`”
- Padrão de string personalizado n.º 15: “`[1-9][0-9]*|[1-9][0-9]*-[1-9][0-9]*`”
- Padrão de string personalizado n.º 16: “`[A-Z][A-Za-z\.]+`”
- Padrão de string personalizado n.º 17: “`[\S]*`”
- Padrão de string personalizado n.º 18: “`[\w]*`”
- Padrão de string personalizado n.º 19: “`arn:aws[a-z\-]*:iam::\d{12}:role/?[a-zA-Z_0-9+=,.@\-_/]+`”
- Padrão de string personalizado n.º 20: “`subnet-[a-z0-9]+`”
- Padrão de string personalizado n.º 21: “`\d{12}`”
- Padrão de string personalizado n.º 22: “`([a-z]+)-([a-z]+-)?([a-z]+)-[0-9]+[a-z]+`”
- Padrão de string personalizado n.º 23: "`[a-zA-Z0-9.-]*`"
- Padrão de string personalizado n.º 24: "`arn:aws[a-z0-9\-]*:lambda:[a-z0-9\-]+:\d{12}:function:([\w\-]{1,64})`"
- Padrão de string personalizado n.º 25: "`^(?!(.*[.\/\\]|aws:)).*$`"
- Padrão de string personalizado n.º 26: "`[^\r\n]`"
- Padrão de string personalizado n.º 27: "`^\w+\.\w+\.\w+$`"
- Padrão de string personalizado n.º 28: "`^\w+\.\w+$`"
- Padrão de string personalizado n.º 29: "`^$|arn:aws[a-z0-9-]*:kms:.*`"
- Padrão de string personalizado n.º 30: "`arn:aws[^:]*:iam::[0-9]*:role/.+`"
- Padrão de string personalizado n.º 31: "`[\.\-_A-Za-z0-9]+`"
- Padrão de string personalizado n.º 32: "`^s3://([^/]+)/([^/]+/)*([^/]+)$`"
- Padrão de string personalizado n.º 33: "`.*`"
- Padrão de string personalizado n.º 34: "`^(Sun|Mon|Tue|Wed|Thu|Fri|Sat):([01]?[0-9]|2[0-3])$`"
- Padrão de string personalizado n.º 35: "`[a-zA-Z0-9_.-]+`"
- Padrão de string personalizado n.º 36: "`^arn:aws(-(cn|us-gov|iso(-[bef])?))?:secretsmanager:.*$`"
- Padrão de string personalizado n.º 37: "`\S+`"
- Padrão de string personalizado n.º 38: "`^[\x20-\x7E]*$`"

- Padrão de string personalizado n.º 39: "^([a-zA-Z0-9_=]+)\.([a-zA-Z0-9_=]+)\.([a-zA-Z0-9_\-\+\/=]*)"
- Padrão de string personalizado n.º 40: "^(https?)://[-a-zA-Z0-9+&@#/%?=~_|!:,.;]*[-a-zA-Z0-9+&@#/%=~_|]"
- Padrão de string personalizado n.º 41: "^(https?):\/\/[^\s/$.?#].[^\s]*$"
- Padrão de string personalizado n.º 42: "^subnet-[a-z0-9]+$"
- Padrão de string personalizado n.º 43: “[\p{L}\p{N}\p{P}]*”
- Padrão de string personalizado n.º 44: “[a-f0-9]{8}-[a-f0-9]{4}-[a-f0-9]{4}-[a-f0-9]{4}-[a-f0-9]{12}”
- Padrão de string personalizado n.º 45: “[a-zA-Z0-9-_$#.]+”
- Padrão de string personalizado n.º 46: "^\d{12}$"
- Padrão de string personalizado n.º 47: "^(\w+\.)+\w+$"
- Padrão de string personalizado n.º 48: "^([2-3]|3[.]9)$"
- Padrão de string personalizado n.º 49: "arn:aws(-(cn|us-gov|iso(-[bef])?))?:glue:.*"
- Padrão de string personalizado n.º 50: "(^arn:aws(-(cn|us-gov|iso(-[bef])?))?:iam::\w{12}:root)"
- Padrão de string personalizado n.º 51: "^arn:aws(-(cn|us-gov|iso(-[bef])?))?:iam::[0-9]{12}:role/.+"
- Padrão de string personalizado n.º 52: "[\s\S]*"
- Padrão de string personalizado n.º 53: "([\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF]|[^\S\r\n"'= ;])*"
- Padrão de string personalizado n.º 54: "^[A-Z_]+$"
- Padrão de string personalizado n.º 55: "^[A-Za-z0-9]+$"
- Padrão de string personalizado n.º 56: "[*A-Za-z0-9_-]*"
- Padrão de string personalizado n.º 57: "([\u0020-\u007E\r\s\n])*"
- Padrão de string personalizado n.º 58: "[A-Za-z0-9_-]*"
- Padrão de string personalizado n.º 59: "([\u0009\u000B\u000C\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF])*"
- Padrão de string personalizado n.º 60: "([\u0020-\uD7FF\uE000-\uFFFD\uD800\uDC00-\uDBFF\uDFFF\s])*"
- Padrão de string personalizado n.º 61: "([^\r\n])*"

Exceções

Esta seção descreve as exceções do AWS Glue que você pode usar para encontrar a origem dos problemas e corrigi-los. Para obter mais informações sobre códigos de erro HTTP e strings para exceções relacionadas a machine learning, consulte the section called “Exceções de machine learning do AWS Glue”.

Estrutura AccessDeniedException

O acesso a um recurso foi negado.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura AlreadyExistsException

Um recurso a ser criado ou adicionado já existe.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura ConcurrentModificationException

Dois processos estão tentando modificar um recurso simultaneamente.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura ConcurrentRunsExceededException

Muitos trabalhos estão sendo executados simultaneamente.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura CrawlerNotRunningException

O crawler especificado não está sendo executado.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura CrawlerRunningException

A operação não pode ser realizada porque o crawler já está sendo executado.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura CrawlerStoppingException

O crawler especificado está sendo interrompido.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura EntityNotFoundException

Uma entidade especificada não existe

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.
- `FromFederationSource` – Booleano.

  Indica se a exceção está relacionada ou não a uma fonte federada.

Estrutura FederationSourceException

Uma fonte de federação falhou.

Campos

- `FederationSourceErrorCode`: string UTF-8 (valores válidos: `AccessDeniedException` | `EntityNotFoundException` | `InvalidCredentialsException` | `InvalidInputException` | `InvalidResponseException` | `OperationTimeoutException` | `OperationNotSupportedException` | `InternalServiceException` | `PartialFailureException` | `ThrottlingException`).

  O código de erro do problema.
- `Message` – String UTF-8.

  A mensagem descrevendo o problema.

Estrutura FederationSourceRetryableException

Uma fonte de federação falhou, mas a operação pode ser repetida.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura de GlueEncryptionException

Uma operação de criptografia falhou.

Campos

- `Message` – String UTF-8.

  A mensagem descrevendo o problema.

Estrutura IdempotentParameterMismatchException

O mesmo identificador exclusivo foi associado a dois registros diferentes.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura IllegalWorkflowStateException

O fluxo de trabalho está em um estado inválido para executar uma operação solicitada.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura InternalServiceException

Ocorreu um erro interno de serviço.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura InvalidExecutionEngineException

Um mecanismo de execução desconhecido ou inválido foi especificado.

Campos

- `message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura InvalidInputException

A entrada fornecida não é válida.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.
- `FromFederationSource` – Booleano.

  Indica se a exceção está relacionada ou não a uma fonte federada.

Estrutura InvalidStateException

Um erro que indica que seus dados estão em um estado inválido.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura InvalidTaskStatusTransitionException

A transição adequada de uma tarefa para a próxima falhou.

Campos

- `message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura JobDefinitionErrorException

Uma definição de trabalho não é válida.

Campos

- `message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura JobRunInTerminalStateException

O estado terminal de uma execução de trabalho sinaliza uma falha.

Campos

- `message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura JobRunInvalidStateTransitionException

Uma execução de trabalho encontrou uma transição inválida do estado de origem para o estado de destino.

Campos

- `jobRunId` – String UTF-8, superior a 1 e inferior a 255 bytes de comprimento, correspondente a Single-line string pattern.

  O ID da execução de trabalho em questão.
- `message` – String UTF-8.

  Uma mensagem descrevendo o problema.
- `sourceState`: string UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

  O estado de origem.
- `targetState`: string UTF-8 (valores válidos: `STARTING` | `RUNNING` | `STOPPING` | `STOPPED` | `SUCCEEDED` | `FAILED` | `TIMEOUT` | `ERROR` | `WAITING` | `EXPIRED`).

O estado do destino.

Estrutura JobRunNotInTerminalStateException

Uma execução de trabalho não está em um estado terminal.

Campos

- `message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura LateRunnerException

Um executor de trabalho está atrasado.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura NoScheduleException

Não há uma programação aplicável.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura OperationTimeoutException

A operação expirou.

Campos

- `Message` – String UTF-8.

Uma mensagem descrevendo o problema.

Estrutura ResourceNotReadyException

Um recurso não estava pronto para uma transação.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura ResourceNumberLimitExceededException

Um limite numérico de recursos foi excedido.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura SchedulerNotRunningException

O programador especificado não está sendo executado.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura SchedulerRunningException

O programador especificado já está sendo executado.

Campos

- `Message` – String UTF-8.

Uma mensagem descrevendo o problema.

Estrutura SchedulerTransitioningException

O programador especificado está em transição.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura UnrecognizedRunnerException

O executor de trabalho não foi reconhecido.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura ValidationException

Não foi possível validar um valor.

Campos

- `Message` – String UTF-8.

  Uma mensagem descrevendo o problema.

Estrutura VersionMismatchException

Houve um conflito de versão.

Campos

- `message` – String UTF-8.

Uma mensagem descrevendo o problema.

Exemplos de código de API do AWS Glue usando os AWS SDKs

Os exemplos de código a seguir mostram como usar o AWS Glue com um kit de desenvolvimento de software (SDK) da AWS.

As noções básicas são exemplos de código que mostram como realizar as operações essenciais em um serviço.

Ações são trechos de código de programas maiores e devem ser executadas em contexto. Embora as ações mostrem como chamar funções de serviço individuais, é possível ver as ações no contexto em seus cenários relacionados.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Conceitos básicos

Olá, AWS Glue

O exemplo de código a seguir mostra como começar a usar o AWS Glue.

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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);
        }
    }
}
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

Código para o arquivo CMakeLists.txt do CMake.

```
# 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})
```

Código para o arquivo de origem 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;
```

```
}
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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);
        });
    }
```

```
}
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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;
};
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para JavaScript.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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()
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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.")
```

```
    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
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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)),
            }
        }
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Rust.

Exemplos de códigos de API do AWS Glue

- Exemplos básicos para o AWS Glue usando SDKs da AWS
  - Olá, AWS Glue
  - Aprender os conceitos básicos do AWS Glue com um SDK da AWS
  - Ações para o AWS Glue usando AWS SDKs
    - Usar CreateCrawler com um SDK da AWS
    - Usar CreateJob com o AWS SDK ou a CLI
    - Usar DeleteCrawler com um SDK da AWS
    - Usar DeleteDatabase com um SDK da AWS
    - Usar DeleteJob com o AWS SDK ou a CLI
    - Usar DeleteTable com um SDK da AWS
    - Usar GetCrawler com um SDK da AWS
    - Usar GetDatabase com um SDK da AWS
    - Usar GetDatabases com o AWS SDK ou a CLI
    - Usar GetJob com o AWS SDK ou a CLI
    - Usar GetJobRun com o AWS SDK ou a CLI
    - Usar GetJobRuns com o AWS SDK ou a CLI
    - Usar GetTables com o AWS SDK ou a CLI
    - Usar ListJobs com um SDK da AWS
    - Usar StartCrawler com o AWS SDK ou a CLI
    - Usar StartJobRun com o AWS SDK ou a CLI

Exemplos básicos para o AWS Glue usando SDKs da AWS

Os exemplos de código a seguir mostram como usar os conceitos básicos do AWS Glue com SDKs da AWS.

Exemplos

- Olá, AWS Glue
- Aprender os conceitos básicos do AWS Glue com um SDK da AWS
- Ações para o AWS Glue usando AWS SDKs
  - Usar CreateCrawler com um SDK da AWS

- Usar CreateJob com o AWS SDK ou a CLI
- Usar DeleteCrawler com um SDK da AWS
- Usar DeleteDatabase com um SDK da AWS
- Usar DeleteJob com o AWS SDK ou a CLI
- Usar DeleteTable com um SDK da AWS
- Usar GetCrawler com um SDK da AWS
- Usar GetDatabase com um SDK da AWS
- Usar GetDatabases com o AWS SDK ou a CLI
- Usar GetJob com o AWS SDK ou a CLI
- Usar GetJobRun com o AWS SDK ou a CLI
- Usar GetJobRuns com o AWS SDK ou a CLI
- Usar GetTables com o AWS SDK ou a CLI
- Usar ListJobs com um SDK da AWS
- Usar StartCrawler com o AWS SDK ou a CLI
- Usar StartJobRun com o AWS SDK ou a CLI

Olá, AWS Glue

O exemplo de código a seguir mostra como começar a usar o AWS Glue.

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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);
       }
   }
```

```
}
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

Código para o arquivo CMakeLists.txt do CMake.

```
# 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})
```

Código para o arquivo de origem 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;
}
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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);
```

```
        });
    }
}
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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;
};
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para JavaScript.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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()
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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.")
```

```
    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
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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)),
            }
        }
```

- Para obter detalhes da API, consulte ListJobs na Referência de API do AWS SDK para Rust.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Aprender os conceitos básicos do AWS Glue com um SDK da AWS

Os exemplos de código a seguir mostram como:

- Criar um crawler que rastreie um bucket público do Amazon S3 e gere um banco de dados de metadados formatado em CSV.
- Listar informações sobre bancos de dados e tabelas no AWS Glue Data Catalog.
- Criar um trabalho para extrair dados em CSV do bucket do S3, transformá-los e carregar a saída formatada em JSON em outro bucket do S3.
- Listar informações sobre execuções de tarefas, visualizar dados transformados e limpar recursos.

Para obter mais informações, consulte Tutorial: conceitos básicos do AWS Glue Studio.

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWS Code Examples Repository.

Crie uma classe que envolva funções do AWS Glue usadas no cenário.

```
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;
    }

}
```

Crie uma classe que execute o cenário.

```
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);
    }
}
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para .NET.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable

- GetCrawler
- GetDatabase
- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
//! 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::Delete 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();
}
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para C++.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase

- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
/**
 * 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 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;
        }
    }


    /**
     * 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.");
            }
        }
    }
}
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK for Java 2.x.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase

- DeleteJob
- DeleteTable
- GetCrawler
- GetDatabase
- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTable
- ListJobs
- StartCrawler
- StartJobRun

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

Crie e execute um crawler que examine um bucket público do Amazon Simple Storage Service (Amazon S3) e gere um banco de dados de metadados que descreva os dados no formato CSV que encontrar.

```
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 };
  };
```

Liste informações sobre bancos de dados e tabelas no 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(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 };
  };
```

Crie e execute um trabalho que extraia dados em CSV do bucket do Amazon S3 de origem, transforme-os removendo e renomeando campos, e carregue a saída formatada em JSON em outro bucket do 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 };
  };
```

Liste informações sobre execuções de tarefas e visualize alguns dos dados transformados.

```
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 };
  };
```

Exclua todos os recursos criados pela demonstração.

```
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, dbNames);
        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 };
};
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para JavaScript.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun
  - GetJobRuns
  - GetTables
  - ListJobs
  - StartCrawler
  - StartJobRun

Kotlin

SDK para Kotlin

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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 targetOb =
        CrawlerTargets {
            s3Targets = targetList
        }

    val crawlerRequest =
        CreateCrawlerRequest {
            databaseName = dbName
            name = crawlerName
            description = "Created by the AWS Glue Java API"
            targets = targetOb
            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 commandOb =
        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 = commandOb
        }

    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")
    }
}
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para Kotlin.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun
  - GetJobRuns
  - GetTables
  - ListJobs
  - StartCrawler

- StartJobRun

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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,
        ]);
    }
}
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para PHP.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob

- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

Crie uma classe que englobe as funções do AWS Glue usadas no cenário.

```
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
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"]


    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
```

Crie uma classe que execute o cenário.

```
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.")
```

Crie um script de ETL usado pelo AWS Glue para extrair, transformar e carregar dados durante execuções de trabalhos.

```
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()
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para Python (Boto3).
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun
  - GetJobRuns
  - GetTables
  - ListJobs
  - StartCrawler
  - StartJobRun

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

Crie uma classe que englobe as funções do AWS Glue usadas no cenário.

```
# 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'
```

```
      },
      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
```

Crie uma classe que execute o cenário.

```
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
```

```
  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
```

Crie um script de ETL usado pelo AWS Glue para extrair, transformar e carregar dados durante execuções de trabalhos.

```
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()
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para Ruby.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun

- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

Crie e execute um crawler que examine um bucket público do Amazon Simple Storage Service (Amazon S3) e gere um banco de dados de metadados que descreva os dados no formato CSV que encontrar.

```
        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)),
            }
        }
    }?;
```

Liste informações sobre bancos de dados e tabelas no 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();
```

Crie e execute um trabalho que extraia dados em CSV do bucket do Amazon S3 de origem, transforme-os removendo e renomeando campos, e carregue a saída formatada em JSON em outro bucket do 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();
```

Exclua todos os recursos criados pela demonstração.

```
        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)?;
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para Rust.

- CreateCrawler
- CreateJob
- DeleteCrawler
- DeleteDatabase
- DeleteJob
- DeleteTable
- GetCrawler
- GetDatabase
- GetDatabases
- GetJob
- GetJobRun
- GetJobRuns
- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

O arquivo `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/awslabs/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")

    ]
)
```

O arquivo de código 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.
    ///   - 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
    }

    /// 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.dateStyle = .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)
        }
    }
}
```

- Para obter detalhes da API, consulte os tópicos a seguir na Referência da API AWS SDK para Swift.
  - CreateCrawler
  - CreateJob
  - DeleteCrawler
  - DeleteDatabase
  - DeleteJob
  - DeleteTable
  - GetCrawler
  - GetDatabase
  - GetDatabases
  - GetJob
  - GetJobRun
  - GetJobRuns

- GetTables
- ListJobs
- StartCrawler
- StartJobRun

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Ações para o AWS Glue usando AWS SDKs

Os exemplos de código a seguir demonstram como realizar ações individuais do AWS Glue com AWS SDKs. Cada exemplo inclui um link para o GitHub, em que você pode encontrar instruções para configurar e executar o código.

Os exemplos a seguir incluem apenas as ações mais utilizadas. Para obter uma lista completa, consulte a Referência de APIs do AWS Glue.

Exemplos

- Usar CreateCrawler com um SDK da AWS
- Usar CreateJob com o AWS SDK ou a CLI
- Usar DeleteCrawler com um SDK da AWS
- Usar DeleteDatabase com um SDK da AWS
- Usar DeleteJob com o AWS SDK ou a CLI
- Usar DeleteTable com um SDK da AWS
- Usar GetCrawler com um SDK da AWS
- Usar GetDatabase com um SDK da AWS
- Usar GetDatabases com o AWS SDK ou a CLI
- Usar GetJob com o AWS SDK ou a CLI
- Usar GetJobRun com o AWS SDK ou a CLI
- Usar GetJobRuns com o AWS SDK ou a CLI
- Usar GetTables com o AWS SDK ou a CLI
- Usar ListJobs com um SDK da AWS

- Usar StartCrawler com o AWS SDK ou a CLI
- Usar StartJobRun com o AWS SDK ou a CLI

Usar **`CreateCrawler`** com um SDK da AWS

Os exemplos de código a seguir mostram como usar o `CreateCrawler`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /// <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;
    }
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
       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;
```

```
        }
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para C ++.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /**
    * 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;
        }
    }
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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);
};
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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 targetOb =
        CrawlerTargets {
            s3Targets = targetList
        }

    val request =
        CreateCrawlerRequest {
            databaseName = dbName
            name = crawlerName
            description = "Created by the AWS Glue Kotlin API"
            targets = targetOb
            role = iam
            schedule = cron
        }

    GlueClient { region = "us-west-2" }.use { glueClient ->
        glueClient.createCrawler(request)
        println("$crawlerName was successfully created")
    }
}
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $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,
                        ]]
                ],
            ]);
        });
    }
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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(()),
        }?;
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
   }
```

- Para obter detalhes da API, consulte CreateCrawler na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`CreateJob`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `CreateJob`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /// <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;
    }
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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;
        }
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK para C++.

CLI

AWS CLI

Para criar um trabalho para transformar dados

O exemplo de `create-job` a seguir cria um trabalho de streaming que executa um script armazenado no 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
```

Conteúdo 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()
    }
}
```

Saída:

```
{
```

```
    "Name": "my-testing-job"
}
```

Para obter mais informações, consulte Criação de trabalhos no AWS Glue no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte CreateJob na Referência de comandos da AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /**
    * 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;
        }
    }
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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);
};
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $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,
        ]);
    }
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK para PHP.

PowerShell

Ferramentas para PowerShell V4

Exemplo 1: esse exemplo cria um novo trabalho no AWS Glue. O valor do nome do comando é sempre **`glueetl`**. AWS O Glue é compatível com a execução de scripts de trabalhos escritos em Python ou Scala. Neste exemplo, o script de trabalho (MyTestGlueJob.py) é escrito em Python. Os parâmetros do Python são especificados na variável **`$DefArgs`** e, em seguida, passados para o comando do PowerShell no parâmetro **`DefaultArguments`**, que aceita uma tabela de hash. Os parâmetros na variável **`$JobParams`** são provenientes da API CreateJob, documentada no tópico Trabalhos (https://docs.aws.amazon.com/glue/latest/dg/aws-glue-api-jobs-job.html) da Referência da API do 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
```

- Para ter detalhes da API, consulte CreateJob na Referência do Cmdlet Ferramentas da AWS para PowerShell (V4).

Ferramentas para PowerShell V5

Exemplo 1: esse exemplo cria um novo trabalho no AWS Glue. O valor do nome do comando é sempre **`glueetl`**. AWS O Glue é compatível com a execução de scripts de trabalhos escritos em Python ou Scala. Neste exemplo, o script de trabalho (MyTestGlueJob.py) é escrito em Python. Os parâmetros do Python são especificados na variável **`$DefArgs`** e, em seguida, passados para o comando do PowerShell no parâmetro **`DefaultArguments`**, que aceita uma tabela de hash. Os parâmetros na variável **`$JobParams`** são provenientes da API CreateJob, documentada no tópico Trabalhos (https://docs.aws.amazon.com/glue/latest/dg/aws-glue-api-jobs-job.html) da Referência da API do 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
```

- Para mais detalhes sobre a API, consulte CreateJob na Referência do Cmdlet Ferramentas da AWS para PowerShell (V5).

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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())
        })?;
```

- Para obter detalhes da API, consulte CreateJob na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
    }
```

- Para obter detalhes da API, consulte CreateJob na Referência de API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`DeleteCrawler`** com um SDK da AWS

Os exemplos de código a seguir mostram como usar o `DeleteCrawler`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
/// <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;
    }
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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;
        }
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK para C ++.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /**
    * 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;
       }
   }
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const deleteCrawler = (crawlerName) => {
  const client = new GlueClient({});

  const command = new DeleteCrawlerCommand({
    Name: crawlerName,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        echo "Delete the crawler.\n";
        $glueClient->deleteCrawler([
```

```
            'Name' => $crawlerName,
        ]);

    public function deleteCrawler($crawlerName)
    {
        return $this->glueClient->deleteCrawler([
            'Name' => $crawlerName,
        ]);
    }
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        glue.delete_crawler()
            .name(self.crawler())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
    }
```

- Para obter detalhes da API, consulte DeleteCrawler na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`DeleteDatabase`** com um SDK da AWS

Os exemplos de código a seguir mostram como usar o `DeleteDatabase`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /// <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;
    }
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
       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;
       }
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /**
    * 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;
       }
   }
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const deleteDatabase = (databaseName) => {
  const client = new GlueClient({});

  const command = new DeleteDatabaseCommand({
    Name: databaseName,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        echo "Delete the databases.\n";
        $glueClient->deleteDatabase([
            'Name' => $databaseName,
        ]);

    public function deleteDatabase($databaseName)
```

```
    {
        return $this->glueClient->deleteDatabase([
            'Name' => $databaseName,
        ]);
    }
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        glue.delete_database()
            .name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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: databaseName)
            )
        } catch {
            print("*** Unable to delete the database.")
        }
        return true
    }
```

- Para obter detalhes da API, consulte DeleteDatabase na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`DeleteJob`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `DeleteJob`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /// <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;
    }
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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;
        }
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para C++.

CLI

AWS CLI

Para excluir um trabalho

O exemplo de `delete-job` a seguir exclui um trabalho que não é mais necessário.

```
aws glue delete-job \
    --job-name my-testing-job
```

Saída:

```
{
    "JobName": "my-testing-job"
}
```

Para obter mais informações, consulte Trabalhar com trabalhos no console do AWS Glue no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte DeleteJob na Referência de comandos da AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /**
     * 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;
        }
    }
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const deleteJob = (jobName) => {
  const client = new GlueClient({});

  const command = new DeleteJobCommand({
    JobName: jobName,
  });
```

```
  return client.send(command);
};
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        echo "Delete the job.\n";
        $glueClient->deleteJob([
            'JobName' => $job['Name'],
        ]);

    public function deleteJob($jobName)
    {
        return $this->glueClient->deleteJob([
            'JobName' => $jobName,
        ]);
    }
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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)
  rescue Aws::Glue::Errors::ServiceError => e
    @logger.error("Glue could not delete job: \n#{e.message}")
  end
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        glue.delete_job()
            .job_name(self.job())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
    }
```

- Para obter detalhes da API, consulte DeleteJob na Referência da API AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`DeleteTable`** com um SDK da AWS

Os exemplos de código a seguir mostram como usar o `DeleteTable`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /// <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;
    }
```

- Para obter detalhes da API, consulte DeleteTable na Referência da API AWS SDK para .NET.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const deleteTable = (databaseName, tableName) => {
  const client = new GlueClient({});

  const command = new DeleteTableCommand({
    DatabaseName: databaseName,
    Name: tableName,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte DeleteTable na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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,
        ]);
    }
```

- Para obter detalhes da API, consulte DeleteTable na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no Repositório de exemplos de código da 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
```

- Para obter detalhes da API, consulte DeleteTable na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte DeleteTable na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no Repositório de exemplos de código da AWS.

```
        for t in &self.tables {
            glue.delete_table()
                .name(t.name())
```

```
                .database_name(self.database())
                .send()
                .await
                .map_err(GlueMvpError::from_glue_sdk)?;
        }
```

- Para obter detalhes da API, consulte DeleteTable na Referência da API do AWS SDK para Rust.

Para obter uma lista completa dos Guias do desenvolvedor do AWS SDK e exemplos de código, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`GetCrawler`** com um SDK da AWS

Os exemplos de código a seguir mostram como usar o `GetCrawler`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
/// <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;
    }
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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;
        }
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /**
     * 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;
        }
    }
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const getCrawler = (name) => {
  const client = new GlueClient({});
```

```
  const command = new GetCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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")
    }
}
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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,
            ]);
        });
    }
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
            let tmp_crawler = glue
                .get_crawler()
                .name(self.crawler())
                .send()
                .await
                .map_err(GlueMvpError::from_glue_sdk)?;
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
        }
    }
```

- Para obter detalhes da API, consulte GetCrawler na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`GetDatabase`** com um SDK da AWS

Os exemplos de código a seguir mostram como usar o `GetDatabase`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /// <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;
    }
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
       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;
       }
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para C++.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /**
    * 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;
       }
   }
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const getDatabase = (name) => {
  const client = new GlueClient({});

  const command = new GetDatabaseCommand({
    Name: name,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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")
    }
}
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $databaseName = "doc-example-database-$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,
            ]);
        });
    }
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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"]
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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()))?;
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
        }
    }
```

- Para obter detalhes da API, consulte GetDatabase na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`GetDatabases`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `GetDatabases`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação em contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

CLI

AWS CLI

Para listar as definições de alguns ou de todos os bancos de dados no Catálogo de Dados do AWS Glue

O exemplo de `get-databases` a seguir retorna informações sobre os bancos de dados no Catálogo de Dados.

```
aws glue get-databases
```

Saída:

```
{
    "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"
        }
    ]
}
```

Para obter mais informações, consulte Definir um banco de dados no seu Catálogo de Dados no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte GetDatabases na Referência de comandos da AWS CLI.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const getDatabases = () => {
  const client = new GlueClient({});

  const command = new GetDatabasesCommand({});

  return client.send(command);
};
```

- Para obter detalhes da API, consulte GetDatabases na Referência de API do AWS SDK para JavaScript.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`GetJob`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `GetJob`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação em contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

CLI

AWS CLI

Para recuperar informações sobre um trabalho

O exemplo de `get-job` a seguir recupera informações sobre um trabalho.

```
aws glue get-job \
    --job-name my-testing-job
```

Saída:

```
{
    "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"
    }
}
```

Para obter mais informações, consulte Trabalhos no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte GetJob na Referência de comandos da AWS CLI.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const getJob = (jobName) => {
  const client = new GlueClient({});

  const command = new GetJobCommand({
    JobName: jobName,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte GetJob na Referência de API do AWS SDK para JavaScript.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`GetJobRun`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `GetJobRun`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /// <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;
    }
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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;
        }
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API AWS SDK para C++.

CLI

AWS CLI

Para obter informações sobre uma execução de trabalho

O exemplo `get-job-run` a seguir recupera informações sobre uma execução de trabalho.

```
aws glue get-job-run \
    --job-name "Combine legistators data" \
    --run-id jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e
```

Saída:

```
{
    "JobRun": {
        "Id":
 "jr_012e176506505074d94d761755e5c62538ee1aad6f17d39f527e9140cf0c9a5e",
        "Attempt": 0,
        "JobName": "Combine legistators 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"
    }
}
```

Para obter mais informações, consulte Execuções de trabalhos no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte GetJobRun na Referência de comandos da AWS CLI.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const getJobRun = (jobName, jobRunId) => {
  const client = new GlueClient({});
  const command = new GetJobRunCommand({
    JobName: jobName,
    RunId: jobRunId,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $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,
        ]);
    }
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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"]
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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();
        }
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
        }
    }
```

- Para obter detalhes da API, consulte GetJobRun na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`GetJobRuns`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `GetJobRuns`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /// <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;
    }
```

- Para obter detalhes da API, consulte GetJobRuns na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
       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());
```

- Para obter detalhes da API, consulte GetJobRuns na Referência da API AWS SDK para C++.

CLI

AWS CLI

Para obter informações sobre todas as execuções de um trabalho

O exemplo `get-job-runs` a seguir recupera informações sobre execuções de trabalho para um trabalho.

```
aws glue get-job-runs \
    --job-name "my-testing-job"
```

Saída:

```
{
    "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/
TXtuGOqfByajkfL/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
+PpC6GpORahyF2fp9flB5SSb2bTGPnUSPVizLXRl1PN3QZldb+v1o9qRVktNYbW8=)",
            "PredecessorRuns": [],
            "AllocatedCapacity": 10,
            "ExecutionTime": 113,
            "Timeout": 2880,
            "MaxCapacity": 10.0,
            "WorkerType": "G.1X",
            "NumberOfWorkers": 10,
            "LogGroupName": "/aws-glue/jobs",
            "GlueVersion": "2.0"
        }
    ]
}
```

Para obter mais informações, consulte Execuções de trabalhos no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte GetJobRuns na Referência de comandos da AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /**
    * 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);
        }
    }
```

- Para obter detalhes da API, consulte GetJobRuns na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const getJobRuns = (jobName) => {
  const client = new GlueClient({});
  const command = new GetJobRunsCommand({
    JobName: jobName,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte GetJobRuns na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $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);
    }
```

- Para obter detalhes da API, consulte GetJobRuns na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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"]
```

- Para obter detalhes da API, consulte GetJobRuns na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte GetJobRuns na Referência da API AWS SDK para Ruby.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`GetTables`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `GetTables`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
/// <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;
}
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
       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();
        }
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK para C++.

CLI

AWS CLI

Para listar as definições de algumas ou de todas as tabelas no banco de dados especificado

O exemplo de `get-tables` a seguir retorna informações sobre as tabelas no banco de dados especificado.

```
aws glue get-tables --database-name 'tempdb'
```

Saída:

```
{
    "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"
        }
    ]
}
```

Para obter mais informações, consulte Definição de tabelas no catálogo de dados do AWS Glue no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte GetTables na Referência de comandos da AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /**
     * 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;
    }
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const getTables = (databaseName) => {
  const client = new GlueClient({});

  const command = new GetTablesCommand({
    DatabaseName: databaseName,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $databaseName = "doc-example-database-$uniqid";

        $tables = $glueService->getTables($databaseName);

    public function getTables($databaseName): Result
    {
```

```
        return $this->glueClient->getTables([
            'DatabaseName' => $databaseName,
        ]);
    }
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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"]
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        let tables = glue
            .get_tables()
            .database_name(self.database())
            .send()
            .await
            .map_err(GlueMvpError::from_glue_sdk)?;

        let tables = tables.table_list();
```

- Para obter detalhes da API, consulte GetTables na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
    }
```

- Para obter detalhes da API, consulte GetTables na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`ListJobs`** com um SDK da AWS

Os exemplos de código a seguir mostram como usar o `ListJobs`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /// <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;
    }
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
       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());
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para C++.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const listJobs = () => {
  const client = new GlueClient({});

  const command = new ListJobsCommand({});

  return client.send(command);
};
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $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);
    }
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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"]
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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)),
            }
        }
```

- Para obter detalhes da API, consulte ListJobs na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
    }
```

- Para obter detalhes da API, consulte ListJobs na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`StartCrawler`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `StartCrawler`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
/// <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;
}
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
       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;
        }
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para C++.

CLI

AWS CLI

Para iniciar um crawler

O exemplo de `start-crawler` a seguir inicia um crawler.

```
aws glue start-crawler --name my-crawler
```

Saída:

```
None
```

Para obter mais informações, consulte Definição de crawlers no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte StartCrawler na Referência de comandos da AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
    /**
     * 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;
        }
    }
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
const startCrawler = (name) => {
  const client = new GlueClient({});

  const command = new StartCrawlerCommand({
    Name: name,
  });

  return client.send(command);
};
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para JavaScript.

Kotlin

SDK para Kotlin

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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.")
    }
}
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para Kotlin.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $crawlerName = "example-crawler-test-" . $uniqid;

        $databaseName = "doc-example-database-$uniqid";

        $glueService->startCrawler($crawlerName);

    public function startCrawler($crawlerName): Result
    {
        return $this->glueClient->startCrawler([
            'Name' => $crawlerName,
        ]);
    }
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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)),
                }
            }
        }?;
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
    }
```

- Para obter detalhes da API, consulte StartCrawler na Referência da API AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Usar **`StartJobRun`** com o AWS SDK ou a CLI

Os exemplos de código a seguir mostram como usar o `StartJobRun`.

Exemplos de ações são trechos de código de programas maiores e devem ser executados em contexto. É possível ver essa ação no contexto no seguinte exemplo de código:

- Conheça os conceitos básicos

.NET

SDK para .NET

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
/// <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;
    }
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK para .NET.

C++

SDK para C++

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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;
          }
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK para C++.

CLI

AWS CLI

Para iniciar a execução de um trabalho

O exemplo de `start-job-run` a seguir inicia um trabalho.

```
aws glue start-job-run \
    --job-name my-job
```

Saída:

```
{
    "JobRunId":
 "jr_22208b1f44eb5376a60569d4b21dd20fcb8621e1a366b4e7b2494af764b82ded"
}
```

Para obter mais informações, consulte Criação de trabalhos no Guia do desenvolvedor do AWS Glue.

- Para obter detalhes da API, consulte StartJobRun na Referência de comandos da AWS CLI.

Java

SDK para Java 2.x

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
   /**
    * 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;
        }
    }
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK for Java 2.x.

JavaScript

SDK para JavaScript (v3)

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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);
};
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK para JavaScript.

PHP

SDK para PHP

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        $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,
            ],
        ]);
    }
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK para PHP.

Python

SDK para Python (Boto3).

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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"]
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK para Python (Boto3).

Ruby

SDK para Ruby

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
# 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
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK para Ruby.

Rust

SDK para Rust

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
        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();
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API AWS SDK para Rust.

Swift

SDK para Swift

> **Note**
>
> Há mais no GitHub. Encontre o exemplo completo e saiba como configurar e executar no AWSCode Examples Repository.

```
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
        }
    }
```

- Para obter detalhes da API, consulte StartJobRun na Referência da API do AWS SDK para Swift.

Para ver uma lista completa dos Guias do desenvolvedor e exemplos de código do SDK da AWS, consulte Usar este serviço com um AWS SDK. Este tópico também inclui informações sobre como começar e detalhes sobre versões anteriores do SDK.

Segurança no AWS Glue

A segurança para com a nuvem na AWS é a nossa maior prioridade. Como cliente da AWS, você contará com um data center e uma arquitetura de rede criados para atender aos requisitos das organizações com as maiores exigências de segurança.

A segurança é uma responsabilidade compartilhada entre a AWS e você. O modelo de responsabilidade compartilhada descreve isto como segurança da nuvem e segurança na nuvem:

- Segurança da nuvem: a AWS é responsável pela proteção da infraestrutura que executa produtos da AWS na Nuvem AWS. A AWS também fornece serviços que podem ser usados com segurança. Auditores de terceiros testam e verificam regularmente a eficácia da nossa segurança como parte dos programas de conformidade da AWS. Para saber mais sobre os programas de conformidade que se aplicam ao AWS Glue, consulte AWS Services in Scope by Compliance Program.
- Segurança na nuvem: sua responsabilidade é determinada pelo serviço da AWS que você usa. Você também é responsável por outros fatores, incluindo a confidencialidade de seus dados, os requisitos da empresa e as leis e regulamentos aplicáveis.

Esta documentação ajuda a entender como aplicar o modelo de responsabilidade compartilhada ao usar o .AWS Glue Os tópicos a seguir mostram como configurar o AWS Glue para atender aos seus objetivos de segurança e conformidade. Saiba como usar outros serviços AWS que ajudam a monitorar e proteger os recursos do AWS Glue.

Tópicos

- Proteção de dados no AWS Glue
- Gerenciamento de identidade e acesso do AWS Glue
- Modelos de controle de acesso do AWS Lake Formation
- Usar Concessão de Acesso do Amazon S3 com o AWS Glue
- Registrar em log e monitorar no AWS Glue
- Validação de conformidade do AWS Glue
- Resiliência no AWS Glue
- Segurança da infraestrutura no AWS Glue

Proteção de dados no AWS Glue

O AWS Glue oferece vários recursos que foram projetados para ajudar a proteger seus dados.

Tópicos

- Criptografar dados em repouso
- Criptografia de dados em trânsito
- Conformidade com os FIPS
- Gerenciamento de chaves
- Dependência do AWS Glue de outros produtos da AWS
- Endpoints de desenvolvimento

Criptografar dados em repouso

O AWS Glue oferece suporte à criptografia de dados em repouso para Criar trabalhos ETL visuais com o AWS Glue Studio e Desenvolver scripts com endpoints de desenvolvimento. Você pode configurar trabalhos de extração, transformação e carregamento (ETL) e endpoints de desenvolvimento para usar chaves do AWS Key Management Service (AWS KMS) para gravar dados criptografados em repouso. Também é possível criptografar os metadados armazenados no AWS Glue Data Catalog usando chaves que você gerencia com o AWS KMS. Além disso, você pode usar chaves do AWS KMS para criptografar marcadores de trabalho e os logs gerados pelos crawlers e trabalhos de ETL.

Você pode criptografar objetos de metadados em seu AWS Glue Data Catalog, além dos dados gravados no Amazon Simple Storage Service (Amazon S3) e no Amazon CloudWatch Logs, por trabalhos, crawlers e endpoints de desenvolvimento. Ao criar trabalhos, crawlers e endpoints de desenvolvimentos no AWS Glue, é possível fornecer configurações de criptografia anexando uma configuração de segurança. As configurações de segurança contêm chaves de criptografia no lado do servidor gerenciadas pelo Amazon S3 (SSE-S3) ou chaves mestras do cliente (CMKs) armazenadas no AWS KMS (SSE-KMS). É possível criar configurações de segurança usando o console do AWS Glue.

Também é possível ativar a criptografia de todo o Data Catalog na conta. Faça isso especificando CMKs armazenadas no AWS KMS.

> **Important**
>
> O AWS Glue oferece suporte somente a chaves gerenciadas pelo cliente simétricas. Para obter mais informações, consulte Chaves gerenciadas pelo cliente (CMKs) no Guia do desenvolvedor do AWS Key Management Service.

Com a criptografia ativada, quando você adiciona objetos do Data Catalog, executa crawlers ou trabalhos ou inicia endpoints de desenvolvimento, as chaves SSE-S3 ou SSE-KMS são usadas para gravar dados em repouso. Além disso, você pode configurar AWS Glue para acessar apenas armazenamentos de dados Java Database Connectivity (JDBC) por meio de um protocolo Transport Layer Security (TLS) confiável.

No AWS Glue, você controla as configurações de criptografia nos seguintes locais:

- As configurações do seu Data Catalog.
- As configurações de segurança que você cria.
- A configuração de criptografia no lado do servidor (SSE-S3 ou SSE-KMS) que é transmitida como um parâmetro para o trabalho de ETL (extração, transformação e carregamento) do AWS Glue.

Para obter mais informações sobre como definir a criptografia, consulte Configurar criptografia no AWS Glue.

Tópicos

- Como criptografar seu Data Catalog
- Criptografar senhas de conexão
- Criptografar dados gravados pelo AWS Glue

Como criptografar seu Data Catalog

A criptografia do AWS Glue Data Catalog fornece segurança aprimorada para seus dados confidenciais. O AWS Glue se integra ao AWS Key Management Service (AWS KMS) para criptografar metadados armazenados no Catálogo de Dados. Você pode habilitar ou desabilitar as configurações de criptografia para recursos no Catálogo de Dados usando o console do AWS Glue ou a AWS CLI.

Quando você habilita a criptografia para seu Catálogo de Dados, todos os novos objetos que você criar serão criptografados. Quando você desabilita a criptografia, os novos objetos criados não serão criptografados, mas os objetos criptografados existentes permanecerão criptografados.

Você pode criptografar todo o seu Catálogo de Dados usando chaves de criptografia gerenciadas pela AWS ou chaves de criptografia gerenciadas pelo cliente. Para obter mais informações sobre os principais tipos e estados, consulte Conceitos do AWS Key Management Service no Guia do desenvolvedor do AWS Key Management Service.

> **Note**
>
> Ao usar o Catálogo de Dados criptografado com um crawler, é necessário manter as configurações de criptografia. A remoção das configurações de criptografia após um crawler processar um catálogo criptografado resulta em erros. Se você precisar remover as configurações de criptografia, crie um novo crawler em vez de modificar o existente.

Chaves gerenciadas pela AWS

Chaves gerenciadas pelo AWS são chaves do KMS em sua conta que são criadas, gerenciadas e usadas em seu nome por um serviço da AWS integrado ao AWS KMS. É possível visualizar as chaves gerenciadas pela AWS na conta, visualize suas políticas de chaves e audite seu uso nos logs do AWS CloudTrail. No entanto, não é possível gerenciar essas chaves nem alterar suas permissões.

A criptografia em repouso se integra automaticamente com o AWS KMS para gerenciar as chaves gerenciadas pela AWS para o AWS Glue que são usadas para criptografar seus metadados. Se uma chave gerenciada pela AWS não existir quando a criptografia de metadados for habilitada, o AWS KMS criará automaticamente uma nova chave para você.

Para obter mais informações, consulte Chaves gerenciadas pela AWS.

Chaves gerenciadas pelo cliente

Chaves gerenciadas pelo cliente são chaves do KMS em sua Conta da AWS que você cria, detém e gerencia. Você tem controle total sobre essas chaves KMS. É possível:

- Estabelecer e manter suas políticas de chaves, políticas do IAM e concessões
- Habilitá-las e desabilitá-las
- Alternar o material criptográfico

- Adicionar tags
- Criar aliases que se referem a elas
- Agendá-las para exclusão

Para obter mais informações sobre como gerenciar as permissões de uma chave gerenciada pelo cliente, consulte Chaves gerenciadas pelo cliente.

> **Important**
>
> O AWS Glue oferece suporte somente a chaves gerenciadas pelo cliente simétricas. A lista de chaves do KMS exibe apenas chaves simétricas. No entanto, se você selecionar Escolher um ARN de chave do KMS, o console permitirá que você insira um ARN para qualquer tipo de chave. Certifique-se de inserir apenas ARNs para chaves simétricas.
> Para criar uma chave simétrica gerenciada pelo cliente, siga as etapas para criar chaves gerenciadas pelo cliente simétricas e o Guia do desenvolvedor do AWS Key Management Service.

Quando você habilita a criptografia do Catálogo de Dados em repouso, os seguintes tipos de recursos são criptografados usando chaves do KMS:

- Bancos de dados
- Tabelas
- Partições
- Versões de tabela
- Estatísticas de colunas
- Funções definidas pelo usuário
- Visualizações do Catálogo de Dados

Contexto de criptografia do AWS Glue

Um contexto de criptografia é um conjunto opcional de pares de chave-valor que pode conter mais informações contextuais sobre os dados. O AWS KMS usa o contexto de criptografia como dados autenticados adicionais para comportar criptografia autenticada. Quando você inclui um contexto de criptografia em uma solicitação para criptografar dados, o AWS KMS vincula de forma criptográfica o contexto de criptografia aos dados criptografados. Para descriptografar dados, é necessário incluir

o mesmo contexto de criptografia na solicitação. O AWS Glue usa o mesmo contexto de criptografia em todas as operações criptográficas do AWS KMS, onde a chave é `glue_catalog_id` e o valor é `catalogId`.

```
"encryptionContext": {
    "glue_catalog_id": "111122223333"
}
```

Ao usar uma chave gerenciada pela AWS ou uma chave simétrica gerenciada pelo cliente para criptografar seu Catálogo de Dados, você também pode utilizar o contexto de criptografia em registros de auditoria e logs para identificar como a chave está sendo utilizada. O contexto de criptografia também aparece nos logs gerados pelo AWS CloudTrail ou logs do Amazon CloudWatch.

Habilitar a criptografia

Você pode habilitar a criptografia para seus objetos do AWS Glue Data Catalog nas Configurações do Catálogo de Dados no console do AWS Glue ou usando a AWS CLI.

Console

Para habilitar a criptografia usando o console

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Escolha Catálogo de Dados no painel de navegação.
3. Na página Configurações do Catálogo de Dados, marque a caixa de seleção Criptografia de metadados e escolha uma chave do AWS KMS.

   Quando você habilita a criptografia, se você não especificar uma chave gerenciada pelo cliente, as configurações de criptografia usarão uma chave do KMS gerenciada pela AWS.
4. (Opcional) Quando você usa uma chave gerenciada pelo cliente para criptografar seu Catálogo de Dados, o Catálogo de Dados oferece a opção de registrar um perfil do IAM para criptografar e descriptografar recursos. É necessário conceder ao seu perfil do IAM permissões que o AWS Glue pode assumir em seu nome. Isso inclui permissões do AWS KMS para criptografar e descriptografar dados.

   Quando você cria um novo recurso no Catálogo de Dados, o AWS Glue assume o perfil do IAM fornecido para criptografar os dados. Da mesma forma, quando um consumidor acessa o recurso, o AWS Glue assume o perfil do IAM para descriptografar dados. Se você registrar

um perfil do IAM com as permissões necessárias, o responsável pela chamada não precisará mais de permissões para acessar a chave e descriptografar os dados.

> **Important**
>
> É possível delegar operações do KMS a um perfil do IAM somente quando uma chave gerenciada pelo cliente for usada para criptografar os recursos do Catálogo de Dados. No momento, o recurso de delegação de perfil do KMS não oferece suporte ao uso de chaves gerenciadas pela AWS para criptografar recursos do Catálogo de Dados.

> **Warning**
>
> Ao habilitar um perfil do IAM para delegar operações do KMS, você não pode mais acessar os recursos do catálogo de dados que foram criptografados anteriormente com uma chave gerenciada pela AWS.

a. Para habilitar um perfil do IAM que AWS Glue pode assumir para criptografar e descriptografar dados em seu nome, selecione a opção Delegar operações do KMS para um perfil do IAM.

b. Em seguida, escolha um perfil do IAM.

   Para criar um perfil do IAM, consulte Criar um perfil do IAM para o AWS Glue.

   O perfil do IAM que o AWS Glue assume para acessar o Catálogo de Dados deve ter as permissões para criptografar e descriptografar metadados no Catálogo de Dados. Você pode criar um perfil do IAM e anexar as políticas em linha a seguir:

   - Adicione a política a seguir para incluir permissões do AWS KMS para criptografar e descriptografar o Catálogo de Dados.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
```

```
                "kms:Decrypt",
                "kms:Encrypt",
                "kms:GenerateDataKey"
            ],
            "Resource": "arn:aws:kms:<region>:<account-id>:key/<key-id>"
        }
    ]
}
```

- Em seguida, adicione a política de confiança a seguir ao perfil para que o serviço AWS Glue assuma o perfil do IAM.

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

- Em seguida, adicione a permissão `iam:PassRole` ao perfil do IAM.

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

```
}
```

Ao habilitar a criptografia, se você não tiver especificado um perfil do IAM para o AWS Glue assumir, a entidade principal que acessa o Catálogo de Dados deverá ter permissões para realizar as seguintes operações de API:

- `kms:Decrypt`
- `kms:Encrypt`
- `kms:GenerateDataKey`

AWS CLI

Para habilitar a criptografia usando o SDK ou o AWS CLI

- Use a operação de API `PutDataCatalogEncryptionSettings`. Se nenhuma chave for especificada, o AWS Glue usará a chave de criptografia gerenciada pela AWS para a conta do cliente para criptografar o Catálogo de Dados.

```
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>"
    }

  }'
```

Quando você habilitar a criptografia, todos os objetos que você criar no Catálogo de Dados serão criptografados. Se você desmarcar essa configuração, os objetos que você criar no Catálogo de Dados não serão mais criptografados. Você pode continuar acessando os objetos criptografados existentes no Catálogo de Dados com as permissões do KMS necessárias.

> **Important**
>
> A chave do AWS KMS deve permanecer disponível no armazenamento de chaves do AWS KMS para todos os objetos que são criptografados com ela no Data Catalog. Se você remover a chave, os objetos não poderão mais ser descriptografados. Isso pode ser desejável em alguns cenários para impedir o acesso aos metadados do Data Catalog.

Monitorar suas chaves do KMS para o AWS Glue

Ao usar chaves do KMS com os recursos do Catálogo de Dados, você pode usar o AWS CloudTrail ou os Logs do Amazon CloudWatch para rastrear solicitações enviadas pelo AWS Glue para o AWS KMS. O AWS CloudTrail monitora e registra as operações do KMS chamadas pelo AWS Glue para acessar dados criptografados por suas chaves do KMS.

Os exemplos a seguir são eventos do AWS CloudTrail para as operações `Decrypt` e `GenerateDataKey`.

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"
}
```

Criptografar senhas de conexão

Você pode recuperar senhas de conexão no AWS Glue Data Catalog usando o `GetConnection` e `GetConnections` as operações da API. Essas senhas são armazenadas na conexão do Data Catalog e são usadas quando o AWS Glue se conecta a um armazenamento de dados do Java Database Connectivity (JDBC). Se a conexão foi criada ou atualizada, uma opção nas configurações do Data Catalog determina se a senha foi criptografada e, neste caso, qual chave do AWS Key Management Service (AWS KMS) foi especificada.

No console do AWS Glue, é possível ativar essa opção na página Data catalog settings (Configurações do catálogo de dados).

Como criptografas senhas de conexão

1. Faça login no AWS Management Console e abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Selecione Configurações no painel de navegação.
3. Na página Data catalog settings (Configurações do catálogo de dados), selecione Encrypt connection passwords (Criptografar senhas de conexão) e escolha uma chave do AWS KMS.

> **Important**
>
> O AWS Glue só oferece suporte a chaves mestras do cliente (CMKs) simétricas. A lista de chaves do AWS KMS exibe apenas chaves simétricas. No entanto, se você selecionar Escolher um ARN de chave AWS KMS, o console permitirá que você insira

um ARN para qualquer tipo de chave. Certifique-se de inserir apenas ARNs para chaves simétricas.

Para ter mais informações, consulte Configurações do Catálogo de Dados .

Criptografar dados gravados pelo AWS Glue

Uma configuração de segurança é um conjunto de propriedades de segurança que pode ser usado pelo AWS Glue. Você pode usar uma configuração de segurança para criptografar dados em repouso. Os cenários a seguir mostram algumas maneiras de usar uma configuração de segurança.

- Anexe uma configuração de segurança a um crawler do AWS Glue para gravar Amazon CloudWatch Logs criptografados. Para obter mais informações sobre como associar configurações de segurança a crawlers, consulte the section called “Definir configurações de segurança”.
- Anexe uma configuração de segurança a um trabalho do tipo extrair, transformar e carregar (ETL) para gravar destinos do Amazon Simple Storage Service (Amazon S3) criptografados e CloudWatch Logs criptografados.
- Anexe uma configuração de segurança a um trabalho de ETL para gravar seus marcadores de trabalhos como dados do Amazon S3 criptografados.
- Anexe uma configuração de segurança a um endpoint de desenvolvimento para gravar destinos do Amazon S3 criptografados.

Important

Atualmente, uma configuração de segurança substitui qualquer configuração de criptografia no lado do servidor (SSE-S3) que seja transmitida como um parâmetro de trabalho de ETL. Portanto, se uma configuração de segurança e um parâmetro SSE-S3 forem associados a um trabalho, o parâmetro SSE-S3 será ignorado.

Para obter mais informações sobre configurações de segurança, consulte Gerenciar configurações de segurança no console do AWS Glue.

Tópicos

- Configurar o AWS Glue para usar configurações de segurança

- Criar uma rota para o AWS KMS para trabalhos e crawlers da VPC
- Gerenciar configurações de segurança no console do AWS Glue

Configurar o AWS Glue para usar configurações de segurança

Siga estas etapas para configurar seu ambiente AWS Glue para usar configurações de segurança.

1. Crie ou atualize as chaves do AWS Key Management Service (AWS KMS) para conceder permissões ao AWS KMS para as funções do IAM que são transmitidas para crawlers e trabalhos do AWS Glue, a fim de criptografar o CloudWatch Logs. Para obter mais informações, consulte Criptografar dados de log no CloudWatch Logs usando o AWS KMS no Manual do usuário do Amazon CloudWatch Logs.

   No exemplo a seguir, *"role1"*, *"role2"* e *"role3"* são funções do IAM que são transmitidas para crawlers e trabalhos.

   ```
   {
          "Effect": "Allow",
          "Principal": { "Service": "logs.region.amazonaws.com",
          "AWS": [
                   "role1",
                   "role2",
                   "role3"
                ] },
                      "Action": [
                             "kms:Encrypt*",
                             "kms:Decrypt*",
                             "kms:ReEncrypt*",
                             "kms:GenerateDataKey*",
                             "kms:Describe*"
                      ],
                      "Resource": "*"
   }
   ```

   A instrução `Service`, mostrada como `"Service": "logs.region.amazonaws.com"`, será necessária se você usar a chave para criptografar o CloudWatch Logs.

2. Certifique-se de que a chave AWS KMS seja `ENABLED` antes de ser usada.

> **Note**
>
> Se você estiver usando o Iceberg como estrutura de data lake, as tabelas do Iceberg têm seus próprios mecanismos para habilitar a criptografia do lado do servidor. Você deve habilitar essas configurações além das configurações de segurança do AWS Glue. Para habilitar a criptografia do lado do servidor nas tabelas do Iceberg, consulte as orientações na documentação do Iceberg.

Criar uma rota para o AWS KMS para trabalhos e crawlers da VPC

Você pode se conectar diretamente ao AWS KMS através de um endpoint privado na sua VPC (virtual private cloud) em vez de fazer a conexão pela Internet. Quando você usa um endpoint da VPC, a comunicação entre seu VPC e o AWS KMS é realizada inteiramente dentro da rede da AWS.

Você pode criar um AWS KMS VPC endpoint dentro de uma VPC. Sem essa etapa, seus trabalhos ou crawlers podem falhar com um `kms timeout` em trabalhos ou com um `internal service exception` em crawlers. Para obter instruções detalhadas, consulte Conectar-se ao AWS KMS por meio de um endpoint da VPC no Guia do desenvolvedor do AWS Key Management Service.

À medida que você seguir estas instruções, no console da VPC, será necessário fazer o seguinte:

- Selecione Enable Private DNS name (Ativar nome de DNS privado).
- Escolha o Grupo de segurança (com regra de autorreferência) que você usa para o seu trabalho ou crawler que acessa o JDBC (Java Database Connectivity). Para obter mais informações sobre conexões do AWS Glue, consulte Conectar a dados.

Quando você adiciona uma configuração de segurança a um crawler ou trabalho que acessa armazenamentos de dados JDBC, o AWS Glue deve ter uma rota para o AWS KMS endpoint. Você pode fornecer essa rota com um gateway de NAT (conversão de endereços de rede) ou com um AWS KMS VPC endpoint. Para criar um gateway NAT, consulte Gateways NAT no Manual do usuário da Amazon VPC.

Gerenciar configurações de segurança no console do AWS Glue

> **Warning**
>
> As configurações de segurança atuais do AWS Glue não são compatíveis com os trabalhos do Ray.

Uma configuração de segurança no AWS Glue contém as propriedades que são necessárias quando você grava dados criptografados. Você cria configurações de segurança no console do AWS Glue para fornecer as propriedades de criptografia usadas por crawlers, trabalhos e endpoints de desenvolvimento.

Para ver uma lista com todas as configurações de segurança que você criou, abra o console do AWS Glue em https://console.aws.amazon.com/glue/ e escolha Security configurations (Configurações de segurança) no painel de navegação.

A lista de Configurações de segurança exibe as seguintes propriedades sobre cada configuração:

Name

O nome exclusivo que você forneceu quando criou a configuração. O nome pode conter letras (A a Z), números (0 a 9), hifens (-) ou sublinhados (_), e pode ter até 255 caracteres.

Habilitar a criptografia do Amazon S3

Se ativado, o modo de criptografia do Amazon Simple Storage Service (Amazon S3), como `SSE-KMS` ou `SSE-S3`, é habilitado para armazenamento de metadados no catálogo de dados.

Habilitar a criptografia do Amazon CloudWatch Logs

Se ativado, o modo de criptografia do Amazon S3, como `SSE-KMS`, será habilitado ao gravar logs no Amazon CloudWatch.

Configurações avançadas: habilitar a criptografia de marcadores de trabalho

Se ativado, o modo de criptografia do Amazon S3, como `CSE-KMS`, será habiltado ao marcar trabalhos.

Você pode adicionar ou excluir configurações na seção Security configurations (Configurações de segurança) do console. Para ver mais detalhes sobre uma configuração, escolha seu nome na lista. Os detalhes incluem as informações que você definiu quando criou a configuração.

Adicionar uma configuração de segurança

Para adicionar uma configuração de segurança usando o console do AWS Glue, na página Security configurations (Configurações de segurança), escolha Add security configuration (Adicionar configuração de segurança).

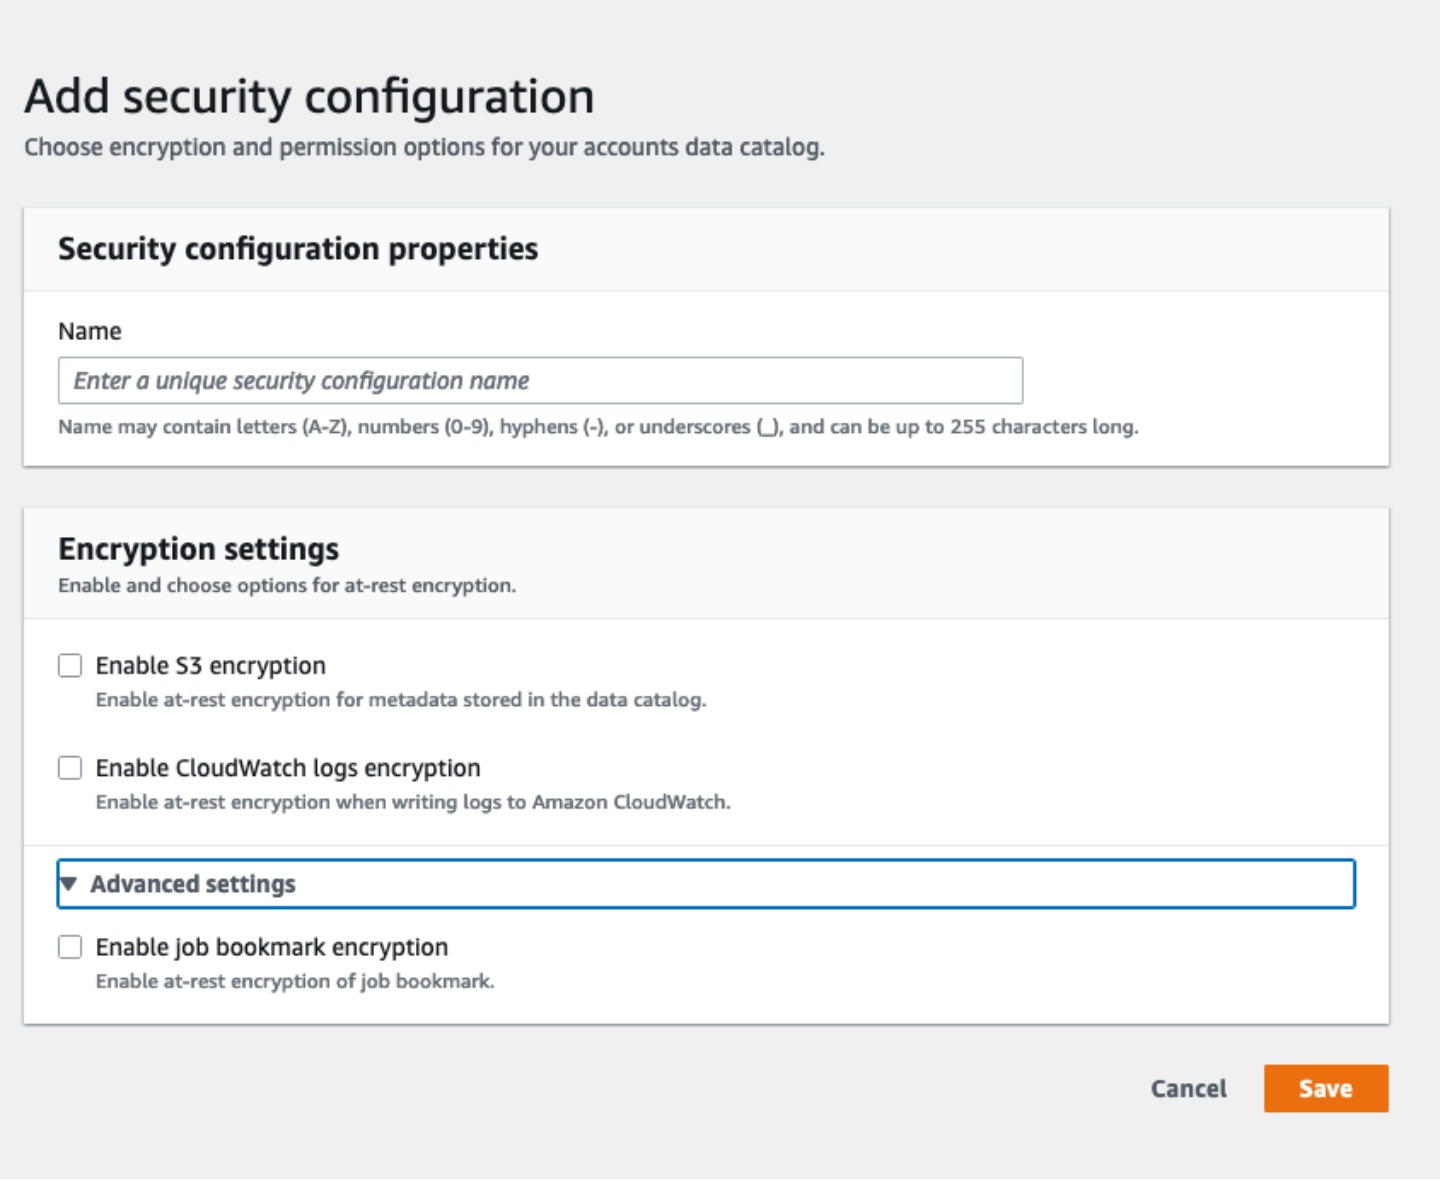

Propriedades de configuração de segurança

Insira um nome de configuração de segurança exclusivo. O nome pode conter letras (A a Z), números (0 a 9), hifens (-) ou sublinhados (_), e pode ter até 255 caracteres.

Configurações de criptografia

Você pode habilitar a criptografia em repouso para metadados armazenados no catálogo de dados no Amazon S3 e nos logs no Amazon CloudWatch. Para configurar a criptografia de dados e metadados com chaves do AWS Key Management Service (AWS KMS) no console do AWS Glue, adicione uma política ao usuário do console. Essa política deve especificar os recursos permitidos como nomes de recurso da Amazon (ARNs) de chaves que são usados para criptografar armazenamentos de dados do Amazon S3, como no exemplo a seguir.

```
{
"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**
>
> Quando uma configuração de segurança está anexada a um crawler ou trabalho, a função do IAM que é transmitida deve ter permissões do AWS KMS. Para obter mais informações, consulte Criptografar dados gravados pelo AWS Glue.

Ao definir uma configuração, você pode fornecer valores para as seguintes propriedades:

Habilitar criptografia do S3

Quando você está gravando dados do Amazon S3, pode usar a criptografia no lado do servidor com chaves gerenciadas do Amazon S3 (SSE-S3) ou a criptografia no lado do servidor com chaves gerenciadas do AWS KMS (SSE-KMS). Esse campo é opcional. Para permitir acesso ao Amazon S3, escolha uma chave do AWS KMS ou Enter a key ARN (Inserir o ARN de uma chave), e forneça o ARN da chave. Insira o ARN no formato `arn:aws:kms:region:account-id:key/key-id`. Você também pode fornecer o ARN como um alias da chave, como `arn:aws:kms:region:account-id:alias/alias-name`.

Se você habilitar a interface do Spark para seu trabalho, o arquivo de log da interface do Spark carregado no Amazon S3 será aplicado com a mesma criptografia.

> **Important**
>
> O AWS Glue só oferece suporte a chaves mestras do cliente (CMKs) simétricas. A lista de chaves do AWS KMS exibe apenas chaves simétricas. No entanto, se você selecionar Escolher um ARN de chave AWS KMS, o console permitirá que você insira um ARN para qualquer tipo de chave. Certifique-se de inserir apenas ARNs para chaves simétricas.

Habilitar criptografia do CloudWatch Logs

A criptografia no lado do servidor (SSE-KMS) é usada para criptografar o CloudWatch Logs. Esse campo é opcional. Para ativá-la, escolha uma chave do AWS KMS ou Enter a key ARN (Inserir ARN da chave), e forneça o ARN da chave. Insira o ARN no formato `arn:aws:kms:`*`region`*`:`*`account-id`*`:key/`*`key-id`*. Você também pode fornecer o ARN como um alias da chave, como `arn:aws:kms:`*`region`*`:`*`account-id`*`:alias/`*`alias-name`*.

Configurações avançadas: criptografia de marcadores de trabalho

A criptografia no lado do cliente (CSE-KMS) é usada para criptografar marcadores de trabalho. Esse campo é opcional. Os dados do marcador são criptografados antes de serem enviados ao Amazon S3 para armazenamento. Para ativá-la, escolha uma chave do AWS KMS ou Enter a key ARN (Inserir ARN da chave), e forneça o ARN da chave. Insira o ARN no formato `arn:aws:kms:`*`region`*`:`*`account-id`*`:key/`*`key-id`*. Você também pode fornecer o ARN como um alias da chave, como `arn:aws:kms:`*`region`*`:`*`account-id`*`:alias/`*`alias-name`*.

Para obter mais informações, consulte os tópicos a seguir no Guia do usuário do Amazon Simple Storage Service:

- Para obter informações sobre o `SSE-S3`, consulte Proteção de dados usando criptografia no lado do servidor com chaves de criptografia gerenciadas do Amazon S3 (SSE-S3).
- Para obter mais informações sobre `SSE-KMS`, consulte Proteger os dados usando criptografia do lado do servidor com AWS KMS keys.
- Para obter informações sobre `CSE-KMS`, consulte Using a KMS key stored in AWS KMS.

Criptografia de dados em trânsito

AWS fornece criptografia Transport Layer Security (TLS) para dados em movimento. Você pode definir as configurações de criptografia para crawlers, trabalhos de ETL e endpoints de desenvolvimento usando configurações de segurança no AWS Glue. É possível ativar a criptografia do AWS Glue Data Catalog por meio das configurações do Data Catalog.

Desde 4 de setembro de 2018, foi adicionado suporte ao AWS KMS (trazer sua própria chave e criptografia no lado do servidor) para o ETL do AWS Glue e o AWS Glue Data Catalog.

Conformidade com os FIPS

Se você precisar de módulos criptográficos validados pelo FIPS 140-2 ao acessar AWS por meio de uma interface de linha de comando ou uma API, use um endpoint FIPS. Para ter mais informações sobre endpoints do FIPS disponíveis, consulte Federal Information Processing Standard (FIPS) 140-2.

Gerenciamento de chaves

É possível usar o AWS Identity and Access Management (IAM) com o AWS Glue para definir usuários, recursos da AWS, grupos, funções e políticas granulares com relação a acesso, negação e muito mais.

Você pode definir o acesso aos metadados usando as políticas baseadas em recursos e as políticas baseadas em identidade dependendo das necessidades da sua organização. As políticas baseadas em recursos listam as entidades principais com acesso permitido ou negado aos seus recursos, permitindo que você configure políticas como acesso entre contas. As políticas baseadas em identidade são anexadas de modo exclusivo a usuários, grupos e funções no IAM.

Para obter um exemplo passo a passo, consulte Restringir o acesso ao seu AWS Glue Data Catalog com permissões de IAM de nível de recursos e políticas baseadas em recursos no AWS Big Data Blog.

A parte de acesso granular da política é definida na cláusula `Resource`. Essa parte define o objeto do AWS Glue Data Catalog no qual a ação pode ser executada e quais objetos resultantes são retornados por essa operação.

Um endpoint de desenvolvimento é um ambiente que você pode usar para desenvolver e testar seus scripts do AWS Glue. É possível adicionar, excluir ou mudar a chave SSH de um endpoint de desenvolvimento.

Desde 4 de setembro de 2018, foi adicionado suporte ao AWS KMS (trazer sua própria chave e criptografia no lado do servidor) para o ETL do AWS Glue e o AWS Glue Data Catalog.

Dependência do AWS Glue de outros produtos da AWS

Para que um usuário trabalhe com o console do AWS Glue, ele deve ter um conjunto mínimo de permissões que liberem o trabalho com os recursos do AWS Glue na conta da AWS. Além dessas permissões do AWS Glue, o console exige permissões dos seguintes serviços:

- Permissões do Amazon CloudWatch Logs para exibir logs.
- Permissões do AWS Identity and Access Management (IAM) para listar e transmitir funções.
- Permissões do AWS CloudFormation para trabalhar com pilhas.
- Permissões do Amazon Elastic Compute Cloud (Amazon EC2) para listar nuvens privadas virtuais (VPCs), sub-redes, grupos de segurança, instâncias e outros objetos (para configurar itens do Amazon EC2, como VPCs, ao executar trabalhos, crawlers e criar endpoints de desenvolvimento).
- Permissões do Amazon Simple Storage Service (Amazon S3) para listar buckets e objetos e para recuperar e salvar scripts.
- Permissões do Amazon Redshift necessárias para trabalhar com clusters.
- Permissões do Amazon Relational Database Service (Amazon RDS) para listar instâncias.

Endpoints de desenvolvimento

Um endpoint de desenvolvimento é um ambiente que você pode usar para desenvolver e testar seus scripts do AWS Glue. Você pode usar o AWS Glue para criar, editar e excluir endpoints de desenvolvimento. Você pode listar todos os endpoints de desenvolvimento criados. É possível adicionar, excluir ou mudar a chave SSH de um endpoint de desenvolvimento. Também é possível criar blocos de anotações que usam o endpoint de desenvolvimento.

Você fornece valores de configuração para a provisão dos ambientes de desenvolvimento. Esses valores informam ao AWS Glue como configurar a rede para que você possa acessar o endpoint de desenvolvimento de forma segura e para que seu endpoint possa acessar seus armazenamentos de dados. Depois, você poderá criar um bloco de anotações que se conecta ao endpoint de desenvolvimento. Você usará o bloco de anotações para criar e testar seu script de ETL.

Escolha uma função do AWS Identity and Access Management (IAM) com permissões semelhantes à função do IAM que você usa para executar os trabalhos de ETL do AWS Glue. Use uma

nuvem privada virtual (VPC), uma sub-rede e um grupo de segurança para criar um endpoint de desenvolvimento que possa se conectar a seus recursos de dados com segurança. Você gera um par de chaves SSH para se conectar ao ambiente de desenvolvimento usando SSH.

É possível criar endpoints de desenvolvimento para dados do Amazon S3 e em uma VPC, que você pode usar para acessar conjuntos de dados usando o JDBC.

Você pode instalar um caderno Jupyter na sua máquina local e usá-lo para depurar e testar scripts de ETL em um endpoint de desenvolvimento. Ou você pode usar um notebook do Sagemaker para criar scripts de ETL no JupyterLab na AWS. Consulte Usar um caderno do SageMaker com seu endpoint de desenvolvimento .

O AWS Glue marca instâncias do Amazon EC2 com um nome que é prefixado com `aws-glue-dev-endpoint`.

Você pode configurar um servidor de caderno em um endpoint de desenvolvimento para executar instruções do PySpark com as extensões do AWS Glue.

Gerenciamento de identidade e acesso do AWS Glue

O AWS Identity and Access Management (IAM) é um serviço da AWS service (Serviço da AWS) que ajuda o administrador no controle de segurança de acesso aos recursos da AWS de forma segura. Os administradores do IAM controlam quem pode ser autenticado (fazer login) e autorizado (ter permissões) a usar os recursos do AWS Glue. O IAM é um AWS service (Serviço da AWS) que pode ser usado sem custo adicional.

> **Note**
>
> Você pode conceder acesso aos dados do AWS Glue Data Catalog usando os métodos do AWS Glue ou as concessões do AWS Lake Formation. Você pode usar as políticas do AWS Identity and Access Management (IAM) para definir um controle de acesso granular com os métodos do AWS Glue. O Lake Formation usa um modelo de permissões `GRANT/REVOKE` mais simples, semelhante aos comandos `GRANT/REVOKE` de um sistema de banco de dados relacional.
>
> Esta seção inclui informações sobre como usar os métodos do AWS Glue. Para obter mais informações sobre o uso das concessões do Lake Formation, consulte Conceder permissões do Lake Formation no Guia do desenvolvedor do AWS Lake Formation.

Tópicos

- Público
- Autenticação com identidades
- Gerenciar acesso usando políticas
- Como o AWS Glue funciona com IAM
- Configurar permissões do KMS para o AWS Glue
- Exemplos de política de controle de acesso do AWS Glue
- Conceder políticas gerenciadas pela AWS para o AWS Glue
- Especificação de ARNs de recursos do AWS Glue
- Concessão de acesso entre contas
- Solução de problemas de identidade e acesso do AWS Glue

Público

A maneira como você usa o AWS Identity and Access Management (IAM) varia dependendo do trabalho que faz no AWS Glue.

Usuário do serviço: se você usar o serviço AWS Glue para fazer seu trabalho, o administrador fornecerá a você as credenciais e as permissões necessárias. À medida que usar mais recursos do AWS Glue para fazer seu trabalho, você poderá precisar de permissões adicionais. Entender como o acesso é gerenciado pode ajudar você a solicitar as permissões corretas ao seu administrador. Se você não puder acessar um recurso no AWS Glue, consulte Solução de problemas de identidade e acesso do AWS Glue.

Administrador do serviço: se você for o responsável pelos recursos do AWS Glue na empresa, provavelmente terá acesso total ao AWS Glue. Cabe a você determinar quais funcionalidades e recursos do AWS Glue os usuários do serviço devem acessar. Assim, você deve enviar solicitações ao administrador do IAM para alterar as permissões dos usuários de seu serviço. Revise as informações nesta página para entender os conceitos básicos do IAM. Para saber mais sobre como a empresa pode usar o IAM com o AWS Glue, consulte Como o AWS Glue funciona com IAM.

Administrador do IAM: se você for um administrador do IAM, talvez queira saber detalhes sobre como pode escrever políticas para gerenciar o acesso ao AWS Glue. Para visualizar um exemplo de política baseada em identidade do AWS Glue que você pode usar no IAM, consulte Exemplos das políticas baseadas em identidade do AWS Glue.

Autenticação com identidades

A autenticação é a forma como você faz login na AWS usando suas credenciais de identidade. É necessário ser autenticado (fazer login na AWS) como Usuário raiz da conta da AWS, como usuário do IAM, ou assumindo um perfil do IAM.

É possível fazer login na AWS como uma identidade federada usando credenciais fornecidas por uma fonte de identidades. AWS IAM Identity Center Os usuários (Centro de Identidade do IAM), a autenticação única da empresa e as suas credenciais do Google ou do Facebook são exemplos de identidades federadas. Quando você faz login como identidade federada, o administrador já configurou anteriormente a federação de identidades usando perfis do IAM. Quando você acessa a AWS usando a federação, está indiretamente assumindo um perfil.

A depender do tipo de usuário, você pode fazer login no AWS Management Console ou no portal de acesso AWS. Para obter mais informações sobre como fazer login na AWS, consulte Como fazer login na conta da Conta da AWS no Guia do usuário do Início de Sessão da AWS.

Se você acessar a AWS programaticamente, a AWS fornecerá um kit de desenvolvimento de software (SDK) e uma interface de linha de comando (CLI) para você assinar criptograficamente as solicitações usando as suas credenciais. Se você não utilizar as ferramentas da AWS, deverá assinar as solicitações por conta própria. Para obter mais informações sobre como usar o método recomendado para assinar solicitações por conta própria, consulte AWS Signature Version 4 para solicitações de API no Guia do usuário do IAM.

Independentemente do método de autenticação usado, também pode ser exigido que você forneça informações adicionais de segurança. Por exemplo, a AWS recomenda o uso da autenticação multifator (MFA) para aumentar a segurança de sua conta. Para saber mais, consulte Autenticação multifator no Guia do Usuário do AWS IAM Identity Center e Autenticação multifator da AWS no IAM no Guia do usuário do IAM.

Usuário-raiz da Conta da AWS

Ao criar uma Conta da AWS, você começa com uma identidade de login com acesso completo a todos os Serviços da AWS e recursos na conta. Essa identidade, chamada usuário-raiz da Conta da AWS, é acessada por login com o endereço de e-mail e a senha usada para criar a conta. É altamente recomendável não usar o usuário raiz para tarefas diárias. Proteja as credenciais do usuário-raiz e use-as para executar as tarefas que somente ele puder executar. Para obter a lista completa das tarefas que exigem login como usuário raiz, consulte Tarefas que exigem credenciais de usuário raiz no Guia do Usuário do IAM.

Identidade federada

Como prática recomendada, exija que os usuários, inclusive os que precisam de acesso de administrador, usem a federação com um provedor de identidades para acessar os Serviços da AWS usando credenciais temporárias.

Uma identidade federada é um usuário de seu diretório de usuários corporativos, um provedor de identidades da web, o AWS Directory Service, o diretório do Centro de Identidade, ou qualquer usuário que acesse os Serviços da AWS usando credenciais fornecidas por meio de uma fonte de identidade. Quando as identidades federadas acessam Contas da AWS, elas assumem perfis que fornecem credenciais temporárias.

Para o gerenciamento de acesso centralizado, recomendamos usar o AWS IAM Identity Center. Você pode criar usuários e grupos no Centro de Identidade do IAM ou conectar-se e sincronizar com um conjunto de usuários e grupos em sua própria fonte de identidade para uso em todas as suas Contas da AWS e aplicações. Para obter mais informações sobre o Centro de Identidade do IAM, consulte O que é o Centro de Identidade do IAM? no Manual do Usuário do AWS IAM Identity Center.

Usuários e grupos do IAM

Um usuário do IAM é uma identidade dentro da Conta da AWS que tem permissões específicas para uma única pessoa ou aplicação. Sempre que possível, recomendamos contar com credenciais temporárias em vez de criar usuários do IAM com credenciais de longo prazo, como senhas e chaves de acesso. No entanto, se você tiver casos de uso específicos que exijam credenciais de longo prazo com usuários do IAM, recomendamos alternar as chaves de acesso. Para obter mais informações, consulte Alterne as chaves de acesso regularmente para casos de uso que exijam credenciais de longo prazo no Guia do Usuário do IAM.

Um grupo do IAM é uma identidade que especifica uma coleção de usuários do IAM. Não é possível fazer login como um grupo. É possível usar grupos para especificar permissões para vários usuários de uma vez. Os grupos facilitam o gerenciamento de permissões para grandes conjuntos de usuários. Por exemplo, você pode ter um grupo chamado IAMAdmins e conceder a esse grupo permissões para administrar recursos do IAM.

Usuários são diferentes de perfis. Um usuário é exclusivamente associado a uma pessoa ou a uma aplicação, mas um perfil pode ser assumido por qualquer pessoa que precisar dele. Os usuários têm credenciais permanentes de longo prazo, mas os perfis fornecem credenciais temporárias. Para saber mais, consulte Casos de uso para usuários do IAM no Guia do usuário do IAM.

Perfis do IAM

Um perfil do IAM é uma identidade dentro da Conta da AWS que tem permissões específicas. Ele é semelhante a um usuário do IAM, mas não está associado a uma pessoa específica. Para assumir temporariamente um perfil do IAM no AWS Management Console, você pode alternar de um usuário para um perfil do IAM (console). É possível presumir um perfil chamando uma operação de API da AWS CLI ou da AWS, ou usando um URL personalizado. Para obter mais informações sobre métodos para usar perfis, consulte Métodos para assumir um perfil no Guia do usuário do IAM.

Os perfis do IAM com credenciais temporárias são úteis nas seguintes situações:

- Acesso de usuário federado: para atribuir permissões a identidades federadas, você pode criar um perfil e definir permissões para ele. Quando uma identidade federada é autenticada, essa identidade é associada ao perfil e recebe as permissões definidas por ele. Para obter mais informações sobre os perfis para federação, consulte Criar um perfil para um provedor de identidade de terceiros (federação) no Guia do usuário do IAM. Se você usar o Centro de Identidade do IAM, configure um conjunto de permissões. Para controlar o que suas identidades podem acessar após a autenticação, o Centro de Identidade do IAM correlaciona o conjunto de permissões a um perfil no IAM. Para obter informações sobre conjuntos de permissões, consulte Conjuntos de permissões no Guia do usuário do AWS IAM Identity Center.
- Permissões temporárias para usuários do IAM: um usuário ou um perfil do IAM pode assumir um perfil do IAM para obter temporariamente permissões diferentes para uma tarefa específica.
- Acesso entre contas: é possível usar um perfil do IAM para permitir que alguém (uma entidade principal confiável) em outra conta acesse recursos em sua conta. Os perfis são a principal forma de conceder acesso entre contas. No entanto, alguns Serviços da AWS permitem que você anexe uma política diretamente a um recurso (em vez de usar um perfil como proxy). Para saber a diferença entre perfis e políticas baseadas em recurso para acesso entre contas, consulte Acesso a recursos entre contas no IAM no Guia do usuário do IAM.
- Acesso entre serviços: alguns Serviços da AWS usam recursos em outros Serviços da AWS. Por exemplo, quando você faz uma chamada em um serviço, é comum que esse serviço execute aplicações no Amazon EC2 ou armazene objetos no Amazon S3. Um serviço pode fazer isso usando as permissões da entidade principal de chamada, usando um perfil de serviço ou um perfil vinculado a serviço.
  - Encaminhamento de sessões de acesso (FAS): qualquer pessoa que utilizar um perfil ou usuário do IAM para realizar ações na AWS é considerada uma entidade principal. Ao usar alguns serviços, você pode executar uma ação que inicia outra ação em um serviço diferente. O recurso FAS utiliza as permissões da entidade principal que chama um AWS service (Serviço da

AWS), combinadas às permissões do AWS service (Serviço da AWS) solicitante, para realizar solicitações para serviços downstream. As solicitações de FAS só são feitas quando um serviço recebe uma solicitação que exige interações com outros Serviços da AWS ou com recursos para serem concluídas. Nesse caso, você precisa ter permissões para executar ambas as ações. Para obter detalhes da política ao fazer solicitações de FAS, consulte Encaminhar sessões de acesso.

- Perfil de serviço: um perfil de serviço é um perfil do IAM que um serviço assume para realizar ações em seu nome. Um administrador do IAM pode criar, modificar e excluir um perfil de serviço do IAM. Para obter mais informações, consulte Criar um perfil para delegar permissões a um AWS service (Serviço da AWS) no Guia do usuário do IAM.
- Perfil vinculado a serviço: um perfil vinculado a serviço é um tipo de perfil de serviço vinculado a um AWS service (Serviço da AWS). O serviço pode assumir o perfil para executar uma ação em seu nome. Os perfis vinculados ao serviço aparecem em sua Conta da AWS e pertencem ao serviço. Um administrador do IAM pode visualizar, mas não editar as permissões para perfis vinculados ao serviço.

- Aplicações em execução no Amazon EC2: é possível usar um perfil do IAM para gerenciar credenciais temporárias para aplicações em execução em uma instância do EC2 e fazer solicitações da AWS CLI ou da AWS API. É preferível fazer isso a armazenar chaves de acesso na instância do EC2. Para atribuir um perfil da AWS a uma instância do EC2 e disponibilizá-la para todas as suas aplicações, crie um perfil de instância que esteja anexado a ela. Um perfil de instância contém o perfil e permite que os programas em execução na instância do EC2 obtenham credenciais temporárias. Para obter mais informações, consulte Use um perfil do IAM para conceder permissões a aplicações em execução em instâncias do Amazon EC2 no Guia do usuário do IAM.

Gerenciar acesso usando políticas

Você controla o acesso na AWS criando políticas e anexando-as a identidades ou recursos da AWS. Uma política é um objeto na AWS que, quando associado a uma identidade ou recurso, define suas permissões. A AWS avalia essas políticas quando uma entidade principal (usuário, usuário-raiz ou sessão de perfil) faz uma solicitação. As permissões nas políticas determinam se a solicitação será permitida ou negada. A maioria das políticas é armazenada na AWS como documentos JSON. Para obter mais informações sobre a estrutura e o conteúdo de documentos de políticas JSON, consulte Visão geral das políticas JSON no Guia do usuário do IAM.

Os administradores podem usar as políticas JSON da AWS para especificar quem tem acesso a o quê. Ou seja, qual entidade principal pode executar ações em quais recursos e em que condições.

Por padrão, usuários e perfis não têm permissões. Para conceder aos usuários permissões para executar ações nos recursos que eles precisam, um administrador do IAM pode criar políticas do IAM. O administrador pode então adicionar as políticas do IAM aos perfis e os usuários podem presumir os perfis.

As políticas do IAM definem permissões para uma ação independentemente do método usado para executar a operação. Por exemplo, suponha que você tenha uma política que permite a ação `iam:GetRole`. Um usuário com essa política pode obter informações de perfis do AWS Management Console, da AWS CLI ou da API da AWS.

Políticas baseadas em identidade

As políticas baseadas em identidade são documentos de políticas de permissões JSON que você pode anexar a uma identidade, como usuário do IAM, grupo de usuários ou perfil. Essas políticas controlam quais ações os usuários e perfis podem realizar, em quais recursos e em que condições. Para saber como criar uma política baseada em identidade, consulte Definir permissões personalizadas do IAM com políticas gerenciadas pelo cliente no Guia do usuário do IAM.

As políticas baseadas em identidade podem ser categorizadas ainda adicionalmente como políticas em linha ou políticas gerenciadas. As políticas em linha são anexadas diretamente a um único usuário, grupo ou perfil. As políticas gerenciadas são políticas independentes que podem ser anexadas a vários usuários, grupos e perfis na Conta da AWS. As políticas gerenciadas incluem políticas gerenciadas pela AWS e políticas gerenciadas pelo cliente. Para saber como escolher entre uma política gerenciada ou uma política em linha, consulte Escolher entre políticas gerenciadas e políticas em linha no Guia do usuário do IAM.

Políticas baseadas no recurso

Políticas baseadas em recursos são documentos de políticas JSON que você anexa a um recurso. São exemplos de políticas baseadas em recursos as políticas de confiança de perfil do IAM e as políticas de bucket do Amazon S3. Em serviços que suportem políticas baseadas em recursos, os administradores de serviço podem usá-las para controlar o acesso a um recurso específico. Para o recurso ao qual a política está anexada, a política define quais ações um principal especificado pode executar nesse recurso e em que condições. Você deve especificar uma entidade principal em uma política baseada em recursos. As entidades principais podem incluir contas, usuários, perfis, usuários federados ou Serviços da AWS.

Políticas baseadas em recursos são políticas em linha localizadas nesse serviço. Não é possível usar as políticas gerenciadas da AWS do IAM em uma política baseada em recursos.

Listas de controle de acesso (ACLs)

As listas de controle de acesso (ACLs) controlam quais entidades principais (membros, usuários ou perfis da conta) têm permissões para acessar um recurso. As ACLs são semelhantes às políticas baseadas em recursos, embora não usem o formato de documento de política JSON.

Amazon S3, AWS WAF e Amazon VPC são exemplos de serviços que oferecem compatibilidade com ACLs. Para saber mais sobre ACLs, consulte Visão geral da lista de controle de acesso (ACL) no Guia do Desenvolvedor do Amazon Simple Storage Service.

Outros tipos de política

A AWS oferece compatibilidade com tipos de política menos comuns. Esses tipos de política podem definir o máximo de permissões concedidas a você pelos tipos de política mais comuns.

- Limites de permissões: um limite de permissões é um recurso avançado no qual você define o máximo de permissões que uma política baseada em identidade pode conceder a uma entidade do IAM (usuário ou perfil do IAM). É possível definir um limite de permissões para uma entidade. As permissões resultantes são a interseção das políticas baseadas em identidade de uma entidade com seus limites de permissões. As políticas baseadas em recurso que especificam o usuário ou o perfil no campo `Principal` não são limitadas pelo limite de permissões. Uma negação explícita em qualquer uma dessas políticas substitui a permissão. Para obter mais informações sobre limites de permissões, consulte Limites de permissões para identidades do IAM no Guia do usuário do IAM.
- Políticas de controle de serviços (SCPs): SCPs são políticas JSON que especificam as permissões máximas para uma organização ou unidade organizacional (UO) no AWS Organizations. O AWS Organizations é um serviço que agrupa e gerencia centralmente várias Contas da AWS pertencentes à sua empresa. Se você habilitar todos os recursos em uma organização, poderá aplicar políticas de controle de serviço (SCPs) a qualquer uma ou a todas as contas. O SCP limita as permissões para entidades em contas membro, o que inclui cada Usuário raiz da conta da AWS. Para obter mais informações sobre o Organizations e SCPs, consulte Service control policies no Guia do usuário do AWS Organizations.
- Políticas de controle de recursos (RCPs): RCPs são políticas JSON que podem ser usadas para definir o máximo de permissões disponíveis para recursos em suas contas sem atualizar as políticas do IAM anexadas a cada recurso que você possui. A RCP limita as permissões para

recursos nas contas de membros e pode afetar as permissões efetivas para identidades, incluindo o Usuário raiz da conta da AWS, independentemente de pertencerem a sua organização. Consulte mais informações sobre o Organizations e as RCPs, incluindo uma lista de Serviços da AWS compatíveis com as RCPs em Resource control policies (RCPs) no Guia do usuário do AWS Organizations.

- Políticas de sessão: são políticas avançadas que você transmite como um parâmetro quando cria de forma programática uma sessão temporária para um perfil ou um usuário federado. As permissões da sessão resultante são a interseção das políticas baseadas em identidade do usuário ou do perfil e das políticas de sessão. As permissões também podem ser provenientes de uma política baseada em recursos. Uma negação explícita em qualquer uma dessas políticas substitui a permissão. Para obter mais informações, consulte Políticas de sessão no Guia do usuário do IAM.

Vários tipos de política

Quando vários tipos de política são aplicáveis a uma solicitação, é mais complicado compreender as permissões resultantes. Para saber como a AWS determina permitir ou não uma solicitação quando há vários tipos de política envolvidos, consulte Lógica da avaliação de políticas no Guia do usuário do IAM.

Como o AWS Glue funciona com IAM

Antes de usar IAM para gerenciar o acesso ao AWS Glue, saiba quais IAM recursos estão disponíveis para uso com o AWS Glue.

IAMrecursos que você pode usar com o AWS Glue

IAMrecurso	AWS Suporte Glue
Políticas baseadas em identidade	Sim
Políticas baseadas em atributos	Parcial
Ações das políticas	Sim
Atributos de políticas	Sim

IAMrecurso	AWS Suporte Glue
Chaves de condição de política (específicas do serviço)	Sim
ACLs	Não
ABAC(tags nas políticas)	Parcial
Credenciais temporárias	Sim
Permissões de entidade principal	Não
Perfis de serviço	Sim
Perfis vinculados ao serviço	Não

Para ter uma visão geral de como o AWS Glue e outros AWS serviços funcionam com a maioria dos IAM recursos, consulte AWS os serviços que funcionam com IAM no Guia do IAM usuário.

Políticas baseadas em identidade para Glue AWS

Compatível com políticas baseadas em identidade: Sim

Políticas baseadas em identidade são documentos de políticas de JSON permissões que você pode anexar a uma identidade, como um IAM usuário, grupo de usuários ou função. Essas políticas controlam quais ações os usuários e perfis podem realizar, em quais recursos e em que condições. Para saber como criar uma política baseada em identidade, consulte Definir IAM permissões personalizadas com políticas gerenciadas pelo cliente no Guia do IAMusuário.

Com políticas IAM baseadas em identidade, você pode especificar ações e recursos permitidos ou negados, bem como as condições sob as quais as ações são permitidas ou negadas. Você não pode especificar a entidade principal em uma política baseada em identidade porque ela se aplica ao usuário ou perfil ao qual ela está anexada. Para saber mais sobre todos os elementos que você pode usar em uma JSON política, consulte a referência IAM JSON de elementos de política no Guia IAM do usuário.

AWS Glue suporta políticas baseadas em identidade (IAMpolíticas) para todos AWS Glue operações. Ao anexar uma política, você pode conceder permissões para criar, acessar ou modificar uma AWS Glue recurso, como uma tabela no AWS Glue Data Catalog.

Exemplos de políticas baseadas em identidade para Glue AWS

Para ver exemplos de políticas baseadas em identidade do AWS Glue, consulte. Exemplos das políticas baseadas em identidade do AWS Glue

Políticas baseadas em recursos no Glue AWS

Compatível com políticas baseadas em recursos: Parcial

Políticas baseadas em recursos são documentos JSON de política que você anexa a um recurso. Exemplos de políticas baseadas em recursos são políticas de confiança de IAM funções e políticas de bucket do Amazon S3. Em serviços que suportem políticas baseadas em recursos, os administradores de serviço podem usá-las para controlar o acesso a um recurso específico. Para o recurso ao qual a política está anexada, a política define quais ações um principal especificado pode executar nesse recurso e em que condições. Você deve especificar uma entidade principal em uma política baseada em recursos. Os diretores podem incluir contas, usuários, funções, usuários federados ou. Serviços da AWS

Para habilitar o acesso entre contas, você pode especificar uma conta ou IAM entidades inteiras em outra conta como principal em uma política baseada em recursos. Adicionar uma entidade principal entre contas à política baseada em recurso é apenas metade da tarefa de estabelecimento da relação de confiança. Quando o principal e o recurso são diferentes Contas da AWS, um IAM administrador na conta confiável também deve conceder permissão à entidade principal (usuário ou função) para acessar o recurso. Eles concedem permissão ao anexar uma política baseada em identidade para a entidade. No entanto, se uma política baseada em recurso conceder acesso a uma entidade principal na mesma conta, nenhuma política baseada em identidade adicional será necessária. Para obter mais informações, consulte Acesso a recursos entre contas IAM no Guia do IAM usuário.

> **Note**
>
> Você só pode usar um AWS Glue política de recursos para gerenciar permissões para recursos do Catálogo de Dados. Você não pode anexá-lo a nenhum outro AWS Glue recursos como trabalhos, acionadores, endpoints de desenvolvimento, rastreadores ou classificadores.
> Apenas uma política de recursos é permitida por catálogo, e seu tamanho é limitado a 10 KB.

No AWS Glue, uma política de recursos é anexada a um catálogo, que é um contêiner virtual para todos os tipos de recursos do Catálogo de Dados mencionados anteriormente. Cada AWS conta possui um único catálogo em uma AWS região cujo ID do catálogo é igual ao ID da AWS conta. Você não pode excluir nem modificar um catálogo.

Uma política de recursos é avaliada para todas as API chamadas para o catálogo em que o chamador principal está incluído no `"Principal"` bloco do documento de política.

Para ver exemplos de políticas baseadas em recursos do AWS Glue, consulte. Exemplos de política baseada em recursos para o AWS Glue

Ações políticas para AWS Glue

Compatível com ações de políticas: Sim

Os administradores podem usar AWS JSON políticas para especificar quem tem acesso ao quê. Ou seja, qual entidade principal pode executar ações em quais recursos, e em que condições.

O `Action` elemento de uma JSON política descreve as ações que você pode usar para permitir ou negar acesso em uma política. As ações de política geralmente têm o mesmo nome da AWS API operação associada. Há algumas exceções, como ações somente de permissão que não têm uma operação correspondente. API Algumas operações também exigem várias ações em uma política. Essas ações adicionais são chamadas de ações dependentes.

Incluem ações em uma política para conceder permissões para executar a operação associada.

Para ver uma lista de ações do AWS Glue, consulte Ações definidas pelo AWS Glue na Referência de Autorização de Serviço.

As ações de política no AWS Glue usam o seguinte prefixo antes da ação:

```
glue
```

Para especificar várias ações em uma única instrução, separe-as com vírgulas.

```
"Action": [
      "glue:action1",
      "glue:action2"
```

```
        ]
```

Você também pode especificar várias ações usando caracteres-curinga (*). Por exemplo, para especificar todas as ações que começam com a palavra `Get`, inclua a seguinte ação:

```
"Action": "glue:Get*"
```

Para ver exemplos de políticas, consulte Exemplos de política de controle de acesso do AWS Glue.

Recursos de políticas para AWS Glue

Compatível com recursos de políticas: Sim

Os administradores podem usar AWS JSON políticas para especificar quem tem acesso ao quê. Ou seja, qual entidade principal pode executar ações em quais recursos, e em que condições.

O elemento `Resource` JSON de política especifica o objeto ou objetos aos quais a ação se aplica. As instruções devem incluir um elemento `Resource` ou `NotResource`. Como prática recomendada, especifique um recurso usando seu Amazon Resource Name (ARN). Isso pode ser feito para ações que oferecem compatibilidade com um tipo de recurso específico, conhecido como permissões em nível de recurso.

Para ações que não oferecem compatibilidade com permissões em nível de recurso, como operações de listagem, use um curinga (*) para indicar que a instrução se aplica a todos os recursos.

```
"Resource": "*"
```

Para obter mais informações sobre como controlar o acesso aos recursos do AWS Glue usandoARNs, consulteEspecificação de ARNs de recursos do AWS Glue.

Para ver uma lista dos tipos de recursos do AWS Glue e seusARNs, consulte Recursos definidos pelo AWS Glue na Referência de Autorização de Serviço. Para saber quais ações você pode usar para especificar cada recurso, consulte Ações definidas pelo AWS Glue. ARN

Chaves de condição de política para AWS Glue

Compatível com chaves de condição de política específicas de serviço: Sim

Os administradores podem usar AWS JSON políticas para especificar quem tem acesso ao quê. Ou seja, qual entidade principal pode executar ações em quais recursos, e em que condições.

O elemento `Condition` (ou bloco `Condition`) permite que você especifique condições nas quais uma instrução estiver em vigor. O elemento `Condition` é opcional. É possível criar expressões condicionais que usem agentes de condição, como “igual a” ou “menor que”, para fazer a condição da política corresponder aos valores na solicitação.

Se você especificar vários elementos `Condition` em uma instrução ou várias chaves em um único `Condition` elemento, a AWS os avaliará usando uma operação lógica `AND`. Se você especificar vários valores para uma única chave de condição, AWS avalia a condição usando uma `OR` operação lógica. Todas as condições devem ser atendidas antes que as permissões da instrução sejam concedidas.

Você também pode usar variáveis de espaço reservado ao especificar condições. Por exemplo, você pode conceder permissão a um IAM usuário para acessar um recurso somente se ele estiver marcado com o nome de IAM usuário. Para obter mais informações, consulte elementos de IAM política: variáveis e tags no Guia IAM do usuário.

AWS suporta chaves de condição globais e chaves de condição específicas do serviço. Para ver todas as chaves de condição AWS globais, consulte as chaves de contexto de condição AWS global no Guia IAM do usuário.

Para ver uma lista das chaves de condição do AWS Glue, consulte Chaves de condição do AWS Glue na Referência de Autorização de Serviço. Para saber com quais ações e recursos você pode usar uma chave de condição, consulte Ações definidas pelo AWS Glue.

Para ver exemplos de políticas, consulte Controlar as configurações usando chaves de condição ou chaves de contexto.

ACLsem AWS Glue

SuportesACLs: Não

As listas de controle de acesso (ACLs) controlam quais diretores (membros da conta, usuários ou funções) têm permissões para acessar um recurso. ACLssão semelhantes às políticas baseadas em recursos, embora não usem o formato de documento JSON de política.

ABACcom AWS Glue

Suportes ABAC (tags nas políticas): Parciais

O controle de acesso baseado em atributos (ABAC) é uma estratégia de autorização que define permissões com base em atributos. Em AWS, esses atributos são chamados de tags. Você pode anexar tags a IAM entidades (usuários ou funções) e a muitos AWS recursos. Marcar entidades e recursos é a primeira etapa doABAC. Em seguida, você cria ABAC políticas para permitir operações quando a tag do diretor corresponde à tag do recurso que ele está tentando acessar.

ABACé útil em ambientes que estão crescendo rapidamente e ajuda em situações em que o gerenciamento de políticas se torna complicado.

Para controlar o acesso baseado em tags, forneça informações sobre as tags no elemento de condição de uma política usando as `aws:ResourceTag/`*`key-name`*, `aws:RequestTag/`*`key-name`* ou chaves de condição `aws:TagKeys`.

Se um serviço oferecer suporte às três chaves de condição para cada tipo de recurso, o valor será Sim para o serviço. Se um serviço oferecer suporte às três chaves de condição somente para alguns tipos de recursos, o valor será Parcial

Para obter mais informações sobreABAC, consulte Definir permissões com ABAC autorização no Guia IAM do usuário. Para ver um tutorial com etapas de configuraçãoABAC, consulte Usar controle de acesso baseado em atributos (ABAC) no Guia do IAMusuário.

> **Important**
>
> As chaves de contexto de condição se aplicam somente a AWS Glue APIações em rastreadores, tarefas, gatilhos e endpoints de desenvolvimento. Para obter mais informações sobre quais API operações são afetadas, consulte Chaves de condição para AWS Glue.
> A ferramenta AWS Glue Atualmente, API as operações do Catálogo de Dados não oferecem suporte `aws:referer` às chaves de contexto de condição `aws:UserAgent` global.

Para visualizar um exemplo de política baseada em identidade para limitar o acesso a um recurso baseado em tags desse recurso, consulte Conceder acesso usando tags.

Usando credenciais temporárias com AWS Glue

Compatível com credenciais temporárias: Sim

Alguns Serviços da AWS não funcionam quando você faz login usando credenciais temporárias. Para obter informações adicionais, incluindo quais Serviços da AWS funcionam com credenciais temporárias, consulte Serviços da AWS esse trabalho IAM no Guia do IAM usuário.

Você está usando credenciais temporárias se fizer login AWS Management Console usando qualquer método, exceto um nome de usuário e senha. Por exemplo, quando você acessa AWS usando o link de login único (SSO) da sua empresa, esse processo cria automaticamente credenciais temporárias. Você também cria automaticamente credenciais temporárias quando faz login no console como usuário e, em seguida, alterna perfis. Para obter mais informações sobre a troca de funções, consulte Alternar de um usuário para uma IAM função (console) no Guia IAM do usuário.

Você pode criar manualmente credenciais temporárias usando o AWS CLI ou AWS API. Em seguida, você pode usar essas credenciais temporárias para acessar AWS. AWS recomenda que você gere credenciais temporárias dinamicamente em vez de usar chaves de acesso de longo prazo. Para obter mais informações, consulte Credenciais de segurança temporárias emIAM.

Permissões principais entre serviços para AWS Glue

Suporta sessões de acesso direto (FAS): Não

Quando você usa um IAM usuário ou uma função para realizar ações em AWS, você é considerado principal. Ao usar alguns serviços, você pode executar uma ação que inicia outra ação em um serviço diferente. FASusa as permissões do diretor chamando um AWS service (Serviço da AWS), combinadas com a solicitação AWS service (Serviço da AWS) para fazer solicitações aos serviços posteriores. FASas solicitações são feitas somente quando um serviço recebe uma solicitação que requer interações com outros Serviços da AWS ou com recursos para ser concluída. Nesse caso, você precisa ter permissões para executar ambas as ações. Para obter detalhes da política ao fazer FAS solicitações, consulte Encaminhar sessões de acesso.

Perfis de serviço do AWS Glue

Compatível com perfis de serviço: Sim

Uma função de serviço é uma IAMfunção que um serviço assume para realizar ações em seu nome. Um IAM administrador pode criar, modificar e excluir uma função de serviço internamenteIAM. Para obter mais informações, consulte Criar uma função para delegar permissões a um AWS service (Serviço da AWS) no Guia do IAM usuário.

> **Warning**
>
> Alterar as permissões de uma função de serviço pode interromper a funcionalidade do AWS Glue. Edite as funções de serviço somente quando o AWS Glue fornecer orientação para fazer isso.

Para obter instruções detalhadas sobre como criar uma função de serviço para o AWS Etapa 1: criar uma política do IAM para o serviço AWS Glue Glue, consulte Etapa 2: criar um perfil do IAM para o AWS Glue e.

Funções vinculadas a serviços para Glue AWS

Compatível com perfis vinculados ao serviço: Não

Uma função vinculada ao serviço é um tipo de função de serviço vinculada a um. AWS service (Serviço da AWS) O serviço pode assumir o perfil para executar uma ação em seu nome. As funções vinculadas ao serviço aparecem em você Conta da AWS e são de propriedade do serviço. Um IAM administrador pode visualizar, mas não editar, as permissões das funções vinculadas ao serviço.

Para obter detalhes sobre como criar ou gerenciar funções vinculadas a serviços, consulte AWS serviços que funcionam com. IAM Encontre um serviço na tabela que inclua um `Yes` na coluna Função vinculada ao serviço. Escolha o link Sim para visualizar a documentação do perfil vinculado a serviço desse serviço.

Configurar permissões do KMS para o AWS Glue

Você usa o AWS Identity and Access Management (IAM) para definir as políticas e os perfis que o AWS Glue usa para acessar os recursos. As etapas a seguir orientam você por várias opções para configurar as permissões para o AWS Glue. Dependendo das necessidades da sua empresa, pode ser necessário adicionar ou reduzir o acesso aos seus recursos.

> **Note**
>
> Para começar a usar as permissões básicas do IAM para o AWS Glue em vez disso, consulte Configurar permissões do IAM para o AWS Glue.

1. Criar uma política do IAM para o serviço AWS Glue: crie uma política de serviço que conceda acesso aos recursos do AWS Glue.
2. Criar um perfil do IAM para o AWS Glue: crie um perfil do IAM e anexe a política do serviço AWS Glue e uma política para os recursos do Amazon Simple Storage Service (Amazon S3) que são usados pelo AWS Glue.
3. Anexar uma política a usuários ou grupos que acessam o AWS Glue: anexe políticas aos usuários ou grupos que fazem login no console do AWS Glue.

4. Criar uma política do IAM para cadernos: crie uma política de servidor de cadernos para usar na criação de servidores de cadernos em endpoints de desenvolvimento.
5. Criar um perfil do IAM para cadernos: crie um perfil do IAM e anexe a política do servidor do cadernos.
6. Criar uma política do IAM para cadernos do Amazon SageMaker AI: crie uma política do IAM a ser usada ao criar cadernos do Amazon SageMaker AI em endpoints de desenvolvimento.
7. Criar um perfil do IAM para cadernos do Amazon SageMaker AI: crie um perfil do IAM e anexe a política para conceder permissões ao criar cadernos do Amazon SageMaker AI em endpoints de desenvolvimento.

Etapa 1: criar uma política do IAM para o serviço AWS Glue

Para qualquer operação que acesse dados em outro recurso da AWS, como o acesso aos seus objetos no Amazon S3,o AWS Glue precisa de permissão para acessar o recurso em seu nome. Você concede essas permissões usando o AWS Identity and Access Management (IAM).

> **Note**
>
> Você pode ignorar esta etapa se usar a política gerenciada pela AWS **`AWSGlueServiceRole`**.

Nesta etapa, você cria uma política semelhante a `AWSGlueServiceRole`. Você pode encontrar a versão mais atual da `AWSGlueServiceRole` no console do IAM.

Para criar uma política do IAM para AWS Glue

Essa política concede permissão a algumas ações do Amazon S3 para o gerenciamento dos recursos na sua conta que são exigidos pelo AWS Glue quando ele assume uma função usando essa política. Alguns dos recursos especificados nessa política referem-se a nomes padrão que são usados pelo AWS Glue para buckets do Amazon S3, scripts de ETL do Amazon S3, CloudWatch Logs e recursos do Amazon EC2. Por questões de simplicidade, o AWS Glue grava alguns objetos do Amazon S3 em buckets da sua conta com o prefixo `aws-glue-*` por padrão.

1. Faça login no AWS Management Console e abra o console do IAM em https://console.aws.amazon.com/iam/.
2. No painel de navegação à esquerda, escolha Políticas.

3. Escolha Criar política.
4. Na tela Create Policy, navegue até uma guia para editar o JSON. Crie um documento de política com as seguintes instruções JSON e escolha Review policy.

> **Note**
>
> Adicione quaisquer permissões necessárias para os recursos do Amazon S3. Convém definir o escopo da seção de recursos da sua política de acesso somente para os recursos necessários.

```
{
    "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/*"
            ]
        }
    ]
}
```

A tabela a seguir descreve as permissões concedidas por esta política.

Ação	Recurso	Descrição
`"glue:*"`	`"*"`	Concede permissão para executar todas as operações de API do AWS Glue.
`"s3:GetBucketLocation", "s3:ListBucket", "s3:ListAllMyBuckets", "s3:GetBucketAcl",`	`"*"`	Permite listar os buckets do Amazon S3 a partir de crawlers, trabalhos, endpoints de desenvolvimento e servidores de cadernos.

Ação	Recurso	Descrição
`"ec2:DescribeVpcEndpoints", "ec2:DescribeRouteTables", "ec2:CreateNetworkInterface", "ec2:DeleteNetworkInterface", "ec2:DescribeNetworkInterfaces", "ec2:DescribeSecurityGroups", "ec2:DescribeSubnets", "ec2:DescribeVpcAttribute",`	`"*"`	Permite a configuração de itens de rede do Amazon EC2, como nuvens privadas virtuais (VPCs), ao executar trabalhos, crawlers e endpoints de desenvolvimento.
`"iam:ListRolePolicies", "iam:GetRole", "iam:GetRolePolicy"`	`"*"`	Permite listar as funções do IAM a partir de crawlers, trabalhos, endpoints de desenvolvimento e servidores de cadernos.
`"cloudwatch:PutMetricData"`	`"*"`	Permite gravar métricas do CloudWatch para trabalhos.
`"s3:CreateBucket", "s3:PutBucketPublicAccessBlock"`	`"arn:aws:s3:::aws-glue-*"`	Permite criar buckets do Amazon S3 na sua conta a partir de trabalhos e servidores de cadernos. Convenção de nomenclatura: usa pastas do Amazon S3 chamadas aws-glue-. Permite que o AWS Glue crie buckets que bloqueiam o acesso público.

Ação	Recurso	Descrição
`"s3:GetObject", "s3:PutObject", "s3:DeleteObject"`	`"arn:aws:s3:::aws-glue-*/*", "arn:aws:s3:::*/*aws-glue-*/*"`	Possibilita obter, inserir e excluir objetos do Amazon S3 contidos na sua conta ao armazenar objetos, como scripts de ETL e locais de servidores de cadernos. Convenção de nomenclatura: concede permissão a buckets ou pastas do Amazon S3 cujos nomes contêm o prefixo aws-glue-.
`"s3:GetObject"`	`"arn:aws:s3:::crawler-public*", "arn:aws:s3:::aws-glue-*"`	Permite obter objetos do Amazon S3 usados por exemplos e tutoriais dos crawlers e trabalhos. Convenção de nomenclatura: os nomes de buckets do Amazon S3 começam com crawler-public e aws-glue-.
`"logs:CreateLogGroup", "logs:CreateLogStream", "logs:PutLogEvents"`	`"arn:aws:logs:*:*:log-group:/aws-glue/*"`	Permite gravar logs no CloudWatch Logs. Convenção de nomenclatura: o AWS Glue grava logs em grupos cujos nomes começam com aws-glue.

Ação	Recurso	Descrição
`"ec2:CreateTags", "ec2:DeleteTags"`	`"arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:instance/*"`	Permite marcar de recursos do Amazon EC2 criados para endpoints de desenvolvimento. Convenção de nomenclatura: o AWS Glue marca interfaces de rede, grupos de segurança e instâncias do Amazon EC2 com aws-glue-service-resource.

5. Na tela Review Policy (Revisar política), insira o Policy Name (Nome da política), por exemplo, GlueServiceRolePolicy. Digite uma descrição opcional e, quando estiver satisfeito com a política, escolha Create policy (Criar política).

Etapa 2: criar um perfil do IAM para o AWS Glue

Você precisa conceder à sua função do IAM as permissões que o AWS Glue pode assumir ao chamar outros serviços em seu nome. Isso inclui acesso do Amazon S3 a quaisquer fontes, destinos, scripts e diretórios temporários utilizados com o AWS Glue. Crawlers, trabalhos e endpoints de desenvolvimento precisam dessa permissão.

Você concede essas permissões usando o AWS Identity and Access Management (IAM). Adicione uma política à função do IAM que você transmitir ao AWS Glue.

Para criar um perfil do IAM para o AWS Glue

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação à esquerda, selecione Perfis.
3. Selecione Criar perfil.
4. Escolha Serviço da AWS como o tipo de entidade confiável. Em seguida, para o serviço ou caso de uso, encontre e escolha AWS Glue. Escolha Próximo.
5. Na página Adicionar permissões, escolha as políticas que contêm as permissões necessárias. Por exemplo, a política gerenciada pela AWS `AWSGlueServiceRole` para permissões gerais

do AWS Glue e a política gerenciada pela AWS AmazonS3FullAccess para acesso a recursos do Amazon S3. Escolha Próximo.

> **Note**
>
> Verifique se uma das políticas nessa função concede permissões aos seus destinos e fontes do Amazon S3. Convém fornecer sua própria política de acesso a recursos específicos do Amazon S3. As fontes de dados exigem permissões `s3:ListBucket` e `s3:GetObject`. Os destinos de dados exigem permissões `s3:ListBucket`, `s3:PutObject` e `s3:DeleteObject`. Para obter mais informações sobre como criar uma política do Amazon S3 para os seus recursos, consulte Especificar recursos em uma política. Para obter um exemplo de política do Amazon S3, consulte Gravar políticas do IAM: como conceder acesso a um bucket do Amazon S3.
> Se você pretende acessar as fontes e os destinos do Amazon S3 que foram criptografados com SSE-KMS, anexe uma política que permita que os crawlers, os trabalhos e os endpoints de desenvolvimento do AWS Glue descriptografem os dados. Para obter mais informações, consulte Proteção de dados usando criptografia do lado do servidor com chaves gerenciadas pelo AWS KMS (SSE-KMS).
> Veja um exemplo a seguir.
>
> ```
> {
>    "Version":"2012-10-17",
>    "Statement":[
>       {
>          "Effect":"Allow",
>          "Action":[
>             "kms:Decrypt"
>          ],
>          "Resource":[
>             "arn:aws:kms:*:account-id-without-hyphens:key/key-id"
>          ]
>       }
>    ]
> }
> ```

6. Dê um nome à sua função e adicione uma descrição (opcional). Em seguida, revise a política de confiança e as permissões. Para Role name (Nome da função), digite um nome para sua função, por exemplo, `AWSGlueServiceRoleDefault`. Crie a função com um nome que tenha a string `AWSGlueServiceRole` como prefixo para permitir que a função seja transmitida dos usuários

do console para o serviço. As políticas fornecidas pelo AWS Glue esperam que as funções de serviço do IAM comecem com `AWSGlueServiceRole`. Caso contrário, você precisará adicionar uma política para conceder aos seus usuários a permissão `iam:PassRole` para que as funções do IAM correspondam às suas conversões de nomenclatura. Selecione Criar função.

> **Note**
>
> Quando você cria um caderno com uma função, essa função é transmitida para sessões interativas, de modo que a mesma função possa ser usada em ambos os lugares. Por isso, a permissão `iam:PassRole` precisa fazer parte da política da função.
> Crie uma nova política para seu perfil usando o exemplo a seguir. Substitua o número da conta e pelo seu próprio e pelo nome do perfil.
>
> ```
> {
>     "Version": "2012-10-17",
>     "Statement": [
>         {
>             "Effect": "Allow",
>             "Action": "iam:PassRole",
>             "Resource": "arn:aws:iam::090000000210:role/<role_name>"
>         }
>     ]
> }
> ```

7. Adicione tags à sua regra (opcional). As tags são pares chave-valor que podem ser adicionados a recursos da AWS para ajudar a identificar, organizar ou pesquisar recursos. Depois, escolha Create role (Criar função).

Etapa 3: anexar uma política aos usuários ou grupos que acessam o AWS Glue

O administrador deve atribuir permissões a todos os usuários, grupos ou perfis que usem o console do AWS Glue ou a AWS Command Line Interface (AWS CLI). Você fornece essas permissões usando o AWS Identity and Access Management (IAM), por meio de políticas. Esta etapa descreve a atribuição de permissões a usuários ou grupos.

Quando você concluir esta etapa, o usuário ou o grupo terá as seguintes políticas anexadas:

- A política gerenciada pela AWS `AWSGlueConsoleFullAccess` ou a política personalizada GlueConsoleAccessPolicy
- **`AWSGlueConsoleSageMakerNotebookFullAccess`**
- **`CloudWatchLogsReadOnlyAccess`**
- **`AWSCloudFormationReadOnlyAccess`**
- **`AmazonAthenaFullAccess`**

Para anexar uma política em linha e incorporá-la em um usuário ou grupo

Você pode anexar uma política gerenciada pela AWS ou uma política em linha a um usuário ou grupo para acessar o console do AWS Glue. Alguns dos recursos especificados nessa política referem-se a nomes padrão que são usados pelo AWS Glue para buckets do Amazon S3, scripts de ETL do Amazon S3, CloudWatch Logs, AWS CloudFormation e recursos do Amazon EC2. Por questões de simplicidade, o AWS Glue grava alguns objetos do Amazon S3 em buckets da sua conta com o prefixo `aws-glue-*` por padrão.

> **Note**
>
> Você pode ignorar esta etapa se usar a política gerenciada pela AWS **`AWSGlueConsoleFullAccess`**.

> **Important**
>
> O AWS Glue precisa de permissão para assumir uma função usada para executar um trabalho em seu nome. Para fazer isso, você adiciona as permissões de **`iam:PassRole`** aos usuários ou aos grupos do AWS Glue. Essa política concede permissão às funções que começam com `AWSGlueServiceRole` para funções de serviço do AWS Glue e com `AWSGlueServiceNotebookRole` para funções necessárias ao criar um servidor de notebook. Você também pode criar sua própria política para permissões `iam:PassRole` seguindo sua convenção de nomenclatura.
>
> De acordo com as práticas recomendadas de segurança, recomenda-se restringir o acesso enrijecendo políticas para restringir ainda mais o acesso ao bucket do Amazon S3 e grupos de logs do Amazon CloudWatch. Para obter um exemplo de política do Amazon S3, consulte Gravar políticas do IAM: como conceder acesso a um bucket do Amazon S3.

Nesta etapa, você cria uma política semelhante a `AWSGlueConsoleFullAccess`. Você pode encontrar a versão mais atual da `AWSGlueConsoleFullAccess` no console do IAM.

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação, selecione Grupos ou Usuários.
3. Na lista, escolha o nome do usuário ou do grupo ao qual deseja incorporar uma política.
4. Selecione a guia Permissions (Permissões) e expanda a seção Permissions policies (Políticas de permissões).
5. Escolha o link Add Inline policy.
6. Na tela Create Policy, navegue até uma guia para editar o JSON. Crie um documento de política com as seguintes instruções JSON e escolha Review policy.

```
{
    "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"
                    ]
                }
            }
        }
    ]
}
```

A tabela a seguir descreve as permissões concedidas por esta política.

Ação	Recurso	Descrição
`"glue:*"`	`"*"`	Concede permissão para executar todas as operações de API do AWS Glue. Se você criou sua política anteriormente sem a ação `"glue:*"`, é necessário adicionar as seguintes permissões individuais à sua política: • "glue:ListCrawlers" • "glue:BatchGetCrawlers" • "glue:ListTriggers" • "glue:BatchGetTriggers" • "glue:ListDevEndpoints" • "glue:BatchGetDevEndpoints" • "glue:ListJobs" • "glue:BatchGetJobs"
`"redshift:DescribeClusters", "redshift:DescribeClusterSubnetGroups"`	`"*"`	Permite criar conexões com o Amazon RedShift.

Ação	Recurso	Descrição
`"iam:ListRoles", "iam:ListRolePolicies", "iam:GetRole", "iam:GetRolePolicy", "iam:ListAttachedRolePolicies"`	`"*"`	Permite listar funções do IAM ao trabalhar com crawlers, trabalhos, endpoints de desenvolvimento e servidores de cadernos.
`"ec2:DescribeSecurityGroups", "ec2:DescribeSubnets", "ec2:DescribeVpcs", "ec2:DescribeVpcEndpoints", "ec2:DescribeRouteTables", "ec2:DescribeVpcAttribute", "ec2:DescribeKeyPairs", "ec2:DescribeInstances"`	`"*"`	Permite a configuração dos itens de rede do Amazon EC2 (como VPCs) ao executar trabalhos, crawlers e endpoints de desenvolvimento.
`"rds:DescribeDBInstances"`	`"*"`	Permite criar conexões com o Amazon RDS.
`"s3:ListAllMyBuckets", "s3:ListBucket", "s3:GetBucketAcl", "s3:GetBucketLocation"`	`"*"`	Permite listar buckets do Amazon S3 ao trabalhar com crawlers, trabalhos, endpoints de desenvolvimento e servidores de cadernos.
`"dynamodb:ListTables"`	`"*"`	Permite listar tabelas do DynamoDB.
`"kms:ListAliases", "kms:DescribeKey"`	`"*"`	Permite trabalhar com chaves KMS.

Ação	Recurso	Descrição
`"cloudwatch:GetMetricData", "cloudwatch:ListDashboards"`	`"*"`	Permite trabalhar com métricas do CloudWatch.
`"s3:GetObject", "s3:PutObject"`	`"arn:aws:s3::: aws-glue-*/*", "arn:aws:s3::: */*aws-glue-*/*", "arn:aws:s3::: aws-glue-*"`	Possibilita obter e inserir objetos do Amazon S3 contidos na sua conta ao armazenar objetos, como scripts de ETL e locais de servidores de cadernos. Convenção de nomenclatura: concede permissão a buckets ou pastas do Amazon S3 cujos nomes contêm o prefixo aws-glue-.
`"tag:GetResources"`	`"*"`	Permite a recuperação de tags da AWS.

Ação	Recurso	Descrição
`"s3:CreateBucket", "s3:PutBucketPublicAccessBlock"`	`"arn:aws:s3::: aws-glue-*"`	Possibilita a criação de um bucket do Amazon S3 na sua conta ao armazenar objetos, como scripts de ETL e locais de servidores de cadernos. Convenção de nomenclatura: concede permissão a buckets do Amazon S3 cujos nomes contêm o prefixo aws-glue-. Permite que o AWS Glue crie buckets que bloqueiam o acesso público.
`"logs:GetLogEvents"`	`"arn:aws:logs:*:*: /aws-glue/*"`	Permite recuperar CloudWatch Logs. Convenção de nomenclatura: o AWS Glue grava logs em grupos cujos nomes começam com aws-glue.

Ação	Recurso	Descrição
`"cloudformation:CreateStack", "cloudformation:DeleteStack"`	`"arn:aws:cloudformation:*:*:stack/aws-glue*/*"`	Permite o gerenciamento de pilhas do AWS CloudFormation ao trabalhar com servidores de notebook. Convenção de nomenclatura: o AWS Glue cria pilhas cujos nomes começam com 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/*"`	Permite a execução de endpoints de desenvolvimento e de servidores de notebook.
`"iam:PassRole"`	`"arn:aws:iam::*:role/ AWSGlueServiceRole*"`	Permite que o AWS Glue assuma permissões `PassRole` de regras que começam com `AWSGlueServiceRole` .

Ação	Recurso	Descrição
`"iam:PassRole"`	`"arn:aws:iam::*:role/ AWSGlueServiceNotebookRole*"`	Permite que o Amazon EC2 assuma permissões `PassRole` de regras que começam com `AWSGlueServiceNotebookRole` .
`"iam:PassRole"`	`"arn:aws:iam::*:role/service-role/AWSGlueServiceRole*"`	Permite que o AWS Glue assuma permissões `PassRole` de regras que começam com `service-role/AWSGlueServiceRole` .

7. Na página Review policy (Revisar política), insira um nome para a política, por exemplo, GlueConsoleAccessPolicy. Quando estiver satisfeito com a política, escolha Create policy (Criar política). Certifique-se de que nenhum erro seja exibido na caixa vermelha na parte superior da tela. Corrija os que foram relatados.

> **Note**
>
> Se a opção Use autoformatting estiver selecionada, a política será reformatada sempre que você abrir uma política ou escolher Validate Policy.

Para anexar a política gerenciada AWSGlueConsoleFullAccess

Você pode anexar a política `AWSGlueConsoleFullAccess` para fornecer permissões exigidas pelo usuário do console do AWS Glue.

> **Note**
>
> Você pode ignorar essa etapa se já criou sua própria política de acesso ao console do AWS Glue.

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação, selecione Políticas.
3. Na lista de políticas, marque a caixa de seleção ao lado da política AWSGlueConsoleFullAccess. Você pode usar o menu Filtro e a caixa de pesquisa para filtrar a lista de políticas.
4. Selecione Ações da política e escolha Anexar.
5. Escolha o usuário ao qual a política será anexada. Você pode usar o menu Filter (Filtro) e a caixa de pesquisa para filtrar a lista de entidades principais. Depois de escolher o usuário ao qual a política será anexada, selecione Attach policy.

Anexe a política gerenciada **`AWSGlueConsoleSageMakerNotebookFullAccess`**

Você pode anexar a política `AWSGlueConsoleSageMakerNotebookFullAccess` a um usuário para gerenciar cadernos do SageMaker AI criados no console do AWS Glue. Além de outras permissões necessárias no console do AWS Glue, essa política concede acesso aos recursos necessários para gerenciar cadernos do SageMaker AI.

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação, selecione Políticas.
3. Na lista de políticas, selecione a caixa de seleção ao lado de AWSGlueConsoleSageMakerNotebookFullAccess. Você pode usar o menu Filtro e a caixa de pesquisa para filtrar a lista de políticas.
4. Selecione Ações da política e escolha Anexar.
5. Escolha o usuário ao qual a política será anexada. Você pode usar o menu Filter (Filtro) e a caixa de pesquisa para filtrar a lista de entidades principais. Depois de escolher o usuário ao qual a política será anexada, selecione Attach policy.

Para anexar a política gerenciada CloudWatchLogsReadOnlyAccess

Você pode anexar a política CloudWatchLogsReadOnlyAccess a um usuário para visualizar os logs criados pelo AWS Glue no console do CloudWatch Logs.

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.

2. No painel de navegação, selecione Políticas.
3. Na lista de políticas, selecione a caixa de seleção ao lado de CloudWatchLogsReadOnlyAccess. Você pode usar o menu Filtro e a caixa de pesquisa para filtrar a lista de políticas.
4. Selecione Ações da política e escolha Anexar.
5. Escolha o usuário ao qual a política será anexada. Você pode usar o menu Filter (Filtro) e a caixa de pesquisa para filtrar a lista de entidades principais. Depois de escolher o usuário ao qual a política será anexada, selecione Attach policy.

Para anexar a política gerenciada AWSCloudFormationReadOnlyAccess

Você pode anexar a política AWSCloudFormationReadOnlyAccess a um usuário para visualizar pilhas do AWS CloudFormation usadas pelo AWS Glue no console do AWS CloudFormation.

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação, selecione Políticas.
3. Na lista de políticas, marque a caixa de seleção ao lado de AWSCloudFormationReadOnlyAccess. Você pode usar o menu Filtro e a caixa de pesquisa para filtrar a lista de políticas.
4. Selecione Ações da política e escolha Anexar.
5. Escolha o usuário ao qual a política será anexada. Você pode usar o menu Filter (Filtro) e a caixa de pesquisa para filtrar a lista de entidades principais. Depois de escolher o usuário ao qual a política será anexada, selecione Attach policy.

Para anexar a política gerenciada AmazonAthenaFullAccess

Você pode anexar a política AmazonAthenaFullAccess a um usuário para visualizar dados do Amazon S3 no console do Athena.

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação, selecione Políticas.
3. Na lista de políticas, marque a caixa de seleção ao lado da política AmazonAthenaFullAccess. Você pode usar o menu Filtro e a caixa de pesquisa para filtrar a lista de políticas.
4. Selecione Ações da política e escolha Anexar.

5. Escolha o usuário ao qual a política será anexada. Você pode usar o menu Filter (Filtro) e a caixa de pesquisa para filtrar a lista de entidades principais. Depois de escolher o usuário ao qual a política será anexada, selecione Attach policy.

Etapa 4: criar uma política do IAM para servidores de cadernos

Se você planeja usar notebooks com endpoints de desenvolvimento, precisará especificar permissões ao criar o servidor de notebook. Você concede essas permissões usando o AWS Identity and Access Management (IAM).

Essa política concede permissão a algumas ações do Amazon S3 para o gerenciamento dos recursos na sua conta que são exigidos pelo AWS Glue quando ele assume uma função usando essa política. Alguns dos recursos especificados nessa política referem-se a nomes padrão que são usados pelo AWS Glue para buckets do Amazon S3, scripts de ETL do Amazon S3 e recursos do Amazon EC2. Por questões de simplicidade, o AWS Glue grava por padrão alguns objetos do Amazon S3 em buckets da sua conta com o prefixo `aws-glue-*`.

> **Note**
>
> Você pode ignorar esta etapa se usar a política gerenciada pela AWS **`AWSGlueServiceNotebookRole`**.

Nesta etapa, você cria uma política semelhante a `AWSGlueServiceNotebookRole`. Você pode encontrar a versão mais atual da `AWSGlueServiceNotebookRole` no console do IAM.

Para criar uma política do IAM para cadernos

1. Faça login no AWS Management Console e abra o console do IAM em https://console.aws.amazon.com/iam/.
2. No painel de navegação à esquerda, escolha Políticas.
3. Escolha Criar política.
4. Na tela Create Policy, navegue até uma guia para editar o JSON. Crie um documento de política com as seguintes instruções JSON e escolha Review policy.

```
{
   "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/*"
         ]
      }
   ]
}
```

A tabela a seguir descreve as permissões concedidas por esta política.

Ação	Recurso	Descrição
`"glue:*"`	`"*"`	Concede permissão para executar todas as operações de API do AWS Glue.
`"s3:GetBucketLocation", "s3:ListBucket", "s3:ListAllMyBuckets", "s3:GetBucketAcl"`	`"*"`	Permite listar buckets do Amazon S3 a partir de servidores de cadernos.
`"s3:GetObject"`	`"arn:aws:s3:::crawler-public*", "arn:aws:s3:::aws-glue-*"`	Permite obter objetos do Amazon S3 usados por exemplos e tutoriais dos cadernos. Convenção de nomenclatura: os nomes de buckets do Amazon S3 começam com crawler-public e aws-glue-.

Ação	Recurso	Descrição
`"s3:PutObject", "s3:DeleteObject"`	`"arn:aws:s3:::aws-glue*"`	Permite incluir e excluir objetos do Amazon S3 na sua conta a partir de cadernos. Convenção de nomenclatura: usa pastas do Amazon S3 chamadas aws-glue.
`"ec2:CreateTags", "ec2:DeleteTags"`	`"arn:aws:ec2:*:*:network-interface/*", "arn:aws:ec2:*:*:security-group/*", "arn:aws:ec2:*:*:instance/*"`	Permite marcar recursos do Amazon EC2 criados para servidores de cadernos. Convenção de nomenclatura: o AWS Glue marca instâncias do Amazon EC2 com aws-glue-service-resource.

5. Na tela Review Policy (Revisar política), digite o Policy Name (Nome da política), por exemplo, GlueServiceNotebookPolicyDefault. Digite uma descrição opcional e, quando estiver satisfeito com a política, escolha Create policy (Criar política).

Etapa 5: criar um perfil do IAM para servidores de cadernos

Se você planeja usar cadernos com endpoints de desenvolvimento, precisará conceder as permissões à função do IAM. Você fornece essas permissões usando o AWS Identity and Access Management IAM, por meio de uma função do IAM.

> **Note**
>
> Se você criar uma função do IAM usando o console do IAM o console criará automaticamente um perfil de instância e dará a ele o mesmo nome da função correspondente.

Para criar uma função do IAM para cadernos

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação à esquerda, selecione Perfis.
3. Selecione Criar perfil.
4. Em tipo de perfil, escolha Serviço da AWS, localize e escolha EC2, depois escolha o caso de uso EC2 e, em seguida, escolha Próximo: permissões.
5. Na página Attach permissions policy (Anexar política de permissões), escolha as políticas que contenham as permissões necessárias, por exemplo, AWSGlueServiceNotebookRole para permissões gerais do AWS Glue e a política gerenciada pela AWS AmazonS3FullAccess para acesso aos recursos do Amazon S3. Então, escolha Próximo: Análise.

> **Note**
>
> Verifique se uma das políticas nessa função concede permissões aos seus destinos e fontes do Amazon S3. Confirme também se a sua política concede acesso total ao local onde você armazena o notebook ao criar um servidor de notebook. Convém fornecer sua própria política de acesso a recursos específicos do Amazon S3. Para obter mais informações sobre como criar uma política do Amazon S3 para os seus recursos, consulte Especificar recursos em uma política.
> Se você pretende acessar as fontes e os destinos do Amazon S3 que foram criptografados com SSE-KMS, anexe uma política para permitir que os cadernos descriptografem os dados. Para obter mais informações, consulte Proteção de dados usando criptografia do lado do servidor com chaves gerenciadas pelo AWS KMS (SSE-KMS).
> Veja um exemplo a seguir.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Effect":"Allow",
         "Action":[
            "kms:Decrypt"
         ],
         "Resource":[
            "arn:aws:kms:*:account-id-without-hyphens:key/key-id"
```

```
            ]
        }
    ]
}
```

6. Em Role name (Nome da função), digite um nome para sua função. Crie a função com um nome que tenha a string `AWSGlueServiceNotebookRole` como prefixo para permitir que a função seja transmitida dos usuários do console para o serviço de caderno. As políticas fornecidas pelo AWS Glue esperam que as funções de serviço do IAM comecem com `AWSGlueServiceNotebookRole`. Caso contrário, você precisará adicionar uma política para conceder aos seus usuários a permissão `iam:PassRole`, para que as funções do IAM correspondam às suas convenções de nomenclatura. Por exemplo, digite `AWSGlueServiceNotebookRoleDefault`. Então, escolha Criar perfil.

Etapa 6: criar uma política do IAM para cadernos do SageMaker AI

Ao planejar usar cadernos do SageMaker AI com endpoints de desenvolvimento, você deve especificar permissões ao criar o caderno. Você concede essas permissões usando o AWS Identity and Access Management (IAM).

Para criar uma política do IAM para cadernos do SageMaker AI

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação à esquerda, escolha Políticas.
3. Escolha Create Policy.
4. Na página Create Policy (Criar política), navegue até uma guia para editar o JSON. Crie um documento de política com as seguintes instruções JSON. Edite *`bucket-name`*, *`region-code`* e *`account-id`* para o seu ambiente.

```
{
    "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/*"
            ]
        }
    ]
}
```

Em seguida, escolha Revisar política.

A tabela a seguir descreve as permissões concedidas por esta política.

Ação	Recurso	Descrição
"s3:ListBucket*"	"arn:aws:s3::: *bucket-name* "	Concede permissão para listar os buckets do Amazon S3.
"s3:GetObject"	"arn:aws:s3::: *bucket-name* *"	Concede permissão para obter objetos do Amazon S3 usados por cadernos do SageMaker AI.
"logs:CreateLogStream", "logs:DescribeLogStreams", "logs:PutLogEvents", "logs:CreateLogGroup"	"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-*"	Concede permissão para gravar logs no Amazon CloudWatch Logs a partir de cadernos. Convenção de nomenclatura: grava grupos de logs cujos nomes começam com aws-glue.
"glue:UpdateDevEndpoint", "glue:GetDevEndpoint", "glue:GetDevEndpoints"	"arn:aws:glue: *region-code* :*account-id* :devEndpoint/*"	Concede permissão para usar um endpoint de desenvolvimento em cadernos do SageMaker AI.

Ação	Recurso	Descrição
`"sagemaker:ListTags"`	`"arn:aws:sagemaker:region-code:account-id:notebook-instance/*"`	Concede permissão para retornar as tags para um recurso do SageMaker AI. A tag `aws-glue-dev-endpoint` é obrigatória no caderno do SageMaker AI para conectá-lo a um endpoint de desenvolvimento.

5. Na tela Review Policy (Revisar política), insira o Policy Name (Nome da política), por exemplo, `AWSGlueSageMakerNotebook`. Digite uma descrição opcional e, quando estiver satisfeito com a política, escolha Create policy (Criar política).

Etapa 7: criar um perfil do IAM para cadernos do SageMaker AI

Se você planeja usar cadernos do SageMaker AI com endpoints de desenvolvimento, precisará conceder as permissões ao perfil do IAM. Você fornece essas permissões usando o AWS Identity and Access Management (IAM), por meio de uma função do IAM.

Para criar um perfil do IAM para cadernos do SageMaker AI

1. Faça login no AWS Management Console e abra o console do IAM, em https://console.aws.amazon.com/iam/.
2. No painel de navegação à esquerda, selecione Perfis.
3. Selecione Criar perfil.
4. Em tipo de perfil, escolha Serviço da AWS, localize e escolha SageMaker, depois escolha o caso de uso SageMaker - Execução. Então, escolha Próximo: permissões.
5. Na página Attach permissions policy (Anexar política de permissões), escolha as políticas que contêm as permissões necessárias; por exemplo, AmazonSageMakerFullAccess. Escolha Próximo: revisar.

   Se você planeja acessar fontes e destinos do Amazon S3 que não foram criptografados com SSE-KMS, anexe uma política que permita que os cadernos descriptografem os dados, conforme mostrado no exemplo a seguir. Para obter mais informações, consulte Proteção de

dados usando criptografia do lado do servidor com chaves gerenciadas pelo AWS KMS (SSE-KMS).

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Effect":"Allow",
         "Action":[
            "kms:Decrypt"
         ],
         "Resource":[
            "arn:aws:kms:*:account-id-without-hyphens:key/key-id"
         ]
      }
   ]
}
```

6. Em Role name (Nome da função), digite um nome para sua função. Para permitir que o perfil seja transmitido dos usuários do console para o SageMaker AI, use um nome com a string `AWSGlueServiceSageMakerNotebookRole` como prefixo. As políticas fornecidas pelo AWS Glue esperam que os perfis do IAM comecem com `AWSGlueServiceSageMakerNotebookRole`. Caso contrário, você precisará adicionar uma política para conceder aos seus usuários a permissão `iam:PassRole`, para que as funções do IAM correspondam às suas convenções de nomenclatura.

   Por exemplom, insira `AWSGlueServiceSageMakerNotebookRole-Default` e escolha Create role (Criar função).

7. Depois de criar o perfil, anexe a política que concede as permissões adicionais necessárias para criar cadernos do SageMaker AI pelo AWS Glue.

   Abra a função que você acabou de criar, `AWSGlueServiceSageMakerNotebookRole-Default`, e escolha Attach policies (Anexar políticas). Anexe a política que você criou, denominada `AWSGlueSageMakerNotebook`, à função.

Exemplos de política de controle de acesso do AWS Glue

Esta seção contém exemplos de políticas de controle de acesso baseadas em identidades (IAM) e de políticas de recursos do AWS Glue.

Sumário

- Exemplos das políticas baseadas em identidade do AWS Glue
  - Práticas recomendadas de política
  - As permissões em nível de recurso só se aplicam a objetos específicos do AWS Glue
  - Usar o console do AWS Glue
  - Permitir que os usuários visualizem suas próprias permissões
  - Conceder permissões somente de leitura para uma tabela
  - Filtrar tabelas pela permissão GetTables
  - Conceder total acesso a uma tabela e a todas as partições
  - Controlar acesso por prefixo de nome e negação explícita
  - Conceder acesso usando tags
  - Negar acesso usando tags
  - Usar tags com as operações de API de lista e lote
  - Controlar as configurações usando chaves de condição ou chaves de contexto
    - Controlar políticas que controlam configurações usando chaves de condição
    - Controlar políticas que controlam configurações usando chaves de contexto
  - Negação da capacidade de criar sessões de pré-visualização de dados para uma identidade
- Exemplos de política baseada em recursos para o AWS Glue
  - Considerações sobre o uso de políticas baseadas em recurso com o AWS Glue
  - Usar uma política de recurso para controlar o acesso na mesma conta

Exemplos das políticas baseadas em identidade do AWS Glue

Por padrão, os usuários e os perfis não têm permissão para criar ou modificar os recursos do AWS Glue. Eles também não podem executar tarefas usando o AWS Management Console, a AWS Command Line Interface (AWS CLI) ou a API da AWS. Para conceder aos usuários permissões para executar ações nos recursos que eles precisam, um administrador do IAM pode criar políticas do IAM. O administrador pode então adicionar as políticas do IAM aos perfis e os usuários podem assumir os perfis.

Para aprender a criar uma política baseada em identidade do IAM ao usar esses documentos de política em JSON de exemplo, consulte Criar políticas do IAM (console) no Guia do usuário do IAM.

Para obter detalhes sobre ações e tipos de recurso definidos pelo AWS Glue, incluindo o formato dos ARNs para cada tipo de recurso, consulte Ações, recursos e chaves de condição do AWS Glue na Referência de autorização do serviço.

> **Note**
>
> Todos os exemplos fornecidos nesta seção usam a região `us-west-2`. Você pode substituí-la pela região da AWS que quiser usar.

Tópicos

- Práticas recomendadas de política
- As permissões em nível de recurso só se aplicam a objetos específicos do AWS Glue
- Usar o console do AWS Glue
- Permitir que os usuários visualizem suas próprias permissões
- Conceder permissões somente de leitura para uma tabela
- Filtrar tabelas pela permissão GetTables
- Conceder total acesso a uma tabela e a todas as partições
- Controlar acesso por prefixo de nome e negação explícita
- Conceder acesso usando tags
- Negar acesso usando tags
- Usar tags com as operações de API de lista e lote
- Controlar as configurações usando chaves de condição ou chaves de contexto
- Negação da capacidade de criar sessões de pré-visualização de dados para uma identidade

Práticas recomendadas de política

As políticas baseadas em identidade determinam se alguém pode criar, acessar ou excluir recursos do AWS Glue em sua conta. Essas ações podem incorrer em custos para sua Conta da AWS. Ao criar ou editar políticas baseadas em identidade, siga estas diretrizes e recomendações:

- Comece com as políticas gerenciadas pela AWS e avance para as permissões de privilégio mínimo: para começar a conceder permissões a seus usuários e workloads, use as políticas gerenciadas pela AWS, que concedem permissões para muitos casos de uso comuns. Elas estão disponíveis em seus Conta da AWS. Recomendamos que você reduza ainda mais as permissões

definindo políticas gerenciadas pelo cliente da AWS que são específicas para seus casos de uso. Para obter mais informações, consulte Políticas gerenciadas pela AWS ou Políticas gerenciadas pela AWS para funções de trabalho no Guia do usuário do IAM.

- Aplique permissões de privilégio mínimo: ao definir permissões com as políticas do IAM, conceda apenas as permissões necessárias para executar uma tarefa. Você faz isso definindo as ações que podem ser executadas em recursos específicos sob condições específicas, também conhecidas como permissões de privilégio mínimo. Para obter mais informações sobre como usar o IAM para aplicar permissões, consulte Políticas e permissões no IAM no Guia do usuário do IAM.
- Use condições nas políticas do IAM para restringir ainda mais o acesso: você pode adicionar uma condição às políticas para limitar o acesso a ações e recursos. Por exemplo, você pode escrever uma condição de política para especificar que todas as solicitações devem ser enviadas usando SSL. Também pode usar condições para conceder acesso a ações de serviço, se elas forem usadas por meio de um AWS service (Serviço da AWS) específico, como o AWS CloudFormation. Para obter mais informações, consulte Elementos da política JSON do IAM: condição no Guia do usuário do IAM.
- Use o IAM Access Analyzer para validar suas políticas do IAM a fim de garantir permissões seguras e funcionais: o IAM Access Analyzer valida as políticas novas e existentes para que elas sigam a linguagem de política do IAM (JSON) e as práticas recomendadas do IAM. O IAM Access Analyzer oferece mais de cem verificações de política e recomendações práticas para ajudar a criar políticas seguras e funcionais. Para obter mais informações, consulte Validação de políticas do IAM Access Analyzer no Guia do Usuário do IAM.
- Exigir autenticação multifator (MFA): se houver um cenário que exija usuários do IAM ou um usuário raiz em sua Conta da AWS, ative a MFA para obter segurança adicional. Para exigir MFA quando as operações de API forem chamadas, adicione condições de MFA às suas políticas. Para obter mais informações, consulte Configuração de acesso à API protegido por MFA no Guia do Usuário do IAM.

Para obter mais informações sobre as práticas recomendadas do IAM, consulte Práticas recomendadas de segurança no IAM no Guia do usuário do IAM.

As permissões em nível de recurso só se aplicam a objetos específicos do AWS Glue

Só é possível definir um controle minucioso para objetos específicos no AWS Glue. Portanto, é necessário gravar a política do IAM do cliente para que as operações de API que permitem nomes de recurso da Amazon (ARNs) para a instrução `Resource` não sejam misturadas com operações de API que não permitem ARNs.

Por exemplo, a política do IAM a seguir permite operações de API para `GetClassifier` e `GetJobRun`. Ela define o `Resource` como `*`, pois o AWS Glue não permite ARNs para classificadores e execuções de tarefa. Como ARNs são permitidos para operações de API específicas, como `GetDatabase` e `GetTable`, os ARNs podem ser especificados na segunda metade da política.

```
{
    "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"
            ]
        }
    ]
}
```

Para obter uma lista de objetos do AWS Glue que permitem ARNs, consulte Especificar ARNs de recursos do AWS Glue.

Usar o console do AWS Glue

Para acessar o console do AWS Glue, você deve ter um conjunto mínimo de permissões. Essas permissões devem autorizar você a listar e visualizar detalhes sobre os recursos do AWS Glue na sua Conta da AWS. Caso crie uma política baseada em identidade mais restritiva que as permissões mínimas necessárias, o console não funcionará como pretendido para entidades (usuários ou perfis) com essa política.

Não é necessário conceder permissões mínimas do console para usuários que fazem chamadas somente à AWS CLI ou à API do AWS. Em vez disso, permita o acesso somente a ações que correspondam à operação de API que estiverem tentando executar.

Para garantir que os usuários e os perfis ainda possam usar o console do AWS Glue, anexe também a política `ConsoleAccess` ou `ReadOnly` do AWS Glue gerenciada pela AWS às entidades. Para obter informações, consulte Adicionar permissões a um usuário no Guia do usuário do IAM.

Para que um usuário trabalhe com o console do AWS Glue, ele deve ter um conjunto mínimo de permissões que liberem o trabalho com os recursos do AWS Glue na conta da AWS. Além dessas permissões do AWS Glue, o console exige permissões dos seguintes serviços:

- Permissões do Amazon CloudWatch Logs para exibir logs.
- Permissões do AWS Identity and Access Management (IAM) para listar e transmitir funções.
- Permissões do AWS CloudFormation para trabalhar com pilhas.
- Permissões do Amazon Elastic Compute Cloud (Amazon EC2) para listar VPCs, sub-redes, grupos de segurança, instâncias e outros objetos.
- Permissões do Amazon Simple Storage Service (Amazon S3) para listar buckets e objetos e para recuperar e salvar scripts.
- Permissões do Amazon Redshift necessárias para trabalhar com clusters.
- Permissões do Amazon Relational Database Service (Amazon RDS) para listar instâncias.

Para obter mais informações sobre as permissões que os usuários necessitam para visualizar e trabalhar com o console do AWS Glue, consulte Etapa 3: anexar uma política aos usuários ou grupos que acessam o AWS Glue.

Se você criar uma política do IAM que seja mais restritiva que as permissões mínimas necessárias, o console do não funcionará como pretendido para os usuários com essa política do IAM. Para garantir que esses usuários ainda possam usar o console do AWS Glue, anexe também a política gerenciada `AWSGlueConsoleFullAccess`, conforme descrito em Políticas gerenciadas pela AWS (predefinidas) para o AWS Glue.

Permitir que os usuários visualizem suas próprias permissões

Este exemplo mostra como criar uma política que permita que os usuários do IAM visualizem as políticas gerenciadas e em linha anexadas a sua identidade de usuário. Essa política inclui

permissões para concluir essa ação no console ou de forma programática usando a AWS CLI ou a API da 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": "*"
        }
    ]
}
```

Conceder permissões somente de leitura para uma tabela

A política a seguir concede permissão somente leitura a uma tabela `books` no banco de dados db1. Para obter mais informações sobre como usar nomes de recurso da Amazon (ARNs), consulte ARNs do Data Catalog.

```
{
```

```
  "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"
      ]
    }
  ]
}
```

Essa política concede permissão somente leitura a uma tabela chamada `books` no banco de dados chamado `db1`. Para conceder a permissão `Get` para uma tabela, também é necessário conceder permissão para os recursos do catálogo e do banco de dados.

A política a seguir concede as permissões mínimas necessárias para um criar a tabela `tb1` no banco de dados `db1`:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "glue:CreateTable"
      ],
      "Resource": [
        "arn:aws:glue:us-west-2:123456789012:table/db1/tbl1",
        "arn:aws:glue:us-west-2:123456789012:database/db1",
        "arn:aws:glue:us-west-2:123456789012:catalog"
      ]
    }
  ]
}
```

Filtrar tabelas pela permissão GetTables

Suponha que há três tabelas: `customers`, `stores` e `store_sales` no banco de dados `db1`. A política a seguir concede a permissão `GetTables` a `stores` e `store_sales`, mas não a `customers`. Quando você chama `GetTables` com essa política, o resultado contém somente as duas tabelas autorizadas (a tabela `customers` não é retornada).

```
{
    "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"
            ]
        }
    ]
}
```

Você pode simplificar a política anterior usando `store*` para corresponder a todos os nomes de tabelas que comecem com `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*"
```

```
            ]
        }
    ]
}
```

Da mesma forma, usando `/db1/*` para corresponder a todas as tabelas no `db1`, a política a seguir concede o acesso `GetTables` a todas as tabelas no `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/*"
            ]
        }
    ]
}
```

Se nenhum ARN de tabela for fornecido, uma chamada para `GetTables` será bem-sucedida, mas retornará uma lista vazia.

```
{
    "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"
            ]
```

```
        }
    ]
}
```

Se o ARN do banco de dados estiver ausente na política, haverá uma falha na chamada para `GetTables` com uma `AccessDeniedException`.

```
{
    "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/*"
            ]
        }
    ]
}
```

Conceder total acesso a uma tabela e a todas as partições

A política a seguir concede todas as permissões em uma tabela denominada `books` no banco de dados `db1`. Isso inclui permissões de leitura e gravação na própria tabela, em versões arquivadas da tabela e em todas as suas partições.

```
{
    "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"
                        ]
        }
    ]
}
```

A política anterior pode ser simplificada na prática.

```
{
    "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"
            ]
        }
    ]
}
```

Observe que a granularidade mínima de um controle de acesso granular é no nível de tabela. Isso significa que você não pode conceder a um usuário acesso a algumas partições em uma tabela, mas não a outras, ou a algumas colunas da tabela, mas não a outras. Um usuário tem acesso a tudo ou a nada de uma tabela.

Controlar acesso por prefixo de nome e negação explícita

Neste exemplo, suponha que os bancos de dados e tabelas em seu AWS Glue Data Catalog são organizados usando prefixos de nomes. Os bancos de dados no estágio de desenvolvimento têm o prefixo de nome `dev-`, e os em produção têm o prefixo de nome `prod-`. Você pode usar a política a seguir para conceder aos desenvolvedores acesso total a todos os bancos de dados, tabelas, UDFs, e assim por diante, que têm o prefixo `dev-`. Mas você concede acesso somente leitura a tudo com o prefixo `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-*"
            ]
        }
    ]
}
```

A segunda instrução na política anterior usa `deny` explícita. Você pode usar `deny` explícita para substituir todas as permissões `allow` que foram concedidas à entidade principal. Isso permite bloquear o acesso a recursos críticos e impedir que outra política conceda acesso a eles acidentalmente.

No exemplo anterior, embora a primeira instrução conceda acesso total aos recursos `prod-`, a segunda instrução revoga explicitamente o acesso de gravação neles, deixando apenas o acesso de leitura aos recursos `prod-`.

Conceder acesso usando tags

Por exemplo, suponha que você deseja limitar o acesso a um gatilho `t2` para um usuário específico chamado `Tom` em sua conta. Todos os outros usuários, inclusive `Sam`, têm acesso ao gatilho `t1`. Os gatilhos `t1` e `t2` têm as seguintes propriedades.

```
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 * * ? *)"
        }
    ]
}
```

O administrador do AWS Glue anexou um valor de tag `Tom` (`aws:ResourceTag/Name": "Tom"`) ao gatilho `t2`. O administrador do AWS Glue também concedeu a Tom uma política do IAM com uma instrução de condição baseada na tag. Como resultado, Tom só pode usar uma operação do AWS Glue que atue sobre recursos com o valor de tag `Tom`.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
         "Effect": "Allow",
         "Action": "glue:*",
         "Resource": "*",
         "Condition": {
             "StringEquals": {
                "aws:ResourceTag/Name": "Tom"
              }
          }
         }
    ]
}
```

Quando Tom tentar acessar o gatilho `t1`, ele receberá uma mensagem de acesso negado. Enquanto isso, ele pode recuperar o gatilho `t2` com êxito.

```
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 não pode usar a operação de API `GetTriggers` plural para listar triggers porque essa operação não é compatível com filtragem por tags.

Para conceder acesso a `GetTriggers` para Tom, o administrador do AWS Glue cria uma política que divide as permissões em duas seções. Uma seção permite que Tom acesse todos os gatilhos com a operação da API `GetTriggers`. A segunda seção permite que Tom acesse as operações de API marcadas com o valor `Tom`. Com essa política, Tom tem permissão de acesso a `GetTriggers` e `GetTrigger` para o gatilho `t2`.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": "glue:GetTriggers",
            "Resource": "*"
        },
        {
```

```
            "Effect": "Allow",
            "Action": "glue:*",
            "Resource": "*",
            "Condition": {
                "StringEquals": {
                    "aws:ResourceTag/Name": "Tom"
                }
            }
        }
    ]
}
```

Negar acesso usando tags

Outra abordagem de uma política de recurso é negar explicitamente o acesso aos recursos.

> **Important**
>
> Uma política de negação explícita não funciona para operações de API no plural, como `GetTriggers`.

No exemplo de política a seguir, todas as operações de trabalho do AWS Glue são permitidas. Porém, a segunda instrução `Effect` nega explicitamente acesso a trabalhos marcados com a chave `Team` e o valor `Special`.

Quando um administrador anexa a política a seguir a uma identidade, essa entidade pode acessar todos os trabalhos, exceto os marcados com a chave `Team` e o valor `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"
        }
      }
    }
  ]
}
```

Usar tags com as operações de API de lista e lote

Uma terceira abordagem para escrever uma política de recurso é permitir o acesso aos recursos usando uma operação da API `List` para listar os recursos para um valor de tag. Depois, use a operação da API `Batch` correspondente para permitir o acesso aos detalhes de recursos específicos. Com essa abordagem, o administrador não precisa conceder acesso às operações de API plurais `GetCrawlers`, `GetDevEndpoints`, `GetJobs` ou `GetTriggers`. Em vez disso, você pode permitir a possibilidade de listar os recursos com as seguintes operações de API:

- `ListCrawlers`
- `ListDevEndpoints`
- `ListJobs`
- `ListTriggers`

E você pode permitir a capacidade de obter detalhes sobre os recursos individuais com as seguintes operações de API:

- `BatchGetCrawlers`
- `BatchGetDevEndpoints`
- `BatchGetJobs`
- `BatchGetTriggers`

Como administrador, para usar essa abordagem, faça o seguinte:

1. Adicionar tags a seus crawlers, endpoints de desenvolvimento, trabalhos e gatilhos.
2. Negar o acesso de usuário a operações de API `Get`, como `GetCrawlers`, `GetDevEndponts`, `GetJobs` e `GetTriggers`.

3. Para permitir que os usuários descubram a quais recursos marcados eles têm acesso, conceda acesso de usuário a operações de API `List`, como `ListCrawlers`, `ListDevEndponts`, `ListJobs` e `ListTriggers`.
4. Negar o acesso de usuário a APIs de marcação do AWS Glue, como `TagResource` e `UntagResource`.
5. Conceder acesso de usuário aos detalhes de recursos com operações de API `BatchGet`, como `BatchGetCrawlers`, `BatchGetDevEndponts`, `BatchGetJobs` e `BatchGetTriggers`.

Por exemplo, ao chamar a operação `ListCrawlers`, forneça um valor de tag de acordo com o nome do usuário. O resultado será uma lista de crawlers que correspondem aos valores de tag fornecidos. Forneça a lista de nomes ao `BatchGetCrawlers` para obter detalhes sobre cada crawler com a tag dada.

Por exemplo, se Tom só deverá ser capaz de recuperar detalhes de triggers marcados com `Tom`, o administrador poderá adicionar tags aos triggers para `Tom`, negar o acesso à operação de API `GetTriggers` a todos os usuários e permitir o acesso de todos os usuários a `ListTriggers` e `BatchGetTriggers`.

Esta é a política de recurso que o administrador do AWS Glue concede a Tom. Na primeira seção da política, as operações de API do AWS Glue são negadas para `GetTriggers`. Na segunda seção da política, `ListTriggers` é permitida para todos os recursos. No entanto, na terceira seção, esses recursos marcados com `Tom` têm o acesso permitido com o acesso a `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"
                }
            }
        }
    ]
}
```

Usando os mesmos gatilhos do exemplo anterior, Tom pode acessar o gatilho `t2`, mas não o gatilho `t1`. O exemplo a seguir mostra os resultados quando Tom tenta acessar `t1` e `t2` com `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.
```

O exemplo a seguir mostra os resultados quando Tom tenta acessar ambos os gatilhos `t2` e `t3` (que não existe) na mesma chamada de `BatchGetTriggers`. Observe que, como Tom tem acesso ao gatilho `t2` e ele existe, somente `t2` é retornado. Embora Tom tenha permissão para acessar o gatilho `t3`, `t3` não existe, de modo que `t3` é retornado na resposta em uma lista 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 * * ? *)"
    }
}
```

Controlar as configurações usando chaves de condição ou chaves de contexto

Você pode usar chaves de condição ou chaves de contexto ao conceder permissões para criar e atualizar trabalhos. Estas seções discutem as chaves:

- Controlar políticas que controlam configurações usando chaves de condição
- Controlar políticas que controlam configurações usando chaves de contexto

Controlar políticas que controlam configurações usando chaves de condição

O AWS Glue fornece três chaves de condição do IAM, `glue:VpcIds`, `glue:SubnetIds` e `glue:SecurityGroupIds`. Você pode usar chaves de condição nas políticas do IAM ao conceder permissões para criar e atualizar trabalhos. Você pode usar essa configuração para garantir que os trabalhos ou sessões não sejam criados (ou atualizados) para serem executados fora de um ambiente de VPC desejado. As informações de configuração da VPC não são uma entrada direta da solicitação `CreateJob`, mas são inferidas do campo "conexões" do trabalho que aponta para uma conexão do AWS Glue.

Exemplo de uso

Crie uma conexão de tipo de rede do AWS Glue denominada "traffic-monitored-connection" com o VpcId "vpc-id1234", SubnetIds e SecurityGroupIds desejados.

Especifique a condição das chaves de condição para as ações `CreateJob` e `UpdateJob` na política do IAM.

```
{
  "Effect": "Allow",
  "Action": [
    "glue:CreateJob",
    "glue:UpdateJob"
  ],
  "Resource": [
    "*"
  ],
  "Condition": {
    "ForAnyValue:StringLike": {
      "glue:VpcIds": [
        "vpc-id1234"
      ]
    }
  }
}
```

Você pode criar uma política do IAM semelhante para proibir a criação de um trabalho do AWS Glue sem especificar informações de conexão.

Restringir sessões em VPCs

Para forçar que as sessões criadas sejam executadas em uma VPC especificada, você restringe a permissão do perfil adicionando um efeito `Deny` na ação `glue:CreateSession` com a condição de que glue:vpc-id not equal to vpc-<123>. Por exemplo:

```
"Effect": "Deny",
"Action": [
    "glue:CreateSession"
 ],
"Condition": {
    "StringNotEquals" : {"glue:VpcIds" : ["vpc-123"]}
}
```

Você também pode forçar que as sessões criadas sejam executadas em uma VPC adicionando um efeito `Deny` na ação `glue:CreateSession` com a condição de que `glue:vpc-id` seja nulo. Por exemplo:

```
{
    "Effect": "Deny",
    "Action": [
        "glue:CreateSession"
    ],
      "Condition": {
        "Null": {"glue:VpcIds": true}
    }
},
{
    "Effect": "Allow",
    "Action": [
        "glue:CreateSession"
    ],
    "Resource": ["*"]
}
```

Controlar políticas que controlam configurações usando chaves de contexto

O Glue da AWS fornece uma chave de contexto (`glue:CredentialIssuingService=glue.amazonaws.com`) para cada sessão de função que o AWS Glue disponibiliza para o endpoint do trabalho e do desenvolvedor. Isso permite que você implemente controles de segurança para as medidas tomadas pelo scripts do AWS Glue. O AWS Glue fornece outra chave de contexto (`glue:RoleAssumedBy=glue.amazonaws.com`) para cada sessão de perfil em que o AWS Glue faz uma chamada para outro serviço da AWS em nome do cliente (não por um endpoint de trabalho/desenvolvimento, mas diretamente pelo serviço AWS Glue).

Exemplo de uso

Especifique a permissão condicional na política do IAM e anexe-a ao perfil a ser usado por um trabalho do AWS Glue. Isso garante que determinadas ações sejam permitidas/negadas dependendo de a sessão de perfil ser ou não usada para um ambiente de runtime de trabalho do AWS Glue.

```
{
    "Effect": "Allow",
    "Action": "s3:GetObject",
    "Resource": "arn:aws:s3:::amzn-s3-demo-bucket/*",
    "Condition": {
        "StringEquals": {
            "glue:CredentialIssuingService": "glue.amazonaws.com"
        }
    }
}
```

Negação da capacidade de criar sessões de pré-visualização de dados para uma identidade

Essa seção contém um exemplo de política do IAM usado para negar a capacidade de criar sessões de pré-visualização de dados para uma identidade. Anexe essa política à identidade, que é separada do perfil usado pela sessão de pré-visualização de dados durante sua execução.

```
{
    "Sid": "DatapreviewDeny",
    "Effect": "Deny",
     "Action": [
           "glue:CreateSession"
     ],
     "Resource": [
          "arn:aws:glue:*:*:session/glue-studio-datapreview*"
      ]
 }
```

Exemplos de política baseada em recursos para o AWS Glue

Esta seção contém exemplos de políticas baseadas em recursos, incluindo políticas que concedem acesso entre contas.

Os exemplos a seguir usam a AWS Command Line Interface (AWS CLI) para interagir com as operações de API do serviço AWS Glue. Você pode executar as mesmas operações no console do AWS Glue ou usar um dos SDKs da AWS.

> **Important**
>
> Ao alterar uma política de recurso do AWS Glue, você pode acidentalmente revogar permissões para usuários do AWS Glue existentes em sua conta e provocar interrupções

inesperadas. Antes de fazer as alterações, tente estes exemplos apenas em contas de desenvolvimento ou de teste e garanta que elas não interrompam nenhum fluxo de trabalho existente.

Tópicos

- Considerações sobre o uso de políticas baseadas em recurso com o AWS Glue
- Usar uma política de recurso para controlar o acesso na mesma conta

Considerações sobre o uso de políticas baseadas em recurso com o AWS Glue

> **Note**
>
> As políticas do IAM e uma política de recursos do AWS Glue levam alguns segundos para serem propagadas. Depois de anexar uma nova política, você pode perceber que a política antiga ainda está em vigor até que a nova política tenha sido propagada pelo sistema.

Você usa um documento de política escrito em formato JSON para criar ou modificar uma política de recurso. A sintaxe da política é a mesma que a de uma política do IAM baseada em identidade (consulte Referência de política JSON do IAM), com as seguintes exceções:

- Um bloco `"Principal"` ou `"NotPrincipal"` é necessário para cada declaração da política.
- O `"Principal"` ou o `"NotPrincipal"` devem identificar as entidades principais válidos existentes. Padrões de curinga (como `arn:aws:iam::`*`account-id`*`:user/*`) não são permitidos.
- O bloco `"Resource"` da política exige que todos os ARNs de recursos correspondam à seguinte sintaxe de expressão regular (em que o primeiro `%s` é a *`região`* e o segundo `%s` é o *`account-id`*):

```
*arn:aws:glue:%s:%s:(\*|[a-zA-Z\*]+\/?.*)
```

  Por exemplo, `arn:aws:glue:us-west-2:`*`account-id`*`:*` e `arn:aws:glue:us-west-2:`*`account-id`*`:database/default` são permitidos, mas `*` não é permitido.

- Ao contrário das políticas baseadas em identidade, a política de recurso do AWS Glue deve conter apenas os nomes dos recursos da Amazon (ARN) que pertencem ao catálogo ao qual a política está anexada. Esses ARNs sempre começam com `arn:aws:glue:`.
- Uma política não pode impedir que a identidade criada por ela crie ou modifique mais a política.
- Um documento JSON de política de recurso não pode exceder 10 KB.

Usar uma política de recurso para controlar o acesso na mesma conta

Neste exemplo, um usuário administrador na conta A cria uma política de recursos que concede à usuária do IAM `Alice` acesso total ao catálogo na conta A. Alice não tem nenhuma política do IAM anexada.

Para fazer isso, o usuário administrador executa o comando da AWS CLI a seguir.

```
# 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:*"
      ]
    }
  ]
}'
```

Em vez de inserir o documento de política JSON como parte do comando da AWS CLI, você pode salvar um documento de política em um arquivo e fazer referência ao caminho do arquivo no comando da AWS CLI, com o prefixo `file://`. Este é um exemplo de como é possível fazer isso:

```
$ 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
```

Depois que essa política de recurso tiver sido propagada, Alice poderá acessar todos os recursos do AWS Glue na Conta A, conforme a seguir.

```
# 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"}
```

Em resposta à chamada `get-table` de Alice, o serviço AWS Glue retorna o seguinte:

```
{
  "Table": {
    "Name": "tbl1",
    "PartitionKeys": [],
    "StorageDescriptor": {
        ......
```

```
    },
    ......
  }
}
```

Conceder políticas gerenciadas pela AWS para o AWS Glue

Uma política gerenciada pela AWS é uma política independente criada e administrada pela AWS. As políticas gerenciadas pela AWS são criadas para fornecer permissões a vários casos de uso comuns e permitir a atribuição de permissões a usuários, grupos e perfis.

Lembre-se de que as políticas gerenciadas pela AWS podem não conceder permissões de privilégio mínimo para casos de uso específicos, por estarem disponíveis para uso por todos os clientes da AWS. Recomendamos que você reduza ainda mais as permissões definindo as políticas gerenciadas pelo cliente que são específicas para seus casos de uso.

Você não pode alterar as permissões definidas em políticas gerenciadas pela AWS. Se a AWS atualiza as permissões definidas em um política gerenciada por AWS, a atualização afeta todas as identidades de entidades principais (usuários, grupos e perfis) às quais a política estiver vinculada. É provável que a AWS atualize uma política gerenciada por AWS quando um novo AWS service (Serviço da AWS) for lançado, ou novas operações de API forem disponibilizadas para os serviços existentes.

Para mais informações, consulte Políticas gerenciadas pela AWS no Manual do usuário do IAM.

Políticas gerenciadas pela AWS (predefinidas) para o AWS Glue

A AWS aborda muitos casos de uso comuns fornecendo políticas autônomas do IAM que são criadas e administradas pela AWS. Essas políticas gerenciadas pela AWS concedem as permissões indispensáveis para casos de uso comuns para que você não precise investigar quais permissões são necessárias. Para mais informações, consulte Políticas gerenciadas pela AWS no Manual do usuário do IAM.

As seguintes políticas gerenciadas pela AWS, que você pode anexar a identidades na sua conta, são específicas do AWS Glue e são agrupadas por cenário de caso de uso:

- AWSGlueConsoleFullAccess: concede acesso total aos recursos do AWS Gluequando uma identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão

acessar todos os recursos do console. Esta política geralmente é anexada aos usuários do console do AWS Glue.

- AWSGlueServiceRole – Concede acesso a recursos que vários processos do AWS Glue exigem para fazer a execução em seu nome. Esses recursos incluem o AWS Glue, Amazon S3, IAM, CloudWatch Logs e Amazon EC2. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os processos do AWS Glue terão as permissões necessárias. Esta política geralmente é anexada a funções especificadas durante a definição de crawlers, trabalhos e endpoints de desenvolvimento.
- AwsGlueSessionUserRestrictedServiceRole: fornece acesso total a todos os recursos do AWS Glue, exceto para sessões. Permite que os usuários criem e usem somente as sessões interativas associadas ao usuário. Essa política também inclui outras permissões exigidas pelo AWS Glue para gerenciar recursos do AWS Glue em outros serviços da AWS. A política também permite adicionar tags aos recursos do AWS Glue em outros serviços da AWS.

  > **Note**
  >
  > Para obter todos os benefícios de segurança, não conceda esta política a um usuário que tenha atribuída a política `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess` ou `AWSGlueConsoleSageMakerNotebookFullAccess`.

- AwsGlueSessionUserRestrictedPolicy: só fornece acesso para criar sessões interativas do AWS Glue usando a operação de API `CreateSession` se uma chave de tag “owner” e um valor que corresponda ao ID de usuário da AWS do usuário designado forem fornecidos. Essa política de identidade está anexada ao usuário do IAM que invoca a operação de API `CreateSession`. Esta política também permite que o usuário designado interaja com os recursos de sessão interativa do AWS Glue que foram criados com uma tag “owner” e um valor que corresponde ao ID de usuário AWS. Essa política nega permissão para alterar ou remover tags de "proprietário" de um recurso de sessão do AWS Glue após a criação da sessão.

  > **Note**
  >
  > Para obter todos os benefícios de segurança, não conceda essa política a um usuário que tenha atribuída a política `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess` ou `AWSGlueConsoleSageMakerNotebookFullAccess`.

- AWSGlueSessionUserRestrictedNotebookServiceRole: fornece acesso suficiente à sessão do caderno do AWS Glue Studio para interagir com recursos específicos de sessão interativa do

AWS Glue. Esses são recursos criados com a tag “owner” e o valor que corresponde ao ID de usuário da AWS da entidade principal (usuário ou perfil do IAM) que cria o caderno. Para obter mais informações sobre essas tags, consulte o gráfico Valores de chave da entidade principal no Guia do usuário do IAM.

Essa política de perfil de serviço é anexada ao perfil especificado com um comando magic no caderno ou é passado como um perfil para a operação de API `CreateSession`. Essa política também permite que a entidade principal crie uma sessão interativa do AWS Glue na interface do caderno do AWS Glue Studio se uma chave de tag “owner” e valor corresponderem ao ID do usuário da AWS da entidade principal. Essa política nega permissão para alterar ou remover tags de "proprietário" de um recurso de sessão do AWS Glue após a criação da sessão. Essa política também inclui permissões para gravação e leitura de buckets do Amazon S3, gravação de logs do CloudWatch, criação e exclusão de tags para recursos do Amazon EC2 usados pelo AWS Glue.

> **Note**
>
> Para obter todos os benefícios de segurança, não conceda essa política a uma função que tenha atribuída a política `AWSGlueServiceRole`, `AWSGlueConsoleFullAccess` ou `AWSGlueConsoleSageMakerNotebookFullAccess`.

- AwsGlueSessionUserRestrictedNotebookPolicy: só fornece acesso para criação de um sessão interativa do AWS Glue na interface do caderno do AWS Glue Studio se houver uma chave de tag “owner” e um valor que corresponda ao ID do usuário da AWS da entidade principal (usuário ou perfil do IAM) que cria o caderno. Para obter mais informações sobre essas tags, consulte o gráfico Valores de chave da entidade principal no Guia do usuário do IAM.

  Essa política é anexada à entidade principal (usuário ou perfil do IAM) que cria sessões na interface do caderno do AWS Glue Studio. Essa política também permite acesso suficiente ao caderno do AWS Glue Studio para interação com recursos específicos de sessão interativa do AWS Glue. Esses são recursos criados com a tag “owner” e o valor que corresponde ao ID de usuário da AWS da entidade principal. Essa política nega permissão para alterar ou remover tags de "proprietário" de um recurso de sessão do AWS Glue após a criação da sessão.
- AWSGlueServiceNotebookRole: concede acesso a sessões do AWS Glue iniciadas em um caderno do AWS Glue Studio. Essa política permite listar e obter informações de sessão para todas as sessões, mas só permite que os usuários criem e usem as sessões marcadas com seus IDs de usuário da AWS. Essa política nega permissão para alterar ou remover tags “owner” de recursos de sessão do AWS Glue marcados com seus IDs da AWS.

Atribua essa política ao usuário da AWS que cria trabalhos usando a interface do notebook no AWS Glue Studio.

- AWSGlueConsoleSageMakerNotebookFullAccess: concede total acesso aos recursos do AWS Glue e do SageMaker AI quando a identidade à qual a política está anexada usa o AWS Management Console. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do console do AWS Glue que gerenciam cadernos do SageMaker AI.
- AWSGlueSchemaRegistryFullAccess: concede total acesso aos recursos do registro de esquemas do AWS Glue quando a identidade à qual a política está anexada usa o AWS Management Console ou a AWS CLI. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do console ou da AWS Glue do AWS CLI que gerenciam o registro de esquemas do AWS Glue.
- AWSGlueSchemaRegistryReadonlyAccess: concede acesso somente de leitura a recursos do registro de esquemas do AWS Glue quando uma identidade à qual a política está anexada usa o AWS Management Console ou a AWS CLI. Se você seguir a convenção de nomenclatura para os recursos especificados nesta política, os usuários poderão acessar todos os recursos do console. Essa política geralmente é anexada aos usuários do console do AWS Glue ou da AWS CLI que usam o registro de esquemas do AWS Glue.

> **Note**
>
> É possível analisar essas políticas de permissões fazendo login no console do IAM e pesquisando políticas específicas.

Você também pode criar suas próprias políticas do IAM personalizadas a fim de conceder permissões para ações e recursos do AWS Glue. Você pode anexar essas políticas personalizadas a usuários ou grupos do IAM que exijam essas permissões.

Para criar uma conexão com a configuração da VPC ao usar um perfil do IAM personalizado, é necessário que ele tenha as seguintes ações de acesso à VPC:

- secretsmanager:GetSecretValue
- secretsmanager:PutSecretValue

- secretsmanager:DescribeSecret
- ec2:CreateNetworkInterface
- ec2:DeleteNetworkInterface
- ec2:DescribeNetworkInterfaces
- ec2:DescribeSubnets

Atualizações do AWS Glue para políticas gerenciadas pela AWS

Visualize detalhes sobre atualizações em políticas gerenciadas pela AWS para o AWS Glue desde que esse serviço começou a rastrear essas alterações. Para receber alertas automáticos sobre alterações feitas nesta página, assine o feed RSS na página de histórico de documentos do AWS Glue.

Alteração	Descrição	Data
AWSGlueSessionUserRestrictedNotebookPolicy: atualização mínima em uma política existente.	Adicione permissão para a ação `glue:TagResource` na chave da tag do proprietário. Necessário para compatibilidade com tag durante a criação para sessões com a chave da tag do proprietário.	30 de agosto de 2024
AwsGlueSessionUserRestrictedNotebookServiceRole: atualização secundária a uma política existente.	Adicione permissão para a ação `glue:TagResource` na chave da tag do proprietário. Necessário para compatibilidade com tag durante a criação para sessões com a chave da tag do proprietário.	30 de agosto de 2024
AwsGlueSessionUserRestrictedPolicy: atualização secundária a uma política existente.	Adicione permissão para a ação `glue:TagResource` na chave da tag do proprietário. Necessário para compatibi	5 de agosto de 2024

Alteração	Descrição	Data
	lidade com tag durante a criação para sessões com a chave da tag do proprietário.	
AwsGlueSessionUserRestrictedServiceRole: atualização secundária a uma política existente.	Adicione permissão para a ação `glue:TagResource` na chave da tag do proprietário. Necessário para compatibilidade com tag durante a criação para sessões com a chave da tag do proprietário.	5 de agosto de 2024
AwsGlueSessionUserRestrictedPolicy: atualização secundária a uma política existente.	Adicione `glue:StartCompletion` e `glue:GetCompletion` à política. Necessário para a integração de dados do Amazon Q no AWS Glue.	30 de abril de 2024
AwsGlueSessionUserRestrictedNotebookServiceRole: atualização secundária a uma política existente.	Adicione `glue:StartCompletion` e `glue:GetCompletion` à política. Necessário para a integração de dados do Amazon Q no AWS Glue.	30 de abril de 2024
AwsGlueSessionUserRestrictedServiceRole: atualização secundária a uma política existente.	Adicione `glue:StartCompletion` e `glue:GetCompletion` à política. Necessário para a integração de dados do Amazon Q no AWS Glue.	30 de abril de 2024

Alteração	Descrição	Data
AWSGlueServiceNotebookRole: atualização menor para uma política existente.	Adicione `glue:StartCompletion` e `glue:GetCompletion` à política. Necessário para a integração de dados do Amazon Q no AWS Glue.	30 de janeiro de 2024
AWSGlueSessionUserRestrictedNotebookPolicy: atualização mínima em uma política existente.	Adicione `glue:StartCompletion` e `glue:GetCompletion` à política. Necessário para a integração de dados do Amazon Q no AWS Glue.	29 de novembro de 2023
AWSGlueServiceNotebookRole: atualização menor para uma política existente.	Adicionar `codewhisperer:GenerateRecommendations` à política. Necessário para um novo recurso em que o Glue gera AWS recomendações do CodeWhisperer.	9 de outubro de 2023
AWSGlueServiceRole: atualização menor para uma política existente.	Aumente o escopo das permissões do CloudWatch para refletir melhor o registro em log do AWS Glue.	4 de agosto de 2023
AWSGlueConsoleFullAccess: atualização menor para uma política existente.	Adicione uma lista de fórmulas de `databrew` e descreva as permissões à política. Necessário para fornecer acesso administrativo total aos novos atributos em que o AWS Glue possa acessar fórmulas.	9 de maio de 2023

Alteração	Descrição	Data
AWSGlueConsoleFullAccess: atualização menor para uma política existente.	Adicionar `cloudformation:ListStacks` à política. Preserva os recursos existentes após alterações nos requisitos de autorização do AWS CloudFormation.	28 de março de 2023
Adicionadas novas políticas gerenciadas para o recurso de sessões interativas: • AwsGlueSessionUserRestrictedServiceRole • AwsGlueSessionUserRestrictedPolicy • AwsGlueSessionUserRestrictedNotebookServiceRole • AwsGlueSessionUserRestrictedNotebookPolicy	Essas políticas visam fornecer segurança adicional para sessões interativas e cadernos no AWS Glue Studio. As políticas restringem o acesso à operação de API `CreateSession` para que somente o proprietário tenha acesso.	30 de novembro de 2021

Alteração	Descrição	Data
AWSGlueConsoleSageMakerNotebookFullAccess: atualização para uma política existente.	Removido um ARN de recurso redundante (`arn:aws:s3:::aws-glue-*/*`) para a ação que concede permissões de leitura/gravação nos buckets do Amazon S3 que o AWS Glue usa para armazenar scripts e arquivos temporários. Corrigido um problema de sintaxe alterando `"StringEquals"` para `"ForAnyValue:StringLike"`, e movidas as linhas `"Effect": "Allow"` para precederem oa linha `"Action":` em cada lugar em que elas estavam fora de ordem.	15 de julho de 2021
AWSGlueConsoleFullAccess: atualização para uma política existente.	Removido um ARN de recurso redundante (`arn:aws:s3:::aws-glue-*/*`) para a ação que concede permissões de leitura/gravação nos buckets do Amazon S3 que o AWS Glue usa para armazenar scripts e arquivos temporários.	15 de julho de 2021
O AWS Glue começo a rastrear alterações.	O AWS Glue começou a monitorar as alterações para as políticas gerenciadas pela AWS.	10 de junho de 2021

Especificação de ARNs de recursos do AWS Glue

No AWS Glue, você pode controlar o acesso a recursos usando uma política do AWS Identity and Access Management (IAM). Em uma política, você usa um Nome de recurso da Amazon (ARN) para identificar o recurso a que a política se aplica. Nem todos os recursos do AWS Glue oferecem suporte a ARNs.

Tópicos

- ARNs do Data Catalog
- ARNs de objetos fora do catálogo no AWS Glue
- Controle de acesso para operações singulares da API fora do catálogo do AWS Glue
- Controle de acesso para operações da API fora do catálogo do AWS Glue que recuperam vários itens
- Controle de acesso para operações da API BatchGet fora do catálogo do AWS Glue

ARNs do Data Catalog

Os recursos do Data Catalog têm uma estrutura hierárquica, com `catalog` como a raiz.

```
arn:aws:glue:region:account-id:catalog
```

Cada conta da AWS tem um único Data Catalog em uma região da AWS com o ID da conta de 12 dígitos como o ID do catálogo. Os recursos têm ARNs exclusivos associados a eles, como exibido na tabela a seguir.

Tipo de atributo	Formato ARN
Catálogo	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog` Por exemplo: `arn:aws:glue:us-east-1:123456789012:catalog`
Banco de dados	`arn:aws:glue:` *`region`*`:`*`account-id`* `:database/` *`database name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:database/db1`

Tipo de atributo	Formato ARN
Tabela	`arn:aws:glue:` *`region`*`:`*`account-id`* `:table/`*`database name`*`/`*`table name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:table/db1/tbl1`
Catálogo de tabelas federadas do S3 (todos os buckets de tabela)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/s3tablescatalog` Por exemplo: `arn:aws:glue:us-east-1:123456789012:catalog/s3tablescatalog`
Catálogo de buckets de tabelas federadas do S3 (catálogo filho)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/s3tablescatalog/` *`bucket name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:catalog/s3tablescatalog/amzn-s3-demo-bucket1`
Banco de dados de tabelas federadas do S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:database/s3tablescatalog/` *`child catalog name`*`/`*`database name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:database/s3tablescatalog/amzn-s3-demo-bucket1/nsdb1`
Tabela federada do S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:table/s3tablescatalog/` *`child catalog name`*`/`*`database name`*`/`*`table name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:table/s3tablescatalog/amzn-s3-demo-bucket1/nsdb1/s3tbl1`
Catálogo de tabelas federadas do S3 (um único bucket de tabela registrado no Lake Formation)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nome do catálogo`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:catalog/amzn-s3-demo-bucket1`

Tipo de atributo	Formato ARN
Banco de dados de tabelas federadas do S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nome do catálogo`*`/`*`nome do banco de dados`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:database/amzn-s3-demo-bucket1/nsdb1`
Tabela federada do S3	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nome do catálogo`*`/`*`nome do banco de dados`*`/`*`nome da tabela`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:table/amzn-s3-demo-bucket1/` *`nsdb1`*`/s3tbl1`
Catálogo federado ou gerenciado (catálogo de nível superior em um vários catálogos)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/` *`top-level catalog name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:catalog/nscatalog` O formato ARN para um catálogo gerenciado segue a mesma estrutura.
Catálogo federado multinível (catálogo filho em um catálogo multinível)	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/` *`top-level catalog name`*`/`*`child catalog name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:catalog/nscatalog/dbcatalog`
Banco de dados federado	`arn:aws:glue:` *`region`*`:`*`account-id`* `:database/` *`name space catalog name`*`/`*`child catalog name`*`/`*`database name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:database/nscatalog/dbcatalog/schemadb`
Tabela federada	`arn:aws:glue:` *`region`*`:`*`account-id`* `:table/`*`name space catalog name`*`/`*`child catalog name`*`/`*`database name`*`/`*`table name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:table/nscatalog/dbcatalog/schemadb/rstbl1`

Tipo de atributo	Formato ARN
Contêiner de link de catálogo	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nome do contêiner de link`* Por exemplo: `arn:aws:glue:glue:us-east-1:123456789012:catalog` /linkcontainer-example
Banco de dados	`arn:aws:glue:` *`region`*`:`*`account-id`* `:catalog/`*`nome do contêiner de link`*`/`*`nome do banco de dados`* Por exemplo: `arn:aws:glue:glue:us-east-1:123456789012:database` /linkcontainer-example/link-db
Função definida pelo usuário	`arn:aws:glue:` *`region`*`:`*`account-id`* `:userDefinedFunction/` *`database name`*`/`*`user-defined function name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:userDefinedFunction/db1/func1`
Conexão	`arn:aws:glue:` *`region`*`:`*`account-id`* `:connection/` *`connection name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:connection/connection1`
Sessão interativa	`arn:aws:glue:` *`region`*`:`*`account-id`* `:session/` *`interactive session id`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:session/a1b2c3d4-5678-90ab-cdef-EXAMPLE11111`

Para habilitar um controle de acesso minucioso, você pode usar esses ARNs em suas políticas do IAM e políticas de recursos para conceder e negar acesso a recursos específicos. Curingas são permitidos nas políticas. Por exemplo, o seguinte ARN corresponde a todas as tabelas no banco de dados `default`.

```
arn:aws:glue:us-east-1:123456789012:table/default/*
```

Important

Todas as operações executadas em um recurso do Data Catalog exigem permissão no recurso e em todos os ancestrais desse recurso. Por exemplo, criar uma partição para uma tabela requer permissão na tabela, no banco de dados e no catálogo em que a tabela está localizada. O exemplo a seguir mostra a permissão necessária para criar partições na tabela `PrivateTable` do banco de dados `PrivateDatabase` no Data Catalog.

```
{
   "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"
   ]
}
```

Além de permissão no recurso e em todos os seus ancestrais, todas as operações de exclusão exigem permissão em todos os filhos desse recurso. Por exemplo, excluir um banco de dados requer permissão em todas as tabelas e funções definidas pelo usuário no banco de dados, além do banco de dados e no catálogo em que o banco de dados está localizado. O exemplo a seguir mostra a permissão necessária para excluir o banco de dados `PrivateDatabase` no Data Catalog.

```
{
   "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"
   ]
```

```
}
```

Resumindo, as ações em recursos do Data Catalog seguem estas regras de permissão:

- As ações no catálogo requerem permissão somente no catálogo.
- As ações em um banco de dados requerem permissão no banco de dados e no catálogo.
- A exclusão de ações em um banco de dados requer permissão no banco de dados e no catálogo e em todas as tabelas e funções definidas pelo usuário no banco de dados.
- As ações em uma tabela, partição ou versão de tabela requerem permissão na tabela, no banco de dados e no catálogo.
- As ações em uma função definida pelo usuário requerem permissão na função definida pelo usuário, no banco de dados e no catálogo.
- As ações em uma conexão requerem permissão na conexão e no catálogo.

ARNs de objetos fora do catálogo no AWS Glue

Alguns recursos do AWS Glue permitem permissões no nível do recurso para controlar o acesso usando um ARN. Você pode usar esses ARNs em suas políticas do IAM para permitir um controle de acesso refinado. A tabela a seguir lista os recursos que podem conter ARNs de recursos.

Tipo de atributo	Formato ARN
Crawler	`arn:aws:glue:` *`region`*`:`*`account-id`* `:crawler/` *`crawler-name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:crawler/mycrawler`
Trabalho	`arn:aws:glue:` *`region`*`:`*`account-id`* `:job/`*`job-name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:job/testjob`
Trigger	`arn:aws:glue:` *`region`*`:`*`account-id`* `:trigger/` *`trigger-name`*

Tipo de atributo	Formato ARN
	Por exemplo: `arn:aws:glue:us-east-1:123456789012:trigger/sampletrigger`
Endpoint de desenvolvimento	`arn:aws:glue:` *`region`*`:`*`account-id`*` :devEndpoint/` *`development-endpoint-name`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:devEndpoint/temporarydevendpoint`
Transformação de machine learning	`arn:aws:glue:` *`region`*`:`*`account-id`*` :mlTransform/` *`transform-id`* Por exemplo: `arn:aws:glue:us-east-1:123456789012:mlTransform/tfm-1234567890`

Controle de acesso para operações singulares da API fora do catálogo do AWS Glue

As operações singulares de API fora do catálogo do AWS Glue atuam em um único item (endpoint de desenvolvimento). Os exemplos são `GetDevEndpoint`, `CreateUpdateDevEndpoint` e `UpdateDevEndpoint`. Para essas operações, uma política deve colocar o nome da API no bloco `"action"` e o ARN do recurso no bloco `"resource"`.

Suponha que você queira permitir que um usuário chame a operação `GetDevEndpoint`. A política a seguir concede as permissões mínimas necessárias para um endpoint chamado `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"
        }
    ]
}
```

A política a seguir permite o acesso `UpdateDevEndpoint` a recursos que correspondem a `myDevEndpoint-` com um caractere curinga (*).

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "PermissionWithWildcard",
            "Effect": "Allow",
            "Action": "glue:UpdateDevEndpoint",
            "Resource": "arn:aws:glue:us-east-1:123456789012:devEndpoint/myDevEndpoint-
*"
        }
    ]
}
```

Você pode combinar as duas políticas, como no exemplo a seguir. Você pode ver `EntityNotFoundException` para qualquer endpoint de desenvolvimento cujo nome começa com A. No entanto, um erro de acesso negado retorna quando você tenta acessar outros endpoints de desenvolvimento.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "CombinedPermissions",
            "Effect": "Allow",
            "Action": [
                "glue:UpdateDevEndpoint",
                "glue:GetDevEndpoint"
            ],
            "Resource": "arn:aws:glue:us-east-1:123456789012:devEndpoint/A*"
        }
    ]
}
```

Controle de acesso para operações da API fora do catálogo do AWS Glue que recuperam vários itens

Algumas operações da API do AWS Glue recuperam vários itens (como vários endpoints de desenvolvimento); por exemplo, `GetDevEndpoints`. Para essa operação, você pode especificar apenas um recurso de caractere curinga (*), e não ARNs específicos.

Por exemplo, para incluir `GetDevEndpoints` na política, o recurso deve estar projetado para o curinga (*). As operações singulares (`GetDevEndpoint`, `CreateDevEndpoint` e `DeleteDevendpoint`) também têm escopo para todos (*) os recursos no exemplo.

```
{
            "Sid": "PluralAPIIncluded",
            "Effect": "Allow",
            "Action": [
                "glue:GetDevEndpoints",
                "glue:GetDevEndpoint",
                "glue:CreateDevEndpoint",
                "glue:UpdateDevEndpoint"
            ],
            "Resource": [
                "*"
            ]
}
```

Controle de acesso para operações da API BatchGet fora do catálogo do AWS Glue

Algumas operações da API do AWS Glue recuperam vários itens (como vários endpoints de desenvolvimento); por exemplo, `BatchGetDevEndpoints`. Para essa operação, você pode especificar um ARN para limitar o escopo dos recursos que podem ser acessados.

Por exemplo, para permitir o acesso a um endpoint de desenvolvimento específico, inclua `BatchGetDevEndpoints` na política com o ARN do seu recurso.

```
{
            "Sid": "BatchGetAPIIncluded",
            "Effect": "Allow",
            "Action": [
                "glue:BatchGetDevEndpoints"
            ],
            "Resource": [
```

```
                "arn:aws:glue:us-east-1:123456789012:devEndpoint/de1"
            ]
}
```

Com essa política, você pode acessar com êxito o endpoint de desenvolvimento chamado `de1`. No entanto, se você tentar acessar o endpoint de desenvolvimento chamado `de2`, um erro será retornado.

```
An error occurred (AccessDeniedException) when calling the BatchGetDevEndpoints
 operation: No access to any requested resource.
```

> **Important**
>
> Para abordagens alternativas de configuração de políticas do IAM, como usar operações da API `List` e `BatchGet`, consulte Exemplos das políticas baseadas em identidade do AWS Glue.

Concessão de acesso entre contas

Conceder acesso aos recursos do Data Catalog entre contas permite que seus trabalhos de extração, transformação e carregamento (ETL) consultem e juntem dados de contas diferentes.

Tópicos

- Métodos de concessão de acesso entre contas no AWS Glue
- Adição ou atualização da política de recursos do catálogo de dados
- Realização de uma chamada de API entre contas
- Realização de uma chamada de ETL entre contas
- Registro em log no CloudTrail entre contas
- Propriedade e faturamento de recursos entre contas
- Limitações de acesso entre contas

Métodos de concessão de acesso entre contas no AWS Glue

Você pode conceder acesso aos seus dados a contas externas da AWS usando métodos do AWS Glue ou concessões entre contas do AWS Lake Formation. Os métodos do AWS Glue usam políticas

do AWS Identity and Access Management (IAM) para obter um controle de acesso minucioso. O Lake Formation usa um modelo de permissões `GRANT/REVOKE` mais simples semelhante aos comandos `GRANT/REVOKE` em um sistema de banco de dados relacional.

Esta seção descreve o uso de métodos do AWS Glue. Para mais informações sobre como usar concessões entre contas do Lake Formation, consulte Conceder permissões do Lake Formation no Guia do desenvolvedor do AWS Lake Formation.

Há dois métodos do AWS Glue para conceder acesso entre contas a um recurso:

- Usar uma política de recursos do Data Catalog
- Usar uma função do IAM

Usar uma política de recursos para conceder acesso entre contas

A seguir estão as etapas gerais para conceder acesso entre contas usando uma política de recursos do Data Catalog:

1. Um administrador (ou outra identidade autorizada) na conta A anexa uma política de recursos ao Data Catalog na conta A. Essa política concede à conta B permissões específicas entre contas para executar operações em um recurso no catálogo da conta A.
2. Um administrador na conta B anexa uma política do IAM a uma identidade do IAM na conta B que delega as permissões recebidas da conta A.

   A identidade na conta B agora tem acesso ao recurso especificado na conta A.

   O usuário precisa de permissão de ambos, o proprietário do recurso (conta A) e a conta superior (conta B), para poder acessar o recurso.

Conceder acesso entre contas utilizando uma função do IAM

A seguir estão as etapas gerais para conceder acesso entre contas usando uma função do IAM:

1. Um administrador (ou outra identidade autorizada) na conta que possui o recurso (conta A) cria uma função do IAM.
2. Um administrador na Conta A anexa uma política à função que concede permissões entre contas para acesso ao recurso em questão.
3. O administrador na conta A anexa uma política de confiança à função que identifica uma identidade do IAM em outra conta (conta B) como a entidade principal que pode assumir a função.

A entidade principal da política de confiança também pode ser a entidade principal de um produto da AWS, se você desejar conceder permissão a um produto da AWS para que ele assuma a função.

4. Um administrador na conta B agora delega permissões para uma ou mais identidades do IAM na conta B, para que elas possam assumir essa função. Isso fornece às identidades na Conta B acesso ao recurso na conta A.

Para obter mais informações sobre o uso do IAM para delegar permissões, consulte Gerenciamento de acesso no Manual do usuário do IAM. Para obter mais informações sobre usuários, grupos, funções e permissões, consulte Identities (users, groups, and roles) no Guia do usuário do IAM.

Para obter uma comparação entre essas duas abordagens, consulte Como as funções do IAM diferem de políticas baseadas em recurso no Guia do usuário do IAM. O AWS Glue é compatível com ambas as opções, com a restrição de que uma política de recurso só pode conceder acesso aos recursos do Data Catalog.

Por exemplo, para conceder ao perfil `Dev` na conta B acesso ao banco de dados `db1` na conta A, anexe a política de recurso a seguir ao catálogo na conta 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"
      ]
    }
  ]
}
```

Além disso, a conta B deve anexar a seguinte política do IAM ao perfil `Dev`para poder realmente ter acesso ao db1 na conta 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"
      ]
    }
  ]
}
```

Adição ou atualização da política de recursos do catálogo de dados

Você pode adicionar ou atualizar a política de recursos do catálogo de dados do AWS Glue usando o console, a API ou a AWS Command Line Interface (AWS CLI).

> **Important**
>
> Se você já tiver feito concessões de permissão entre contas da sua conta com o AWS Lake Formation, adicionar ou atualizar a política de recursos do Data Catalog exigirá uma etapa extra. Para obter mais informações, consulte Gerenciar permissões entre contas usando o AWS Glue e o Lake Formation no Guia do desenvolvedor do AWS Lake Formation.
> Para determinar se existem concessões entre contas do Lake Formation, use a operação de API `glue:GetResourcePolicies` ou a AWS CLI. Se `glue:GetResourcePolicies` retornar qualquer outra política, exceto uma política já existente do Data Catalog, será porque existem concessões do Lake Formation. Para obter mais informações, consulte Visualizar todas as concessões entre contas usando a operação de API GetResourcePolicies no Guia do desenvolvedor do AWS Lake Formation.

Para adicionar ou atualizar a política de recursos do Data Catalog (console)

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.

   Faça login como um usuário administrativo do AWS Identity and Access Management (IAM) que tem a permissão de `glue:PutResourcePolicy`.
2. No painel de navegação, selecione Configurações.
3. Na página Data catalog settings (Configurações de catálogo de dados), em Permissions (Permissões), cole uma política de recursos na área de texto. Em seguida, escolha Salvar.

   Se o console exibir um alerta informando que as permissões na política serão adicionais às permissões concedidas usando o Lake Formation, escolha Proceed (Continuar).

Para adicionar ou atualizar a política de recursos do Data Catalog (AWS CLI)

- Envie um comando `aws glue put-resource-policy`. Se já existirem concessões do Lake Formation, certifique-se de incluir a opção `--enable-hybrid` com o valor `'TRUE'`.

  Para obter exemplos de uso dessa operação, consulte Exemplos de política baseada em recursos para o AWS Glue.

Realização de uma chamada de API entre contas

Todas as operações do AWS Glue Data Catalog têm um campo `CatalogId`. Se as permissões necessárias foram concedidas para habilitar o acesso entre contas, um autor da chamada pode fazer chamadas de API do Data Catalog entre contas. O autor da chamada faz isso transmitindo o ID da conta da AWS de destino no `CatalogId` para acessar o recurso nessa conta de destino.

Se nenhum valor de `CatalogId` for fornecido, o AWS Glue usará o ID da conta do próprio chamador por padrão, e a chamada não será entre contas.

Realização de uma chamada de ETL entre contas

Algumas APIs de PySpark e Scala do AWS Glue têm um campo de ID do catálogo. Se todas as permissões necessárias forem concedidas para habilitar o acesso entre contas, um trabalho de ETL poderá fazer chamadas de PySpark e Scala às operações da API entre contas transmitindo o ID da conta da AWS de destino no campo de ID do catálogo para acessar os recursos do Data Catalog em uma conta de destino.

Se nenhum valor de ID de catálogo for fornecido, o AWS Glue usará o ID da conta do próprio chamador por padrão, e a chamada não será entre contas.

Para APIs do PySpark que oferecem suporte ao `catalog_id`, consulte Classe GlueContext. Para APIs do Scala que oferecem suporte ao `catalogId`, consulte APIs GlueContext em Scala do AWS Glue.

O exemplo a seguir mostra as permissões exigidas pelo usuário autorizado para executar um trabalho de ETL. Neste exemplo, *`grantee-account-id`* é o `catalog-id` do cliente que executa a tarefa e *`grantor-account-id`* é o proprietário do recurso. Este exemplo concede permissão a todos os recursos do catálogo na conta do concessor. Para limitar o escopo de recursos concedidos, você pode fornecer ARNs específicos para o catálogo, o banco de dados, a tabela e a conexão.

```
{
    "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**
>
> Se uma tabela na conta do concessor apontar para um local do Amazon S3 que também está na conta do concessor, a função do IAM usada para executar um trabalho de ETL na conta do usuário autorizado deverá ter permissão para listar e obter objetos da conta do concessor.

Uma vez que o cliente na Conta A já tem permissão para criar e executar tarefas de ETL, as etapas básicas para configurar uma tarefa de ETL para acesso entre contas são:

1. Permita acesso a dados entre contas (ignore esta etapa se o acesso entre contas do Amazon S3 já estiver configurado).
    a. Atualize a política do bucket do Amazon S3 na conta B para permitir o acesso entre contas na conta A.
    b. Atualizar a política do IAM na Conta A para permitir o acesso ao bucket na Conta B.
2. Permita o acesso entre contas ao Data Catalog.
    a. Crie ou atualize a política de recursos anexada ao Data Catalog na conta B para permitir o acesso na conta A.
    b. Atualize a política do IAM na conta A para permitir o acesso ao Data Catalog na conta B.

Registro em log no CloudTrail entre contas

Quando um trabalho de extração, transformação e carregamento (ETL) do AWS Glue acessa os dados subjacentes de uma tabela do catálogo de dados compartilhada por concessões entre contas do AWS Lake Formation, há um comportamento de registro em log adicional do AWS CloudTrail.

Para efeitos desta discussão, a conta da AWS que compartilha a tabela é a conta de proprietário, já a conta com a qual a tabela é compartilhada é a conta de destinatário. Quando um trabalho de ETL na conta de destinatário acessa dados da tabela na conta de proprietário, o evento de acesso a dados do CloudTrail que é adicionado aos logs da conta de destinatário é copiado para os logs do CloudTrail da conta de proprietário. Isso é para que as contas de proprietário possam rastrear acessos a dados pelas várias contas de destinatários. Por padrão, os eventos do CloudTrail não incluem um identificador de entidade principal legível (ARN da entidade principal). Um administrador na conta de destinatário pode optar por incluir o ARN da entidade principal nos logs.

Para obter mais informações, consulte Registro em log entre contas do CloudTrail no Guia do desenvolvedor do AWS Lake Formation.

Consulte também

- the section called “Registro e monitoramento”

Propriedade e faturamento de recursos entre contas

Quando um usuário em uma conta da AWS (conta A) cria um novo recurso, como um banco de dados em outra conta (conta B), esse recurso é propriedade da conta B, a conta em que ele foi criado. Um administrador na Conta B automaticamente recebe permissões completas para acessar o novo recurso, incluindo leitura, gravação e concessão de permissões de acesso a uma conta de terceiros. O usuário na Conta A pode acessar o recurso que acabou de criar somente se tiver as permissões apropriadas concedidas pela Conta B.

Os custos de armazenamento e outros custos que estão diretamente associados ao novo recurso são cobrados da Conta B, a proprietária do recurso. O custo das solicitações do usuário que criou o recurso é faturado na conta do solicitante, a Conta A.

Para obter mais informações sobre faturamento e preços do AWS Glue, consulte Como funciona a definição de preços da AWS.

Limitações de acesso entre contas

O acesso entre contas do AWS Glue tem as seguintes limitações:

- O acesso entre contas ao AWS Glue não é permitido se você criou bancos de dados e tabelas usando o Amazon Athena ou o Amazon Redshift Spectrum antes de uma região ter suporte ao AWS Glue e a conta do proprietário do recurso não ter migrado o catálogo de dados do Amazon Athena para o AWS Glue. Você pode encontrar o status atual da migração usando o GetCatalogImportStatus (get_catalog_import_status). Para obter mais detalhes sobre como migrar um catálogo do Athena para o AWS Glue, consulte Processo detalhado do upgrade para o AWS Glue Data Catalog no Guia do usuário do Amazon Athena.
- O acesso entre contas é compatível somente para recursos do Data Catalog, incluindo bancos de dados, tabelas, funções definidas pelo usuário e conexões.
- O acesso entre contas ao catálogo de dados do Athena exige que você registre o catálogo como um recurso do `DataCatalog` do Athena. Para obter instruções, consulte Registrar um AWS Glue Data Catalog de outra conta no Guia do usuário do Amazon Athena.

Solução de problemas de identidade e acesso do AWS Glue

Use as seguintes informações para ajudar a diagnosticar e corrigir problemas comuns que podem ser encontrados ao trabalhar com o AWS Glue e o IAM.

Tópicos

- Não tenho autorização para realizar uma ação no AWS Glue
- Não estou autorizado a executar iam:PassRole
- Quero permitir que pessoas de fora da minha Conta da AWS acessem meus recursos do AWS Glue

Não tenho autorização para realizar uma ação no AWS Glue

Se você receber uma mensagem de erro informando que não tem autorização para executar uma ação, suas políticas deverão ser atualizadas para permitir que você realize a ação.

O erro do exemplo a seguir ocorre quando o usuário do IAM `mateojackson` tenta usar o console para visualizar detalhes sobre um atributo *`my-example-widget`* fictício, mas não tem as permissões `glue:`*`GetWidget`* fictícias.

```
User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform:
 glue:GetWidget on resource: my-example-widget
```

Nesse caso, a política do usuário `mateojackson` deve ser atualizada para permitir o acesso ao recurso *`my-example-widget`* usando a ação `glue:`*`GetWidget`*.

Se você precisar de ajuda, entre em contato com seu administrador AWS. Seu administrador é a pessoa que forneceu suas credenciais de login.

Não estou autorizado a executar iam:PassRole

Se você receber uma mensagem de erro informando que não está autorizado a realizar a ação `iam:PassRole`, suas políticas deverão ser atualizadas para permitir a passagem de um perfil para o AWS Glue.

Alguns Serviços da AWS permitem que você passe um perfil existente para o serviço, em vez de criar um novo perfil de serviço ou perfil vinculado ao serviço. Para fazer isso, é preciso ter permissões para passar o perfil para o serviço.

O exemplo de erro a seguir ocorre quando uma usuária do IAM chamada `marymajor` tenta usar o console para realizar uma ação no AWS Glue. No entanto, a ação exige que o serviço tenha permissões concedidas por um perfil de serviço. Mary não tem permissões para passar o perfil para o serviço.

```
User: arn:aws:iam::123456789012:user/marymajor is not authorized to perform:
 iam:PassRole
```

Nesse caso, as políticas de Mary devem ser atualizadas para permitir que ela realize a ação `iam:PassRole`.

Se você precisar de ajuda, entre em contato com seu administrador AWS. Seu administrador é a pessoa que forneceu suas credenciais de login.

Quero permitir que pessoas de fora da minha Conta da AWS acessem meus recursos do AWS Glue

Você pode criar um perfil que os usuários de outras contas ou pessoas fora da sua organização podem usar para acessar seus recursos. Você pode especificar quem é confiável para assumir o perfil. Para serviços que oferecem compatibilidade com políticas baseadas em recursos ou listas de controle de acesso (ACLs), você pode usar essas políticas para conceder às pessoas acesso aos seus recursos.

Para saber mais, consulte:

- Para saber se o AWS Glue é compatível com esses recursos, consulte Como o AWS Glue funciona com IAM.
- Para saber como conceder acesso a seus recursos em todas as Contas da AWS pertencentes a você, consulte Fornecimento de acesso a um usuário do IAM em outra Conta da AWS pertencente a você no Guia de usuário do IAM.
- Para saber como conceder acesso a seus recursos para terceiros Contas da AWS, consulte Fornecimento de acesso a Contas da AWS pertencentes a terceiros no Guia do usuário do IAM.
- Para saber como conceder acesso por meio da federação de identidades, consulte Conceder acesso a usuários autenticados externamente (federação de identidades) no Guia do usuário do IAM.
- Para saber a diferença entre perfis e políticas baseadas em recurso para acesso entre contas, consulte Acesso a recursos entre contas no IAM no Guia do usuário do IAM.

Modelos de controle de acesso do AWS Lake Formation

O AWS Glue 5.0 oferece suporte a dois modelos para acessar dados por meio do AWS Lake Formation:

Tópicos

- Como usar AWS Glue com AWS Lake Formation para acesso total à tabela
- Usar o AWS Glue com AWS Lake Formation para controle de acesso refinado

Como usar AWS Glue com AWS Lake Formation para acesso total à tabela

Introdução ao acesso total à tabela

O AWS Glue 5.0 é compatível com o controle de acesso total à tabela (FTA) no Apache Spark com base em suas políticas definidas no AWS Lake Formation. Esse recurso habilita operações de leitura e gravação de seus trabalhos Spark do AWS Glue em tabelas registradas no AWS Lake Formation quando o perfil de trabalho tiver acesso total à tabela. O FTA é ideal para casos de uso que precisam estar em conformidade com os regulamentos de segurança no nível da tabela e oferece suporte aos recursos do Spark, incluindo conjuntos de dados distribuídos resilientes (RDDs), bibliotecas personalizadas e funções definidas pelo usuário (UDFs) com tabelas do AWS Lake Formation.

Quando um trabalho do Spark do AWS Glue é configurado para acesso total à tabela (FTA), as credenciais do AWS Lake Formation são usadas para ler/gravar dados do Amazon S3 em tabelas registradas no AWS Lake Formation, enquanto as credenciais do perfil de runtime do trabalho serão usadas para ler/gravar tabelas não registradas no AWS Lake Formation. Esse recurso permite operações de linguagem de manipulação de dados (DML), incluindo as instruções CREATE, ALTER, DELETE, UPDATE e MERGE INTO em tabelas do Apache Hive e do Iceberg.

> **Note**
>
> Analise seus requisitos e determine se o controle de acesso de alta granularidade (FGAC) ou o acesso total à tabela (FTA) atende às suas necessidades. Só é possível ativar um método de permissão do AWS Lake Formation para um determinado trabalho do AWS Glue. Um trabalho não pode executar simultaneamente o acesso total à tabela (FTA) e o controle de acesso de alta granularidade (FGAC) ao mesmo tempo.

Como o acesso total à tabela (FTA) funciona no AWS Glue

O AWS Lake Formation oferece duas abordagens para controle de acesso a dados: controle de acesso de alta granularidade (FGAC) e acesso total à tabela (FTA). O FGAC fornece segurança aprimorada por meio de filtragem no nível de coluna, linha e célula, ideal para cenários que exigem permissões granulares. O FTA é ideal para cenários simples de controle de acesso em que você

precisa de permissões no nível de tabela. Ele simplifica a implementação ao eliminar a necessidade de habilitar o modo de acesso refinado, melhora o desempenho e reduz os custos ao evitar o driver do sistema e os executores do sistema, além de oferecer suporte às operações de leitura e de gravação (incluindo os comandos CREATE, ALTER, DELETE, UPDATE e MERGE INTO).

No AWS Glue 4.0, o acesso a dados baseado no AWS Lake Formation funcionava por meio da classe GlueContext, a classe utilitária fornecida pelo AWS Glue. No AWS Glue 5.0, o acesso a dados baseado no AWS Lake Formation está disponível por meio do SQL nativo do Spark, o Spark DataFrames, e continua sendo suportado pela classe GlueContext.

Implementação do acesso total à tabela

Etapa 1: habilitar o acesso total à tabela no AWS Lake Formation

Para usar o modo de acesso total à tabela (FTA), você precisa permitir que mecanismos de consulta de terceiros acessem dados sem a validação da tag de sessão do IAM no AWS Lake Formation. Para habilitar, siga as etapas em Application integration for full table access.

Etapa 2: configurar permissões do IAM para o perfil de runtime do trabalho

Para acesso de leitura ou gravação aos dados subjacentes, além das permissões do AWS Lake Formation, um perfil de runtime do trabalho precisa da permissão `lakeformation:GetDataAccess` do IAM. Com essa permissão, o AWS Lake Formation concede a solicitação de credenciais temporárias para acessar os dados.

Confira a seguir um exemplo de política de como fornecer permissões do IAM para acesso a um script no Amazon S3, upload de logs no Amazon S3, permissões de API do AWS Glue e permissão para acessar o 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": "*"
    }
  ]
}
```

Etapa 2.1: configurar permissões do AWS Lake Formation

Os trabalhos do Spark do AWS Glue que leem dados do Amazon S3 exigem a permissão SELECT do AWS Lake Formation.

Os trabalhos do Spark do AWS Glue que gravam/excluem dados no Amazon S3 exigem a permissão ALL do AWS Lake Formation.

Os trabalhos do Spark do AWS Glue que interagem com o Catálogo de Dados do AWS Glue exigem as permissões DESCRIBE, ALTER, DROP, conforme apropriado.

Etapa 3: inicializar uma sessão do Spark para acesso total à tabela usando o AWS Lake Formation

Para acessar as tabelas registradas no AWS Lake Formation, é necessário definir as seguintes configurações durante a inicialização do Spark a fim de configurá-lo para usar credenciais do AWS Lake Formation.

Para acessar as tabelas registradas no AWS Lake Formation, você precisa configurar explicitamente sua sessão do Spark para usar credenciais do AWS Lake Formation. Adicione as seguintes configurações ao inicializar sua sessão do 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()
```

Principais configurações:

- `spark.sql.catalog.glue_catalog`: registra um catálogo chamado “glue_catalog” que usa a implementação GlueCatalog.
- `spark.sql.catalog.glue_catalog.glue.lakeformation-enabled`: habilita explicitamente a integração AWS Lake Formation para esse catálogo.
- O nome do catálogo (“glue_catalog” neste exemplo) pode ser personalizado, mas precisa ser consistente em ambas as configurações.

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`: configure o EMR Filesystem (EMRFS) para usar credenciais do S3 do AWS Lake Formation para tabelas registradas do AWS Lake Formation. Se a tabela não estiver registrada, use as credenciais do perfil de runtime do trabalho.
- `spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true` e `spark.hadoop.fs.s3.folderObject.autoAction.disabled=true`: configure o EMRFS para usar o cabeçalho do tipo de conteúdo application/x-directory em vez do sufixo $folder$ ao criar pastas do S3. Isso é necessário ao ler tabelas do AWS Lake Formation, pois as credenciais do AWS Lake Formation não permitem a leitura de pastas de tabelas com o sufixo $folder$.
- `spark.sql.catalog.skipLocationValidationOnCreateTable.enabled=true`: configure o Spark para ignorar a validação da ausência do local da tabela antes da criação. Isso é necessário para tabelas registradas do AWS Lake Formation, pois as credenciais do AWS Lake Formation para verificar o local vazio só estão disponíveis após a criação da tabela do Catálogo

de Dados do AWS Glue. Sem essa configuração, as credenciais do perfil de runtime do trabalho validarão o local da tabela vazia.

- `spark.sql.catalog.createDirectoryAfterTable.enabled=true`: configure o Spark para criar a pasta do Amazon S3 após a criação da tabela no metastore do Hive. Isso é necessário para tabelas registradas do AWS Lake Formation, pois as credenciais do AWS Lake Formation para criar a pasta do Amazon S3 só estão disponíveis após a criação da tabela do Catálogo de Dados do AWS Glue.
- `spark.sql.catalog.dropDirectoryBeforeTable.enabled=true`: configure o Spark para encerrar a pasta do Amazon S3 antes da exclusão da tabela no metastore do Hive. Isso é necessário para tabelas registradas do AWS Lake Formation, pois as credenciais do AWS Lake Formation para encerrar a pasta do S3 não estão disponíveis após a exclusão da tabela do Catálogo de Dados do AWS Glue.
- `spark.sql.catalog.<catalog>.AWS Glue.lakeformation-enabled=true`: configure o catálogo do Iceberg para usar as credenciais do Amazon S3 do AWS Lake Formation para tabelas registradas do AWS Lake Formation. Se a tabela não estiver registrada, use as credenciais de ambiente padrão.

Padrões de uso

Como usar o FTA com DataFrames

Para usuários familiarizados com o Spark, é possível usar o DataFrames com acesso total à tabela (FTA) do AWS Lake Formation.

O AWS Glue 5.0 acrescenta suporte nativo do Spark para o acesso total à tabela do Lake Formation, simplificando a forma como você trabalha com tabelas protegidas. No AWS Glue 5.0, esse recurso permite que trabalhos do Spark do AWS Glue leiam e gravem dados diretamente quando o acesso total à tabela for concedido, removendo limitações que antes restringiam determinadas operações de extração, transformação e carregamento (ETL). Agora, você pode aproveitar os recursos avançados do Spark, incluindo conjuntos de dados distribuídos resilientes (RDDs), bibliotecas personalizadas e funções definidas pelo usuário (UDFs) com tabelas do AWS Lake Formation.

FTA nativo do Spark no AWS Glue 5.0

O AWS Glue 5.0 é compatível com o controle de acesso total à tabela (FTA) no Apache Spark com base em suas políticas definidas no AWS Lake Formation. Esse nível de controle é ideal para casos de uso que precisam estar em conformidade com os regulamentos de segurança no nível da tabela.

Exemplo de Tabela do 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.IcebergSparkSessionExtensi
 \
    .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()
```

Permissões obrigatórias do IAM

Seu perfil de execução de trabalho do AWS Glue precisa ter:

```
{
    "Action": "lakeformation:GetDataAccess",
    "Resource": "*",
    "Effect": "Allow"
}
```

As permissões de acesso apropriadas do S3 para seus locais de dados.

Configuração do Lake Formation

Antes de usar o FTA nativo do Spark no AWS Glue 5.0:

1. Permita que mecanismos de consulta de terceiros acessem dados sem a validação da tag de sessão do IAM no AWS Lake Formation.
2. Conceda permissões de tabela apropriadas ao seu perfil de execução de trabalho do AWS Glue por meio do console do AWS Lake Formation.
3. Configure sua sessão do Spark com os parâmetros necessários mostrados no exemplo acima.

Como usar o FTA com DynamicFrames

O DynamicFrames nativo do AWS Glue pode ser usado com o acesso total à tabela (FTA) do AWS Lake Formation para operações otimizadas de ETL. O acesso total à tabela (FTA) fornece um modelo de segurança que concede permissões no nível da tabela, permitindo um processamento mais rápido de dados em comparação com o controle de acesso de alta granularidade (FGAC), pois ignora a sobrecarga das verificações de permissão no nível de linha e de coluna. Essa abordagem é útil quando você precisa processar tabelas inteiras e as permissões no nível de tabela atendem aos seus requisitos de segurança.

No AWS Glue 4.0, o DynamicFrames com FTA exigia uma configuração específica do GlueContext. Embora o código existente do DynamicFrame no AWS Glue 4.0 com FTA continue funcionando no AWS Glue 5.0, a versão mais recente também oferece suporte nativo ao FTA do Spark com maior flexibilidade. Para novos desenvolvimentos, considere usar a abordagem nativa do Spark descrita na seção DataFrames, especialmente se você precisar de recursos adicionais, como conjuntos de dados distribuídos resilientes (RDDs), bibliotecas personalizadas e funções definidas pelo usuário (UDFs) com tabelas do AWS Lake Formation.

Permissões obrigatórias

O perfil do IAM que executa seu trabalho do Glue precisa ter:

- Permissão `lakeformation:GetDataAccess`
- Permissões apropriadas da tabela do Lake Formation concedidas pelo console do Lake Formation

Exemplo de implementação do DynamicFrame no AWS Glue 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"
)
```

Configuração adicional

Configurar o modo de acesso total à tabela em cadernos do AWS Glue Studio

Para acessar tabelas registradas do AWS Lake Formation em sessões interativas do Spark em cadernos do AWS Glue Studio, você precisa usar o modo de permissão de compatibilidade. Use o comando mágico `%%configure` para definir sua configuração do Spark antes de iniciar sua sessão interativa. Essa configuração precisa ser o primeiro comando em seu caderno, pois não poderá ser aplicada após o início da sessão. Escolha a configuração com base no seu tipo de tabela:

Para tabelas do 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
```

Para tabelas do 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
```

Substitua os espaços reservados:

- S3_DATA_LOCATION: *s3://amzn-s3-demo-bucket*
- REGION: *região da AWS (p. ex., us-east-1)*
- ACCOUNT_ID: *seu ID de conta da AWS*

> **Note**
>
> Você precisa definir essas configurações antes de executar qualquer operação do Spark em seu caderno.

Operações com Suporte

Essas operações usarão credenciais do AWS Lake Formation para acessar os dados da tabela.

> **Note**
>
> Ao habilitar AWS Lake Formation:
>
> - Para FTA: habilite a configuração `spark.sql.catalog.{catalog_name}.glue.lakeformation-enabled` do Spark

- CRIAR TABELA
- ALTER TABLE
- INSERT INTO
- INSERT OVERWRITE
- SELECT
- UPDATE
- MERGE INTO
- DELETE FROM
- ANALYZE TABLE
- REPAIR TABLE
- DESCARTAR TABELA
- Consultas de fontes de dados do Spark
- Gravações na fonte de dados do Spark

> **Note**
>
> As operações não listadas acima continuarão usando as permissões do IAM para acessar os dados da tabela.

Migrar do FTA do AWS Glue 4.0 para o AWS Glue 5.0

Ao migrar do Spark do GlueContext AWS Glue 4.0 para o FTA do Spark nativo do AWS Glue 5.0:

1. Permita que mecanismos de consulta de terceiros acessem dados sem a validação da tag de sessão do IAM no AWS Lake Formation. Confira Etapa 1: habilitar o acesso total à tabela no AWS Lake Formation.
2. Você não precisa alterar o perfil de runtime do trabalho. No entanto, verifique se o perfil de execução de trabalho do AWS Glue tem a permissão lakeformation:GetDataAccess do IAM.
3. Modifique as configurações da sessão do Spark no script. Certifique-se de que as seguintes configurações do Spark estejam presentes:

```
--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. Atualize o script de modo que os DataFrames do GlueContext sejam alterados para DataFrames nativos do Spark.
5. Atualize seu trabalho do AWS Glue para usar o AWS Glue 5.0.

Condições e limitações

- Se uma tabela do Hive for criada usando um trabalho que não tem acesso total à tabela habilitado e nenhum registro for inserido, as leituras ou gravações subsequentes de um trabalho com acesso total à tabela falharão. Isso ocorre porque o Spark do AWS Glue sem acesso total à tabela adiciona o sufixo $folder$ ao nome da pasta da tabela. Para resolver isso, você tem as seguintes opções:
  - Insira pelo menos uma linha na tabela diretamente de um trabalho no qual o FTA não esteja habilitado.
  - Configure o trabalho no qual o FTA não está habilitado para não usar o sufixo $folder$ no nome da pasta no S3. É possível fazer isso definindo a configuração `spark.hadoop.fs.s3.useDirectoryHeaderAsFolderObject=true` do Spark.
  - Crie uma pasta do Amazon S3 no local de tabela `s3://path/to/table/table_name` usando o console do Amazon S3 ou a CLI do Amazon S3.
- O acesso total à tabela funciona exclusivamente com EMR Filesystem (EMRFS). O sistema de arquivos S3A não é compatível.

- O acesso total à tabela é compatível com tabelas do Hive e do Iceberg. Ainda não há suporte para tabelas do Hudi e do Delta.
- Os trabalhos que mencionam tabelas com regras de controle de acesso de alta granularidade (FGAC) do AWS Lake Formation ou visualizações do catálogo de dados do AWS Glue falharão. Para consultar uma tabela com regras de FGAC ou uma visualização do Catálogo de Dados do AWS Glue, você precisará usar o modo FGAC. Você pode habilitar o modo FGAC seguindo as etapas descritas na documentação do AWS: como usar o AWS Glue com o AWS Lake Formation para controle de acesso de alta granularidade.
- O acesso total à tabela não é compatível com Spark Streaming.
- Não pode ser usado simultaneamente com FGAC.

Usar o AWS Glue com AWS Lake Formation para controle de acesso refinado

Visão geral

Com o AWS Glue versão 5.0 e superior, você pode usar o AWS Lake Formation para aplicar controles de acesso refinados em tabelas do Catálogo de Dados com suporte do S3. Esse recurso permite configurar controles de acesso em nível de tabela, linha, coluna e célula para consultas read nos trabalhos do AWS Glue para Apache Spark. Consulte as seções a seguir para saber mais sobre o Lake Formation e como usá-lo com o AWS Glue.

O controle de acesso em nível de tabela baseado no `GlueContext` com permissões AWS Lake Formation compatíveis com o Glue 4.0 ou anteriores não é compatível com o Glue 5.0. Use o novo controle de acesso refinado (FGAC) nativo do Spark no Glue 5.0. Observe os detalhes a seguir:

- Se precisar de controle de acesso refinado (FGAC) para controle de acesso em linha/coluna/célula, você precisará migrar do `GlueContext`/Glue DynamicFrame no Glue 4.0 e versões anteriores para o Spark dataframe no Glue 5.0. Para ver exemplos, consulte Migração de GlueContext/Glue DynamicFrame para Spark DataFrame
- Se você precisar do controle de acesso total à tabela (FTA), poderá aproveitar o FTA com DynamicFrames no Glue 5.0. Você também pode migrar para a abordagem nativa do Spark a fim de obter recursos adicionais, como conjuntos de dados distribuídos resilientes (RDDs), bibliotecas personalizadas e funções definidas pelo usuário (UDFs) com tabelas do AWS Lake Formation. Para exemplos, consulte Migrating from AWS Glue 4.0 to AWS Glue 5.0 FTA.

- Se não precisar do FGAC, nenhuma migração para dataframes do Spark será necessária, e os recursos `GlueContext`, como marcadores de tarefas e predicados push-down, continuarão funcionando.
- Os trabalhos com o FGAC exigem no mínimo 4 operadores: um driver de usuário, um driver de sistema, um executor de sistema e um executor de usuário em espera.

Utilizar o AWS Glue com o AWS Lake Formation gera cobranças adicionais.

Como o AWS Glue funciona com o AWS Lake Formation

Usar o AWS Glue com o Lake Formation permite impor uma camada de permissões em cada trabalho do Spark para aplicar o controle de permissões do Lake Formation quando o AWS Glue executa trabalhos. O AWS Glue usa perfis de recursos do Spark para criar dois perfis para executar trabalhos de forma efetiva. O perfil do usuário executa o código fornecido pelo usuário, enquanto o perfil do sistema impõe as políticas do Lake Formation. Para obter mais informações, consulte What is AWS Lake Formation e Considerations and limitations.

Veja a seguir uma visão geral de alto nível sobre como o AWS Glue obtém acesso aos dados protegidos pelas políticas de segurança do Lake Formation.

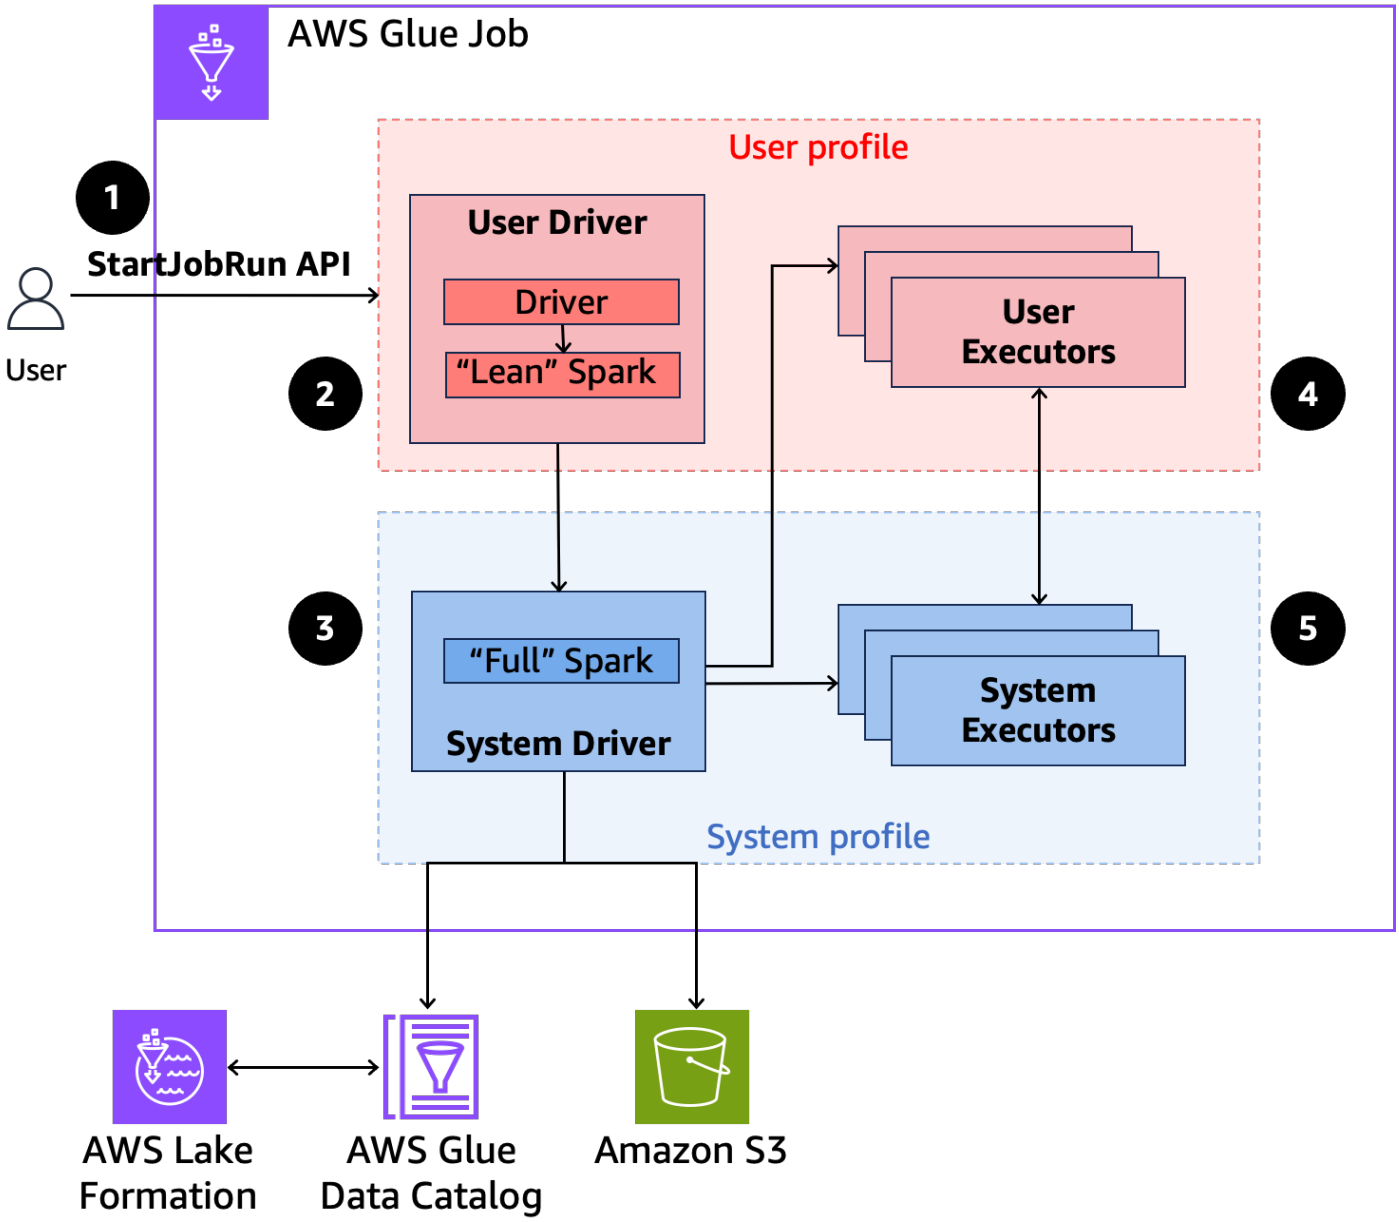

1. Um usuário chama a API `StartJobRun` em uma tarefa do AWS Glue habilitada para AWS Lake Formation.
2. O AWS Glue envia o trabalho para um driver de usuário e executa o trabalho no perfil do usuário. O driver do usuário executa uma versão enxuta do Spark que não tem a capacidade de iniciar tarefas, solicitar executores, acessar o S3 ou o Glue Catalog. Ele cria um plano de trabalho.
3. O AWS Glue configura um segundo driver chamado driver do sistema e o executa no perfil do sistema (com uma identidade privilegiada). O AWS Glue configura um canal TLS criptografado entre os dois drivers para comunicação. O driver do usuário usa o canal para enviar os planos

de trabalho ao driver do sistema. O driver do sistema não executa o código enviado pelo usuário. Ele executa o Spark completo e se comunica com o S3 e com o Data Catalog para acesso aos dados. Ele solicita executores e compila o plano de trabalho em uma sequência de estágios de execução.

4. Em seguida, o AWS Glue executa os estágios nos executores com o driver do usuário ou o driver do sistema. O código do usuário em qualquer estágio é executado exclusivamente nos executores do perfil do usuário.
5. Os estágios que lêem dados das tabelas do Data Catalog protegidas pelo AWS Lake Formation ou que aplicam filtros de segurança são delegados aos executores do sistema.

Requisito mínimo de operadores

Um trabalho habilitado para Lake Formation no AWS Glue requer no mínimo 4 operadores: um driver de usuário, um driver de sistema, um executor de sistema e um executor de usuário em espera. Isso é mais do que o mínimo de 2 operadores necessários para jobs padrão do AWS Glue.

Um trabalho habilitado para Lake Formation no AWS Glue utiliza dois drivers do Spark, um para o perfil do sistema e outro para o perfil do usuário. Da mesma forma, os executores também são divididos em dois perfis:

- Executores do sistema: lidam com tarefas nas quais os filtros de dados do Lake Formation são aplicados.
- Executores do usuário: são solicitados pelo driver do sistema conforme necessário.

Como os trabalhos do Spark são lentos por natureza, o AWS Glue reserva 10% do total de operadores (mínimo de 1), após deduzir os dois drivers, para os executores de usuário.

Todos os trabalhos habilitados para Lake Formation têm o ajuste de escala automático ativado, o que significa que os executores de usuário só iniciarão quando necessário.

Para ver um exemplo de configuração, consulte Considerações e limitações.

Permissões do IAM do perfil de runtime do trabalho

As permissões do Lake Formation controlam o acesso aos recursos do Catálogo de Dados do AWS Glue, aos locais do Amazon S3 e aos dados subjacentes nesses locais. As permissões do IAM controlam o acesso às APIs e aos recursos do Lake Formation e do AWS Glue. Embora você possa

ter a permissão do Lake Formation para acessar uma tabela no Data Catalog (SELECT), a operação falhará se você não tiver a permissão do IAM na operação de API `glue:Get*`.

Confira a seguir um exemplo de política de como fornecer permissões do IAM para acesso a um script no S3, upload de logs no S3, permissões da API do AWS Glue e permissão para acessar o 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": ["*"]
        }
    ]
}
```

Configuração de permissões do Lake Formation para perfil de runtime do trabalho

Primeiro, registre a localização da tabela do Hive no Lake Formation. Em seguida, crie permissões para o perfil de runtime do trabalho na tabela desejada. Para obter mais detalhes sobre o Lake Formation, consulte What is AWS Lake Formation? no Guia do desenvolvedor do AWS Lake Formation.

Depois de configurar as permissões do Lake Formation, você pode enviar trabalhos do Spark no AWS Glue.

Envio da execução de um trabalho

Depois de concluir a configuração das concessões do Lake Formation, você pode enviar trabalhos do Spark no AWS Glue. Para executar trabalhos do Iceberg, é necessário fornecer as configurações do Spark a seguir. Para configurar por meio dos parâmetros de trabalho do Glue, inclua o seguinte parâmetro:

- Chave:

```
--conf
```

- Valor:

```
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
```

Uso de uma sessão interativa

Após concluir a configuração das permissões do AWS Lake Formation, é possível usar as sessões interativas no AWS. As configurações do Spark apresentadas a seguir devem ser fornecidas por meio do comando mágico `%%configure` antes da execução do código.

```
%%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 aplicado a cadernos e sessões interativas no AWS Glue 5.0

Para habilitar o controle de acesso refinado (FGAC, na sigla em inglês) no AWS, é necessário especificar as configurações do Spark requeridas pelo Lake Formation por meio do comando mágico %%configure, antes da criação da primeira célula.

Caso essas configurações sejam fornecidas posteriormente usando as chamadas `SparkSession.builder().conf("").get()` e `SparkSession.builder().conf("").create()`, o controle não será aplicado corretamente. Trata-se de uma alteração em relação ao comportamento observado na versão AWS Glue 4.0.

Suporte ao formato de tabela aberta

O AWS Glue versão 5.0 ou posterior inclui suporte ao controle de acesso refinado com base no Lake Formation. O AWS Glue é compatível com os tipos de tabela do Hive e do Iceberg. A tabela a seguir descreve todas as operações compatíveis.

Operações	Hive	Iceberg
Comandos de DDL	Somente com permissões de perfil do IAM	Somente com permissões de perfil do IAM
Consultas incrementais	Não aplicável	Suporte total
Consultas de viagem no tempo	Não aplicável a esse formato de tabela	Suporte total
Tabelas de metadados	Não aplicável a esse formato de tabela	Compatível, mas algumas tabelas estão ocultas. Para obter mais informações, consulte Considerations and limitations.
`DML INSERT`	Somente com permissões do IAM	Somente com permissões do IAM
ATUALIZAÇÃO DE DML	Não aplicável a esse formato de tabela	Somente com permissões do IAM
`DML DELETE`	Não aplicável a esse formato de tabela	Somente com permissões do IAM
Operações de leitura	Suporte total	Suporte total
Procedimentos armazenados	Não aplicável	Compatível com as exceções de `register_table` e `migrate`. Para obter mais informações, consulte Considerations and limitations.

Migração de GlueContext/Glue DynamicFrame para Spark DataFrame

Veja a seguir exemplos em Python e Scala da migração de `GlueContext`/Glue `DynamicFrame` no Glue 4.0 para Spark `DataFrame` no Glue 5.0.

Python

Antes:

```
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)
```

Depois:

```
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

Antes:

```
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()
```

Depois:

```
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")
```

Considerações e limitações

Confira as considerações e limitações a seguir ao usar o Lake Formation com o AWS Glue.

O AWS Glue com o Lake Formation está disponível em todas as regiões compatíveis, exceto AWS GovCloud (Leste dos EUA) e AWS GovCloud (Oeste dos EUA).

- O AWS Glue oferece suporte ao controle de acesso refinado por meio do Lake Formation somente para tabelas do Apache Hive e do Apache Iceberg. Os formatos do Apache Hive incluem Parquet, ORC e CSV.
- Você só pode usar o Lake Formation com trabalhos do Spark.
- O AWS Glue com Lake Formation oferece suporte apenas a uma única sessão do Spark durante todo o trabalho.
- Quando o Lake Formation está habilitado, o AWS Glue requer um número maior de operadores, pois exige um driver de sistema, executores de sistema, um driver de usuário e, opcionalmente, executores de usuários (necessários quando o trabalho tem UDFs ou `spark.createDataFrame`).
- O AWS Glue com Lake Formation só oferece suporte a consultas de tabelas entre contas compartilhadas por meio de links de recursos. O link de recurso precisa ser nomeado de maneira idêntica ao recurso da conta de origem.
- Para habilitar o controle de acesso refinado para trabalhos do AWS Glue, passe o parâmetro de trabalho `--enable-lakeformation-fine-grained-access`.
- É possível configurar suas tarefas do AWS Glue para funcionar com a hierarquia de vários catálogos do AWS Glue. Para obter informações sobre os parâmetros de configuração a serem usados com a API `StartJobRun` do AWS Glue, consulte Como trabalhar com a hierarquia de vários catálogos do AWS Glue no EMR sem servidor.
- As seguintes opções não são compatíveis:
  - Conjuntos de dados distribuídos resilientes (RDD)
  - Streaming do Spark

  - Gravação com as permissões concedidas pelo Lake Formation
  - Controle de acesso para colunas aninhadas
- O AWS Glue bloqueia funcionalidades que podem prejudicar o isolamento completo do driver do sistema, incluindo as seguintes:
  - UDTs, HiveUDFs e qualquer função definida pelo usuário que envolva classes personalizadas
  - Fontes de dados personalizadas
  - Fornecimento de JARs adicionais para extensão, conector ou metastore do Spark
  - Comando `ANALYZE TABLE`
- Para impor controles de acesso, `EXPLAIN PLAN` e operações de DDL, como `DESCRIBE TABLE`, não expõem informações restritas.
- O AWS Glue restringe o acesso aos logs do Spark do driver do sistema em aplicações habilitadas para Lake Formation. Como o driver do sistema é executado com mais acesso, os eventos e logs que o driver do sistema gera podem incluir informações confidenciais. Para evitar que usuários ou códigos não autorizados acessem esses dados confidenciais, o AWS Glue desabilitou o acesso aos logs do driver do sistema. Para solucionar problemas, entre em contato com o suporte da AWS.
- Se você registrou uma localização de tabela no Lake Formation, o caminho de acesso aos dados passa pelas credenciais armazenadas do Lake Formation, independentemente da permissão do IAM para o perfil de runtime do trabalho do AWS Glue. Se você configurar incorretamente o perfil registrado com a localização da tabela, os trabalhos enviados que usam o perfil com a permissão do IAM para o S3 na localização da tabela falharão.
- Gravar em uma tabela do Lake Formation usa a permissão do IAM em vez das permissões concedidas pelo Lake Formation. Se o runtime do trabalho tiver as permissões necessárias do S3, será possível usá-lo para executar operações de gravação.

Observe estas considerações e limitações ao usar o Apache Iceberg:

- Você só pode usar o Apache Iceberg com o catálogo de sessões e não com catálogos nomeados arbitrariamente.
- As tabelas do Iceberg registradas no Lake Formation oferecem suporte apenas às tabelas de metadados `history`, `metadata_log_entries`, `snapshots`, `files`, `manifests` e `refs`. O AWS Glue oculta as colunas que podem conter dados confidenciais, como `partitions`, `path` e `summaries`. Essa limitação não se aplica às tabelas do Iceberg que não estão registradas no Lake Formation.

- As tabelas que você não registra no Lake Formation oferecem suporte a todos os procedimentos armazenados do Iceberg. Os procedimentos `register_table` e `migrate` não são compatíveis com nenhuma tabela.
- Recomendamos usar o Iceberg DataFrameWriterV2 em vez do V1.

Exemplo de alocação de operadores

Para um trabalho configurado com os seguintes parâmetros:

```
--enable-lakeformation-fine-grained-access=true
--number-of-workers=20
```

A alocação de operadores seria:

- Um operador para o driver do usuário.
- Um operador para o driver do sistema.
- 10% dos 18 operadores restantes (ou seja, 2 trabalhadores) reservados para os executores do usuário.
- Até 16 operadores alocados para executores do sistema.

Com o ajuste de escala automático ativado, os executores do usuário podem utilizar qualquer capacidade não alocada dos executores do sistema, se necessário.

Controlar a alocação de executores do usuário

Você pode ajustar a porcentagem de reserva para executores do usuário usando a seguinte configuração:

```
--conf spark.dynamicAllocation.maxExecutorsRatio=<value between 0 and 1>
```

Essa configuração permite um controle preciso sobre quantos executores do usuário são reservados em relação à capacidade total disponível.

Solução de problemas

Consulte as seções a seguir para soluções de problemas.

Registro em log

O AWS Glue usa perfis de recursos do Spark para dividir a execução do trabalho. O AWS Glue usa o perfil do usuário para executar o código fornecido, enquanto o perfil do sistema impõe as políticas do Lake Formation. Você pode acessar os logs das tarefas executadas como perfil de usuário.

Interface do usuário do Live e servidor de histórico do Spark

A interface de usuário do Live e o servidor de histórico do Spark têm todos os eventos do Spark gerados no perfil do usuário e os eventos editados gerados pelo driver do sistema.

Você pode ver todas as tarefas dos drivers do usuário e do sistema na guia Executores. No entanto, os links de logs estão disponíveis somente para o perfil do usuário. Além disso, algumas informações são retiradas da interface de usuário do Live, como o número de registros de saída.

O trabalho falhou com permissões insuficientes do Lake Formation

Certifique-se de que o perfil de runtime do trabalho tenha as permissões para executar SELECT e DESCRIBE na tabela que você está acessando.

Falha na execução do trabalho com RDD

No momento, o AWS Glue não oferece suporte a operações de conjunto de dados resilientes distribuídos (RDD) em trabalhos habilitados para o Lake Formation.

Não é possível acessar arquivos de dados no Amazon S3

Certifique-se de ter registrado a localização do data lake no Lake Formation.

Exceção de validação de segurança

O AWS Glue detectou um erro de validação de segurança. Entre em contato com o suporte da AWS para obter ajuda.

Compartilhamento do AWS Glue Data Catalog e de tabelas entre contas

Você pode compartilhar bancos de dados e tabelas entre contas e ainda usar o Lake Formation. Para obter mais informações, consulte Compartilhamento de dados entre contas no Lake Formation e Como faço para compartilhar o Catálogo de Dados e tabelas do AWS Glue entre contas?.

A tabela a seguir apresenta um resumo de como escolher entre o controle de acesso de alta granularidade (FGAC) e o acesso total à tabela (FTA) para sua workload.

Recurso	Controle de acesso refinado (FGAC)	Acesso total à tabela (FTA)
Access Level	Column/row level	Full table
Use Case	Queries and ETL with limited permissions	ETL
Performance Impact	Requires system/user space transitions for access control evaluation, adding latency	Optimized performance

Usar Concessão de Acesso do Amazon S3 com o AWS Glue

Com o Glue versão 5.0, a Concessão de Acesso do Amazon S3 fornece uma solução de controle de acesso escalável que você pode usar para aumentar o acesso aos dados do Amazon S3 via AWS Glue. Se você tiver uma configuração de permissão complexa ou grande para os dados do S3, poderá usar a funcionalidade Concessão de Acesso do S3 para escalar as permissões de dados do S3 para usuários e perfis.

Use a Concessão de Acesso do S3 para aumentar o acesso aos dados do Amazon S3 além das permissões concedidas pelo perfil de runtime ou pelos perfis do IAM anexados às identidades com acesso ao seu trabalho do AWS Glue. Para obter mais informações, consulte Gerenciar o acesso com o S3 Access Grants no Guia do usuário do Amazon S3.

Como o AWS Glue funciona com a Concessão de Acesso do S3

O AWS Glue versões 5.0 e superiores oferecem uma integração nativa com a Concessão de Acesso do S3. Você pode habilitar a Concessão de Acesso do S3 no AWS Glue e executar trabalhos do Spark. Quando um trabalho do Spark faz uma solicitação de dados do S3, o Amazon S3 fornece credenciais temporárias que têm como escopo o bucket, prefixo ou objeto específico.

Veja a seguir uma visão geral de alto nível sobre como o AWS Glue obtém acesso a dados aos quais a Concessão de Acesso do S3 gerencia o acesso.

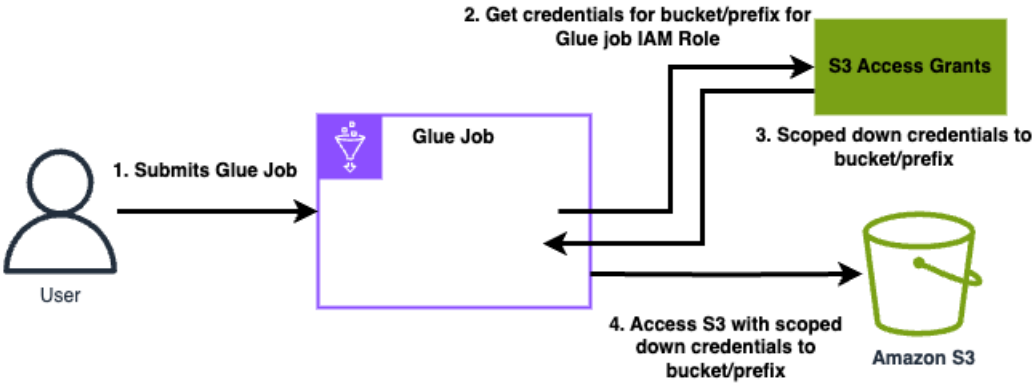

1. Um usuário envia um trabalho do AWS Glue Spark que usa dados armazenados no Amazon S3.
2. O AWS Glue solicita à Concessão de Acesso do S3 que forneça credenciais temporárias ao usuário que concedam acesso ao bucket, prefixo ou objeto.
3. O AWS Glue retorna credenciais temporárias na forma de um token do AWS Security Token Service (STS) para o usuário. O escopo do token é acessar o bucket, prefixo ou objeto do S3.
4. O AWS Glue usa o token do STS para recuperar dados do S3.
5. O AWS Glue recebe os dados do S3 e retorna os resultados ao usuário.

Considerações sobre a Concessão de Acesso do S3 com o AWS Glue

Observe os comportamentos e as limitações a seguir ao usar a Concessão de Acesso do S3 com o AWS Glue.

Suporte a recursos

- A Concessão de Acesso do S3 é compatível com o AWS Glue versões 5.0 e superiores.
- O Spark é o único tipo de trabalho válido quando a Concessão de Acesso do S3 é usada com o AWS Glue.
- Delta Lake e Hudi são os únicos formatos de tabela aberta válidos quando a Concessão de Acesso do S3 é usada com o AWS Glue.
- Os seguintes recursos não podem ser usados com a Concessão de Acesso do S3:
  - Tabelas Apache Iceberg
  - Solicitações da AWS CLI para o Amazon S3 que usam perfis do IAM
  - Acesso ao S3 por meio do protocolo de código aberto S3A

Considerações comportamentais

- O AWS Glue fornece um cache de credenciais para garantir que o usuário não precise fazer solicitações repetidas das mesmas credenciais em um trabalho do Spark. Portanto, o AWS Glue sempre solicita o privilégio de nível padrão ao solicitar credenciais. Para obter mais informações, consulte Solicitação de acesso aos dados do S3 no Guia do usuário do Amazon S3.

Configurar a Concessão de Acesso do S3 com o AWS Glue

Pré-requisitos

O chamador ou administrador criou uma instância de Concessão de Acesso do S3.

Configurar políticas e trabalhos do AWS Glue

Para configurar a Concessão de Acesso do S3 com o AWS Glue, é necessário configurar políticas de confiança e do IAM e passar a configuração por meio de parâmetros do trabalho.

1. Configure as seguintes políticas mínimas de confiança e do IAM para o perfil usado para concessões (o perfil AWS Glue que executa sessões ou trabalhos).

   Política de confiança:

```
{
            "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"
                }
            }
```

```
        }
```

Política do 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. Em seu trabalho do AWS Glue, passe a seguinte configuração do Spark por meio dos parâmetros do trabalho do AWS Glue ou `SparkConf`.

```
--conf spark.hadoop.fs.s3.s3AccessGrants.enabled=true \
--conf spark.hadoop.fs.s3.s3AccessGrants.fallbackToIAM=false
```

Registrar em log e monitorar no AWS Glue

Você pode automatizar a execução dos seus trabalhos de ETL (extração, transformação e carregamento). O AWS Glue fornece métricas para crawlers e trabalhos que você pode monitorar. Depois de configurar o AWS Glue Data Catalog com os metadados necessários, o AWS Glue fornecerá estatísticas sobre a integridade do seu ambiente. Você pode automatizar a invocação de crawlers e trabalhos com uma programação de cron baseada em hora. Você também pode ativar trabalhos quando um gatilho baseado em eventos é acionado.

O AWS Glue é integrado ao AWS CloudTrail, um serviço que fornece um registro das ações realizadas por um usuário, por uma função ou por um produto da AWS no AWS Glue. Ao criar uma trilha, você poderá habilitar a entrega contínua de eventos do CloudTrail para um bucket do Amazon Simple Storage Service (Amazon S3), Amazon CloudWatch Logs e Amazon CloudWatch Events. Cada entrada de log ou evento contém informações sobre quem gerou a solicitação.

Use o Amazon CloudWatch Events para automatizar seus produtos da AWS e responder automaticamente a eventos do sistema, como problemas de disponibilidade de aplicação ou alterações de recursos. Os eventos dos produtos da AWS são entregues ao CloudWatch Events quase em tempo real. Você pode escrever regras simples para indicar quais eventos são

interessantes e quais ações automatizadas devem ser tomadas quando um evento corresponder a uma regra.

Consulte também

- Automação do AWS Glue com o EventBridge
- Registro em log no CloudTrail entre contas

Um aspecto importante da segurança na nuvem é o registro em log. Você deve configurar o registro em log de modo a não capturar segredos e material confidencial enquanto captura as informações necessárias para depurar e proteger sua estrutura de infraestrutura na nuvem. Não esqueça de se familiarizar com o que está sendo registrado em log.

Validação de conformidade do AWS Glue

Para saber se um AWS service (Serviço da AWS) está no escopo de programas de conformidade específicos, consulte Serviços da AWS no escopo por programa de conformidade e selecione o programa de conformidade em que você está interessado. Para obter informações gerais, consulte Programas de Conformidade da AWS.

É possível baixar relatórios de auditoria de terceiros usando o AWS Artifact. Para obter mais informações, consulte Baixar relatórios no AWS Artifact.

Sua responsabilidade de conformidade ao usar o Serviços da AWS é determinada pela confidencialidade dos seus dados, pelos objetivos de conformidade da sua empresa e pelos regulamentos e leis aplicáveis. A AWS fornece os recursos a seguir para ajudar com a conformidade:

- Governança e conformidade de segurança: esses guias de implementação de solução abordam considerações sobre a arquitetura e fornecem etapas para implantar recursos de segurança e conformidade.
- Referência de serviços qualificados para HIPAA: lista os serviços qualificados para HIPAA. Nem todos os Serviços da AWS estão qualificados pela HIPAA.
- Recursos de Conformidade da AWS: essa coleção de manuais e guias pode ser aplicada ao seu setor e local.
- Guias de conformidade do cliente da AWS: entenda o modelo de responsabilidade compartilhada sob a ótica da conformidade. Os guias resumem as práticas recomendadas para proteção de

Serviços da AWS e mapeiam as diretrizes para controles de segurança em várias estruturas (incluindo o Instituto Nacional de Padrões e Tecnologia (NIST), o Conselho de Padrões de Segurança do Setor de Cartões de Pagamento (PCI) e a Organização Internacional de Padronização (ISO)).

- Avaliar recursos com regras no Guia do desenvolvedor do AWS Config: o serviço AWS Config avalia como as configurações de recursos estão em conformidade com práticas internas, diretrizes do setor e regulamentos.
- AWS Security Hub: este AWS service (Serviço da AWS) fornece uma visão abrangente do seu estado de segurança na AWS. O Security Hub usa controles de segurança para avaliar os recursos da AWS e verificar a conformidade com os padrões e as práticas recomendadas do setor de segurança. Para obter uma lista dos serviços e controles aceitos, consulte a Referência de controles do Security Hub.
- Amazon GuardDuty: este AWS service (Serviço da AWS) detecta possíveis ameaças às suas Contas da AWS, workloads, contêineres e dados ao monitorar o ambiente em busca de atividades suspeitas e maliciosas. O GuardDuty pode ajudar você a atender a diversos requisitos de conformidade, como o PCI DSS, com o cumprimento dos requisitos de detecção de intrusões requeridos por determinadas estruturas de conformidade.
- AWS Audit Manager: este AWS service (Serviço da AWS) ajuda você a auditar continuamente o seu uso da AWS para simplificar o modo como você gerencia os riscos e a conformidade com regulamentos e padrões do setor.

Resiliência no AWS Glue

A infraestrutura global da AWS é criada com base em AWS Regiões e Zonas de Disponibilidade. AWS As regiões fornecem várias zonas de disponibilidade separadas e isoladas fisicamente, as quais são conectadas com baixa latência, alto throughput e redes altamente redundantes. Com as zonas de disponibilidade, você pode projetar e operar aplicações e bancos de dados que executam o failover automaticamente entre as zonas de disponibilidade sem interrupção. As zonas de disponibilidade são mais altamente disponíveis, tolerantes a falhas e escaláveis que uma ou várias infraestruturas de data center tradicionais.

Para mais informações sobre regiões e zonas de disponibilidade da AWS, consulte Infraestrutura global da AWS.

Para obter mais informações sobre resiliência do trabalho do AWS Glue, consulte Erro: comportamento de failover entre VPCs no AWS Glue.

Segurança da infraestrutura no AWS Glue

Como um serviço gerenciado, o AWS Glue é protegido pelos procedimentos de segurança de rede global da AWS que estão descritos no whitepaper Amazon Web Services: Overview of Security Processes.

Você usa AWS Glue chamadas de API publicadas pela para acessarAWS o por meio da rede. Os clientes devem oferecer compatibilidade com Transport Layer Security (TLS) 1.0 ou posterior. Recomendamos TLS 1.2 ou posterior. Os clientes também devem ter compatibilidade com conjuntos de criptografia com perfect forward secrecy (PFS) como Ephemeral Diffie-Hellman (DHE) ou Ephemeral Elliptic Curve Diffie-Hellman (ECDHE). A maioria dos sistemas modernos como Java 7 e versões posteriores oferece compatibilidade com esses modos.

Além disso, as solicitações devem ser assinadas usando um ID da chave de acesso e uma chave de acesso secreta associada a uma entidade principal do IAM. Ou você pode usar o AWS Security Token Service (AWS STS) para gerar credenciais de segurança temporárias para assinar solicitações.

Tópicos

- Configurar VPC endpoints de interface (AWS PrivateLink) para AWS Glue (AWS PrivateLink)
- Configurar Amazon VPCs compartilhadas

Configurar VPC endpoints de interface (AWS PrivateLink) para AWS Glue (AWS PrivateLink)

É possível estabelecer uma conexão privada entre a VPC e o AWS Glue criando um endpoint da VPC de interface. Os endpoints de interface são habilitados por AWS PrivateLink, uma tecnologia que permite acessar de forma privada as APIs do AWS Glue sem um gateway da Internet, um dispositivo NAT, uma conexão VPN ou uma conexão do AWS Direct Connect. As instâncias na VPC não precisam de endereços IP públicos para a comunicação com APIs do AWS Glue. O tráfego de rede entre a VPC e o AWS Glue não deixa a rede da Amazon.

Cada endpoint de interface é representado por uma ou mais interfaces de rede elástica nas sub-redes.

Para mais informações, consulte VPC endpoints de interface (AWS PrivateLink) no Guia do usuário da Amazon VPC.

Considerações sobre endpoints da VPC do AWS Glue

Antes de configurar um endpoint da VPC de interface para AWS Glue, certifique-se de revisar as Propriedades e limitações do endpoint de interface no Guia do Usuário da Amazon VPC.

O AWS Glue oferece suporte a chamadas para todas as ações de API da VPC.

Criar um endpoint da VPC de interface para o AWS Glue

É possível criar um endpoint da VPC para o serviço AWS Glue usando o console do Amazon VPC ou a AWS Command Line Interface (AWS CLI). Para obter mais informações, consulte Criar um endpoint de interface no Guia do Usuário do Amazon VPC.

Crie um endpoint da VPC para o AWS Glue usando o seguinte nome de serviço:

- com.amazonaws.*região*.glue

Se você habilitar o DNS privado para o endpoint, poderá fazer solicitações de API para o AWS Glue usando seu nome DNS padrão para a região, por exemplo, `glue.us-east-1.amazonaws.com`.

Para obter mais informações, consulte Acessar um serviço por um endpoint de interface no Manual do Usuário do Amazon VPC.

Criando uma política de endpoint da VPC para o AWS Glue

É possível anexar uma política de endpoint ao endpoint da VPC que controla o acesso ao AWS Glue. Essa política especifica as seguintes informações:

- A entidade principal que pode executar ações.
- As ações que podem ser executadas.
- Os recursos sobre os quais as ações podem ser realizadas.

Para obter mais informações, consulte Controlar o acesso a serviços com endpoints da VPC no Guia do Usuário do Amazon VPC.

Exemplo: política de endpoint de VPC para o AWS Glue para permitir a criação e atualização do trabalho

Veja a seguir um exemplo de uma política de endpoint para o AWS Glue. Quando anexada a um endpoint, essa política concede acesso às ações indicadas do AWS Glue para todos os principais em todos os recursos.

```
{
   "Statement":[
      {
         "Principal":"*",
         "Effect":"Allow",
         "Action":[
             "glue:CreateJob",
             "glue:UpdateJob",
             "iam:PassRole"
         ],
         "Resource":"*"
      }
   ]
}
```

Exemplo: política de endpoint de VPC para permitir acesso somente de leitura ao catálogo de dados

Veja a seguir um exemplo de uma política de endpoint para o AWS Glue. Quando anexada a um endpoint, essa política concede acesso às ações indicadas do AWS Glue para todos os principais em todos os recursos.

```
{
    "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": "*"
        }
    ]
}
```

Configurar Amazon VPCs compartilhadas

O AWS Glue é compatível com nuvens privadas virtuais (VPCs) compartilhadas na Amazon Virtual Private Cloud. O compartilhamento da Amazon VPC permite que várias contas da AWS criem os recursos de aplicações, como instâncias do Amazon EC2 e bancos de dados do Amazon Relational Database Service (Amazon RDS), em Amazon VPCs compartilhadas e gerenciadas centralmente. Nesse modelo, a conta que possui a VPC (proprietária) compartilha uma ou mais sub-redes com outras contas (participantes) que pertencem à mesma organização no AWS Organizations. Quando uma sub-rede é compartilhada, os participantes podem visualizar, criar, modificar e excluir os recursos de aplicativos nas sub-redes compartilhadas com eles.

No AWS Glue, para criar uma conexão com uma sub-rede compartilhada, é necessário criar um grupo de segurança em sua conta e anexá-lo à sub-rede compartilhada.

Para obter mais informações, consulte estes tópicos:

- Trabalhar com VPCs compartilhadas no Manual do usuário da Amazon VPC
- O que é o AWS Organizations? no Manual do usuário do AWS Organizations

Solução de problemas de AWS Glue

Se você encontrar problemas ao trabalhar com AWS Glue, consulte os tópicos desta seção.

Tópicos

- Reunir informações sobre a solução de problemas do AWS Glue
- Solucionar problemas de erros no Spark
- Erros do crawler ao usar permissões do Lake Formation
- Solucionar problemas do AWS Glue para erros do Ray a partir de logs
- Exceções de machine learning do AWS Glue
- Cotas do AWS Glue

Reunir informações sobre a solução de problemas do AWS Glue

Se você encontrar erros ou um comportamento inesperado no AWS Glue e precisar entrar em contato com o AWS Support, reúnas as informações sobre nomes, IDs e logs associados à ação com falha. A disponibilização dessas informações permite que o Suporte ajude você a solucionar os problemas.

Além do seu ID de conta, forneça as seguintes informações para cada um desses tipos de falhas:

Quando um crawler falhar, reúna as seguintes informações:

- Nome do crawler

  Os logs das execuções de crawlers estão localizados no CloudWatch Logs, em `/aws-glue/crawlers`.

Quando uma conexão de teste falhar, reúna as seguintes informações:

- Connection name (Nome da conexão)
- ID da conexão
- String de conexão do JDBC no formato `jdbc:protocol://host:port/database-name`.

  Os logs das conexões de teste estão localizados no CloudWatch Logs, em `/aws-glue/testconnection`.

Quando um trabalho falhar, reúna as seguintes informações:

- Nome do trabalho

- ID de execução do trabalho, no formato `jr_xxxxx`.

  Os logs das execuções de trabalhos estão localizados no CloudWatch Logs, em `/aws-glue/jobs`.

Solucionar problemas de erros no Spark

Se você encontrar erros no AWS Glue, use as seguintes soluções para ajudar você a encontrar a origem dos problemas e corrigi-los.

> **Note**
>
> O repositório do AWS Glue no GitHub contém mais orientações para a solução de problemas em Perguntas frequentes do AWS Glue.

Tópicos

- Erro: Resource unavailable (Recurso indisponível)
- Erro: Could not find S3 endpoint or NAT gateway for subnetId in VPC (Não foi possível encontrar o endpoint do S3 nem o gateway NAT para subnetId na VPC)
- Erro: Inbound rule in security group required (A regra de entrada no grupo de segurança é obrigatória)
- Erro: Outbound rule in security group required (A regra de saída no grupo de segurança é obrigatória)
- Erro: falha na execução do trabalho porque o perfil passado deveria receber as permissões de assumir o perfil para o serviço AWS Glue
- Erro: a ação DescribeVpcEndpoints não está autorizada. Não foi possível validar o ID da VPC vpc-id
- Erro: a ação DescribeRouteTables não está autorizada. Não é possível validar o ID da sub-rede Subnet-id no ID da VPC vpc-id
- Erro: Failed to call ec2:DescribeSubnets (Falha ao chamar ec2:DescribeSubnets)
- Erro: Failed to call ec2:DescribeSecurityGroups (Falha ao chamar ec2:DescribeSecurityGroups)
- Erro: Could not find subnet for AZ (Não foi possível encontrar uma sub-rede para zona de disponibilidade)

- Erro: Job run exception when writing to a JDBC target (Exceção de execução de trabalho ao gravar um destino JDBC)
- Erro: Amazon S3: a operação não é válida para a classe de armazenamento do objeto
- Erro: Amazon S3 timeout (Tempo limite do Amazon S3)
- Erro: Amazon S3 access denied (Acesso negado ao Amazon S3)
- Erro: Amazon S3 access key ID does not exist (O ID da chave de acesso do Amazon S3 não existe)
- Erro: falha na execução do trabalho ao acessar o Amazon S3 com um URI s3a://
- Erro: Amazon S3 service token expired (O token do serviço do Amazon S3 expirou)
- Erro: No private DNS for network interface found (Nenhum DNS privado foi encontrado na interface de rede)
- Erro: Development endpoint provisioning failed (Falha no provisionamento do endpoint de desenvolvimento)
- Erro: Notebook server CREATE_FAILED (Servidor de cadernos com status CREATE_FAILED)
- Erro: Local notebook fails to start (Falha ao iniciar o caderno local)
- Erro: Running crawler failed (Falha na execução do crawler)
- Erro: Partitions were not updated (As partições não foram atualizadas)
- Erro: Job bookmark update failed due to version mismatch (A atualização do marcador de trabalho falhou devido à incompatibilidade da versão)
- Erro: A job is reprocessing data when job bookmarks are enabled (Um trabalho está reprocessando dados quando marcadores do trabalho estão habilitados)
- Erro: comportamento de failover entre VPCs no AWS Glue

Erro: Resource unavailable (Recurso indisponível)

Se o AWS Glue retornar uma mensagem de recurso indisponível, você poderá visualizar as mensagens ou logs de erro para saber mais sobre o problema. As tarefas a seguir descrevem métodos gerais para a solução de um problema.

- Para quaisquer conexões e endpoints de desenvolvimento que você usar, verifique se o seu cluster não ficou sem interfaces de rede elástica.

Erro: Could not find S3 endpoint or NAT gateway for subnetId in VPC (Não foi possível encontrar o endpoint do S3 nem o gateway NAT para subnetId na VPC)

Verifique o ID da sub-rede e o ID da VPC na mensagem para diagnosticar o problema.

- Verifique se você possui um endpoint da VPC do Amazon S3 configurado (necessário para uso com o AWS Glue). Além disso, verifique seu gateway NAT se ele for parte da configuração. Para ter mais informações, consulte Endpoints da Amazon VPC para o Amazon S3.

Erro: Inbound rule in security group required (A regra de entrada no grupo de segurança é obrigatória)

Pelo menos um security group precisa abrir todas as portas de entrada. Para limitar o tráfego, o security group de origem na sua regra de entrada pode ser restrito ao mesmo security group.

- Para todas as conexões que você usar, verifique se seu security group contém uma regra de entrada de autorreferenciada. Para ter mais informações, consulte Configurar o acesso de rede aos armazenamentos de dados.
- Ao usar um endpoint de desenvolvimento, verifique se seu security group contém para uma regra de entrada de autorreferenciada. Para ter mais informações, consulte Configurar o acesso de rede aos armazenamentos de dados.

Erro: Outbound rule in security group required (A regra de saída no grupo de segurança é obrigatória)

Pelo menos um security group precisa abrir todas as portas de saída. Para limitar o tráfego, o security group de origem na sua regra de saída pode ser restrito ao mesmo security group.

- Para todas as conexões que você usar, verifique se seu security group contém uma regra de saída de autorreferenciada. Para ter mais informações, consulte Configurar o acesso de rede aos armazenamentos de dados.
- Ao usar um endpoint de desenvolvimento, verifique se seu security group contém para uma regra de saída de autorreferenciada. Para ter mais informações, consulte Configurar o acesso de rede aos armazenamentos de dados.

Erro: falha na execução do trabalho porque o perfil passado deveria receber as permissões de assumir o perfil para o serviço AWS Glue

O usuário que define um trabalho precisa ter permissão para `iam:PassRole` no AWS Glue.

- Quando um usuário cria um trabalho do AWS Glue, confirme se a função do usuário contém uma política com `iam:PassRole` para o AWS Glue. Para ter mais informações, consulte Etapa 3: anexar uma política aos usuários ou grupos que acessam o AWS Glue.

Erro: a ação DescribeVpcEndpoints não está autorizada. Não foi possível validar o ID da VPC vpc-id

- Verifique a política transmitida para o AWS Glue pela permissão `ec2:DescribeVpcEndpoints`.

Erro: a ação DescribeRouteTables não está autorizada. Não é possível validar o ID da sub-rede Subnet-id no ID da VPC vpc-id

- Verifique a política transmitida para o AWS Glue pela permissão `ec2:DescribeRouteTables`.

Erro: Failed to call ec2:DescribeSubnets (Falha ao chamar ec2:DescribeSubnets)

- Verifique a política transmitida para o AWS Glue pela permissão `ec2:DescribeSubnets`.

Erro: Failed to call ec2:DescribeSecurityGroups (Falha ao chamar ec2:DescribeSecurityGroups)

- Verifique a política transmitida para o AWS Glue pela permissão `ec2:DescribeSecurityGroups`.

Erro: Could not find subnet for AZ (Não foi possível encontrar uma sub-rede para zona de disponibilidade)

- A zona de disponibilidade pode estar indisponível para o AWS Glue. Crie e use uma nova sub-rede em uma zona de disponibilidade diferente da especificada na mensagem.

Erro: Job run exception when writing to a JDBC target (Exceção de execução de trabalho ao gravar um destino JDBC)

Ao executar um trabalho que grava em um destino JDBC, ele pode encontrar erros nas seguintes situações:

- Se o seu trabalho gravar em uma tabela do Microsoft SQL Server, e a tabela possuir colunas definidas como tipo `Boolean`, ela deverá ser predefinida no banco de dados do SQL Server. Ao definir o trabalho no console do AWS Glue usando um destino do SQL Server com a opção Create tables in your data target (Criar tabelas no seu destino de dados), não mapeie nenhuma coluna de origem para uma coluna de destino com tipo de dados `Boolean`. Você poderá encontrar um erro quando o trabalho for executado.

  Você pode evitar fazendo o seguinte:

  - Escolha uma tabela existente com a coluna Boolean.
  - Edite a transformação `ApplyMapping` e mapeie a coluna Boolean na fonte para um número ou uma string no destino.
  - Edite a transformação `ApplyMapping` para remover a coluna Boolean da fonte.
- Se o seu trabalho escrever em uma tabela Oracle, será necessário ajustar o comprimento dos nomes dos objetos Oracle. Em algumas versões do Oracle, o comprimento máximo do identificador é limitado a 30 ou 128 bytes. Esse limite afeta os nomes das tabelas e os nomes das colunas dos armazenamentos de dados de destino Oracle.

  Você pode evitar fazendo o seguinte:

  - Nomeie as tabelas de destino Oracle de acordo com o limite da sua versão.
  - Os nomes de coluna padrão são gerados a partir dos nomes dos campos nos dados. Quando os nomes das colunas forem mais longos do que o limite, use transformações `ApplyMapping` ou `RenameField` para alterar o nome da coluna de modo que ela fique dentro do limite.

Erro: Amazon S3: a operação não é válida para a classe de armazenamento do objeto

Se o AWS Glue retornar esse erro, seu trabalho do AWS Glue pode estar lendo dados de tabelas que têm partições em vários níveis de classe de armazenamento do Amazon S3.

- Ao usar exclusões de classe de armazenamento, você pode garantir que seus trabalhos do AWS Glue funcionarão em tabelas com partições entre esses níveis de classe de armazenamento. Sem exclusões, trabalhos que leem dados desses níveis falham com o seguinte erro: `AmazonS3Exception: The operation is not valid for the object's storage class`.

  Para ter mais informações, consulte Excluir classes de armazenamento do Amazon S3.

Erro: Amazon S3 timeout (Tempo limite do Amazon S3)

Se o AWS Glue retornar um erro de tempo limite de conexão, é possível que ele esteja tentando acessar um bucket do Amazon S3 em outra região da AWS.

- Um endpoint da VPC do Amazon S3 pode rotear tráfego somente para os buckets de uma região da AWS. Se você precisar se conectar aos buckets em outras regiões, tente usar um gateway NAT como uma solução alternativa. Para obter mais informações, consulte Gateways NAT.

Erro: Amazon S3 access denied (Acesso negado ao Amazon S3)

Se o AWS Glue retornar um erro de acesso negado a um bucket ou objeto do Amazon S3, é possível que a função do IAM fornecida não possua uma política com permissão para o seu datastore.

- Um trabalho de ETL precisa de acesso ao datastore do Amazon S3 usado como fonte ou destino. Um crawler precisa de acesso ao datastore do Amazon S3 que ele rastreia. Para ter mais informações, consulte Etapa 2: criar um perfil do IAM para o AWS Glue.

Erro: Amazon S3 access key ID does not exist (O ID da chave de acesso do Amazon S3 não existe)

Se, ao executar um trabalho, o AWS Glue retornar um erro informando que o ID de chave de acesso não existe, é possível que:

- Um trabalho de ETL usa uma função do IAM para acessar os armazenamentos de dados. Verifique se a função do IAM para o seu trabalho não foi excluída antes do início dele.
- Uma função do IAM contém permissões para acessar seus armazenamentos de dados. Verifique se as políticas anexadas do Amazon S3 que contêm `s3:ListBucket` estão corretas.

Erro: falha na execução do trabalho ao acessar o Amazon S3 com um URI **s3a://**

Se a execução de um trabalho retornar um erro como Failed to parse XML document with handler class (Falha ao analisar um documento XML com a classe handler), pode ser devido a uma falha ao tentar listar centenas de arquivos usando um URI `s3a://`. Acesse seu datastore usando um URI `s3://`. O rastreamento de exceções a seguir destaca os erros a serem procurados:

```
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(XmlRespons
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(ParquetOutputWrit
32. at org.apache.spark.sql.execution.datasources.FileFormatWriter
$SingleDirectoryWriteTask.releaseResources(FileFormatWriter.scala:252)
33. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun
$org$apache$spark$sql$execution$datasources$FileFormatWriter$$executeTask
$3.apply(FileFormatWriter.scala:191)
34. at org.apache.spark.sql.execution.datasources.FileFormatWriter$$anonfun
$org$apache$spark$sql$execution$datasources$FileFormatWriter$$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$datasources$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)
```

Erro: Amazon S3 service token expired (O token do serviço do Amazon S3 expirou)

Ao mover dados de e para o Amazon Redshift, as credenciais temporárias do Amazon S3, que expiram após uma hora, são usadas. Se você tiver um trabalho de longa execução, ele poderá falhar. Para obter informações sobre como configurar seus trabalhos de longa duração de execução para mover dados de e para o Amazon Redshift, consulte aws-glue-programming-etl-connect-redshift-home.

Erro: No private DNS for network interface found (Nenhum DNS privado foi encontrado na interface de rede)

Se um trabalho falhar ou um endpoint de desenvolvimento não for provisionado, é possível que tenha ocorrido um problema na configuração da rede.

- Se você estiver usando o DNS fornecido pela Amazon, o valor de `enableDnsHostnames` deverá ser true. Para mais informações, consulte DNS.

Erro: Development endpoint provisioning failed (Falha no provisionamento do endpoint de desenvolvimento)

Se o AWS Glue não conseguir fornecer um endpoint de desenvolvimento com sucesso, é possível que tenha ocorrido um problema na configuração da rede.

- Ao definir um endpoint de desenvolvimento, a VPC, a sub-rede e os security groups são validados para confirmar se atendem a determinados requisitos.
- Se você forneceu a chave pública SSH opcional, verifique se ela está válida.
- Verifique no console da VPC se a sua VPC está usando um DHCP option set válido. Para obter mais informações, consulte Conjuntos de opções de DHCP.
- Se o cluster permanecer no estado PROVISIONING (Provisionamento), entre em contato com o AWS Support.

Erro: Notebook server CREATE_FAILED (Servidor de cadernos com status CREATE_FAILED)

Se o AWS Glue não conseguir criar o servidor de notebook para um endpoint de desenvolvimento, é possível que um dos seguintes problemas tenha ocorrido:

- O AWS Glue transmite uma função do IAM para o Amazon EC2 durante a configuração do servidor de cadernos. A função do IAM precisa ter uma relação de confiança com o Amazon EC2.
- A função do IAM precisa ter um perfil da instância com o mesmo nome. Quando você cria a função para o Amazon EC2 usando o console do IAM, o perfil da instância com o mesmo nome é automaticamente criado. Verifique se há um erro no log referente a um nome de perfil da instância `iamInstanceProfile.name` que seja inválido. Para obter mais informações, consulte Usar perfis de instância.
- Verifique se sua função tem permissão para acessar buckets do `aws-glue*` na política que você transmitiu para criar o servidor da notebook.

Erro: Local notebook fails to start (Falha ao iniciar o caderno local)

Se o seu notebook local não for iniciado houver indicação de erros referentes a diretórios ou pastas não encontrados, é possível que um dos seguintes problemas tenha ocorrido:

- Se você estiver utilizando o Microsoft Windows, verifique se a variável de ambiente `JAVA_HOME` aponta para o diretório correto do Java. É possível atualizar o Java sem atualizar essa variável e, se ela apontar para uma pasta que não existe mais, os cadernos Jupyter não serão inicializados.

Erro: Running crawler failed (Falha na execução do crawler)

Se o AWS Glue apresentar falha ao executar um crawler para catalogar seus dados, é possível que um destes problemas tenha ocorrido. Verifique primeiro se o erro está presente na lista de crawlers do console do AWS Glue. Verifique se há um ícone de exclamação ao lado do nome do crawler e posicione o mouse sobre o ícone para ver as mensagens associadas.

- Verifique os logs de execução do crawler no CloudWatch Logs, em `/aws-glue/crawlers`.

Erro: Partitions were not updated (As partições não foram atualizadas)

Caso as suas partições não tenham sido atualizadas no Data Catalog ao executar um trabalho de ETL, estas instruções de log da classe `DataSink` no CloudWatch Logs podem ser úteis:

- `"Attempting to fast-forward updates to the Catalog - nameSpace:"` – mostra qual banco de dados, tabela e catalogId este trabalho tentará modificar. Se essa instrução não estiver aqui, verifique se `enableUpdateCatalog` está definido como verdadeiro e corretamente passado como um parâmetro `getSink()` ou em `additional_options`.
- `"Schema change policy behavior:"` – mostra qual valor `updateBehavior` do esquema foi passado.
- `"Schemas qualify (schema compare):"` – será verdadeiro ou falso.
- `"Schemas qualify (case-insensitive compare):"` – será verdadeiro ou falso.
- Se ambos forem false e o `updateBehavior` não estiver definido como `UPDATE_IN_DATABASE`, o esquema do DynamicFrame deverá ser idêntico ou conter um subconjunto das colunas visualizadas no esquema da tabela do Data Catalog.

Para obter mais informações sobre a atualização de partições, consulte Atualizar esquemas e adicionar novas partições ao Catálogo de Dados em trabalhos do AWS Glue ETL.

Erro: Job bookmark update failed due to version mismatch (A atualização do marcador de trabalho falhou devido à incompatibilidade da versão)

Você pode estar tentando parametrizar trabalhos do AWS Glue para aplicar a mesma transformação/lógica em conjuntos de dados diferentes no Amazon S3. Você deseja rastrear arquivos processados nos locais fornecidos. Quando você executa o mesmo trabalho no mesmo bucket de origem e grava simultaneamente no mesmo/em outro destino (simultaneidade >1), o trabalho falha com este erro:

```
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
```

Solução: defina a simultaneidade como 1 ou não execute o trabalho simultaneamente.

Atualmente os marcadores do AWS Glue não são compatíveis com execuções de trabalhos simultâneas, e as confirmações falharão.

Erro: A job is reprocessing data when job bookmarks are enabled (Um trabalho está reprocessando dados quando marcadores do trabalho estão habilitados)

Pode haver situações em que você habilitou os marcadores de trabalho do AWS Glue, mas o trabalho de ETL está reprocessando dados que já foram processados em uma execução anterior. Verifique se essas causas comuns desse erro existem:

Simultaneidade máxima

Definir o número máximo de execuções simultâneas para o trabalho maior que o valor padrão de 1 pode interferir nos marcadores do trabalho. Isso pode ocorrer quando marcadores de trabalhos verificam a hora da última modificação de objetos para verificar quais objetos precisam ser reprocessados. Para obter mais informações, consulte a discussão sobre simultaneidade máxima em Configurar propriedades de trabalho para trabalhos do Spark no AWS Glue.

Objeto de trabalho ausente

Verifique se o script de execução do trabalho termina com a seguinte confirmação:

```
job.commit()
```

Quando você inclui esse objeto, o AWS Glue registra o time stamp e o caminho da execução do trabalho. Se você executar o trabalho novamente com o mesmo caminho, o AWS Glue processará apenas os arquivos novos. Se você não incluir esse objeto, e os marcadores do trabalho estiverem habilitados, o trabalho reprocessará os arquivos já processados junto com os arquivos novos e criará redundância no datastore de destino do trabalho.

Parâmetro de contexto da transformação ausente

O contexto de transformação é um parâmetro opcional na classe `GlueContext`, mas os marcadores de trabalho não funcionarão se você não o incluir. Para resolver esse erro, adicione o parâmetro de contexto de transformação ao criar o DynamicFrame, conforme mostrado a seguir:

```
sample_dynF=create_dynamic_frame_from_catalog(database,
 table_name,transformation_ctx="sample_dynF")
```

Fonte de entrada

Se você estiver usando um banco de dados relacional (uma conexão JDBC) para a fonte de entrada, os marcadores de trabalho só funcionarão se as chaves primárias da tabela estiverem em ordem sequencial. Os marcadores de trabalhos funcionam para linhas novas, mas não para linhas atualizadas. Isso ocorre porque os marcadores de trabalho procuram as chaves primárias, que já existem. Isso não se aplica se a fonte de entrada for o Amazon Simple Storage Service (Amazon S3).

Hora da última modificação

Para fontes de entrada do Amazon S3, os marcadores de trabalho verificam a hora da última modificação dos objetos, em vez dos nomes de arquivo, para verificar quais objetos precisam ser reprocessados. Se os dados da fonte de entrada tiverem sido modificados desde a última execução do trabalho, os arquivos serão reprocessados quando você executar o trabalho novamente.

Erro: comportamento de failover entre VPCs no AWS Glue

O processo a seguir é usado para failover de trabalhos no AWS Glue versão 4.0 e nas versões anteriores.

Resumo: uma conexão do AWS Glue é selecionada no momento em que uma execução de trabalho é enviada. Se a execução do trabalho encontrar alguns problemas (falta de endereços IP, conectividade com a fonte, problema de roteamento), a execução do trabalho falhará. Se as novas tentativas estiverem configuradas, o AWS Glue tentará novamente com a mesma conexão.

1. Para cada tentativa de execução, o AWS Glue verificará a integridade das conexões, na ordem listada na configuração do trabalho, até encontrar uma que possa ser usada. No caso de uma falha na Zona de Disponibilidade (AZ), as conexões dessa AZ falharão na verificação e serão ignoradas.
2. O AWS Glue valida a conexão com o seguinte:
   - verifica se existem ID e sub-rede da Amazon VPC válidos.
   - verifica se existe um gateway NAT ou um endpoint da Amazon VPC.
   - verifica se a sub-rede tem mais de 0 endereços IP alocados.
   - verifica se a AZ está íntegra.

   O AWS Glue não consegue verificar a conectividade no momento do envio da execução do trabalho.
3. Para trabalhos usando a Amazon VPC, todos os drivers e executores serão criados na mesma AZ com a conexão selecionada no momento do envio da execução do trabalho.

4. Se as novas tentativas estiverem configuradas, o AWS Glue tentará novamente com a mesma conexão. Isso ocorre porque não podemos garantir que os problemas com essa conexão sejam de longa duração. Se uma AZ falhar, as execuções de trabalhos existentes (dependendo do estágio da execução do trabalho) nessa AZ poderá falhar. Uma nova tentativa deve detectar uma falha de AZ e escolher outra AZ para a nova execução.

Erros do crawler ao usar permissões do Lake Formation

Use as informações abaixo para diagnosticar e corrigir vários problemas ao configurar o crawler usando as credenciais do Lake Formation.

Erro: The S3 location: s3://examplepath is not registered (O local do S3: s3://examplepath não está registrado)

Para que um crawler seja executado usando as credenciais do Lake Formation, você precisa primeiro configurar as permissões do Lake Formation. Para resolver esse erro, registre o local de destino do Amazon S3 no Lake Formation. Para obter mais informações, consulte Registering an Amazon S3 location (Registrar um local do Amazon S3).

Erro: User/Role is not authorized to perform: lakeformation:GetDataAccess on resource (O usuário/função não está autorizado(a) a executar lakeformation:GetDataAccess no recurso)

Adicione a permissão `lakeformation:GetDataAccess` à função do crawler usando o console do IAM ou a AWS CLI. Com essa permissão, o Lake Formation concede a solicitação de credenciais temporárias para acessar os dados. Consulte a política abaixo:

```
{
  "Version": "2012-10-17",
  "Statement": {
    "Effect": "Allow",
    "Action": [
      "lakeformation:GetDataAccess"
    ],
    "Resource": "*"
  }
}
```

Erro: Insufficient Lake Formation permission(s) on (Database name: exampleDatabase, Table Name: exampleTable) (Permissão(ões) do Lake Formation insuficiente(s) em (Nome do banco de dados: exampleDatabase, Nome da tabela: exampleTable))

No console do Lake Formation (https://console.aws.amazon.com/lakeformation/), conceda permissões de acesso à função do crawler (`Create`, `Describe`, `Alter`) no banco de dados, que é especificado como o banco de dados de saída. Você também pode conceder permissões na tabela. Para obter mais informações, consulte Granting database permissions using the named resource method (Conceder permissões de banco de dados usando o método de recurso nomeado).

Erro: Insufficient Lake Formation permission(s) on s3://examplepath (Permissão(ões) insuficiente(s) do Lake Formation em s3://examplepath)

1. Crawling entre contas
   a. Faça login no console do Lake Formation (https://console.aws.amazon.com/lakeformation/) usando a conta em que o bucket do Amazon S3 está registrado (conta B). Conceda permissões de localização de dados para a conta em que o crawler será executado. Isso permitirá que o crawler leia os dados da localização de destino do Amazon S3.
   b. Na conta na qual o crawler é criado (conta A), conceda permissões de localização de dados na localização de destino do Amazon S3 ao perfil do IAM usado para a execução do crawler, de modo que o crawler possa ler os dados do destino no Lake Formation. Para obter mais informações, consulte Granting data location permissions (same account) (Conceder permissões de localização de dados (mesma conta)).
2. Crawling na conta (crawler e localização registrada do Amazon S3 estão na mesma conta): conceda permissões de localização de dados ao perfil do IAM usado para a execução do crawler, de modo que o crawler possa ler os dados do destino no Lake Formation. Para obter mais informações, consulte Granting data location permissions (same account) (Conceder permissões de localização de dados [mesma conta]).

Perguntas frequentes sobre a configuração do crawler usando as credenciais do Lake Formation

1. Como faço para configurar um crawler para ser executado usando as credenciais do Lake Formation por meio do console da AWS?

   No console do AWS Glue (https://console.aws.amazon.com/glue/), ao configurar o crawler, selecione a opção Use Lake Formation credentials for crawling Amazon S3 data source (Usar credenciais do Lake Formation para crawling da fonte de dados do Amazon S3). Para crawling entre contas, especifique o ID da Conta da AWS na qual a localização de destino do Amazon S3 está registrada no Lake Formation. O campo accountId é opcional para crawling na conta.

2. Como faço para configurar um crawler para ser executado usando as credenciais do Lake Formation por meio da AWS CLI?

   Durante a chamada da API `CreateCrawler`, adicione `LakeFormationConfiguration`:

   ```
   "LakeFormationConfiguration": {
       "UseLakeFormationCredentials": true,
       "AccountId": "111111111111" (AWS account ID where the target Amazon S3 location
    is registered with Lake Formation)
     }
   ```

3. Quais são os destinos compatíveis com um crawler que usa as credenciais do Lake Formation?

   Um crawler que usa credenciais do Lake Formation só é compatível com destinos do Amazon S3 (crawling na conta e entre contas) e do catálogo de dados na conta (onde a localização subjacente é o Amazon S3) e em destinos do Apache Iceberg.

4. Posso fazer crawling de vários buckets do Amazon S3 como parte de um único crawler usando as credenciais do Lake Formation?

   Não. Para destinos de crawling que utilizam o fornecimento de credenciais do Lake Formation, as localizações subjacentes do Amazon S3 devem pertencer ao mesmo bucket. Por exemplo, os clientes podem usar vários locais de destino (`s3://bucket1/folder1, s3://bucket1/folder2`) se estiverem no mesmo bucket (bucket1). Não existe suporte para a especificação de buckets diferentes (s3://bucket1/folder1, s3://bucket2/folder2).

Solucionar problemas do AWS Glue para erros do Ray a partir de logs

O AWS Glue dá acesso aos logs emitidos pelos processos do Ray durante a execução do trabalho. Se você encontrar erros ou comportamentos inesperados nos trabalhos do Ray, primeiro colete as informações dos logs para determinar a causa da falha. Também fornecemos logs semelhantes para sessões interativas. Os logs das sessões são fornecidos com o prefixo `/aws-glue/ray/sessions`.

As linhas de log são enviadas para o CloudWatch em tempo real, à medida que seu trabalho é executado. As instruções de impressão são anexadas aos registros do CloudWatch após a conclusão da execução. Os registros são retidos por duas semanas após a execução de um trabalho.

Inspecionar logs de tarefas do Ray

Quando um trabalho falhar, colete o nome e o ID de execução do trabalho. É possível encontrá-los no console do AWS Glue. Navegue até a página do trabalho e, em seguida, navegue até a guia Runs (Execuções). Os logs de tarefas do Ray são armazenados nos seguintes grupos de logs dedicados do CloudWatch.

- `/aws-glue/ray/jobs/script-log/`: armazena logs emitidos pelo seu principal script do Ray.
- `/aws-glue/ray/jobs/ray-monitor-log/`: armazena logs emitidos pelo processo do autoscaler do Ray. Esses logs são gerados para o nó principal e não para outros nós de processamento.
- `/aws-glue/ray/jobs/ray-gcs-logs/`: armazena logs emitidos pelo processo GCS (loja de controle global). Esses logs são gerados para o nó principal e não para outros nós de processamento.
- `/aws-glue/ray/jobs/ray-process-logs/`: armazena logs emitidos por outros processos do Ray (principalmente o agente do painel) em execução no nó principal. Esses logs são gerados para o nó principal e não para outros nós de processamento.
- `/aws-glue/ray/jobs/ray-raylet-logs/`: Armazena logs emitidos por cada processo raylet. Esses logs são coletados em um único fluxo para cada nó de processamento, incluindo o nó principal.

- `/aws-glue/ray/jobs/ray-worker-out-logs/`: armazena logs do `stdout` para cada operador no cluster. Esses logs são gerados para cada nó de processamento, incluindo o nó principal.
- `/aws-glue/ray/jobs/ray-worker-err-logs/`: armazena logs do `stderr` para cada operador no cluster. Esses logs são gerados para cada nó de processamento, incluindo o nó principal.
- `/aws-glue/ray/jobs/ray-runtime-env-log/`: armazena logs sobre o processo de configuração do Ray. Esses logs são gerados para cada nó de processamento, incluindo o nó principal.

Solucionar de problemas de erros do Ray

Para entender a organização dos grupos de logs do Ray e encontrar os grupos de logs que ajudarão você a solucionar os erros, é útil ter informações básicas sobre a arquitetura do Ray.

No ETL AWS Glue, um proceesador corresponde a uma instância. Ao configurar processadores para um trabalho do AWS Glue, você está definindo o tipo e a quantidade de instâncias dedicadas ao trabalho. O Ray usa o termo processador de maneiras diferentes.

O Ray usa o nó principal e o nó de processamento para distinguir as responsabilidades de uma instância em um cluster do Ray. Um nó de processamento do Ray pode hospedar vários processos de atores que realizam cálculos para obter o resultado da computação distribuída. Os atores que executam uma réplica de uma função são chamados de réplicas. Os atores de réplica também podem ser chamados de processos de processador. As réplicas também podem ser executadas no nó principal, conhecido como principal porque executa processos adicionais para coordenar o cluster.

Cada ator que contribui para a computação gera seu próprio fluxo de logs. Isso nos fornece alguns insights:

- O número de processos que emitem logs pode ser maior que o número de processadores que podem ser alocados ao trabalho. Muitas vezes, cada núcleo em cada instância tem um ator.
- Os nós principais do Ray emitem logs de gerenciamento e de inicialização de cluster. Por outro lado, os nós de processamento do Ray só emitem logs para o trabalho realizado neles.

Para obter mais informações sobre a arquitetura Ray, consulte Architecture Whitepapers (Documentos técnicos de arquitetura) na documentação do Ray.

Área problemática: acesso ao Amazon S3

Verifique a mensagem de falha da execução de trabalho. Se isso não fornecer informações suficientes, verifique `/aws-glue/ray/jobs/script-log/`.

Área problemática: gerenciamento de dependências de PIP

Verifique `/aws-glue/ray/jobs/ray-runtime-env-log/`.

Área problemática: inspecionar valores intermediários no processo principal

Escreva para `stderr` ou `stdout` a partir do seu script principal e recupere logs de `/aws-glue/ray/jobs/script-log/`.

Área problemática: inspecionar valores intermediários no processo secundário

Escreva para `stderr` ou `stdout` partir da função `remote`. Em seguida, recupere os logs de `/aws-glue/ray/jobs/ray-worker-out-logs/` ou `/aws-glue/ray/jobs/ray-worker-err-logs/`. A função pode ter sido executada em qualquer réplica, então pode ser necessário examinar vários logs para encontrar a saída pretendida.

Área de problema: interpretação de endereços IP em mensagens de erro

Em determinadas situações de erro, seu trabalho pode emitir uma mensagem de erro contendo um endereço IP. Esses endereços IP são efêmeros e são usados pelo cluster para identificação e comunicação entre os nós. Os logs de um nó serão publicados em um fluxo de logs com um sufixo exclusivo baseado no endereço IP.

No CloudWatch, você pode filtrar os logs para inspecionar aqueles específicos desse endereço IP identificando esse sufixo. Por exemplo, considerando *`FAILED_IP`* e *`JOB_RUN_ID`*, você pode identificar o sufixo com:

```
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
```

Exceções de machine learning do AWS Glue

Este tópico descreve strings e códigos de erro HTTP para exceções do AWS Glue relacionadas a machine learning. Os códigos de erro e as strings de erro são fornecidos para cada atividade de machine learning que pode ocorrer quando você executa uma operação. Além disso, você pode ver se é possível repetir a operação que resultou no erro.

CancelMLTaskRunActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."
  - "Nenhuma execução de tarefa de ML encontrada para [taskRunId]: na conta [accountId] para a transformação [transformName]."

  OK para tentar novamente: não.

CreateMLTaskRunActivity

Essa atividade tem as seguintes exceções:

- InvalidInputException (400)
  - "Falha de serviço interno devido a entrada inesperada."
  - “Uma fonte de entrada da tabela do AWS Glue deve ser especificada na transformação.”
  - "A coluna de fonte de entrada [columnName] tem um tipo de dados inválido definido no catálogo."
  - "Exatamente uma tabela de registro de entrada deve ser fornecida."
  - "Deve especificar o nome do banco de dados."
  - "Deve especificar o nome da tabela."
  - "O esquema não está definido na transformação."
  - "O esquema deve conter a chave primária fornecida: [primaryKey]."
  - "Problema ao obter o esquema do catálogo de dados: [message]."
  - "Não é possível definir a capacidade máxima e o Núm./Tipo de operador ao mesmo tempo."

- "Tanto WorkerType quanto NumberOfWorkers devem ser definidos."
- "MaxCapacity deve ser >= [maxCapacity]."
- "NumberOfWorkers deve ser >= [maxCapacity]."
- "O máximo de novas tentativas não deve ser negativo."
- "Os parâmetros de Encontrar correspondências não foram definidos."
- "Uma chave primária deve ser especificada nos parâmetros de Encontrar correspondências."

OK para tentar novamente: não.

- AlreadyExistsException (400)
  - "Já existe uma transformação com o nome [transformName]."

  OK para tentar novamente: não.
- IdempotentParameterMismatchException (400)
  - "A solicitação de criação idempotente para a transformação [transformName] tinha parâmetros não correspondentes."

  OK para tentar novamente: não.
- InternalServiceException (500)
  - "Falha de dependência."

  OK para tentar novamente: sim.
- ResourceNumberLimitExceededException (400)
  - "A contagem de transformações de ML ([count]) excedeu o limite de [limit] transformações."

  OK para tentar novamente: sim, depois de excluir uma transformação a fim de criar espaço para a nova.

DeleteMLTransformActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]"

  OK para tentar novamente: não.

GetMLTaskRunActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."
  - "Nenhuma execução de tarefa de ML encontrada para [taskRunId]: na conta [accountId] para a transformação [transformName]."

  OK para tentar novamente: não.

GetMLTaskRunsActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."
  - "Nenhuma execução de tarefa de ML encontrada para [taskRunId]: na conta [accountId] para a transformação [transformName]."

  OK para tentar novamente: não.

GetMLTransformActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.

GetMLTransformsActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "O ID da conta não pode ficar em branco."
  - "Classificação não compatível com a coluna [column]."
  - "[column] não pode ficar em branco."
  - "Falha de serviço interno devido a entrada inesperada."

  OK para tentar novamente: não.

GetSaveLocationForTransformArtifactActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "Tipo de artefato [artifactType] não compatível."
  - "Falha de serviço interno devido a entrada inesperada."

  OK para tentar novamente: não.

GetTaskRunArtifactActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

- "Nenhuma execução de tarefa de ML encontrada para [taskRunId]: na conta [accountId] para a transformação [transformName].”

OK para tentar novamente: não.

- InvalidInputException (400)
  - "O nome de arquivo '[fileName]' é inválido para publicação."
  - "Não é possível recuperar o artefato para o tipo de tarefa [taskType]."
  - "Não é possível recuperar o artefato para [artifactType]."
  - "Falha de serviço interno devido a entrada inesperada."

OK para tentar novamente: não.

PublishMLTransformModelActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."
  - "Não foi possível encontrar um modelo existente com a versão – [version] para a conta de ID – [accountId] – e ID de transformação – [transformId]."

OK para tentar novamente: não.

- InvalidInputException (400)
  - "O nome de arquivo '[fileName]' é inválido para publicação."
  - "Sinal de menos inicial ilegal na string não assinada [string]."
  - "Dígito inválido no final de [string]."
  - "O valor da string [string] excede o intervalo de longo não assinado."
  - "Falha de serviço interno devido a entrada inesperada."

OK para tentar novamente: não.

PullLatestMLTransformModelActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "Falha de serviço interno devido a entrada inesperada."

  OK para tentar novamente: não.
- ConcurrentModificationException (400)
  - "Não é possível criar a versão do modelo para treinar devido a inserções de corrida com parâmetros incompatíveis."
  - "O modelo de transformação de ML para transformação de ID [transformId] está obsoleto ou está sendo atualizado por outro processo. Tente novamente."

  OK para tentar novamente: sim.

PutJobMetadataForMLTransformActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."
  - "Nenhuma execução de tarefa de ML encontrada para [taskRunId]: na conta [accountId] para a transformação [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "Falha de serviço interno devido a entrada inesperada."
  - "Tipo de metadados de trabalho [jobType] desconhecido."
  - "É necessário fornecer um ID de execução de tarefa para atualizar."

  OK para tentar novamente: não.

StartExportLabelsTaskRunActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."
  - "Não existe nenhum conjunto de rótulos para transformId [transformId] na conta de ID [accountId]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "[message]."
  - "O caminho do S3 fornecido não está na mesma região que a transformação. Esperava-se a região – [region], mas foi obtida – [region]."

  OK para tentar novamente: não.

StartImportLabelsTaskRunActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "[message]."
  - "Caminho de arquivo de rótulo inválido."
  - "Não é possível acessar o arquivo de rótulo em [labelPath]. [message]."
  - "Não é possível usar a função do IAM fornecida na transformação. Função: [role]."
  - "Arquivo de rótulo inválido de tamanho 0."
  - "O caminho do S3 fornecido não está na mesma região que a transformação. Esperava-se a região – [region], mas foi obtida – [region]."

OK para tentar novamente: não.

- ResourceNumberLimitExceededException (400)
  - "O arquivo de rótulo excedeu o limite de [limit] MB."

  OK para tentar novamente: não. Considere dividir o arquivo de rótulo em vários arquivos menores.

StartMLEvaluationTaskRunActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "Exatamente uma tabela de registro de entrada deve ser fornecida."
  - "Deve especificar o nome do banco de dados."
  - "Deve especificar o nome da tabela."
  - "Os parâmetros de Encontrar correspondências não foram definidos."
  - "Uma chave primária deve ser especificada nos parâmetros de Encontrar correspondências."

  OK para tentar novamente: não.
- MLTransformNotReadyException (400)
  - "Esta operação só pode ser aplicada a uma transformação que está em um estado READY."

  OK para tentar novamente: não.
- InternalServiceException (500)
  - "Falha de dependência."

  OK para tentar novamente: sim.
- ConcurrentRunsExceededException (400)
  - "A contagem de execuções de tarefas de ML [count] excedeu o limite de transformação de [limit] execuções de tarefas."

- "A contagem de execuções de tarefas de ML [count] excedeu o limite de [limit] execuções de tarefas."

OK para repetir: sim, depois de aguardar a conclusão das execuções da tarefa.

StartMLLabelingSetGenerationTaskRunActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "Exatamente uma tabela de registro de entrada deve ser fornecida."
  - "Deve especificar o nome do banco de dados."
  - "Deve especificar o nome da tabela."
  - "Os parâmetros de Encontrar correspondências não foram definidos."
  - "Uma chave primária deve ser especificada nos parâmetros de Encontrar correspondências."

  OK para tentar novamente: não.
- InternalServiceException (500)
  - "Falha de dependência."

  OK para tentar novamente: sim.
- ConcurrentRunsExceededException (400)
  - "A contagem de execuções de tarefas de ML [count] excedeu o limite de transformação de [limit] execuções de tarefas."

  OK para repetir: sim, após a conclusão das execuções de tarefa.

UpdateMLTransformActivity

Essa atividade tem as seguintes exceções:

- EntityNotFoundException (400)
  - "Não é possível encontrar MLTransform na conta [accountId] com o identificador [transformName]."

  OK para tentar novamente: não.
- InvalidInputException (400)
  - "Já existe outra transformação com o nome [transformName]."
  - "[message]."
  - "O nome da transformação não pode ficar em branco."
  - "Não é possível definir a capacidade máxima e o Núm./Tipo de operador ao mesmo tempo."
  - "Tanto WorkerType quanto NumberOfWorkers devem ser definidos."
  - "MaxCapacity deve ser >= [minMaxCapacity]."
  - "NumberOfWorkers deve ser >= [minNumWorkers]."
  - "O máximo de novas tentativas não deve ser negativo."
  - "Falha de serviço interno devido a entrada inesperada."
  - "Os parâmetros de Encontrar correspondências não foram definidos."
  - "Uma chave primária deve ser especificada nos parâmetros de Encontrar correspondências."

  OK para tentar novamente: não.
- AlreadyExistsException (400)
  - "Já existe uma transformação com o nome [transformName]."

  OK para tentar novamente: não.
- IdempotentParameterMismatchException (400)
  - "A solicitação de criação idempotente para a transformação [transformName] tinha parâmetros não correspondentes."

  OK para tentar novamente: não.

Cotas do AWS Glue

Você pode entrar em contato com o AWS Support para solicitar um aumento de quota para as quotas de serviço listadas na Referência geral da AWS. A menos que especificado de outra forma,

cada cota é específica da região . Para obter mais informações, consulte Endpoints e cotas do AWS Glue.

Aprimorar a performance do AWS Glue

Estratégia de linha de base para ajuste de performance

Para melhorar a performance do AWS Glue, considere atualizar determinados parâmetros de performance do AWS Glue. Quando for ajustar os parâmetros, observe as seguintes práticas recomendadas:

- Determine suas metas de performance antes de começar a identificar os problemas.
- Use as métricas para identificar os problemas antes de tentar alterar os parâmetros de ajuste.

Para obter os resultados mais consistentes ao ajustar um trabalho, desenvolva uma estratégia de linha de base para fazer os ajustes.

Geralmente, o ajuste de performance é feito no seguinte fluxo de trabalho:

1. Determine as metas de performance.
2. Meça as métricas.
3. Identifique os gargalos.
4. Reduza o impacto dos gargalos.
5. Repita as etapas de 2 a 4 até atingir a meta pretendida.

Estratégias de ajuste para seu tipo de trabalho

Trabalhos do Spark: siga as orientações em Práticas recomendadas para ajuste de performance do AWS Glue para Apache Spark em Recomendações da AWS.

Outros trabalhos: é possível pode ajustar o AWS Glue para trabalhos de shell do Ray e do AWS Glue Python adaptando as estratégias disponíveis em outros ambientes de runtime.

Melhorar a performance do AWS Glue em trabalhos do Apache Spark

Para melhorar a performance do AWS Glue for Spark, você pode considerar a atualização de determinados parâmetros de performance do AWS Glue e do Spark.

Para obter mais informações sobre estratégias específicas para identificar gargalos por meio de métricas e reduzir seu impacto, consulte Best practices for performance tuning AWS Glue for Apache Spark jobs em AWS Prescriptive Guidance. Este guia apresenta os principais tópicos aplicáveis ao Apache Spark em todos os ambientes de runtime, como a arquitetura do Spark e conjuntos de dados distribuídos resilientes. Usando esses tópicos, o guia orienta você a implementar estratégias específicas de ajuste de performance, como otimizar embaralhamentos e paralelizar tarefas.

É possível identificar gargalos configurando o AWS Glue para mostrar a interface do usuário do Spark. Para ter mais informações, consulte the section called “Monitorar com a interface do usuário do Spark”.

Além disso, o AWS Glue fornece recursos de performance que podem ser aplicáveis ao tipo específico de datastore ao qual seu trabalho se conecta. Informações de referência sobre parâmetros de performance para datastores podem ser encontradas em the section called “Parâmetros de conexão”.

Otimizando leituras com o pushdown no Glue ETL AWS

Pushdown é uma técnica de otimização que aproxima a lógica de recuperação de dados da fonte de seus dados. A fonte pode ser um banco de dados ou um sistema de arquivos, como o Amazon S3. Ao executar determinadas operações diretamente na fonte, você pode economizar tempo e poder de processamento não levando todos os dados da rede para o mecanismo Spark gerenciado pelo AWS Glue.

Em outras palavras, o pushdown reduz as varreduras de dados. Para obter mais informações sobre o processo para identificar quando essa técnica é adequada, consulte Reduce the amount of data scan no guia Best practices for performance tuning AWS Glue for Apache Spark jobs em AWS Prescriptive Guidance.

Pushdown de predicados em arquivos armazenados no Amazon S3

Ao trabalhar com arquivos no Amazon S3 que foram organizados por prefixo, você pode filtrar os caminhos de destino do Amazon S3 definindo um predicado de pushdown. Em vez de ler o conjunto de dados completo e aplicar filtros em um `DynamicFrame`, você pode aplicar o filtro diretamente aos metadados da partição armazenados no catálogo de dados do AWS Glue. Essa abordagem permite listar e ler seletivamente somente os dados necessários. Para obter mais informações sobre esse processo, incluindo gravação em um bucket por partições, consulte the section called “Gerenciar partições”.

Você consegue fazer pushdown de predicados no Amazon S3 usando o parâmetro `push_down_predicate`. Considere um bucket no Amazon S3 que você particionou por ano, mês e dia. Se você quiser recuperar dados de clientes de junho de 2022, poderá instruir o AWS Glue a ler somente os caminhos relevantes do Amazon S3. Nesse caso, `push_down_predicate` é `year='2022' and month='06'`. Resumindo, a operação de leitura pode ser realizada conforme abaixo:

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()
```

No cenário anterior, `push_down_predicate` recupera uma lista de todas as partições do catálogo de dados do AWS Glue e as filtra antes de ler os arquivos subjacentes do Amazon S3. Embora isso ajude na maioria dos casos, ao trabalhar com conjuntos de dados que têm milhões de partições, o processo de listar partições pode ser demorado. Para resolver esse problema, a remoção de partições do lado do servidor pode ser usada para melhorar a performance. Isso é feito criando um índice de partição para seus dados no catálogo de dados do AWS Glue. Para obter mais informações sobre particionamento, consulte the section called “Criar índices de partição”. Depois, você pode usar a opção `catalogPartitionPredicate` para referenciar o índice. Para obter um exemplo de recuperação de partições com `catalogPartitionPredicate`, consulte the section called “Predicados de partição de catálogo”.

Pushdown ao trabalhar com fontes JDBC

O leitor de JDBC do AWS Glue usado no `GlueContext` é compatível com pushdown em bancos de dados compatíveis, fornecendo consultas SQL personalizadas que podem ser executadas

diretamente na fonte. Isso pode ser feito definindo o parâmetro `sampleQuery`. Sua consulta de amostra pode especificar quais colunas selecionar, bem como fornecer um predicado de pushdown para limitar os dados transferidos para o mecanismo Spark.

Por padrão, as consultas de amostra operam em um único nó, o que pode resultar em falhas de trabalho ao lidar com grandes volumes de dados. Para usar esse atributo para consultar dados em grande escala, você deve configurar o particionamento de consultas definindo `enablePartitioningForSampleQuery` como verdadeiro, o que distribuirá a consulta para vários nós em uma chave de sua escolha. O particionamento de consultas também requer alguns outros parâmetros de configuração necessários. Para obter mais informações sobre particionamento de consultas, consulte the section called “Leitura do JDBC em paralelo”.

Ao configurar `enablePartitioningForSampleQuery`, o AWS Glue combinará seu predicado de pushdown com um predicado de particionamento ao consultar seu banco de dados. A `sampleQuery` deve terminar com um `AND` para o AWS Glue anexar as condições de particionamento. (Se você não fornecer um predicado de pushdown, a `sampleQuery` deverá terminar com um `WHERE`). Veja um exemplo abaixo, em que fizemos o pushdown de um predicado para recuperar somente linhas com `id` maiores do que 1000. Essa `sampleQuery` retornará somente as colunas de nome e localização das linhas em que `id` for maior que o valor especificado:

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**
>
> Se `customer_tbl` tiver um nome diferente no Catálogo de Dados e no datastore subjacente, você deverá fornecer o nome da tabela subjacente em sample_query, pois a consulta é transmitida para o datastore subjacente.

Você também pode consultar tabelas JDBC sem fazer a integração com o catálogo de dados do AWS Glue. Em vez de fornecer o nome de usuário e a senha como parâmetros para o método, você pode reutilizar as credenciais de uma conexão preexistente fornecendo e `useConnectionProperties` e `connectionName`. Neste exemplo, recuperamos as credenciais a partir de uma conexão denominada `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()
```

Notas e limitações para pushdown no AWS Glue

Pushdown, como conceito, é aplicável ao ler de fontes que não são de streaming. O AWS Glue é compatível com uma variedade de fontes; a capacidade de pushdown depende da fonte e do conector.

- Ao se conectar ao Snowflake, você pode usar a opção `query`. Existe uma funcionalidade semelhante no conector do Redshift no AWS Glue 4.0 e versões posteriores. Para obter mais informações sobre como doe Snowflake com `query`, consulte the section called “Ler no Snowflake”.
- O leitor de ETL do DynamoDB não é compatível com filtros ou predicados de aplicação. O MongoDB e o DocumentDB também não são compatíveis com esse tipo de funcionalidade.
- Ao ler dados armazenados do Amazon S3 em formatos de tabela aberta, o método de particionamento para arquivos no Amazon S3 não é mais suficiente. Para ler e gravar de partições usando formatos de tabela aberta, consulte a documentação do formato.
- Os métodos DynamicFrame não executam o pushdown de projeção do Amazon S3. Todas as colunas serão lidas nos arquivos que passam pelo filtro de predicados.

- Ao trabalhar com conectores `custom.jdbc` no AWS Glue, a capacidade de executar o pushdown depende da fonte e do conector. Consulte a documentação apropriada do conector para confirmar se e como ele é compatível com pushdown no AWS Glue.

Usando o escalonamento automático para AWS Glue

O Auto Scaling está disponível para seu AWS Glue ETL, sessões interativas e trabalhos de streaming com AWS Glue versão 3.0 ou posterior.

Com o Auto Scaling habilitado, você obtém os seguintes benefícios:

- AWS Glue adiciona e remove automaticamente trabalhadores do cluster, dependendo do paralelismo em cada estágio ou microlote da execução do trabalho.
- Isso reduz a necessidade de você experimentar e decidir sobre o número de trabalhadores a serem designados para seu AWS Glue ETLempregos.
- Com o número máximo de trabalhadores determinado, AWS Glue escolherá os recursos do tamanho certo para a carga de trabalho.
- Você pode ver como o tamanho do cluster muda durante a execução do trabalho consultando CloudWatch as métricas na página de detalhes da execução do trabalho em AWS Glue Estúdio.

Auto Scaling para AWS Glue ETLe os trabalhos de streaming permitem a expansão e ampliação sob demanda dos recursos de computação de seu AWS Glue empregos. Aumentar a escala verticalmente sob demanda ajuda você a alocar apenas os recursos de computação necessários ao iniciar a execução do trabalho e também a provisionar os recursos necessários de acordo com a demanda durante o trabalho.

O Auto Scaling também suporta a escalabilidade dinâmica do AWS Glue recursos de trabalho ao longo de um trabalho. Em uma execução de trabalho, quando mais executores forem solicitados pela aplicação Spark, mais operadores serão adicionados ao cluster. Quando o executor ficar ocioso sem tarefas de computação ativas, o executor e o operador correspondente serão removidos.

Os cenários comuns em que o Auto Scaling ajuda no custo e na utilização de suas aplicações do Spark incluem:

- um driver do Spark listando um grande número de arquivos no Amazon S3 ou executando uma carga enquanto os executores estão inativos

- estágios do Spark em execução com apenas alguns executores devido ao excesso de provisionamento
- distorções de dados ou demanda de computação desigual nos estágios do Spark

Requisitos

O Auto Scaling está disponível somente para AWS Glue versão 3.0 ou posterior. Para usar o Auto Scaling, você pode seguir o guia de migração para migrar seus trabalhos existentes para AWS Glue versão 3.0 ou posterior ou crie novos trabalhos com AWS Glue versão 3.0 ou posterior.

O Auto Scaling está disponível para AWS Glue trabalhos com os tipos de trabalhadores `G.1X` `G.2X` `G.4X` `G.8X`,,, ou `G.025X` (somente para trabalhos de streaming). DPUsOs padrões não são suportados.

Habilitando o Auto Scaling em AWS Glue Studio

Na guia Detalhes do trabalho em AWS Glue Studio, escolha o tipo como Spark ou Spark Streaming e a versão Glue igual **`Glue 3.0`** ou posterior. Uma caixa de seleção será exibida abaixo de Tipo de operador.

- Selecione a opção Automatically scale the number of workers (Dimensionar automaticamente o número de operadores).
- Defina Maximum numer of workers (Número máximo de operadores) para estabelecer o número máximo de operadores que podem ser transferidos para a execução do trabalho.

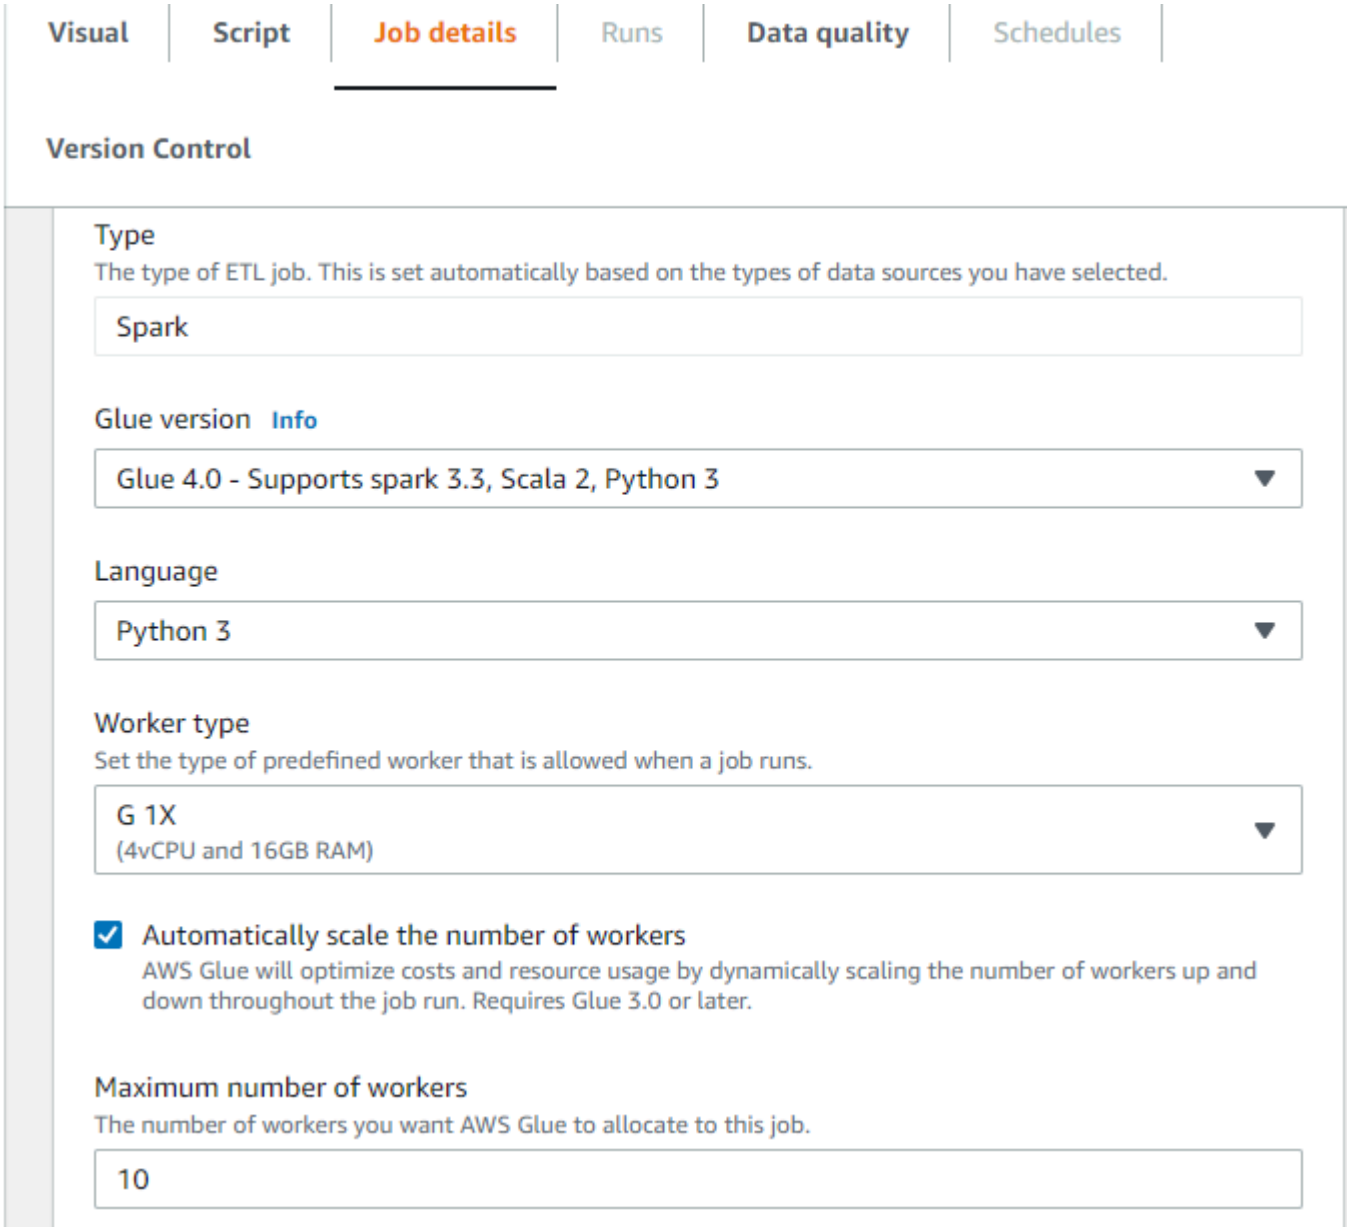

Habilitando o Auto Scaling com o ou AWS CLI SDK

Para ativar o Auto Scaling a partir do AWS CLI para a execução do seu trabalho, execute `start-job-run` com a seguinte configuração:

```
{
    "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...
}
```

Depois que a execução do ETL trabalho for concluída, você também poderá ligar `get-job-run` para verificar o uso real dos recursos da execução do trabalho em DPU -segundos. Observação: o novo campo só DPUSecondsaparecerá para seus trabalhos em lote na AWS Glue versão 4.0 ou posterior habilitados com o Auto Scaling. Esse campo não é compatível com trabalhos de transmissão.

```
$ 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
    }
}
```

Você também pode configurar execuções de trabalhos com o Auto Scaling usando o AWS Glue SDKcom a mesma configuração.

Habilitar o Auto Scaling com sessões interativas

Para ativar o Auto Scaling ao criar AWS Glue trabalhos com sessões interativas, consulte Configuração de sessões interativas. AWS Glue

Dicas e considerações

Dicas e considerações para ajustar o Auto Scaling AWS Glue :

- Caso você não tenha ideia do valor inicial do número máximo de trabalhadores, você pode começar com o cálculo aproximado explicado em Estimativa AWS Glue DPU. Não configure um valor extremamente alto no número máximo de operadores para dados de volume muito baixos.
- AWS Glue O Auto Scaling configura `spark.sql.shuffle.partitions` e se `spark.default.parallelism` baseia no número máximo de DPU (calculado com o número máximo de trabalhadores e o tipo de trabalhador) configurados no trabalho. Caso prefira o valor fixo nessas configurações, substitua esses parâmetros pelos seguintes parâmetros de trabalho:

- Chave: `--conf`
- Valor: `spark.sql.shuffle.partitions=200 --conf spark.default.parallelism=200`

- Para trabalhos de streaming, por padrão, AWS Glue não é escalonado automaticamente em microlotes e requer vários microlotes para iniciar o escalonamento automático. Caso você queira habilitar o ajuste de escala automático em microlotes, forneça `--auto-scale-within-microbatch`. Para obter mais informações, consulte Referência de parâmetro de trabalho.

Monitoramento do Auto Scaling com métricas da Amazon CloudWatch

As métricas do CloudWatch executor estão disponíveis para você AWS Glue Tarefas 3.0 ou posteriores se você ativar o Auto Scaling. As métricas podem ser usadas para monitorar a demanda e o uso otimizado dos executores em suas aplicações do Spark habilitadas com o Auto Scaling. Para obter mais informações, consulte Monitorar o AWS Glue usando métricas do Amazon CloudWatch.

Você também pode utilizar métricas de AWS Glue observabilidade para obter insights sobre a utilização de recursos. Por exemplo, ao monitorar `glue.driver.workerUtilization`, é possível monitorar quanto do recurso foi realmente usado com e sem o ajuste de escala automático. Em outro exemplo, monitorando `glue.driver.skewness.job` e `glue.driver.skewness.stage`, você pode ver como os dados estão distorcidos. Esses insights ajudarão a decidir quando ativar o ajuste de escala automático e ajustar as configurações. Para obter mais informações, consulte Monitoramento com o Monitoramento com métricas de observabilidade do AWS Glue.

- cola. driver. ExecutorAllocationManager.executores. numberAllExecutors
- cola. driver. ExecutorAllocationManager.executores. numberMaxNeededExecutores

Para obter mais detalhes sobre essas métricas, consulte Monitorar planejamento de capacidade de DPU.

> **Note**
>
> CloudWatch as métricas do executor não estão disponíveis para sessões interativas.

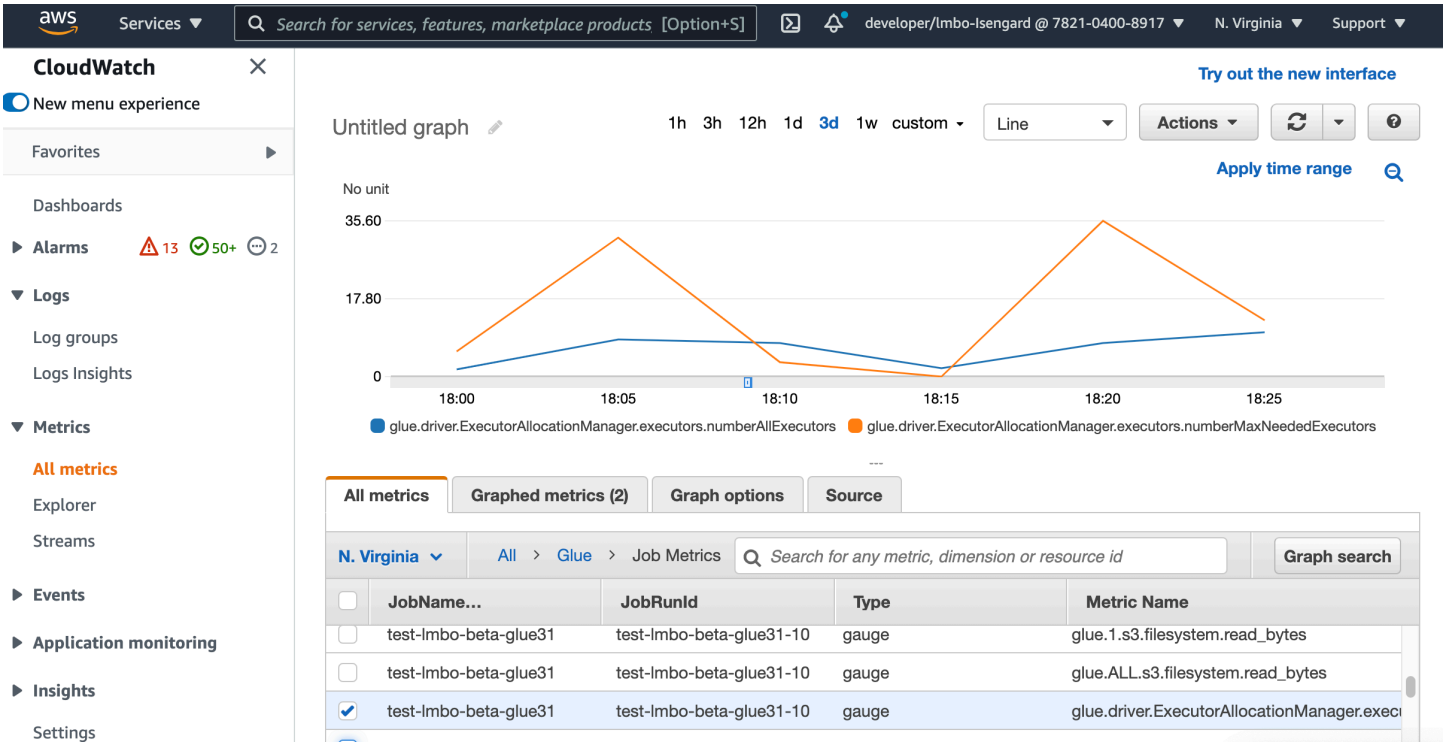

Monitoramento do Auto Scaling com Amazon Logs CloudWatch

Se você estiver usando sessões interativas, poderá monitorar o número de executores ativando Amazon CloudWatch Logs contínuos e pesquisando “executor” nos registros, ou usando a interface do Spark. Para fazer isso, use a mágica `%%configure` para ativar o registro em log contínuo com `enable auto scaling`.

```
%%configure{
    "--enable-continuous-cloudwatch-log": "true",
    "--enable-auto-scaling": "true"
}
```

Nos CloudWatch eventos do Amazon Logs, pesquise “executor” nos registros:

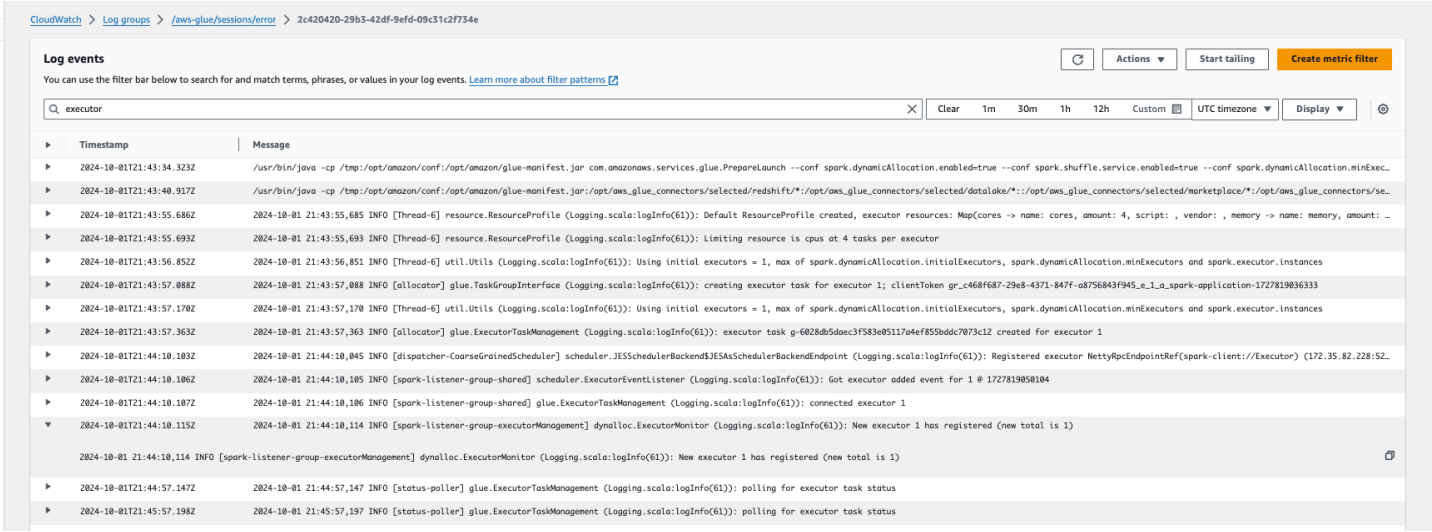

Monitoramento do Auto Scaling com o Spark UI

Com o Auto Scaling ativado, você também pode monitorar executores sendo adicionados e removidos com aumento e redução dinâmicos com base na demanda de seu AWS Glue trabalhos usando a interface do Glue Spark. Para obter mais informações, consulte Habilitar a interface do usuário da Web do Apache Spark para trabalhos do AWS Glue.

Ao usar sessões interativas do caderno Jupyter, você pode executar a seguinte mágica para ativar o ajuste de escala automático com a IU do Spark:

```
%%configure{
    "--enable-auto-scaling": "true",
    "--enable-continuous-cloudwatch-log": "true"
}
```

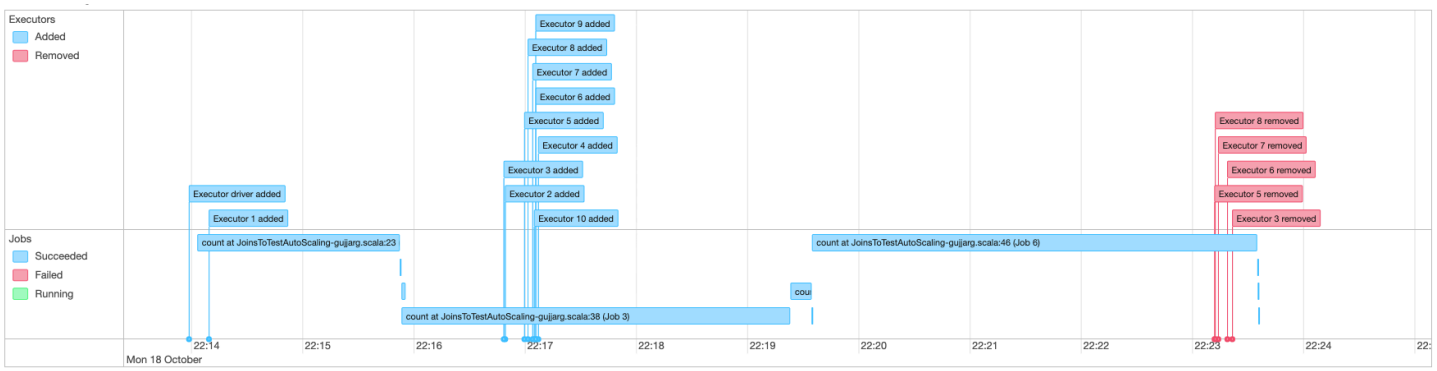

Monitorando o uso da execução de tarefas do Auto Scaling DPU

Você pode usar a visualização AWS Glue Studio Job run para verificar o DPU uso de suas tarefas do Auto Scaling.

1. Escolha Monitoramento no painel AWS Glue Studio de navegação. A página de monitoramento será exibida.
2. Localize o quadro Job runs (Execuções de trabalho).
3. Navegue até a execução da tarefa de seu interesse e vá até a coluna de DPU horas para verificar o uso da execução específica da tarefa.

Limitações

AWS Glue O Auto Scaling de streaming atualmente não suporta uma DataFrame junção de streaming com uma estática DataFrame criada fora do. `ForEachBatch` Uma estática DataFrame criada dentro do `ForEachBatch` funcionará conforme o esperado.

Particionar workloads com execução limitada

Erros em aplicações do Spark geralmente surgem de scripts ineficientes do Spark, execução distribuída na memória de transformações em grande escala e anormalidades do conjunto de dados. Há muitas razões que podem causar problemas de memória de driver ou executor, por exemplo, uma distorção de dados, listar muitos objetos ou colocar em ordem aleatória dados grandes. Esses problemas geralmente aparecem quando você está processando grandes quantidades de dados de backlog com o Spark.

O AWS Glue permite que você resolva problemas de OOM e torne seu processamento ETL mais fácil com o particionamento de workload. Com o particionamento de workload habiltado, cada execução de trabalho de ETL seleciona somente dados não processados, com um limite superior no tamanho do conjunto de dados ou o número de arquivos a serem processados com essa execução de trabalho. Futuras execuções de trabalho processarão os dados restantes. Por exemplo, se houver 1.000 arquivos que precisem ser processados, você pode definir o número de arquivos para 500 e separá-los em duas execuções de trabalho.

O particionamento de workload é suportado apenas para fontes de dados do Amazon S3.

Habilitar o particionamento de workloads

Você pode habilitar a execução limitada definindo manualmente as opções no seu script ou adicionando propriedades da tabela de catálogo.

Para habilitar o particionamento de workload com execução limitada no seu script:

1. Para evitar o reprocessamento de dados, habilite os marcadores de trabalho no novo trabalho ou no já existente. Para obter mais informações, consulte Rastreamento de dados processados usando marcadores de trabalho.
2. Modifique seu script e defina o limite nas opções adicionais na API `getSource` do AWS Glue. Você também deve definir o contexto de transformação para que o marcador de trabalho armazene o elemento `state`. Por exemplo:

   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", "")
```

Para habilitar o particionamento de workload com execução limitada na tabela do Data Catalog:

1. Defina os pares de chave-valor no campo `parameters` de sua estrutura de tabela no Data Catalog. Para obter mais informações, consulte Visualização e edição dos detalhes da tabela.
2. Defina o limite superior para o tamanho do conjunto de dados ou o número de arquivos processados:

   - Defina `boundedSize` para o tamanho de destino do conjunto de dados em bytes. A execução do trabalho será interrompida depois de atingir o tamanho desejado da tabela.
   - Defina `boundedFiles` para o número de destino de arquivos. A execução do trabalho será interrompida após o processamento do número de arquivos desejado.

> **Note**
>
> Você deve definir apenas um entre `boundedSize` ou `boundedFiles`, pois somente um limite é suportado.

Configurar um acionador do AWS Glue para executar o trabalho automaticamente

Depois de habilitar a execução limitada, é possível configurar um acionador do AWS Glue para executar automaticamente o trabalho e carregar os dados incrementalmente em execuções sequenciais. Vá para console do AWS Glue e crie um acionador, configure o horário de programação e anexe-o ao seu trabalho. Em seguida, ele acionará automaticamente a próxima execução do trabalho e processará o novo lote de dados.

Você também pode usar fluxos de trabalho do AWS Glue para orquestrar vários trabalhos a fim de processar dados de diferentes partições simultaneamente. Para obter mais informações, consulte Acionadores do AWS Glue e Fluxos de trabalho do AWS Glue.

Para obter mais informações sobre casos de uso e opções, consulte o blog Optimizing Spark applications with workload partitioning in AWS Glue.

Problemas conhecidos do AWS Glue

Observe os seguintes problemas conhecidos do AWS Glue.

Tópicos

- Impedir acesso a dados entre trabalhos

Impedir acesso a dados entre trabalhos

Considere a situação em que você tenha dois trabalhos do AWS Glue Spark em uma única conta da AWS, cada um em execução em um cluster do AWS Glue Spark separado. Os trabalhos estão usando conexões do AWS Glue para acessar recursos na mesma nuvem privada virtual (VPC). Nessa situação, um trabalho em execução em um cluster pode acessar os dados do trabalho em execução no outro cluster.

O diagrama a seguir ilustra um exemplo dessa situação.

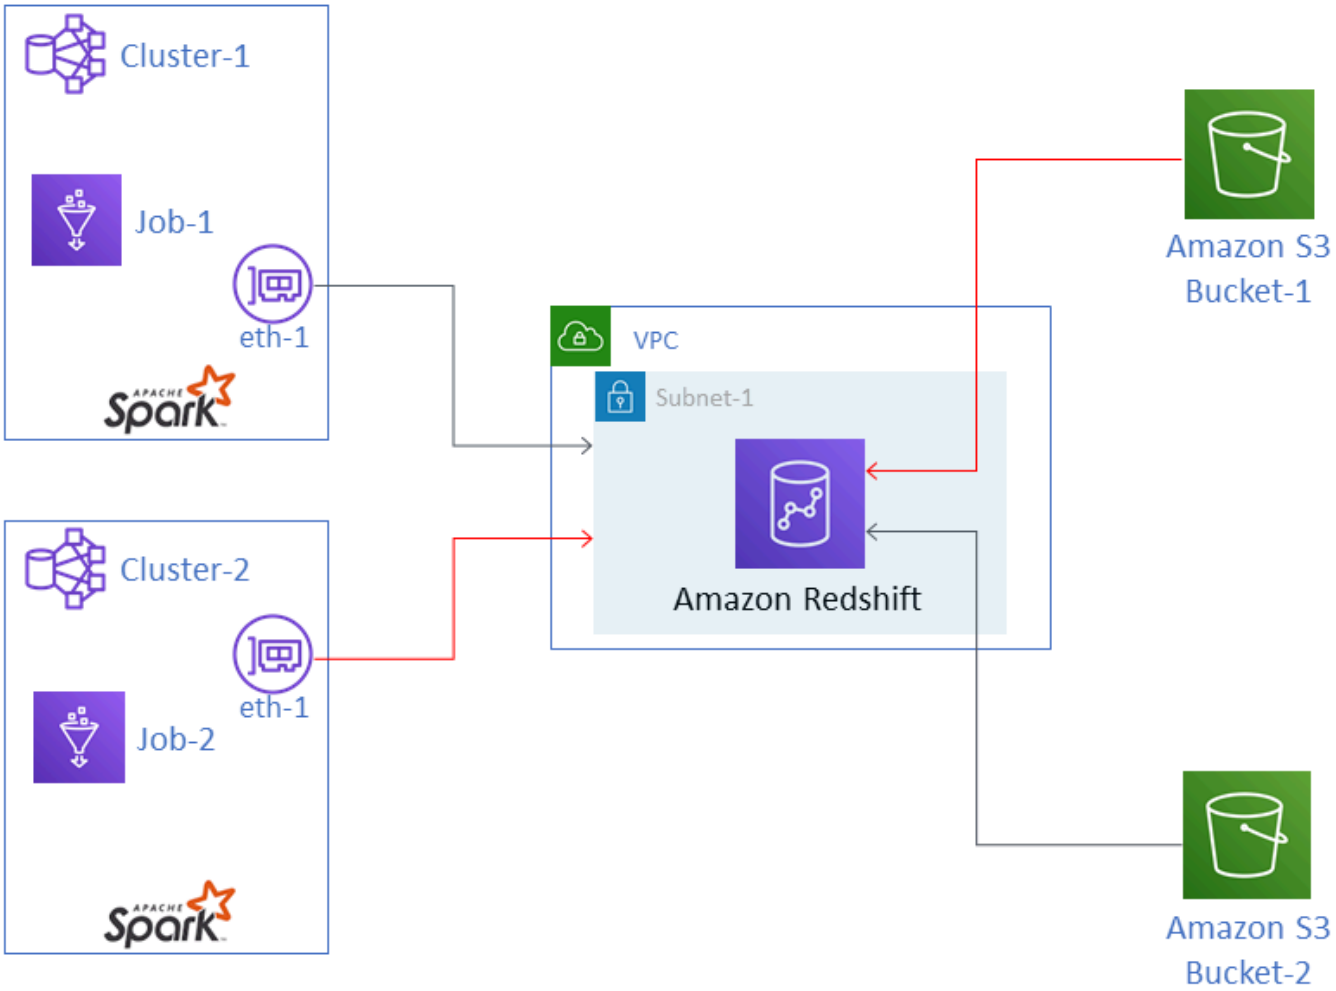

No diagrama, o AWS Glue `Job-1` está em execução no `Cluster-1`, e o Job-2 está em execução no `Cluster-2`. Os dois trabalhos estão atuando com a mesma instância do Amazon RedShift, que reside na `Subnet-1` de uma VPC. A `Subnet-1` pode ser uma sub-rede pública ou privada.

`Job-1` está transformando dados do `Bucket-1` do Amazon Simple Storage Service (Amazon S3) e gravando-os no Amazon RedShift. `Job-2` está fazendo o mesmo com os dados do `Bucket-2`. `Job-1` usa a função do AWS Identity and Access Management (IAM) `Role-1` (não mostrada), que dá acesso ao `Bucket-1`. `Job-2` usa `Role-2` (não mostrada), que dá acesso ao `Bucket-2`.

Esses trabalhos têm caminhos de rede que permitem que eles se comuniquem com os clusters uns dos outros e, assim, acessem os dados uns dos outros. Por exemplo, o `Job-2` pode acessar dados no `Bucket-1`. No diagrama, isso é mostrado como o caminho em vermelho.

Para evitar essa situação, recomendamos que você associe diferentes configurações de segurança ao `Job-1` e ao `Job-2`. Ao associar as configurações de segurança, o acesso entre trabalhos aos dados é bloqueado em virtude dos certificados que o AWS Glue cria. As configurações de segurança podem ser fictícias. Ou seja, é possível criar as configurações de segurança sem habilitar a criptografia de dados do Amazon S3, dados do Amazon CloudWatch ou marcadores de trabalho. Todas as três opções de criptografia podem ser desabilitadas.

Para obter mais informações sobre configurações de segurança, consulte the section called “Criptografar dados gravados pelo AWS Glue”.

Como associar uma configuração de segurança a um trabalho

1. Abra o console do AWS Glue em https://console.aws.amazon.com/glue/.
2. Na página Configure the job properties (Configurar as propriedades do trabalho) para o trabalho, expanda a seção Security configuration, scripts libraries e job parameters (Configuração de segurança, bibliotecas de scripts e parâmetros de trabalho).
3. Selecione uma configuração de segurança na lista.

Histórico de documentação do AWS Glue

Alteração	Descrição	Data
Suporte para mais 14 novos conectores SaaS nativos para o AWS Glue	Quatorze conectores SaaS nativos foram adicionados ao AWS Glue. Para obter mais informações, consulte Adding an AWS Glue connection.	30 de janeiro de 2025
Suporte para mais 16 novos conectores SaaS nativos para o AWS Glue	Dezesseis conectores SaaS nativos foram adicionados ao AWS Glue. Para obter mais informações, consulte Adding an AWS Glue connection.	17 de dezembro de 2024
Geração automática de estatísticas de colunas	O AWS Glue Data Quality agora oferece suporte a tabelas do Amazon SageMaker AI LakeHouse e tabelas do Iceberg, Delta e HUDI gerenciadas pelo AWS Lake Formation no Catálogo de Dados e ETL. Para obter mais informações, consulte o AWS Glue Data Quality.	06 de dezembro de 2024
Suporte a integrações ETL zero	ETL zero é um conjunto de integrações totalmente gerenciadas pela AWS que minimiza a necessidade de criar pipelines de dados ETL. Para obter mais informaçõ es, consulte Integrações ETL zero.	3 de dezembro de 2024

Suporte a conexões reutilizáveis	Um novo esquema de conexões do AWS Glue oferece uma forma unificada de gerenciar conexões de dados entre serviços e aplicações da AWS, como AWS Glue, Amazon Athena e Amazon SageMaker Unified Studio. Para obter mais informações, consulte Conectar a dados.	3 de dezembro de 2024
Suporte ao AWS Glue versão 5.0.	Adição de informações sobre compatibilidade com o AWS Glue versão 5.0. Os recursos incluem uma atualização do Apache Spark para 3.52, atualização do Java para 17, atualizaç ões no formato de tabela aberto, controle de acesso refinado nativo do Spark, integração de abstração do Sagemaker Lakehouse e do data warehouse, suporte no Sagemaker Unified Studio e mais. Para obter mais informações, consulte as Notas de versão do AWS Glue e Migrar trabalhos do AWS Glue para o AWS Glue versão 5.0.	3 de dezembro de 2024

Conectar ao AWS Glue Data Catalog usando o endpoint REST do Iceberg do AWS Glue	O endpoint REST do Iceberg do AWS Glue oferece suporte a operações de API definidas na especificação REST do Apache Iceberg. Usando um cliente REST do Iceberg, você pode conectar sua aplicação em execução em um mecanismo de análise ao catálogo REST hospedado no Catálogo de Dados. Para obter mais informações, consulte Acessar o Catálogo de Dados.	3 de dezembro de 2024
Geração automática de estatísticas de colunas	Gere automaticamente estatísticas de colunas para novas tabelas no AWS Glue Data Catalog. Para obter mais informações, consulte Geração automática de estatísticas de colunas.	3 de dezembro de 2024
Suporte para atualizações de IA generativa para o Apache Spark no AWS Glue	As atualizações do Spark no AWS Glue permitem que engenheiros e desenvolv edores de dados atualizem e migrem trabalhos existentes do Spark no AWS Glue para as versões mais recentes do Spark usando IA generativ a. Para obter mais informaçõ es, consulte Upgrade analysis with AI.	22 de novembro de 2024

Suporte para solução de problemas de IA generativa para o Apache Spark no AWS Glue	A solução de problemas de IA generativa para trabalhos do Apache Spark no AWS Glue ajuda engenheiros e cientistas de dados a diagnosticar e corrigir problemas nas aplicações Spark com facilidade. Para obter mais informações, consulte Troubleshooting Spark jobs with AI.	22 de novembro de 2024
Suporte para otimizadores do Iceberg acessarem buckets do Amazon S3 em uma VPC	O AWS Glue Data Catalog oferece suporte a otimizadores de tabela do Iceberg para acessar buckets do Amazon S3 em uma nuvem privada virtual (VPC) específica usando uma conexão de rede do AWS Glue. Para obter mais informações, consulte Como otimizar tabelas do Iceberg.	20 de novembro de 2024
Suporte para mais nove novos conectores SaaS nativos para o AWS Glue	Nove conectores SaaS nativos foram adicionados ao AWS Glue. Para obter mais informações, consulte Adding an AWS Glue connection.	19 de novembro de 2024
Suporte para dez novos conectores SaaS nativos para o AWS Glue	Dez conectores SaaS nativos foram adicionados ao AWS Glue. Para obter mais informações, consulte Adding an AWS Glue connection.	15 de novembro de 2024

Suporte a filas de execução de trabalhos para trabalhos ETL do AWS Glue	Será possível ativar as filas de execução de trabalhos para executá-los posterior mente quando não for possível executá-los imediatamente devido às cotas de serviço. Para obter mais informaçõ es, consulte Configurar propriedades de trabalhos para trabalhos do Spark no AWS Glue.	3 de setembro de 2024
Atualização de modificações em políticas	Alterações documentadas nas políticas AWSGlueSe ssionUserRestrictedNotebook Policy e AWSGlueSe ssionUserRestrictedNotebook ServiceRole, as quais são necessárias para oferecer suporte à criação de tags para sessões com chave de tag do proprietário. Para ter mais informações, consulte Atualizações da AWS Glue para políticas gerenciadas pela AWS.	30 de agosto de 2024

A detecção de anomalias e as regras dinâmicas já estão disponíveis ao público	O AWS Glue Data Quality utiliza um algoritmo de machine learning para aprender com base nas tendências passadas e, em seguida, prever valores futuros para detectar anomalias. As regras dinâmicas permitem que você forneça limites dinâmicos. Para obter mais informações, consulte Otimizar a performance de consultas para tabelas do Iceberg.	7 de agosto de 2024
Atualização de modificações em políticas	Alterações documentadas nas políticas AwsGlueSessionUserRestrictedPolicy e AwsGlueSessionUserRestrictedServiceRole, as quais são necessárias para oferecer suporte à criação de tags para sessões com chave de tag do proprietário. Para ter mais informações, consulte Atualizações da AWS Glue para políticas gerenciadas pela AWS.	5 de agosto de 2024
A geração de estatísticas de colunas para tabelas do Iceberg agora está disponível para o público geral	O AWS Glue oferece suporte ao cálculo e à atualização do número de valores distintos (NDVs) para cada coluna nas tabelas do Iceberg. Para obter mais informações, consulte Anomaly detection in AWS Glue Data Quality e Dynamic rules.	9 de julho de 2024

Compatibilidade com perfis de uso do AWS Glue	Os administradores podem criar perfis de uso do AWS Glue para diversas classes de usuários na conta, como equipes de desenvolvedores, testadores e de produto. Essa flexibilidade permite que os administradores apliquem diferentes controles de uso e custo a cada classe de usuários. Para obter mais informações, consulte Setting up AWS Glue usage profiles.	18 de junho de 2024
Compatibilidade com um conector do Salesforce no AWS Glue para Spark	Adição de informações sobre um novo conector do AWS Glue para Salesforce. Esse recurso permite que você use o AWS Glue para Spark a fim de ler e gravar no Salesforce no AWS Glue 4.0 e em versões posteriores. Para obter mais informaçõ es, consulte Connecting to Salesforce.	22 de maio de 2024

Integração de dados do Amazon Q no AWS Glue (disponibilidade geral)	A integração de dados do Amazon Q no AWS Glue é um novo recurso de IA generativa do AWS Glue que permite que engenheiros de dados e desenvolvedores de ETL criem trabalhos de integração de dados usando linguagem natural. Engenheiros e desenvolvedores podem pedir ao Q para criar trabalhos, solucionar problemas e responder perguntas sobre o AWS Glue e integração de dados. Para obter mais informações, consulte Integração de dados do Amazon Q no AWS Glue. Esse recurso inclui uma atualização das políticas `AwsGlueSessionUserRestrictedPolicy`, `AwsGlueSessionUserRestrictedNotebookServiceRole` e `AwsGlueSessionUserRestrictedServiceRole` gerenciadas pela AWS. Para ter mais informações, consulte Atualizações da AWS Glue para políticas gerenciadas pela AWS.	30 de abril de 2024

Integração de dados do Amazon Q no AWS Glue (preview)	A integração de dados do Amazon Q no AWS Glue é um novo recurso de IA generativa do AWS Glue que permite que engenheiros de dados e desenvolvedores de ETL criem trabalhos de integração de dados usando linguagem natural. Engenheiros e desenvolvedores podem pedir ao Q para criar trabalhos, solucionar problemas e responder perguntas sobre o AWS Glue e integração de dados. Para obter mais informações, consulte Integração de dados do Amazon Q no AWS Glue. Esse atributo inclui uma atualização da política `AwsGlueSessionUserRestrictedNotebookPolicy` gerenciada pela AWS. Para obter mais informações, consulte Atualizações do AWS Glue para políticas gerenciadas pela AWS.	30 de janeiro de 2024

Atualização da documentação do AWS Glue Streaming	Adição de um novo capítulo com conteúdo novo e reorganizado para o AWS Glue Streaming. Este conteúdo descreve como o streaming funciona com o AWS Glue, as caracterí sticas do processamento de dados em tempo real e como monitorar os trabalhos de streaming. Para obter mais informações, consulte AWS Glue Streaming.	27 de dezembro de 2023
Suporte para a detecção detalhada de dados confidenc iais	A transformação “Detectar dados confidenciais” permite detectar, mascarar ou remover entidades definidas por você ou que são predefinidas pelo AWS Glue. Além disso, ações minuciosas permitem que você aplique uma ação específica por entidade. Para obter mais informaçõ es, consulte Como usar a detecção detalhada de dados confidenciais .	26 de novembro de 2023

Suporte para monitoramento de trabalhos com métricas de observabilidade do AWS Glue	Use métricas de observabilidade do AWS Glue para gerar insights sobre o que está acontecendo dentro do seu AWS Glue para trabalhos do Apache Sparks para melhorar a triagem e a análise de problemas. Para obter mais informações, consulte Monitoramento com métricas e observabilidade do AWS Glue.	26 de novembro de 2023
Suporte para detecção de anomalias no AWS Glue Data Quality	A detecção de anomalias no AWS Glue Data Quality usa algoritmos de machine learning (ML) nas estatísticas de dados ao longo do tempo para detectar padrões anormais e problemas ocultos de qualidade de dados que são difíceis de detectar por meio de regras. Para obter mais informações, consulte Detecções de anomalias no AWS Glue Data Quality .	26 de novembro de 2023

Atualização do comportamento do registro em log padrão da IU do Spark	Os trabalhos que geram logs da IU do Spark agora serão gravados com um padrão de nome de arquivo diferente para ser compatível com a IU do Spark no console do AWS Glue. Isso não altera o comportamento de log do CloudWatch. É possível reverter para o comportamento antigo atualizando a configuração do seu trabalho. Para obter mais informações, consulte Como monitorar os trabalhos usando a IU web do Spark.	17 de novembro de 2023

Suporte para fontes de dados novas no AWS Glue para Spark	Conexões com Amazon OpenSearch Service, Azure SQL, Azure Cosmos for NoSQL, SAP HANA Teradata Vantage e Vertica agora têm suporte nativo no AWS Glue. Além disso, as conexões com essas fontes de dados, junto com o MongoDB, agora estão disponíveis para uso no editor visual AWS Glue Studio. Para obter mais informações, consulte Tipos e opções de conexão para ETL no AWS Glue para Spark para saber mais sobre o suporte do AWS Glue para Spark e Como adicionar uma conexão do AWS Glue para saber mais sobre o uso no editor visual AWS Glue Studio.	17 de novembro de 2023
Suporte à geração de estatísticas de colunas	É possível calcular estatísticas em nível de coluna para tabelas do AWS Glue Data Catalog em formatos de dados como Parquet, ORC, JSON, ION, CSV e XML sem precisar configurar pipelines de dados adicionais. Para obter mais informações, consulte Trabalhar com estatísticas de colunas.	16 de novembro de 2023

Suporte à compactação de dados para tabelas do Iceberg	Para obter uma melhor performance de leitura por serviços de analytics da AWS, como o Amazon Athena e o Amazon EMR e trabalhos de ETL do AWS Glue, o Catálogo de Dados oferece compactaç ão gerenciada (um processo que compacta pequenos objetos do Amazon S3 em objetos maiores) para tabelas do Iceberg no Catálogo de Dados. Para obter mais informações, consulte Como otimizar tabelas do Iceberg.	13 de novembro de 2023
Atualização do comportam ento de espera na execução do trabalho	As execuções de trabalhos de shell padrão do Spark e do Python agora avançarão para `WAITING` em determina das situações em vez de avançarem imediatamente para `FAILED`. Para obter mais informações, consulte Status de execução do trabalho do AWS Glue.	8 de novembro de 2023
AWS Glue Studio guia do usuário consolidado no AWS Glue guia do desenvolvedor	O AWS Glue Studio guia do usuário foi movido para o guia do desenvolvedor para criar um único guia de usuário unificado para AWS Glue Studio o AWS Glue console e o acesso AWS Glue Studio programático.	25 de outubro de 2023

Atualização da política gerenciada pela AWS AWSGlueServiceNotebookRole	Adicionadas informações sobre uma pequena atualização na política gerenciada pela AWS AWSGlueServiceNotebookRole. Para obter mais informações, consulte Atualizações do AWS Glue nas políticas gerenciadas pela AWS.	9 de outubro de 2023
O AWS Glue Studio suporta cinco novas transformações integradas	O AWS Glue Studio suporta as cinco novas transformações integradas a seguir: Record matching, Remove null rows, Parse JSON column, Extract JSON path e Regex extractor. Para obter mais informações, consulte Editar nós de transformação de dados gerenciados pelo AWS Glue.	11 de agosto de 2023
Atualização da política gerenciada pela AWS AWSGlueServiceRole	Adicionadas informações sobre uma pequena atualização na política gerenciada pela AWS AWSGlueServiceRole. Para obter mais informações, consulte Atualizações do AWS Glue nas políticas gerenciadas pela AWS.	4 de agosto de 2023

Compatibilidade com crawling em tabelas do Apache Hudi	Adicionadas informações sobre o uso do AWS Glue para crawling em tabelas do Hudi em buckets do Amazon S3 e sobre o registro de tabelas do Hudi no AWS Glue Data Catalog. Para obter mais informações, consulte Em quais armazenamentos de dados posso fazer crawling? e Propriedades do crawler.	21 de julho de 2023
Atualização da política AWSGlueConsoleFullAccess gerenciada da AWS	Informações adicionadas sobre uma pequena atualização para a política gerenciada pela AWS AWSGlueConsoleFullAccess. Para obter mais informações, consulte Atualizações do AWS Glue nas políticas gerenciadas pela AWS.	14 de julho de 2023
Compatibilidade com crawling em tabelas do Apache Iceberg	Adicionadas informações sobre o uso do AWS Glue para fazer crawling em tabelas do Iceberg em buckets do Amazon S3 e sobre o registro das tabelas do Iceberg no AWS Glue Data Catalog. Para obter mais informações, consulte Em quais armazenamentos de dados posso fazer crawling? e Propriedades do crawler.	7 de julho de 2023

Compatibilidade com o AWS Glue com Ray	Adicionadas informações sobre o AWS Glue com Ray, um novo mecanismo que pode ajudar em trabalhos do AWS Glue. Reorganizado o conteúdo existente do AWS Glue com Spark para eliminar ambiguidades.	30 de maio de 2023
Compatibilidade com o AWS Glue Data Quality (GA)	O AWS Glue Data Quality agora está disponível para uso geral. O AWS Glue Data Quality ajuda a avaliar e monitorar a qualidade dos dados. Para obter informaçõ es sobre o uso do AWS Glue Data Quality com o catálogo de dados, consulte AWS Glue Data Quality. Para saber sobre o AWS Glue Data Quality para AWS Glue Studio, consulte Avaliar a qualidade dos dados com o AWS Glue Studio.	24 de maio de 2023
Compatibilidade com tipos de operadores maiores para trabalhos do Apache Spark	Agora o uso dos tipos de operador `G.4X` e `G.8X` para trabalhos do Apache Spark é compatível. Esses tipos de operadores são adequados para trabalhos que têm workloads que contém as transformações, agregaçõe s, uniões e consultas mais exigentes. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	8 de maio de 2023

Compatibilidade com a criação de índices de partição ao fazer crawling em tabelas	Adicionadas informações sobre como os crawlers são compatíveis com a criação de índices de partição para as tabelas que o crawler detecta. Para obter mais informações, consulte Definir a opção de configuração do crawler de índice de partição.	24 de abril de 2023
Compatibilidade com métricas de uso de recursos	Adicionadas informações sobre a visualização do uso de recursos do serviço e sobre a configuração de alarmes no Amazon CloudWatch. Para obter mais informações, consulte Monitorar recursos do AWS Glue.	7 de abril de 2023
Atualização da política AWSGlueConsoleFullAccess gerenciada da AWS	Informações adicionadas sobre uma pequena atualizaç ão para a política gerenciad a pela AWS AWSGlueCo nsoleFullAccess. Para obter mais informações, consulte Atualizações do AWS Glue nas políticas gerenciadas pela AWS.	28 de março de 2023

Adicionada orientação para uso do AWS Glue com um AWS SDK com exemplos	O Guia do desenvolvedor do AWS Glue tem duas novas seções que fornecem informações para ajudar você a usar o AWS Glue com um AWS SDK. Para obter mais informações, consulte Usar o AWS Glue com um AWS SDK e Exemplos de código do AWS Glue usando AWS SDKs.	23 de fevereiro de 2023
Atualização da documentação do IAM com o AWS Glue	Reorganizadas e adicionadas informações sobre o uso do IAM com o AWS Glue. Para obter mais informações, consulte Gerenciamento de identidade e acesso do AWS Glue.	15 de fevereiro de 2023
Compatibilidade com execução de trabalhos de ETL de streaming no AWS Glue versão 4.0	Foram adicionadas informações sobre compatibilidade com execução de trabalhos de ETL de streaming no Glue versão 4.0 e novas opções para conexão com um cluster do Kafka ou um cluster do Amazon Managed Streaming for Apache Kafka e Amazon Kinesis Data Streams. Para obter mais informações, consulte Adicionar trabalhos de ETL de streaming no AWS Glue e Tipos de conexão e opções de ETL no AWS Glue.	8 de fevereiro de 2023

Compatibilidade com crawling em fontes de dados do MongoDB Atlas	Adicionadas informações sobre o uso do AWS Glue para fazer crawling em fontes de dados do MongoDB Atlas. Para obter mais informações, consulte Em quais armazenamentos de dados posso fazer crawling?, Propriedades de conexão do MongoDB e do MongoDB Atlas e Usar uma conexão do MongoDB ou do MongoDB Atlas.	6 de fevereiro de 2023
Compatibilidade com crawling de tabelas do Delta Lake usando um conector do Delta Lake	Adicionadas informações sobre como usar o AWS Glue para rastrear tabelas do Delta Lake. Esse recurso permite que você use mecanismos de consulta da AWS para consultar diretamente o log de transações do Delta e usar recursos como viagem no tempo e garantias ACID, além de sincronizar os metadados do Delta Lake dos arquivos de transação do Amazon S3 com o Data Catalog para habilitar permissões de coluna em consultas no Lake Formation. Para obter mais informações, consulte Como especificar opções de configuração para um datastore Delta Lake e Consulta a tabelas Data Lake.	15 de dezembro de 2022

Compatibilidade com o AWS Glue Data Quality (versão pré-lançamento)	Agora existe compatibilidade com o AWS Glue Data Quality (versão pré-lançamento). AWS Glue O Data Quality ajuda você a avaliar e monitorar a qualidade dos dados quando você usa o AWS Glue 3.0. Para obter informações sobre como usar o AWS Glue Data Quality com o Data Catalog, consulte AWS Glue Data Quality (versão pré-lançamento). Para saber sobre o AWS Glue Data Quality para AWS Glue Studio, consulte Avaliar a qualidade dos dados com o AWS Glue Studio.	30 de novembro de 2022
Compatibilidade com um novo conector do Amazon Redshift Spark com novos recursos e melhorias de performance	Agora é possível usar um novo conector do Spark do Amazon Redshift com um novo driver JDBC com tarefas do AWS Glue ETL para criar aplicações do Apache Spark que leem e gravam dados no Amazon Redshift como parte de seus pipelines de ingestão e transformação de dados. Para obter mais informações, consulte Mover dados de e para o Amazon Redshift.	29 de novembro de 2022

Compatibilidade com o AWS Glue versão 4.0.	Informações adicionadas sobre compatibilidade com o AWS Glue versão 4.0. Os recursos incluem suporte nativo para estruturas de data lake aberto com Apache Hudi, Delta Lake e Apache Iceberg, e suporte nativo para o Cloud Shuffle Storage Plugin baseado no Amazon S3 (um plug-in do Apache Spark) para usar o Amazon S3 para capacidade de armazenam ento aleatório e elástico. Para obter mais informaçõ es, consulte as Notas de versão do AWS Glue e Migrar trabalho do AWS Glue para o AWS Glue versão 4.0.	28 de novembro de 2022
O AWS Glue Studio agora oferece transformações visuais personalizadas	As transformações visuais personalizadas permitem que os clientes definam, reutilizem e compartilhem a lógica de ETL específica da empresa entre suas equipes. Para obter mais informaçõ es, consulte Transformações visuais personalizadas.	28 de novembro de 2022

Compatibilidade com o uso do crawler do AWS Glue para publicar metadados para armazenamentos de dados JDBC	Agora é possível usar o crawler do AWS Glue para publicar metadados, como comentários e tipos brutos, no Data Catalog para armazenamentos de dados JDBC. Para obter mais informações, consulte Parâmetros definidos nas tabelas do Data Catalog pelo crawler, Propriedades do crawler e Estrutura JdbcTarget.	18 de novembro de 2022
Compatibilidade com crawling de armazenamentos de dados do Snowflake	Agora, é possível usar o AWS Glue para rastrear de tabelas e visualizações do Snowflake e para publicar os metadados no Data Catalog como uma entrada de tabela. Para tabelas externas do Snowflake no Amazon S3, o crawler também rastreia locais do Amazon S3 e o tipo de formato de arquivo da tabela externa e os insere como parâmetros da tabela. Para obter mais informações, consulte Em quais armazenamentos de dados posso fazer crawling?, Propriedades de conexão do AWS Glue e Parâmetros definidos nas tabelas do Data Catalog pelo crawler.	18 de novembro de 2022

Compatibilidade com um melhor gerenciamento de ordem aleatória das aplicações do Spark	Agora é possível usar um novo Cloud Shuffle Storage Plugin for Apache Spark. Para obter mais informações, consulte Gerenciador de ordem aleatória do Spark no AWS Glue com o Amazon S3 e Cloud Shuffle Storage Plugin for Apache Spark.	15 de novembro de 2022
Adicionado suporte para destinos do Data Catalog ao serem acelerados crawls com notificações de eventos do Amazon S3	Além do suporte existente para destinos do Amazon S3, agora está disponível o suporte para acelerar crawls para destinos do Data Catalog usando notificações de eventos do Amazon S3. Para obter mais informações, consulte Aceleração de crawls usando notificações de eventos do Amazon S3.	13 de outubro de 2022
Compatibilidade com a especificação do número máximo de tabelas que um crawler pode criar	Agora, há compatibilidade com a especificação do número máximo de tabelas que o crawler tem permissão para criar. Para obter mais informações, consulte Como especificar o número máximo de tabelas que o crawler pode criar.	6 de setembro de 2022

Compatibilidade com Python 3.9 em trabalhos de shell do Python no AWS Glue	Agora, o AWS Glue oferece suporte para a execução de scripts compatíveis com o Python 3.9 em trabalhos de shell do Python e para optar pelo uso de conjuntos pré-empacotados de bibliotecas. Para obter mais informações, consulte Trabalhos de shell do Python no AWS Glue.	11 de agosto de 2022
Compatibilidade com a execução de trabalhos não urgentes ou não temporários do AWS Glue utilizando capacidade extra	Agora, há suporte para a configuração de execuções flexíveis de trabalho para trabalhos não urgentes, como trabalhos de pré-produção, testes e cargas de dados ocasionais. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	9 de agosto de 2022
Suporte para um novo tipo de operador para trabalhos de streaming	O suporte agora está disponível para uso do tipo de operador `G.025X` para trabalhos de streaming de baixo volume. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	14 de julho de 2022
Suporte para o uso do Kafka SASL em conexões do AWS Glue	O suporte agora está disponível para uso do Kafka SASL em conexões do AWS Glue. Para obter mais informações, consulte Propriedades de conexão do AWS Glue Kafka para autenticação do cliente.	5 de julho de 2022

Compatibilidade com o conector do Apache Kafka para esquemas protobuf	O suporte para o Apache Kafka Connector agora está disponível para esquemas Protobuf. Para obter mais informações, consulte Registro de esquemas do AWS Glue.	9 de junho de 2022
Compatibilidade com Auto Scaling para trabalhos do AWS Glue (disponível ao público)	Adição de informações sobre como usar o Auto Scaling para trabalhos no AWS Glue versão 3.0 para escalar dinamicamente os recursos de computação. Para mais informações, consulte Uso de Auto Scaling para o AWS Glue.	14 de abril de 2022
Atualização na documentação para desenvolvimento e testes do AWS Glue de scripts de trabalho do AWS Glue	Informações reorganizadas e adicionadas sobre os métodos de desenvolvimento e testes disponíveis para o AWS Glue, incluindo instruções de desenvolvimento com o Docker. Para mais informaçõ es, consulte Desenvolvimento e teste de scripts de trabalho do AWS Glue.	14 de março de 2022
Adição de protocol buffers (protobuf) como formato de dados compatível para o registro de esquemas do AWS Glue	Adicionadas informaçõ es sobre o Protobuf como formato de dados suportado (além do AVRO e JSON). Para obter mais informaçõ es, consulte Registro de esquemas do AWS Glue.	25 de fevereiro de 2022

Suporte ao crawling de tabelas do Delta Lake	Adição de informações sobre como usar o AWS Glue para o crawling de tabelas do Delta Lake. Para obter mais informações, consulte Como especificar opções de configuração para um datastore do Delta Lake.	24 de fevereiro de 2022
Suporte a insights de trabalhos do AWS Glue	Adição de informações sobre como usar insights de trabalhos do AWS Glue para simplificar a depuração e a otimização de trabalhos para seus trabalhos do AWS Glue. Para obter mais informaçõ es, consulte Monitorar com insights de trabalhos do AWS Glue.	8 de fevereiro de 2022
Suporte a crawling de tabelas de catálogo de dados baseadas no Amazon S3 usando um endpoint da VPC	Além de armazenamentos de dados do Amazon S3, é possível configurar suas tabelas de catálogo de dados baseadas no Amazon S3 para serem acessadas somente por um ambiente da Amazon Virtual Private Cloud (Amazon VPC) para fins de segurança , auditoria ou controle. Para obter mais informações, consulte Crawling de um datastore do Amazon S3 ou de tabelas de catálogo de dados baseado no Amazon S3 usando um endpoint da VPC.	3 de fevereiro de 2022

Suporte a tabelas governadas pelo Lake Formation	Adição de informações sobre o suporte do AWS Glue para tabelas governadas pelo Lake Formation, com suporte a transações ACID, compactação automática de dados e consultas de viagem no tempo. Para obter mais informações, consulte a API do AWS Glue e o Guia do desenvolvedor do AWS Lake Formation.	30 de novembro de 2021
Novas políticas gerenciadas da AWS adicionadas para sessões interativas e cadernos	Novas políticas gerenciad as para o IAM fornecera m segurança aprimorad a para uso do AWS Glue com sessões interativas e cadernos. Para obter mais informações, consulte Políticas gerenciadas pela AWS para o AWS Glue.	30 de novembro de 2021
O registro de esquemas do Glue agora oferece suporte a trabalhos de transmissão	É possível criar trabalhos de transmissão que acessem tabelas que fazem parte do Glue Schema Registry. Para obter mais informações, consulte AWS Glue Schema Registry e Adição de trabalhos de ETL de transmissão no AWS Glue.	15 de novembro de 2021

Suporte a novos recursos de machine learning	Adicionadas informações sobre novos recursos para a transformação de machine learning de correspondências de Find (Localizar), incluindo correspondência incremental e pontuação de correspondência. Para obter mais informações, consulte Localização de correspondências incrementais e Estimação da qualidade das correspondências usando as pontuações de confiança de correspondência.	31 de outubro de 2021
(prévia privada) Suporte para trabalhos flexíveis do AWS Glue	Adição de informações sobre a configuração de trabalhos do Spark no AWS Glue com uma classe de execução flexível, adequada para trabalhos insensíveis ao tempo, cujos horários de início e conclusão podem variar. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	29 de outubro de 2021
Suporte para a aceleração de crawls usando notificações de eventos do Amazon S3	Adição de informações sobre a aceleração de crawls usando notificações de eventos do Amazon S3 Para obter mais informações, consulte Aceleração de crawls usando notificações de eventos do Amazon S3.	15 de outubro de 2021

Opções de configuração de segurança adicionais relacionadas ao controle de acesso e a VPCs	Adição de informações sobre como é possível configurar novas permissões de controle de acesso no AWS Glue e configurar VPCs. Para obter mais informações, consulte Tags da AWS no AWS Glue, Políticas baseadas em identidade (políticas do IAM) que controlam configurações usando chaves de condição ou chaves de contexto, e Configuração de todas as chamadas da AWS para passar pela sua VPC.	13 de outubro de 2021
Suporte para políticas de endpoint da VPC	Adição de informações sobre o suporte a políticas de endpoint da Virtual Private Cloud (VPC) no AWS Glue. Para obter mais informações, consulte Endpoints de VPC do AWS Glue e interface (AWS PrivateLink).	11 de outubro de 2021
O Glue Studio agora está disponível na China	O AWS Glue Studio agora está disponível nas regiões Pequim e Ningxia da China.	11 de outubro de 2021

O AWS Glue Studio oferece criação de cadernos, para edição interativa de trabalhos	Os cadernos ajudam você a escrever e executar código, visualizar os resultados e compartilhar ideias. Normalmente, os cientistas de dados usam cadernos para experimentos e tarefas de exploração de dados. Para obter mais informações, consulte Usar cadernos.	1.º de outubro de 2021
O acesso direto a fontes de transmissão agora está disponível	Ao adicionar origens de dados ao seu trabalho de ETL no editor visual, é possível fornecer informações para acessar o fluxo de dados em vez de usar um banco de dados e uma tabela do Data Catalog.	30 de setembro de 2021
Documentada a política de suporte à versão do AWS Glue	Adicionadas informações sobre a política de suporte à versão do AWS Glue e as fases de fim de vida para certas versões do AWS Glue. Para obter mais informações, consulte a Política de suporte à versão do AWS Glue.	24 de setembro de 2021
Conectores personalizados agora podem ser usados com visualizações de dados	Ao editar o nó da origem dos dados usando um conector personalizado, é possível visualizar o conjunto de dados escolhendo a guia de visualização de dados. Para obter mais informações, consulte Conectores personalizados .	24 de setembro de 2021

Suporte para sessões interativas do AWS Glue (pré-visualização privada)	(Previsualização privada) Adição de informações sobre o uso de sessões interativas do AWS Glue para executar workloads do Spark na nuvem a partir de qualquer Jupyter Notebook. As sessões interativas são o método preferido para desenvolver seu código de extrair, transformar e carregar (ETL) do AWS Glue usando o AWS Glue 2.0 ou posterior. Para obter mais informações, consulte Configurar e executar sessões interativas do AWS Glue para o caderno Jupyter.	24 de agosto de 2021
Compatibilidade com a criação de fluxos de trabalho com base em esquemas (disponível ao público)	Adição de informações sobre a codificação de casos de uso comuns de extração, transformação e carregamento (ETL) nos blueprints e, em seguida, a criação de fluxos de trabalho de blueprints. Permite que os analistas de dados criem e executem facilmente processos de ETL complexos. Para obter mais informações, consulte Realização de atividades de ETL complexas usando esquemas e fluxos de trabalho no AWS Glue.	23 de agosto de 2021

Compatibilidade com o AWS Glue versão 3.0.	Adição de informações sobre o suporte para o AWS Glue versão 3.0, que é compatível com a atualização do mecanismo Apache Spark 3.0 para executar trabalhos de ETL do Apache Spark, além de outras otimizações e atualizações. Para obter mais informações, consulte Notas de release do AWS Glue e Migrar trabalho do AWS Glue para o AWS Glue versão 3.0. Outros recursos nesta versão incluem o gerenciador de ordem aleatória do AWS Glue, um leitor CSV vetorizado SIMD e predicados de partição de catálogo. Para obter mais informações, consulte o Gerenciador de ordem aleatória do Spark do AWS Glue com o Amazon S3, Opções de formato para entradas e saídas de ETL no AWS Glue e Filtragem do lado do servidor usando predicados de partição de catálogo.	18 de agosto de 2021
AWS GovCloud (US) Region	O AWS Glue Studio agora está disponível na AWS GovCloud (US) Region	18 de agosto de 2021

Criação de shell do Python disponível no AWS Glue Studio	Agora, ao criar um novo trabalho, é possível optar por criar um trabalho do shell do Python. Para obter mais informações, consulte Iniciar o processo de criação de trabalho e Editar trabalhos de shell do Python no AWS Glue Studio.	13 de agosto de 2021
Compatibilidade com a inicialização de um fluxo de trabalho com um evento do Amazon EventBridge	Adicionadas informações sobre como o AWS Glue pode ser um consumidor de eventos em uma arquitetura orientada a eventos. Para obter mais informações, consulte Iniciar um fluxo de trabalho do AWS Glue com um evento do Amazon EventBridge e Exibir os eventos do EventBridge que iniciaram um fluxo de trabalho.	14 de julho de 2021
Adição do JSON como um formato de dados com suporte para o AWS Glue Schema Registry	Adicionadas informações sobre o JSON como um formato de dados suportado (além do AVRO). Para obter mais informações, consulte Registro de esquemas do AWS Glue.	30 de junho de 2021

Criar trabalhos de transmissão do AWS Glue sem uma tabela do Data Catalog	A função `create_data_frame_from_options` do Python ou `getSource` para scripts Scala é compatível com a criação de trabalhos de ETL de transmissão que fazem referência aos fluxos de dados diretamente, em vez de exigir uma tabela do Data Catalog.	15 de junho de 2021
Agora as transformações de machine learning do AWS Glue são compatíveis com chaves do AWS Key Management Service	É possível especificar uma configuração de segurança ou chave do AWS KMS ao configurar as transformações de machine learning do AWS Glue com o console, a CLI ou APIs do AWS Glue. Para obter mais informações, consulte Usar a criptografia dos dados com transformações de machine learning e API de machine learning do AWS Glue.	15 de junho de 2021
Atualização da política AWSGlueConsoleFullAccess gerenciada da AWS	Informações adicionadas sobre uma pequena atualização para a política gerenciada pela AWS AWSGlueConsoleFullAccess. Para obter mais informações, consulte Atualizações do AWS Glue nas políticas gerenciadas pela AWS.	10 de junho de 2021

Visualizar o conjunto de dados do trabalho ao criar e editar trabalhos	É possível usar a nova guia Previsualização de dados para um nó no diagrama de trabalhos a fim de ver uma amostra dos dados processados por esse nó. Para obter mais informações, consulte Usar previsualizações de dados no editor de trabalhos visual.	7 de junho de 2021
Compatibilidade com a especificação de um valor que indica o local da tabela para a saída do crawler.	Informações adicionadas sobre a especificação de um valor que indica o local da tabela ao configurar a saída do crawler. Para obter mais informações, consulte Como especificar o local da tabela.	04 de junho de 2021
Compatibilidade com crawling em uma amostra de arquivos em um conjunto de dados ao realizar o crawling em um datastore do Amazon S3	Informações adicionadas sobre crawling de uma amostra de arquivos ao realizar o crawling no Amazon S3. Para obter mais informações, consulte Propriedades do crawler.	10 de maio de 2021

Suporte para o gravador de parquet otimizado do AWS Glue	Informações adicionadas sobre o uso do gravador de parquet otimizado do AWS Glue para DynamicFrames a fim de criar ou atualizar tabelas com a classificação `parquet`. Para obter mais informações, consulte Criar tabelas, atualizar esquemas e adicionar novas partições no catálogo de dados de trabalhos de ETL do AWS Glue e Opções de formato para entradas e saídas de ETL no AWS Glue.	4 de maio de 2021
Compatibilidade com senhas de autenticação de cliente do Kafka	Informações adicionadas sobre trabalhos de ETL de transmissão no AWS Glue suportam autenticação de certificado de cliente SSL com produtores de transmissão do Apache Kafka. Agora é possível fornecer um certifica do personalizado ao definir uma conexão do AWS Glue com um cluster do Apache Kafka, que o AWS Glue usará ao autenticar com ele. Para obter mais informações, consulte Propriedades de conexão do AWS Glue e API de conexão.	28 de abril de 2021

Compatibilidade com o consumo de dados do Amazon Kinesis Data Streams em outra conta em trabalhos de ETL de transmissão	Informações adicionadas sobre como criar um trabalho de ETL de transmissão para consumir dados do Amazon Kinesis Data Streams em outra conta. Para obter mais informações, consulte Adicionar trabalhos ETL de streaming no AWS Glue.	30 de março de 2021
Transformação SQL disponível	É possível usar um nó de transformação SQL para gravar sua própria transformação na forma de uma consulta SQL. Para obter mais informações, consulte Usar uma consulta SQL para transformar dados.	23 de março de 2021
Suporte para a criação de fluxos de trabalho de esquemas (pré-visualização pública)	(Previsualização pública) Informações adicionadas sobre a codificação de casos de uso comuns de extração, transformação e carregamento (ETL) nos blueprints e subsequente criação de fluxos de trabalho de blueprints. Permite que os analistas de dados criem e executem facilmente processos de ETL complexos. Para obter mais informações, consulte Realização de atividades de ETL complexas usando esquemas e fluxos de trabalho no AWS Glue.	22 de março de 2021

Conectores podem ser usados para destinos de dados	Agora, o uso de um conector personalizado ou do AWS Marketplace para seu destino de dados é suportado. Para obter mais informações, consulte Criação de trabalhos com conectores personalizados.	15 de março de 2021
Suporte para métricas de importância de coluna para transformações de machine learning do AWS Glue	Informações adicionadas sobre a exibição de métricas de importância de coluna ao trabalhar com transformações de machine learning do AWS Glue. Para obter mais informações, consulte Trabalhar com transformações de machine learning no console do AWS Glue	5 de fevereiro de 2021
O recurso de programação de trabalhos agora está disponível no AWS Glue Studio	É possível definir uma programação baseada em tempo para suas execuções de trabalhos no AWS Glue Studio. É possível usar o console para criar uma programação básica ou definir uma programação mais complexa usando a sintaxe cron. Para obter mais informações, consulte Programar execuções de trabalhos.	21 de dezembro de 2020

Lançamento de conectores personalizados do AWS Glue	Os conectores personalizados do AWS Glue permitem que você descubra e assine conectores no AWS Marketplace. Também lançamos interfaces do runtime do Spark no AWS Glue para ligar conectores criados para a fonte de dados do Apache Spark, consulta federada do Athena e APIs do JDBC. Para obter mais informações, consulte Uso de conectores e conexões com o AWS Glue Studio.	21 de dezembro de 2020
Suporte para execução de trabalhos de ETL de transmissão no AWS Glue versão 2.0	Informações adicionadas sobre suporte para a execução de trabalhos de ETL de transmissão no Glue versão 2.0. Para obter mais informações, consulte Adicionar trabalhos ETL de streaming no AWS Glue.	18 de dezembro de 2020

Compatibilidade com o particionamento de workload com execução limitada	Informações adicionadas sobre como habilitar o particionamento de workload para configurar os limites superiores no tamanho do conjunto de dados ou o número de arquivos processados em execuções de trabalho de ETL. Para obter mais informações, consulte Particionamento de workload com execução limitada.	23 de novembro de 2020
Compatibilidade com gerenciamento aprimorado de partições	Informações adicionadas sobre como usar novas APIs para adicionar ou excluir um índice de partição para/de uma tabela existente. Para obter mais informações, consulte Trabalhar com índices de partição.	23 de novembro de 2020
Suporte para o AWS Glue Schema Registry	Informações adicionadas sobre o uso do registro de esquema do AWS Glue para descobrir, controlar e evoluir esquemas centralmente. Para obter mais informações, consulte Registro de esquemas do AWS Glue.	19 de novembro de 2020

Compatibilidade com o formato de entrada Grok em trabalhos de ETL de transmissão	Informações adicionadas sobre a aplicação de padrões Grok a fontes de transmissão, como arquivos de log. Para obter mais informações, consulte Aplicar padrões Grok a fontes de transmissão.	17 de novembro de 2020
Suporte para a adição de tags a fluxos de trabalho no console do AWS Glue	Informações adicionadas sobre como adicionar tags ao criar um fluxo de trabalho usando o console do AWS Glue. Para obter mais informações, consulte Criar e desenvolver um fluxo de trabalho usando o console do AWS Glue.	27 de outubro de 2020
Compatibilidade com execuções incrementais de crawler	Informações adicionadas sobre o suporte para execuções incrementais de crawler, que rastreiam somente as pastas do Amazon S3 adicionadas desde a última execução. Para obter mais informações, consulte Crawls incrementais.	21 de outubro de 2020

Suporte para detecção de esquema para fontes de dados de ETL de transmissão. Suporte para transmissão Avro de fontes de dados de ETL e Kafka autogerenciado	A transmissão de trabalhos de extração, transformação e carregamento (ETL) no AWS Glue agora pode detectar automaticamente o esquema de registros de entrada e lidar com alterações de esquema por registro. Origens dos dados do Kafka autogerenciado agora são suportadas. Trabalhos de ETL de transmissão agora suportam o formato Avro nas origens dos dados. Para obter mais informações, consulte ETL de transmissão no AWS Glue, Definir propriedades de trabalho para um trabalho de ETL de transmissão e Notas e restrições para fontes de transmissão do Avro.	7 de outubro de 2020
Compatibilidade com crawling em origens de dados do MongoDB e DocumentDB	Informações adicionadas sobre suporte para crawling de origens dos dados do MongoDB e do Amazon DocumentDB (compatível com MongoDB). Para obter mais informações, consulte Definir crawlers.	5 de outubro de 2020

Compatibilidade com conformidade com FIPS	Informações adicionadas sobre endpoints dos FIPS para clientes que precisam de módulos criptográficos validados pelo FIPS 140-2 ao acessar dados usando o AWS Glue. Para obter mais informações, consulte Conformidade com os FIPS.	23 de setembro de 2020
O AWS Glue Studio fornece uma interface visual fácil de usar para criar e monitorar trabalhos	Agora é possível usar uma interface simples baseada em gráficos para compor trabalhos que movem e transformam dados e executá-los no AWS Glue. Em seguida, é possível usar o painel de execução de tarefas no AWS Glue Studio para monitorar a execução de ETL e garantir que seus trabalhos estejam operando conforme pretendido. Para obter mais informações, consulte o Guia do usuário do AWS Glue Studio.	23 de setembro de 2020
Compatibilidade com a criação de índices de tabela para melhorar a performance de consulta	Informações adicionadas sobre a criação de índices de tabela para permitir que você recupere um subconjunto das partições de uma tabela. Para obter mais informações, consulte Trabalhar com índices de partição.	9 de setembro de 2020

Compatibilidade com tempos reduzidos de inicialização ao executar trabalhos de ETL do Apache Spark no AWS Glue versão 2.0.	Informações adicionadas sobre o suporte para o AWS Glue versão 2.0 que fornece uma infraestrutura atualizada para executar trabalhos de ETL do Apache Spark com tempos de inicialização reduzidos, alterações no registro e suporte para especificar módulos Python adicionais no nível do trabalho. Para obter mais informações, consulte Notas de release do AWS Glue e Executar trabalhos de ETL do Spark com startup reduzidos.	10 de agosto de 2020
Compatibilidade com a limitação do número de execuções simultâneas de fluxo de trabalho.	Informações adicionadas sobre como limitar o número de execuções de fluxo de trabalho simultâneas para um determinado fluxo de trabalho. Para obter mais informações, consulte Criar e desenvolver um fluxo de trabalho usando o console do AWS Glue.	10 de agosto de 2020

Compatibilidade com crawling em um datastore do Amazon S3 usando um endpoint da VPC	Informações adicionadas sobre a configuração do datastore do Amazon S3 para acesso somente por um ambiente da Amazon Virtual Private Cloud (Amazon VPC), para fins de segurança , auditoria ou controle. Para obter mais informações, consulte Crawling de um datastore do Amazon S3 usando um endpoint da VPC.	7 de agosto de 2020
Compatibilidade com a retomada de execuções de fluxo de trabalho	Informações adicionad as sobre como retomar execuções de fluxo de trabalho que foram concluída s apenas parcialmente porque um ou mais nós (trabalhos ou crawlers) não foram concluído s com êxito. Para obter mais informações, consulte Reparar e retomar uma execução de fluxo de trabalho.	27 de julho de 2020
Compatibilidade com a habilitação de certificados de CA privada em conexões do Kafka no AWS Glue.	Informações adicionadas sobre novas opções de conexão que são compatíve is com a habilitação de certificados CA privados para conexões Kafka no AWS Glue. Para obter mais informações, consulte Tipos de conexão e opções para ETL no AWS Glue e Parâmetros especiais usados pelo AWS Glue.	20 de julho de 2020

Compatibilidade com a leitura de dados do DynamoDB em outra conta	Informações adicionadas sobre o suporte do AWS Glue para leitura de dados de tabela do DynamoDB de outra conta da AWS. Para obter mais informações, consulte Leitura de dados do DynamoDB em outra conta.	17 de julho de 2020
Compatibilidade com uma conexão de gravador do DynamoDB no AWS Glue versão 1.0 ou posterior	Informações adicionadas sobre o suporte ao gravador do DynamoDB e opções de conexão novas ou atualizadas para o DynamoDB ler ou gravar. Para obter mais informações, consulte Tipos de conexão e opções para ETL no AWS Glue.	17 de julho de 2020
Compatibilidade com links de recursos e controle de acesso entre contas usando o AWS Glue e o Lake Formation	Conteúdo adicionado sobre novos objetos do Data Catalog chamados links de recursos, e sobre como gerenciar o compartilhamento de recursos do Data Catalog entre contas com o AWS Glue e o AWS Lake Formation. Para obter mais informações, consulte Concessão de acesso entre contas e Links de recursos de tabela.	7 de julho de 2020

Compatibilidade com amostragem de registros ao realizar crawling dos armazenamentos de dados do DynamoDB	Adicionadas informações sobre novas propriedades que podem ser configuradas ao realizar crawling de um datastore do DynamoDB. Para obter mais informaçõ es, consulte Propriedades do crawler.	12 de junho de 2020
Compatibilidade com a interrupção de uma execução de fluxo de trabalho.	Informações adicionadas sobre como interromper a execução de determinado fluxo de trabalho. Para obter mais informações, consulte Interromper uma execução de fluxo de trabalho.	14 de maio de 2020
Compatibilidade com trabalhos de ETL de transmissão do Spark	Inclusão de informações sobre a criação de trabalhos de extração, transformação e carregamento (ETL) com fontes de dados de streaming . Para obter mais informações, consulte Adicionar trabalhos ETL de streaming no AWS Glue.	27 de abril de 2020

Compatibilidade com a criação de tabelas, atualização do esquema e adição de novas partições ao Data Catalog após a execução de um trabalho de ETL	Adição de informações sobre como é possível habilitar a criação de tabelas, atualizar o esquema e adicionar novas partições para visualizar os resultados do trabalho de ETL no catálogo de dados. Para obter mais informações, consulte Criar tabelas, atualizar esquemas e adicionar novas partições no Data Catalog de trabalhos de ETL do AWS Glue.	2 de abril de 2020
Compatibilidade com a especificação de uma versão para o formato de dados Apache Avro como uma entrada e saída de ETL no AWS Glue	Adição de informações sobre como especificar uma versão para o formato de dados do Apache Avro como uma entrada e saída de ETL no AWS Glue. A versão padrão é 1.7. É possível usar a opção de formato `version` para especificar o Avro versão 1.8 para habilitar a leitura/gravação lógica. Para obter mais informações, consulte Opções de formato para entradas e saídas de ETL no AWS Glue.	31 de março de 2020

Compatibilidade com o committer otimizado para EMRFS do S3 para gravação de dados Parquet no Amazon S3	Informações adicionadas sobre como definir um novo sinalizador para habilitar o committer otimizado para EMRFR S3, para gravar dados parquet no Amazon S3 ao criar ou atualizar um trabalho do AWS Glue. Para obter mais informações, consulte Parâmetros especiais usados pelo AWS Glue.	30 de março de 2020
Suporte para transformações de machine learning como um recurso gerenciado por tags de recursos da AWS	Informações adicionadas sobre o uso de tags de recursos da AWS para gerenciar e controlar o acesso às transformações de machine learning no AWS Glue. É possível atribuir tags de recursos da AWS a trabalhos , acionadores, endpoints, crawlers e transformações de machine learning no AWS Glue. Para obter mais informações, consulte Tags da AWS no AWS Glue.	2 de março de 2020
Compatibilidade com argumentos de trabalho não substituíveis	Adição de informações sobre suporte para parâmetros especiais de trabalho que não podem ser substituídos em triggers ou quando o trabalho é executado. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	12 de fevereiro de 2020

Compatibilidade com novas transformações para conjuntos de dados no Amazon S3	Informações adicionadas sobre novas transformações (Merge, Purge e Transitio n) e exclusões de classe de armazenamento do Amazon S3 para que aplicações do Apache Spark funcionem com conjuntos de dados no Amazon S3. Para obter mais informações sobre o suporte a essas transform ações para Python, consulte mergeDynamicFrame e Trabalhar com conjuntos de dados no Amazon S3. Para Scala, consulte mergeDyna micFrames e APIs GlueConte xt em Scala do AWS Glue.	16 de janeiro de 2020
Compatibilidade com a atualização do Data Catalog com novas informações de partição de um trabalho de ETL	Adição de informações sobre como codificar um script de extração, transformação e carregamento (ETL) para atualizar o AWS Glue Data Catalog com novas informaçõ es de partição. Com esse recurso, não é mais necessári o executar novamente o crawler após a conclusão do trabalho para exibir as novas partições. Para obter mais informações, consulte Atualizar o Data Catalog com novas partições.	15 de janeiro de 2020

Novo tutorial: usar um caderno do SageMaker AI	Adição de um tutorial que demonstra como usar um caderno do Amazon SageMaker para ajudar a desenvolver seus scripts de ETL e machine learning. Consulte Tutorial: usar um caderno do Amazon SageMaker com o endpoint de desenvolvimento.	3 de janeiro de 2020
Compatibilidade com leitura do MongoDB e do Amazon DocumentDB (compatível com MongoDB)	Informações adicionadas sobre novos tipos e opções de conexão para ações de leitura e gravação no MongoDB e no Amazon DocumentDB (compatível com MongoDB). Para obter mais informações, consulte Tipos de conexão e opções para ETL no AWS Glue.	17 de dezembro de 2019

Várias correções e esclarecimentos	Adição de correções e esclarecimentos ao longo do documento. Itens removidos do capítulo Problemas conhecidos. Adição de avisos informando que o AWS Glue oferece suporte apenas a chaves mestras do cliente (CMKs) simétricas ao especificar configurações de criptografia do Catálogo de Dados e criar configurações de segurança. Adição de uma nota informando que o AWS Glue não permite gravar no Amazon DynamoDB.	9 de dezembro de 2019
Compatibilidade com drivers JDBC personalizados	Adição de informações sobre como conectar destinos e fontes de dados com drivers JDBC que não são compatíveis nativamente com o AWS Glue, como MySQL versão 8 e Oracle Database versão 18. Para obter mais informações, consulte Valores de connectionType do JDBC.	25 de novembro de 2019

Suporte à conexão de cadernos do SageMaker AI com diferentes endpoints de desenvolvimento	Informações adicionadas sobre como é possível conectar um caderno do SageMaker AI a diferentes endpoints de desenvolvimento. Atualizações para descrever a nova ação do console para alternar para um novo endpoint de desenvolvimento e a nova política do IAM do SageMaker AI. Para obter mais informações, consulte Trabalhar com cadernos no console do AWS Glue e Criar uma política do IAM para cadernos do Amazon SageMaker AI.	21 de novembro de 2019
Compatibilidade com a versão do AWS Glue em transformações de machine learning	Informações adicionadas sobre como definir a versão do AWS Glue em uma transformação de machine learning de maneira a indicar com qual versão do AWS Glue uma transformação de machine learning é compatível. Para obter mais informações, consulte Trabalhar com transformações de machine learning no console do AWS Glue.	21 de novembro de 2019

Compatibilidade com a recuperação de estados anteriores de seus marcadores de trabalho	Adição de informações sobre como retroceder seus marcadores de trabalho para qualquer execução de trabalho anterior, resultando no reprocessamento subsequente de dados de execução de trabalho somente a partir da execução do trabalho marcado. Descrição de duas novas subopções para a opção `job-bookmark-pause` que permitem executar um trabalho entre dois marcadores. Para obter mais informações, consulte Rastrear dados processados usando marcadores de trabalho e Parâmetros especiais usados pelo AWS Glue.	22 de outubro de 2019
Compatibilidade com certificados JDBC personalizados para conexão com um datastore	Adição de informações sobre o suporte do AWS Glue a certificados JDBC personalizados para conexões SSL a fontes de dados ou destinos do AWS Glue. Para obter mais informações, consulte Trabalhar com conexões no console do AWS Glue.	10 de outubro de 2019

Compatibilidade com o formato de distribuição wheel do Python	Informações adicionadas sobre o suporte do AWS Glue a arquivos wheel (junto com arquivos egg) como dependências para trabalhos de shell do Python. Para obter mais informações, consulte Fornecer sua própria bibliotec a Python.	26 de setembro de 2019
Compatibilidade com versionamento de endpoints de desenvolvimento no AWS Glue	Adição de informações sobre como definir o `Glue version` em endpoints de desenvolvimento. O `Glue version` determina as versões de Apache Spark e Python que são compatíveis com o AWS Glue. Para obter mais informações, consulte Adicionar um endpoint de desenvolvimento.	19 de setembro de 2019
Compatibilidade com monitoramento do AWS Glue usando a interface de usuário do Spark	Adição de informações sobre como usar a IU do Apache Spark para monitorar e depurar trabalhos de ETL do AWS Glue em execução no sistema de trabalhos do AWS Glue e aplicações do Spark em endpoints de desenvolv imento do AWS Glue. Para obter mais informações, consulte Monitorar o AWS Glue usando a interface do usuário do Spark.	19 de setembro de 2019

Aprimoramento do suporte para desenvolvimento de script de ETL local usando a biblioteca de ETL pública do AWS Glue	Atualização do conteúdo da biblioteca de ETL do AWS Glue para refletir que o AWS Glue versão 1.0 agora é compatível. Para obter mais informações, consulte Desenvolver e testar scripts de ETL localmente usando a biblioteca de ETL do AWS Glue.	18 de setembro de 2019
Compatibilidade com a exclusão de classes de armazenamento do Amazon S3 ao executar trabalhos	Informações adicionadas sobre a exclusão de classes de armazenamento do Amazon S3 ao executar trabalhos de ETL do AWS Glue que leem arquivos ou partições do Amazon S3. Para obter mais informações, consulte Excluir classes de armazenamento do Amazon S3.	29 de agosto de 2019
Suporte para desenvolvimento de script de ETL local usando a biblioteca de ETL pública do AWS Glue	Adição de informações sobre como desenvolver e testar scripts Python e Scala de ETL localmente sem a necessida de de uma conexão de rede. Para obter mais informaçõ es, consulte Desenvolver e testar scripts de ETL localment e usando a biblioteca de ETL do AWS Glue.	28 de agosto de 2019

Problemas conhecidos	Adição de informações sobre problemas conhecidos no AWS Glue. Para obter mais informações, consulte Problemas conhecidos do AWS Glue,	28 de agosto de 2019
Compatibilidade com transformações de machine learning no AWS Glue	Adição de informações sobre recursos de machine learning fornecidos pelo AWS Glue para criar transformações personalizadas. É possível criar essas transformações ao criar uma tarefa. Para obter mais informações, consulte Transformações de machine learning no AWS Glue.	8 de agosto de 2019
Compatibilidade com Amazon Virtual Private Cloud compartilhada	Informações adicionadas sobre o suporte do AWS Glue para Amazon Virtual Private Cloud compartilhada. Para obter mais informações, consulte Amazon VPCs compartilhadas.	6 de agosto de 2019
Compatibilidade com versionamento no AWS Glue	Informações adicionadas sobre como definir a `Glue version` em endpoints de desenvolvimento. A versão do AWS Glue determina as versões de Apache Spark e Python que são compatíveis com o AWS Glue. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	24 de julho de 2019

Compatibilidade com opções adicionais de configuração para endpoints de desenvolvimento	Adição de informações sobre opções de configuração para endpoints de desenvolvimento que têm cargas de trabalho com uso intensivo de memória. É possível escolher entre duas novas configurações que fornecem mais memória por executor. Para obter mais informações, consulte Trabalhar com endpoints de desenvolvimento no console do AWS Glue.	24 de julho de 2019
Compatibilidade com atividades de extração, transferência e carregamento (ETL) usando fluxos de trabalho	Informações adicionadas sobre como usar uma nova construção chamada de fluxo de trabalho para criar uma atividade complexa de vários trabalhos de extração, transformação e carregamento (ETL) que o AWS Glue pode executar e rastrear como uma entidade única. Para obter mais informações, consulte Realizar atividades complexas de ETL usando fluxos de trabalho no AWS Glue.	20 de junho de 2019

Compatibilidade com Python 3.6 em tarefas de shell do Python	Adicionadas informações sobre o suporte a Python 3.6 em tarefas de shell do Python. É possível especificar Python 2.7 ou Python 3.6 como uma propriedade da tarefa. Para obter mais informações, consulte Adicionar trabalhos de shell do Python no AWS Glue.	5 de junho de 2019
Compatibilidade com endpoints de nuvem privada virtual (VPC)	Informações adicionadas sobre como se conectar diretamente ao AWS Glue por meio de um endpoint de interface na VPC. Quando você usa um endpoint de interface de VPC, a comunicaç ão entre a VPC e o AWS Glue é realizada integralmente e com segurança na rede da AWS. Para obter mais informações, consulte Usar o AWS Glue com endpoints da VPC.	4 de junho de 2019

Suporte para o registro de logs contínuo e em tempo real para trabalhos do AWS Glue	Informações adicionadas sobre como habilitar e visualizar em tempo real logs de trabalho do Apache Spark no CloudWatch, incluindo os logs de driver, cada um dos logs de executor e uma barra de progresso de trabalhos do Spark. Para obter mais informações, consulte Registro contínuo para tarefas do AWS Glue.	28 de maio de 2019
Compatibilidade com tabelas existentes do Data Catalog como fontes do crawler	Informações adicionadas sobre como especificar uma lista de tabelas existentes do Data Catalog como fontes do crawler. Os crawlers podem detectar alterações nos esquemas da tabela, atualizar as definições da tabela e registrar novas partições conforme novos dados ficam disponíveis. Para obter mais informações, consulte Propriedades do crawler.	10 de maio de 2019

Compatibilidade com opções adicionais de configuração para trabalhos com uso intenso de memória	Adicionadas informaçõ es sobre as opções de configuração para tarefas do Apache Spark com cargas de trabalho com uso intensivo de memória. É possível escolher entre duas novas configurações que fornecem mais memória por executor. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	5 de abril de 2019
Compatibilidade com classific adores personalizados de CSV	Adicionadas informações sobre como usar um classific ador CSV personalizado para inferir o esquema de vários tipos de dados CSV. Para obter mais informaçõ es, consulte Escrever classific adores personalizados.	26 de março de 2019
Suporte para tags de recursos da AWS	Informações adicionadas sobre como usar tags de recursos da AWS para ajudar você a gerenciar e controlar o acesso aos seus recursos do AWS Glue. É possível atribuir tags de recursos da AWS para trabalhos, acionador es, endpoints e crawlers no AWS Glue. Para obter mais informações, consulte Tags da AWS no AWS Glue.	20 de março de 2019

Compatibilidade do Data Catalog com trabalhos do Spark SQL	Informações adicionadas sobre como configurar os trabalhos e endpoints de desenvolvimento do AWS Glue para usar o AWS Glue Data Catalog como um metastore do Apache Hive externo. Isso permite que os trabalhos e os endpoints de desenvolvimento executem consultas do Apache Spark SQL diretamente nas tabelas armazenadas no AWS Glue Data Catalog. Para obter mais informações, consulte Suporte do AWS Glue Data Catalog para trabalhos do Spark SQL.	14 de março de 2019
Compatibilidade com trabalhos de shell do Python	Adição de informações sobre trabalhos de shell do Python e o novo campo Maximum capacity (Capacida de máxima). Para obter mais informações, consulte Adicionar trabalhos de shell do Python no AWS Glue.	18 de janeiro de 2019

Compatibilidade com notificações quando houver alterações em bancos de dados e tabelas	Adição de informações sobre eventos que são gerados para alterações em chamadas de API de partição, tabela e banco de dados. É possível configurar ações no CloudWatch Events para responder a esses eventos. Para obter mais informações, consulte Automatizar o AWS Glue com o CloudWatch Events.	16 de janeiro de 2019
Compatibilidade com criptografia de senhas de conexão	Adicionadas informações sobre criptografia de senhas usadas em objetos de conexão. Para mais informações, consulte Como criptografar senhas de conexão.	11 de dezembro de 2018
Compatibilidade com permissão por recurso e políticas baseadas em recursos	Adição de informações sobre como usar políticas de permissões em nível de recurso e baseadas em recursos com o AWS Glue. Para obter mais informações, consulte os tópicos em Segurança no AWS Glue.	15 de outubro de 2018
Suporte a cadernos do SageMaker AI	Informações adicionadas sobre o uso de cadernos do SageMaker AI com endpoints de desenvolvimento do AWS Glue. Para obter mais informações, consulte Gerenciamento de cadernos.	5 de outubro de 2018

Compatibilidade com criptografia	Adicionadas informações sobre como usar criptografia com o AWS Glue. Para obter mais informações, consulte Criptografia em repouso, Criptografia em trânsito e Configurar a criptografia no AWS Glue.	24 de agosto de 2018
Compatibilidade com métricas de trabalho do Apache Spark	Adição de informações sobre o uso de métricas do Apache Spark para melhorar a depuração e a criação de perfis de trabalhos de ETL. É possível facilment e acompanhar métricas do runtime como bytes lidos e gravados, uso de memória e carga de CPU do driver e executores, e ordem aleatória de dados entre os executore s no console do AWS Glue. Para obter mais informaçõ es, consulte Monitorar o AWS Glue usando métricas do CloudWatch, Monitorar e depurar trabalhos e Trabalhar com trabalhos no console do AWS Glue.	13 de julho de 2018

Compatibilidade com o DynamoDB como uma origem dos dados	Informações adicionadas sobre o crawling do DynamoDB e como usá-lo como uma origem dos dados de trabalhos de ETL. Para obter mais informações, consulte Catalogamento de tabelas com um crawler e Parâmetros de conexão.	10 de julho de 2018
Atualizações do procedimento para criar um servidor de cadernos	Informações atualizadas sobre como criar um servidor de cadernos em uma instância do Amazon EC2 associada a um endpoint de desenvolvimento. Para obter mais informações, consulte Criação de um servidor de caderno associado a um endpoint de desenvolvimento.	9 de julho de 2018
Atualizações agora disponíveis em RSS	Agora, é possível assinar um feed RSS para receber notificações sobre atualizações do Guia do desenvolvedor do AWS Glue.	25 de junho de 2018
Compatibilidade com notificações de atraso para trabalhos	Adicionadas informações sobre como configurar um limite de atraso quando um trabalho for executado. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	25 de maio de 2018

Configurar um crawler para acrescentar novas colunas	Adicionadas informações sobre a nova opção de configuração para crawlers, MergeNewColumns. Para obter mais informações, consulte Configuração de um crawler.	7 de maio de 2018
Compatibilidade com tempo limite para trabalhos	Adicionadas informações sobre como definir um tempo limite quando um trabalho é executado. Para obter mais informações, consulte Adição de trabalhos no AWS Glue.	10 de abril de 2018
Compatibilidade com script de ETL Scala e acionamento de trabalhos com base em estados adicionais de execução	Informações adicionadas sobre o uso do Scala como linguagem de programação de ETL. Além disso, a API do gatilho agora é compatível com disparos quando as condições são atendidas (junto com todas as outras condições). Os trabalhos podem ser acionados com base em uma execução de trabalho com falha ou interrompida (além de uma execução de trabalho concluída com sucesso).	12 de janeiro de 2018

Atualizações anteriores

A tabela a seguir descreve as alterações importantes em cada versão do Guia de desenvolvedor do AWS Glue antes de janeiro de 2018.

Alteração	Descrição	Data
Suporte a fontes de dados XML e nova opção de configuração do crawler	Informações adicionadas sobre a classificação de fontes de dados XML e nova opção de crawler para alterações de partição.	16 de novembro de 2017
Novas transformações, suporte a mecanismos de banco de dados adicionais do Amazon RDS e aprimoramentos do endpoint de desenvolvimento	Informações adicionadas sobre as transformações de filtro e mapa, suporte para o Amazon RDS Microsoft SQL Server e Amazon RDS Oracle, além de novos recursos para endpoints de desenvolvimento.	29 de setembro de 2017
Versão inicial do AWS Glue	Este é o lançamento inicial do Guia do desenvolvedor do AWS Glue.	14 de agosto de 2017

Glossário da AWS

Para obter a terminologia mais recente da AWS, consulte o glossário da AWS na Referência do Glossário da AWS.