

Managed Service für Apache Flink Entwicklerleitfaden

Managed Service für Apache Flink



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

Managed Service für Apache Flink: Managed Service für Apache Flink Entwicklerleitfaden

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

Die Handelsmarken und Handelsaufmachung von Amazon dürfen nicht in einer Weise in Verbindung mit nicht von Amazon stammenden Produkten oder Services verwendet werden, durch die Kunden irregeführt werden könnten oder Amazon in schlechtem Licht dargestellt oder diskreditiert werden könnte. Alle anderen Handelsmarken, die nicht Eigentum von Amazon sind, gehören den jeweiligen Besitzern, die möglicherweise zu Amazon gehören oder nicht, mit Amazon verbunden sind oder von Amazon gesponsert werden.

Table of Contents

X	wii
Was ist Managed Service für Apache Flink?	. 1
Entscheiden Sie sich zwischen der Verwendung von Managed Service für Apache Flink oder	
Managed Service für Apache Flink Studio	. 1
Wählen Sie aus, welcher Apache Flink in Managed Service für Apache Flink verwendet APIs	
werden soll	. 3
Wählen Sie eine Flink-API	. 3
Beginnen Sie mit Streaming-Datenanwendungen	5
Funktionsweise	6
Programmieren Sie Ihre Apache Flink-Anwendung	. 6
DataStream API	. 6
Tabellen-API	. 7
Erstellen Sie Ihre Anwendung Managed Service für Apache Flink	8
Erstellen einer Anwendung	8
Erstellen Sie Ihren Anwendungscode für Managed Service für Apache Flink	. 9
Erstellen Sie Ihre Managed Service für Apache Flink-Anwendung	10
Starten Sie Ihre Managed Service for Apache Flink-Anwendung	11
Überprüfen Sie Ihre Anwendung Managed Service für Apache Flink	11
Aktivieren Sie System-Rollbacks	12
Ausführen einer Anwendung	15
Identifizieren Sie den Bewerbungs- und Jobstatus	15
Batch-Workloads ausführen	17
Ressourcen für die Anwendung	17
Ressourcen für Managed Service für Apache Flink-Anwendungen	17
Ressourcen für die Apache Flink-Anwendung	18
Preisgestaltung	19
Funktionsweise	17
AWS-Region Verfügbarkeit	20
Beispiele für Preisgestaltung	21
DataStream API-Komponenten überprüfen 2	25
Konnektoren	25
Operatoren	36
Nachverfolgung von Ereignissen	37
Tabellen-API-Komponenten	38

Tabellen-API-Konnektoren	38
Zeitattribute der Tabellen-API	40
Benutze Python	40
Programmieren Sie Ihre Python-Anwendung	41
Erstellen Sie Ihre Python-Anwendung	44
Überwachen Sie Ihre Python-Anwendung	45
Verwenden Sie Laufzeiteigenschaften	47
Verwalten Sie Runtime-Eigenschaften mithilfe der Konsole	47
Laufzeiteigenschaften mit der CLI verwalten	48
Greifen Sie auf Laufzeiteigenschaften in einer Managed Service for Apache Flink-	
Anwendung zu	51
Verwenden Sie Apache Flink-Konnektoren	52
Bekannte Probleme	55
Implementieren Sie Fehlertoleranz	55
Konfigurieren Sie Checkpointing in Managed Service für Apache Flink	56
Sehen Sie sich die Beispiele für Checkpoint-APIs an	57
Anwendungs-Backups mithilfe von Snapshots verwalten	59
Verwalten Sie die automatische Erstellung von Snapshots	60
Wiederherstellung aus einem Snapshot, der inkompatible Statusdaten enthält	61
Sehen Sie sich die Snapshot-API-Beispiele	62
Verwenden Sie direkte Versionsupgrades für Apache Flink	65
Aktualisieren Sie Anwendungen	65
Führen Sie ein Upgrade auf eine neue Version durch	67
Machen Sie Anwendungs-Upgrades rückgängig	72
Bewährte Methoden	73
Bekannte Probleme	74
Implementieren Sie Anwendungsskalierung	75
Konfigurieren Sie Anwendungsparallelität und KPU ParallelismPer	76
Kinesis-Verarbeitungseinheiten zuweisen	77
Aktualisieren Sie die Parallelität Ihrer Anwendung	77
Verwenden Sie die automatische Skalierung	79
Überlegungen zu maxParallelism	81
Fügen Sie Tags zu Anwendungen hinzu	82
Fügen Sie Tags hinzu, wenn eine Anwendung erstellt wird	83
Fügen Sie Tags für eine bestehende Anwendung hinzu oder aktualisieren Sie sie	84
Tags für eine Anwendung auflisten	84

Entfernen Sie Tags aus einer Anwendung	85
Verwenden CloudFormation	85
Bevor Sie beginnen	85
Schreiben Sie eine Lambda-Funktion	85
Eine Lambda-Rolle erstellen	87
Aufrufen der Lambda-Funktion	88
Sehen Sie sich ein erweitertes Beispiel an	89
Verwenden Sie das Apache Flink Dashboard	95
Greifen Sie auf das Apache Flink Dashboard Ihrer Anwendung zu	95
Release-Versionen	97
Amazon Managed Service für Apache Flink 1.20	99
Unterstützte Features	99
Komponenten	100
Bekannte Probleme	101
Amazon Managed Service für Apache Flink 1.19	102
Unterstützte Features	102
Änderungen in Amazon Managed Service für Apache Flink 1.19.1	105
Komponenten	107
Bekannte Probleme	107
Amazon Managed Service für Apache Flink 1.18	108
Änderungen in Amazon Managed Service für Apache Flink mit Apache Flink 1.15	109
Komponenten	111
Bekannte Probleme	112
Amazon Managed Service für Apache Flink 1.15	112
Änderungen in Amazon Managed Service für Apache Flink mit Apache Flink 1.15	114
Komponenten	111
Bekannte Probleme	116
Frühere Versionen	116
Verwenden des Apache Flink Kinesis Streams-Konnektor mit früheren Apache Flink-	
Versionen	117
Anwendungen mit Apache Flink 1.8.2 erstellen	119
Anwendungen mit Apache Flink 1.6.2 erstellen	119
Aktualisieren von Anwendungen	120
Verfügbare Konnektoren in Apache Flink 1.6.2 und 1.8.2	121
Erste Schritte: Flink 1.13.2	121
Erste Schritte: Flink 1.11.1	149

Erste Schritte: Flink 1.8.2 — veraltet	178
Erste Schritte: Flink 1.6.2 — veraltet	205
Legacybeispiele	233
Verwenden Sie Studio-Notebooks mit Managed Service für Apache Flink	414
Verwenden Sie die richtige Runtime-Version des Studio-Notebooks	415
Erstellen Sie ein Studio-Notizbuch	416
Führen Sie eine interaktive Analyse von Streaming-Daten durch	417
Flink-Interpreter	418
Tabellenumgebungsvariablen von Apache Zeppelin	419
Stellen Sie es als Anwendung mit dauerhaftem Zustand bereit	419
Scala/Python-Kriterien	421
SQL-Kriterien	421
IAM-Berechtigungen	422
Verwenden Sie Konnektoren und Abhängigkeiten	422
Standardkonnektoren	423
Fügen Sie Abhängigkeiten und benutzerdefinierte Konnektoren hinzu	424
Benutzerdefinierte Funktionen	425
Überlegungen zu benutzerdefinierten Funktionen	426
Checkpointing aktivieren	428
Stellen Sie das Checkpoint-Intervall ein	428
Stellen Sie den Checkpoint-Typ ein	429
Aktualisieren Sie Studio Runtime	429
Führen Sie ein Upgrade Ihres Notebooks auf eine neue Studio Runtime durch	429
Arbeiten Sie mit AWS Glue	434
Tabelleneigenschaften	434
Beispiele und Tutorials für Studio-Notebooks in Managed Service für Apache Flink	436
Tutorial: Erstellen Sie ein Studio-Notizbuch in Managed Service für Apache Flink	437
Tutorial: Stellen Sie ein Studio-Notebook als Managed Service für eine Apache Flink-	
Anwendung mit dauerhaftem Zustand bereit	458
Sehen Sie sich Beispielabfragen zur Analyse von Daten in einem Studio-Notizbuch an	461
Beheben Sie Probleme mit Studio-Notebooks für Managed Service für Apache Flink	473
Stoppen Sie eine blockierte Anwendung	474
Als Anwendung mit dauerhaftem Zustand in einer VPC ohne Internetzugang bereitstelle	n 474
Deploy-as-app Reduzierung von Größe und Bauzeit	475
Jobs stornieren	477
Starten Sie den Apache Flink-Interpreter neu	478

Erstellen Sie benutzerdefinierte IAM-Richtlinien für Managed Service für Apache Flink Studic)-
Notebooks	478
AWS Glue	479
CloudWatch Logs	480
Kinesis-Streams	481
Amazon-MSK-Cluster	483
Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink	484
Überprüfen Sie die Anwendungskomponenten	179
Erfüllen Sie die erforderlichen Voraussetzungen	485
Einrichten eines -Kontos	486
Melde dich an für ein AWS-Konto	123
Erstellen eines Benutzers mit Administratorzugriff	123
Erteilen programmgesteuerten Zugriffs	489
Nächster Schritt	490
Richten Sie das ein AWS CLI	490
Nächster Schritt	492
Erstellen einer Anwendung	. 492
Erstellen Sie abhängige Ressourcen	493
Einrichten der lokalen Entwicklungsumgebung	495
Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn	496
Schreiben Sie Beispieldatensätze in den Eingabestream	500
Führen Sie Ihre Anwendung lokal aus	502
Beobachten Sie Eingabe- und Ausgabedaten in Kinesis-Streams	505
Stoppen Sie, dass Ihre Anwendung lokal ausgeführt wird	506
Kompilieren und verpacken Sie Ihren Anwendungscode	506
Laden Sie die JAR-Datei mit dem Anwendungscode hoch	507
Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink	507
Nächster Schritt	515
Bereinigen von -Ressourcen	515
Löschen Sie Ihre Managed Service for Apache Flink-Anwendung	515
Löschen Sie Ihre Kinesis-Datenstreams	516
Löschen Sie Ihre Amazon S3 S3-Objekte und Ihren Bucket	516
Löschen Sie Ihre IAM-Ressourcen	517
CloudWatch Löschen Sie Ihre Ressourcen	. 517
Erkunden Sie zusätzliche Ressourcen für Apache Flink	517
Erkunden Sie zusätzliche Ressourcen	517

Tutorial: Erste Schritte mit der TableAPI in Managed Service für Apache Flink	519
Überprüfen Sie die Anwendungskomponenten	519
Sorgen Sie dafür, dass die Voraussetzungen erfüllt sind	520
Erstellen einer Anwendung	521
Erstellen Sie abhängige Ressourcen	521
Einrichten der lokalen Entwicklungsumgebung	522
Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn	523
Führen Sie Ihre Anwendung lokal aus	529
Beobachten Sie, wie die Anwendung Daten in einen S3-Bucket schreibt	532
Stoppen Sie die lokale Ausführung Ihrer Anwendung	533
Kompilieren und verpacken Sie Ihren Anwendungscode	533
Laden Sie die Anwendungscode-JAR-Datei hoch	534
Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink	535
Nächster Schritt	541
Bereinigen von -Ressourcen	541
Löschen Sie die Anwendung Managed Service für Apache Flink	542
Löschen Sie Ihre Amazon-S3-Objekte und Buckets	542
Löschen Ihrer IAM-Ressourcen	543
CloudWatch Löschen Sie Ihre Ressourcen 5	543
Nächster Schritt	543
Erkunden Sie weitere Ressourcen	543
Tutorial: Erste Schritte mit Python in Managed Service für Apache Flink	544
Überprüfen Sie die Anwendungskomponenten	544
Erfüllen Sie die Voraussetzungen	545
Erstellen einer Anwendung	547
Erstellen Sie abhängige Ressourcen	548
Einrichten der lokalen Entwicklungsumgebung	549
Laden Sie den Apache Flink-Streaming-Python-Code herunter und untersuchen Sie ihn	551
JAR-Abhängigkeiten	554
Schreiben Sie Beispieldatensätze in den Eingabestream	556
Führen Sie Ihre Anwendung lokal aus	558
Beobachten Sie Eingabe- und Ausgabedaten in Kinesis-Streams	560
Stoppen Sie die lokale Ausführung Ihrer Anwendung	561
Package Sie Ihren Anwendungscode	561
Hochladen des Anwendungspakets in einen Amazon S3 Bucket	561
Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink	562

Nächster Schritt	569
Bereinigen von -Ressourcen	569
Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt	569
Löschen Ihrer Kinesis-Datenstreams	570
Löschen Sie Ihre Amazon-S3-Objekte und Buckets	570
Löschen Ihrer IAM-Ressourcen	571
CloudWatch Löschen Sie Ihre Ressourcen	571
Tutorial: Erste Schritte mit Scala in Managed Service für Apache Flink	572
Erstellen Sie abhängige Ressourcen	572
Schreiben Sie Beispieldatensätze in den Eingabestream	573
Laden Sie den Anwendungscode herunter und überprüfen Sie ihn	575
Kompilieren Sie den Anwendungscode und laden Sie ihn hoch	576
Erstellen und Ausführen der Anwendung (Konsole)	577
Erstellen Sie die Anwendung	578
Konfigurieren der Anwendung	578
Bearbeiten Sie die IAM-Richtlinie	580
Führen Sie die Anwendung aus.	582
Stoppt die Anwendung	582
Erstellen und Ausführen der Anwendung (CLI)	582
Erstellen einer Berechtigungsrichtlinie	582
Eine IAM-Richtlinie erstellen	584
Erstellen der Anwendung	586
Starten der Anwendung	587
Stoppt die Anwendung	409
Fügen Sie eine CloudWatch Protokollierungsoption hinzu	409
Aktualisieren von Umgebungseigenschaften	409
Den Anwendungscode aktualisieren	410
Bereinigen von AWS -Ressourcen	591
So löschen Sie die Anwendung Managed Service für Apache Flink	591
So löschen Sie die Kinesis Data Streams	591
Löschen Sie Ihr Amazon S3 S3-Objekt und Ihren Bucket	591
So löschen Sie die IAM-Ressourcen	592
CloudWatch Löschen Sie Ihre Ressourcen	592
Verwenden Sie Apache Beam mit Managed Service für Apache Flink-Anwendungen	593
Einschränkungen des Apache Flink Runners mit Managed Service für Apache Flink	593
Funktionen von Apache Beam mit Managed Service für Apache Flink	594

Erstellen einer Anwendung mit Apache Beam	594
Erstellen Sie abhängige Ressourcen	595
Schreiben Sie Beispieldatensätze in den Eingabestream	595
Laden Sie den Anwendungscode herunter und untersuchen Sie ihn	596
Kompilieren des Anwendungscodes	597
Hochladen des Apache Flink-Streaming-Java-Codes	598
Erstellen Sie die Anwendung Managed Service für Apache Flink und führen Sie sie aus	598
Bereinigen	602
Nächste Schritte	604
Schulungsworkshops, Labore und Lösungsimplementierungen	605
Workshop zu Managed Service für Apache Flink	605
Entwickeln Sie Apache Flink-Anwendungen lokal, bevor Sie sie auf Managed Service for	
Apache Flink bereitstellen	606
Ereigniserkennung mit Managed Service für Apache Flink Studio	606
AWS Lösung für Streaming-Daten	606
Üben Sie die Nutzung eines Clickstream-Labors mit Apache Flink und Apache Kafka	607
Richten Sie benutzerdefinierte Skalierung mit Application Auto Scaling ein	607
Sehen Sie sich ein Beispiel für ein CloudWatch Amazon-Dashboard an	607
Verwenden Sie Vorlagen für die AWS Streaming-Datenlösung für Amazon MSK	608
Weitere Managed Service für Apache Flink-Lösungen finden Sie unter GitHub	608
Verwenden Sie praktische Hilfsprogramme für Managed Service für Apache Flink	609
Snapshot-Manager	609
Benchmarking	609
Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-	
Anwendungen	610
Java-Beispiele für Managed Service für Apache Flink	610
Python-Beispiele für Managed Service für Apache Flink	614
	614
Scala-Beispiele für Managed Service für Apache Flink	616
Managed Service für Apache Flink verwenden	617
Datenschutz	618
Datenverschlüsselung	618
Identity and Access Management für Managed Service für Apache Flink	619
Zielgruppe	619
Authentifizierung mit Identitäten	620
Verwalten des Zugriffs mit Richtlinien	624

So funktioniert Amazon Managed Service für Apache Flink mit IAM	627
Beispiele für identitätsbasierte Richtlinien	635
Fehlerbehebung	639
Serviceübergreifende Confused-Deputy-Prävention	641
Compliance-Validierung für Managed Service für Apache Flink	643
FedRAMP	644
Ausfallsicherheit und Notfallwiederherstellung in Managed Service für Apache Flink	644
Notfallwiederherstellung	644
Versionsverwaltung	645
Infrastruktursicherheit in Managed Service für Apache Flink	645
Bewährte Methoden für die Sicherheit für Managed Service für Apache Flink	646
Implementieren des Zugriffs mit geringsten Berechtigungen	646
Verwenden von IAM-Rollen zum Zugriff auf andere Amazon-Services	646
Implementieren der serverseitigen Verschlüsselung in abhängigen Ressourcen	647
Wird zur Überwachung von API-Aufrufen verwendet CloudTrail	647
Protokollierung und Überwachung in Amazon Managed Service für Apache Flink	648
Anmeldung bei Managed Service für Apache Flink	649
Logs mit CloudWatch Logs Insights abfragen	649
Überwachung im Managed Service für Apache Flink	649
Anwendungsprotokollierung in Managed Service für Apache Flink einrichten	651
Richten Sie die CloudWatch Protokollierung mithilfe der Konsole ein	651
CloudWatch Logging mit der CLI einrichten	652
Steuern Sie die Ebenen der Anwendungsüberwachung	657
Wenden Sie bewährte Methoden für die Protokollierung an	658
Führen Sie eine Fehlerbehebung bei der Protokol	658
Verwenden Sie CloudWatch Logs Insights	659
Analysieren Sie Logs mit CloudWatch Logs Insights	659
Ausführen einer Beispielabfrage	660
Sehen Sie sich Beispielabfragen an	661
Metriken und Dimensionen in Managed Service für Apache Flink	664
Anwendungsmetriken	664
Metriken des Kinesis Data Streams Streams-Konnektors	696
Amazon MSK-Connector-Metriken	697
Apache Zeppelin-Metriken	699
Metriken anzeigen CloudWatch	700
Legen Sie Berichtsebenen für CloudWatch Kennzahlen fest	701

Verwenden Sie benutzerdefinierte Metriken mit Amazon Managed Service für Apache	
Flink	702
Verwenden Sie CloudWatch Alarme mit Amazon Managed Service für Apache Flink	706
Schreiben Sie benutzerdefinierte Nachrichten in CloudWatch Logs	720
Schreiben Sie mit CloudWatch Log4J in Protokolle	721
Schreiben Sie mit J in CloudWatch Logs SLF4	722
Log Managed Service für Apache Flink API-Aufrufe mit AWS CloudTrail	723
Informationen zu Managed Service für Apache Flink finden Sie unter CloudTrail	723
Verstehen Sie die Einträge in der Protokolldatei von Managed Service for Apache Flink	724
Optimieren Sie die Leistung	727
Beheben Sie Leistungsprobleme	727
Verstehen Sie den Datenpfad	727
Lösungen zur Fehlerbehebung bei der Leistung	728
Verwenden Sie bewährte Methoden zur Leistungssteigerung	730
Richtiges Verwalten der Skalierung	730
Überwachen der Nutzung externer Abhängigkeitsressourcen	733
Lokales Ausführen Ihrer Apache-Flink-Anwendung	733
Überwachen Sie die Leistung	733
Überwachen Sie die Leistung anhand von CloudWatch Kennzahlen	733
Überwachen Sie die Leistung mithilfe von CloudWatch Protokollen und Alarmen	733
Managed Service für Apache Flink und Studio Notebook-Kontingent	735
Wartungsaufgaben für Managed Service für Apache Flink verwalten	737
Wählen Sie ein Wartungsfenster	739
Identifizieren Sie Wartungsinstanzen	740
Erzielen Sie die Produktionsreife Ihres Managed Service für Apache Flink-Anwendungen	741
Testen Sie Ihre Anwendungen unter Last	741
Definieren Sie Max. Parallelität	742
Festlegen einer UUID für alle Operatoren	742
Bewährte Methoden	743
Minimiere die Größe des Uber-JAR	743
Fehlertoleranz: Prüfpunkte und Savepoints	746
Nicht unterstützte Konnektor-Versionen	747
Leistung und Parallelität	747
Parallelität pro Operator festlegen	748
Protokollierung	748
Codierung	749

Verwalten von Anmeldeinformationen.	749
Lesen aus Quellen mit wenigen Shards/Partitionen	750
Aktualisierungsintervall für Studio-Notebooks	750
Optimale Leistung des Studio-Notebooks	750
Wie sich Strategien mit Wasserzeichen und ungenutzte Shards auf Zeitfenster auswirken	751
Übersicht	753
Beispiel	753
Festlegen einer UUID für alle Operatoren	762
Zum Maven ServiceResourceTransformer Shade-Plugin hinzufügen	763
Stateful-Funktionen von Apache Flink	764
Apache Flink-Anwendungsvorlage	764
Ort der Modulkonfiguration	765
Erfahren Sie mehr über die Apache Flink-Einstellungen	766
Apache Flink-Konfiguration	766
Bundesstaatliches Backend	767
Checkpointing	767
Savepointing	768
Haufengrößen	769
Puffer-Entlastung	769
Anpassbare Flink-Konfigurationseigenschaften	769
Strategie neu starten	769
Checkpoints und Status-Backends	770
Checkpointing	770
Native RocksDB-Metriken	770
RocksDB-Optionen	771
Erweiterte State-Backend-Optionen	772
Vollständige Optionen TaskManager	772
Arbeitsspeicherkonfiguration	772
RPC / Akka	773
Client	773
Erweiterte Cluster-Optionen	773
Dateisystemkonfigurationen	773
Erweiterte Optionen für die Fehlertoleranz	773
Arbeitsspeicherkonfiguration	772
Metriken	774
Erweiterte Optionen für den REST-Endpunkt und -Client	774

Erweiterte SSL-Sicherheitsoptionen	774
Erweiterte Planungsoptionen	774
Erweiterte Optionen für die Flink-Weboberfläche	774
Konfigurierte Flink-Eigenschaften anzeigen	774
MSF für den Zugriff auf Ressourcen in einer Amazon VPC konfigurieren	775
Amazon VPC-Konzepte	775
VPC-Anwendungsberechtigungen	776
Fügen Sie eine Berechtigungsrichtlinie für den Zugriff auf eine Amazon VPC hinzu	777
Richten Sie den Internet- und Servicezugriff für eine VPC-verbundene Managed Service for	
Apache Flink-Anwendung ein	778
Ähnliche Informationen	779
Verwenden Sie die Managed Service for Apache Flink VPC-API	779
Anwendung erstellen	779
AddApplicationVpcConfiguration	780
DeleteApplicationVpcConfiguration	781
Anwendung aktualisieren	781
Beispiel: Verwenden Sie eine VPC	782
Problembehandlung bei Managed Service für Apache Flink	783
Fehlerbehebung bei der Entwicklung	783
Bewährte Methoden für das Rollback von Systemen	784
Bewährte Methoden für die Hudi-Konfiguration	785
Apache Flink Flame-Diagramme	785
Problem mit dem Anmeldeinformationsanbieter mit dem EFO-Connector 1.15.2	786
Anwendungen mit nicht unterstützten Kinesis-Konnektoren	786
Kompilierungsfehler: "Abhängigkeiten für das Projekt konnten nicht aufgelöst werden"	789
Ungültige Auswahl: "kinesisanalyticsv2"	789
UpdateApplication Aktion ist kein erneutes Laden des Anwendungscodes	790
S3 StreamingFileSink FileNotFoundExceptions	790
FlinkKafkaConsumer Problem mit Stop with Savepoint	792
Flink 1.15 Async Sink Deadlock	792
Die Quellverarbeitung von Amazon Kinesis Kinesis-Datenstreams ist beim Re-Sharding	
nicht in der richtigen Reihenfolge	802
Häufig gestellte Fragen und Problemlösungen zum Einbetten von Vektoren in Echtzeit	803
Fehlerbehebung während der Laufzeit	816
Tools zur Fehlerbehebung	817
Probleme mit der Anwendung	817

Die Anwendung wird neu gestartet	822
Der Durchsatz ist zu langsam	825
Unbegrenztes staatliches Wachstum	826
E/A-gebundene Operatoren	828
Upstream- oder Quelldrosselung aus einem Kinesis-Datenstrom	828
Checkpoints	829
Beim Checkpointing kommt es zu einer Zeitüberschreitung	836
Checkpoint-Fehler für Apache Beam	837
Gegendruck	839
Verzerrte Datenverteilung	841
Zustandsverzerrung	841
Integrieren Sie Ressourcen in verschiedenen Regionen	842
Dokumentverlauf	843
API-Beispielcode	850
AddApplicationCloudWatchLoggingOption	851
AddApplicationInput	851
AddApplicationInputProcessingConfiguration	852
AddApplicationOutput	853
AddApplicationReferenceDataSource	853
AddApplicationVpcConfiguration	854
CreateApplication	855
CreateApplicationSnapshot	856
DeleteApplication	856
DeleteApplicationCloudWatchLoggingOption	856
DeleteApplicationInputProcessingConfiguration	857
DeleteApplicationOutput	857
DeleteApplicationReferenceDataSource	857
DeleteApplicationSnapshot	858
DeleteApplicationVpcConfiguration	858
DescribeApplication	858
DescribeApplicationSnapshot	858
DiscoverInputSchema	859
ListApplications	859
ListApplicationSnapshots	860
StartApplication	860
StopApplication	860

UpdateApplication	861
API-Referenz	862
	863

Amazon Managed Service für Apache Flink war zuvor als Amazon Kinesis Data Analytics für Apache Flink bekannt.

Die vorliegende Übersetzung wurde maschinell erstellt. Im Falle eines Konflikts oder eines Widerspruchs zwischen dieser übersetzten Fassung und der englischen Fassung (einschließlich infolge von Verzögerungen bei der Übersetzung) ist die englische Fassung maßgeblich.

Was ist Amazon Managed Service für Apache Flink?

Mit Amazon Managed Service für Apache Flink können Sie Java, Scala, Python oder SQL verwenden, um Streaming-Daten zu verarbeiten und zu analysieren. Mit diesem Service können Sie Code für Streaming-Quellen und statische Quellen erstellen und ausführen, um Zeitreihenanalysen durchzuführen, Echtzeit-Dashboards und Metriken bereitzustellen.

Mithilfe von Open-Source-Bibliotheken, die auf Apache Flink basieren, können Sie in Managed Service für Apache Flink Anwendungen in der Sprache Ihrer Wahl erstellen. Apache Flink ist ein beliebtes Framework und eine verteilte Engine zum Verarbeiten von Datenströmen.

Managed Service für Apache Flink stellt die zugrunde liegende Infrastruktur für Ihre Apache-Flink-Anwendungen bereit. Es verarbeitet Kernfunktionen wie die Bereitstellung von Rechenressourcen, AZ-Failover-Resilienz, parallel Berechnung, automatische Skalierung und Anwendungs-Backups (implementiert als Checkpoints und Snapshots). Sie können die allgemeinen Flink-Programmier-Features (wie Operatoren, Funktionen, Quellen und Senken) genauso verwenden, wie Sie sie verwenden, wenn Sie die Flink-Infrastruktur selbst hosten.

Entscheiden Sie sich zwischen der Verwendung von Managed Service für Apache Flink oder Managed Service für Apache Flink Studio

Sie haben zwei Möglichkeiten, Ihre Flink-Jobs mit Amazon Managed Service für Apache Flink auszuführen. Mit <u>Managed Service für Apache Flink</u> erstellen Sie Flink-Anwendungen in Java, Scala oder Python (und Embedded SQL) mit einer IDE Ihrer Wahl und dem Apache Flink Datastream oder Table. APIs Mit <u>Managed Service für Apache Flink Studio</u> können Sie Datenströme interaktiv in Echtzeit abfragen und problemlos Streamverarbeitungsanwendungen mit Standard-SQL, Python und Scala erstellen und ausführen.

Sie können auswählen, welche Methode am besten zu Ihrem Anwendungsfall passt. Wenn Sie sich nicht sicher sind, finden Sie in diesem Abschnitt allgemeine Anleitungen, die Ihnen weiterhelfen sollen.

Entscheiden Sie sich zwischen der Verwendung von Managed Service für Apache Flink oder Managed Service für Apache Flink Studio



Bevor Sie sich entscheiden, ob Sie Amazon Managed Service für Apache Flink oder Amazon Managed Service für Apache Flink Studio verwenden möchten, sollten Sie Ihren Anwendungsfall berücksichtigen.

Wenn Sie planen, eine lang laufende Anwendung zu betreiben, die Workloads wie Streaming ETL oder Continuous Applications übernimmt, sollten Sie die Verwendung von <u>Managed Service für</u> Apache Flink in Betracht ziehen. Das liegt daran, dass Sie Ihre Flink-Anwendung mit dem Flink APIs direkt in der IDE Ihrer Wahl erstellen können. Die lokale Entwicklung mit Ihrer IDE stellt außerdem sicher, dass Sie die gängigen Prozesse und Tools des Software Development Lifecycle (SDLC) wie Codeversionierung in Git, CI/CD-Automatisierung oder Unit-Tests nutzen können.

Wenn Sie an der Ad-hoc-Datenexploration interessiert sind, Streaming-Daten interaktiv abfragen oder private Echtzeit-Dashboards erstellen möchten, hilft Ihnen <u>Managed Service für Apache Flink Studio</u> dabei, diese Ziele mit nur wenigen Klicks zu erreichen. Benutzer, die mit SQL vertraut sind, können erwägen, eine lang laufende Anwendung direkt von Studio aus bereitzustellen.

Note

Sie können Ihr Studio-Notizbuch zu einer Anwendung mit langer Laufzeit heraufstufen. Wenn Sie jedoch Tools wie Codeversionierung auf Git und CI/CD-Automatisierung oder Techniken wie Unit-Tests in Ihre SDLC-Tools integrieren möchten, empfehlen wir Managed Service for Apache Flink mit der IDE Ihrer Wahl.

Wählen Sie aus, welcher Apache Flink in Managed Service für Apache Flink verwendet APIs werden soll

Sie können Anwendungen mit Java, Python und Scala in Managed Service für Apache Flink mithilfe von Apache Flink APIs in einer IDE Ihrer Wahl erstellen. <u>In der Dokumentation finden Sie Anleitungen zum Erstellen von Anwendungen mit dem Flink Datastream und der Tabellen-API.</u> Sie können die Sprache, in der Sie Ihre Flink-Anwendung erstellen, und die Sprache, die APIs Sie verwenden, auswählen, um den Anforderungen Ihrer Anwendung und Ihres Betriebs am besten gerecht zu werden. Wenn Sie sich nicht sicher sind, finden Sie in diesem Abschnitt allgemeine Anleitungen, die Ihnen weiterhelfen sollen.

Wählen Sie eine Flink-API

Die Apache Flink APIs haben unterschiedliche Abstraktionsebenen, die sich darauf auswirken können, wie Sie Ihre Anwendung erstellen. Sie sind ausdrucksstark und flexibel und können zusammen verwendet werden, um Ihre Anwendung zu erstellen. Sie müssen nicht nur eine Flink-API verwenden. Sie können mehr über den Flink APIs in der <u>Apache Flink-Dokumentation</u> erfahren.

Flink bietet vier Ebenen der API-Abstraktion: Flink SQL, Tabellen-API, DataStream API und Process Function, die in Verbindung mit der API verwendet wird. DataStream Diese werden alle in Amazon Managed Service für Apache Flink unterstützt. Es ist ratsam, wenn möglich mit einer höheren Abstraktionsebene zu beginnen. Einige Flink-Funktionen sind jedoch nur mit der <u>Datastream-API</u> verfügbar, mit der Sie Ihre Anwendung in Java, Python oder Scala erstellen können. Sie sollten die Verwendung der Datastream-API in Betracht ziehen, wenn:

- Sie benötigen eine detaillierte Kontrolle über den Status
- Sie möchten die Möglichkeit nutzen, eine externe Datenbank oder einen externen Endpunkt asynchron aufzurufen (z. B. für Inferenzen)

- Sie möchten benutzerdefinierte Timer verwenden (z. B. um benutzerdefiniertes Windowing oder Late-Event-Handling zu implementieren)
- Sie möchten in der Lage sein, den Ablauf Ihrer Anwendung zu ändern, ohne den Status zurückzusetzen



Apache Flink APIs

Note

Wählen Sie eine Sprache mit der DataStream API:

- SQL kann in jede Flink-Anwendung eingebettet werden, unabhängig von der gewählten Programmiersprache.
- Wenn Sie planen, die DataStream API zu verwenden, werden nicht alle Konnektoren in Python unterstützt.
- Wenn Sie wenig benötigen, latency/high-throughput you should consider Java/Scala unabhängig von der API.
- Wenn Sie Async IO in der Process Functions API verwenden möchten, müssen Sie Java verwenden.

Die Wahl der API kann sich auch auf Ihre Fähigkeit auswirken, die Anwendungslogik weiterzuentwickeln, ohne den Status zurücksetzen zu müssen. Dies hängt von einer bestimmten Funktion ab, der Fähigkeit, UID für Operatoren festzulegen, die nur in der DataStream API für Java und Python verfügbar ist. Weitere Informationen finden Sie unter UUIDs Für alle Operatoren festlegen in der Apache Flink-Dokumentation.

Beginnen Sie mit Streaming-Datenanwendungen

Sie können damit beginnen, eine Anwendung, die Managed Service für Apache Flink nutzt, zu erstellen, die kontinuierlich Streaming-Daten liest und verarbeitet. Verfassen Sie dann Ihren Code mit der IDE Ihrer Wahl und testen Sie ihn mit Live-Streaming-Daten. Sie können auch Ziele konfigurieren, an die Managed Service für Apache Flink die Ergebnisse senden soll.

Um loszulegen, empfehlen wir Ihnen, die folgenden Abschnitte zu lesen:

- Managed Service für Apache Flink: So funktioniert's
- Erste Schritte mit Amazon Managed Service für Apache Flink (DataStream API)

Alternativ können Sie damit beginnen, ein Managed Service for Apache Flink Studio-Notebook zu erstellen, mit dem Sie Datenströme interaktiv in Echtzeit abfragen und Streamverarbeitungsanwendungen mit Standard-SQL, Python und Scala einfach erstellen und ausführen können. Mit ein paar Klicks können Sie ein serverloses Notebook starten AWS Management Console, um Datenströme abzufragen und innerhalb von Sekunden Ergebnisse zu erhalten. Um loszulegen, empfehlen wir Ihnen, die folgenden Abschnitte zu lesen:

- Verwenden Sie ein Studio-Notebook mit Managed Service für Apache Flink
- Erstellen Sie ein Studio-Notizbuch

Managed Service für Apache Flink: So funktioniert's

Managed Service for Apache Flink ist ein vollständig verwalteter Amazon-Service, mit dem Sie eine Apache Flink-Anwendung zur Verarbeitung von Streaming-Daten verwenden können. Zuerst programmieren Sie Ihre Apache Flink-Anwendung und dann erstellen Sie Ihre Managed Service for Apache Flink-Anwendung.

Programmieren Sie Ihre Apache Flink-Anwendung

Eine Apache-Flink-Anwendung ist eine Java- oder Scala-Anwendung, die mit dem Apache-Flink-Framework erstellt wurde. Sie entwickeln und erstellen Ihre Apache-Flink-Anwendung lokal.

Anwendungen verwenden hauptsächlich entweder die <u>DataStream API</u> oder die <u>Tabellen-API</u>. Die anderen Apache Flink APIs stehen Ihnen ebenfalls zur Verfügung, werden jedoch weniger häufig beim Erstellen von Streaming-Anwendungen verwendet.

Die Funktionen der beiden APIs sind wie folgt:

DataStream API

Das Apache Flink DataStream API-Programmiermodell basiert auf zwei Komponenten:

- Datenstrom: Die strukturierte Darstellung eines kontinuierlichen Flusses von Datensätzen.
- Transformationsoperator: Nimmt einen oder mehrere Datenströme als Eingabe und erzeugt einen oder mehrere Datenströme als Ausgabe.

Mit der DataStream API erstellte Anwendungen haben folgende Funktionen:

- Daten aus einer Datenquelle (z. B. einem Kinesis-Strom oder einem Amazon-MSK-Thema).
- Transformationen auf die Daten anwenden, z. B. Filterung, Aggregation oder Anreicherung.
- Transformierte Daten in eine Datensenke schreiben.

Anwendungen, die die DataStream API verwenden, können in Java oder Scala geschrieben werden und können aus einem Kinesis-Datenstream, einem Amazon MSK-Thema oder einer benutzerdefinierten Quelle lesen.

Ihre Anwendung verarbeitet Daten mithilfe eines Konnektors. Apache Flink verwendet die folgenden Arten von Konnektoren:

- Quelle: Ein Konnektor, der zum Lesen externer Daten verwendet wird.
- Senke: Ein Konnektor, der zum Schreiben an externe Standorte verwendet wird.
- Operator: Ein Konnektor, der zur Verarbeitung von Daten innerhalb der Anwendung verwendet wird.

Eine typische Anwendung besteht aus mindestens einem Datenstrom mit einer Quelle, einem Datenstrom mit einem oder mehreren Operatoren und mindestens einer Datensenke.

Weitere Informationen zur Verwendung der DataStream API finden Sie unter. <u>DataStream API-</u> Komponenten überprüfen

Tabellen-API

Das Programmiermodell der Tabellen-API von Apache Flink basiert auf den folgenden Komponenten:

- Tabellenumgebung: Eine Schnittstelle zu zugrunde liegenden Daten, die Sie verwenden, um eine oder mehrere Tabellen zu erstellen und zu hosten.
- Tabelle: Ein Objekt, das den Zugriff auf eine SQL-Tabelle oder -Ansicht ermöglicht.
- Tabellenquelle: Wird verwendet, um Daten aus einer externen Quelle zu lesen, z. B. aus einem Amazon-MSK-Thema.
- Tabellenfunktion: Eine SQL-Abfrage oder ein API-Aufruf, der zur Transformation von Daten verwendet wird.
- Tabellensenke: Wird verwendet, um Daten an einen externen Speicherort zu schreiben, z. B. in einen Amazon-S3-Bucket.

Anwendungen, die mit der Tabellen-API erstellt werden, haben folgende Funktionen:

- Erstellen einer TableEnvironment durch Herstellen einer Verbindung zu einer Table Source.
- Erstellen einer Tabelle in der TableEnvironment durch entweder SQL-Abfragen oder Tabellen-API-Funktionen.
- Ausführen einer Tabellenabfrage über die Tabellen-API oder SQL
- Anwenden von Transformationen auf die Abfrageergebnisse über Tabellenfunktionen oder SQL-Abfragen.

• Schreiben der Abfrage- oder Funktionsergebnisse in eine Table Sink.

Anwendungen, die die Tabellen-API verwenden, können in Java oder Scala geschrieben werden und Daten entweder mittels API-Aufrufen oder SQL-Abfragen abfragen.

Weitere Informationen zur Verwendung der Tabellen-API finden Sie unter <u>API-Komponenten von</u> Review Table.

Erstellen Sie Ihre Anwendung Managed Service für Apache Flink

Managed Service für Apache Flink ist ein AWS Dienst, der eine Umgebung für das Hosten Ihrer Apache Flink-Anwendung erstellt und ihr die folgenden Einstellungen zur Verfügung stellt:

- <u>Verwenden Sie Laufzeiteigenschaften</u>: Parameter, die Sie Ihrer Anwendung zur Verfügung stellen können. Sie können diese Parameter ändern, ohne Ihren Anwendungscode neu kompilieren zu müssen.
- Implementieren Sie Fehlertoleranz: Wie sich Ihre Anwendung nach Unterbrechungen und Neustarts wiederherstellt.
- <u>Protokollierung und Überwachung in Amazon Managed Service für Apache Flink</u>: Wie Ihre Anwendung Ereignisse in Logs protokolliert. CloudWatch
- Implementieren Sie Anwendungsskalierung: Wie Ihre Anwendung Datenverarbeitungsressourcen bereitstellt.

Sie können die Anwendung mit Managed Service für Apache Flink entweder über die Konsole oder die AWS CLI erstellen und ausführen. Erste Schritte zum Erstellen einer Anwendung mit Managed Service für Apache Flink finden Sie unter <u>Tutorial: Erste Schritte mit der DataStream API in Managed</u> Service für Apache Flink.

Erstellen Sie einen Managed Service für die Apache Flink-Anwendung

Dieses Thema enthält Informationen zum Erstellen einer Managed Service für Apache Flink-Anwendung.

Dieses Thema enthält die folgenden Abschnitte:

• Erstellen Sie Ihren Anwendungscode für Managed Service für Apache Flink

- Erstellen Sie Ihre Managed Service für Apache Flink-Anwendung
- Starten Sie Ihre Managed Service for Apache Flink-Anwendung
- <u>Überprüfen Sie Ihre Anwendung Managed Service für Apache Flink</u>
- Aktivieren Sie System-Rollbacks für Ihre Managed Service for Apache Flink-Anwendung

Erstellen Sie Ihren Anwendungscode für Managed Service für Apache Flink

In diesem Abschnitt werden die Komponenten beschrieben, mit denen Sie den Anwendungscode für Ihre Managed Service for Apache Flink-Anwendung erstellen.

Es wird empfohlen, die neueste unterstützte Version von Apache Flink für Ihren Anwendungscode zu verwenden. Informationen zur Aktualisierung von Managed Service für Apache Flink-Anwendungen finden Sie unter Verwenden Sie direkte Versionsupgrades für Apache Flink.

Sie erstellen Ihren Anwendungscode mit <u>Apache Maven</u>. Ein Apache Maven-Projekt verwendet eine pom.xml-Datei, um die Versionen der verwendeten Komponenten anzugeben.

Note

Managed Service für Apache Flink unterstützt JAR-Dateien mit einer Größe von bis zu 512 MB. Wenn Sie eine größere JAR-Datei verwenden, kann Ihre Anwendung nicht gestartet werden.

Anwendungen können jetzt die Java-API von jeder Scala-Version aus verwenden. Sie müssen die Scala-Standardbibliothek Ihrer Wahl in Ihre Scala-Anwendungen integrieren.

Informationen zum Erstellen einer Managed-Service-für-Apache-Flink-Anwendung, die Apache Beam verwendet, finden Sie unter <u>Verwenden Sie Apache Beam mit Managed Service für Apache Flink-Anwendungen</u>.

Geben Sie die Apache Flink-Version Ihrer Anwendung an

Wenn Sie Managed Service für Apache Flink Laufzeit Version 1.1.0 und höher verwenden, geben Sie die Version von Apache Flink an, die Ihre Anwendung verwendet, wenn Sie Ihre Anwendung kompilieren. Sie geben die Version von Apache Flink mit dem Parameter an-Dflink.version. Wenn Sie beispielsweise Apache Flink 1.19.1 verwenden, geben Sie Folgendes an:

mvn package -Dflink.version=1.19.1

Informationen zum Erstellen von Anwendungen mit früheren Versionen von Apache Flink finden Sie unter. Frühere Versionen

Erstellen Sie Ihre Managed Service für Apache Flink-Anwendung

Nachdem Sie Ihren Anwendungscode erstellt haben, gehen Sie wie folgt vor, um Ihre Managed Service for Apache Flink-Anwendung zu erstellen:

- Laden Sie Ihren Anwendungscode hoch: Laden Sie Ihren Anwendungscode in einen Amazon-S3-Bucket hoch. Geben Sie beim Erstellen Ihrer Anwendung den S3-Bucket-Namen und den Objektnamen Ihres Anwendungscodes an. Ein Tutorial, das zeigt, wie Sie Ihren Anwendungscode hochladen, finden Sie im <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für</u> Apache Flink Tutorial.
- Erstellen Sie Ihre Managed Service für Apache Flink-Anwendung: Verwenden Sie eine der folgenden Methoden, um Ihre Managed Service für Apache Flink-Anwendung zu erstellen:
 - Erstellen Sie Ihre Managed Service for Apache Flink-Anwendung mithilfe der AWS Konsole: Sie können Ihre Anwendung mithilfe der AWS Konsole erstellen und konfigurieren.

Wenn Sie Ihre Anwendung mithilfe der Konsole erstellen, werden die abhängigen Ressourcen Ihrer Anwendung (wie CloudWatch Log-Streams, IAM-Rollen und IAM-Richtlinien) für Sie erstellt.

Wenn Sie die Anwendung mithilfe der Konsole erstellen, geben Sie an, welche Version von Apache Flink Ihre Anwendung verwendet, indem Sie sie aus dem Pulldown-Menü auf der Seite Managed– Service für Apache Flink Anwendung erstellen auswählen.

Ein Tutorial zur Verwendung der Konsole zum Erstellen einer Anwendung finden Sie im <u>Tutorial:</u> Erste Schritte mit der DataStream API in Managed Service für Apache Flink Tutorial.

• Erstellen Sie Ihre Managed Service for Apache Flink-Anwendung mit der AWS CLI: Sie können Ihre Anwendung mit der AWS CLI erstellen und konfigurieren.

Wenn Sie Ihre Anwendung mithilfe der CLI erstellen, müssen Sie auch die abhängigen Ressourcen Ihrer Anwendung (wie CloudWatch Log-Streams, IAM-Rollen und IAM-Richtlinien) manuell erstellen. Wenn Sie Ihre Anwendung mit der CLI erstellen, geben Sie mithilfe des RuntimeEnvironment-Aktionsparameters der CreateApplication-Aktion an, welche Version von Apache Flink Ihre Anwendung verwendet.

1 Note

Sie können die RuntimeEnvironment einer vorhandenen Anwendung ändern. Um zu erfahren wie dies geht, vgl. <u>Verwenden Sie direkte Versionsupgrades für Apache Flink</u>.

Starten Sie Ihre Managed Service for Apache Flink-Anwendung

Nachdem Sie Ihren Anwendungscode erstellt, in S3 hochgeladen und Ihre Managed Service für Apache Flink-Anwendung erstellt haben, starten Sie die Anwendung. Das Starten einer Anwendung Managed Service für Apache Flink dauert in der Regel mehrere Minuten.

Verwenden Sie eine der folgenden Methoden, um die Anwendung zu starten:

- Starten Sie Ihre Managed Service for Apache Flink-Anwendung über die AWS Konsole: Sie können Ihre Anwendung ausführen, indem Sie auf der Seite Ihrer Anwendung in der AWS Konsole auf Ausführen klicken.
- Starten Sie Ihre Managed Service for Apache Flink-Anwendung mithilfe der AWS API: Sie können Ihre Anwendung mithilfe der <u>StartApplication</u>Aktion ausführen.

Überprüfen Sie Ihre Anwendung Managed Service für Apache Flink

Sie können auf folgende Arten überprüfen, ob die Anwendung funktioniert:

- Verwendung von CloudWatch Protokollen: Sie können CloudWatch Logs and CloudWatch Logs Insights verwenden, um zu überprüfen, ob Ihre Anwendung ordnungsgemäß ausgeführt wird. Informationen zur Verwendung von CloudWatch Logs mit Ihrer Managed Service for Apache Flink-Anwendung finden Sie unter<u>Protokollierung und Überwachung in Amazon Managed Service für</u> <u>Apache Flink</u>.
- Verwenden von CloudWatch Metriken: Sie können CloudWatch Metriken verwenden, um die Aktivität Ihrer Anwendung oder die Aktivitäten in den Ressourcen zu überwachen, die Ihre Anwendung für die Eingabe oder Ausgabe verwendet (wie Kinesis-Streams, Firehose-Streams)

oder Amazon S3 S3-Buckets). Weitere Informationen zu CloudWatch Metriken finden Sie unter Arbeiten mit Metriken im CloudWatch Amazon-Benutzerhandbuch.

 Überwachung der Ausgabespeicherorte: Wenn Ihre Anwendung die Ausgabe an einen Speicherort schreibt (z. B. einen Amazon S3-Bucket oder eine Datenbank), können Sie diesen Speicherort auf geschriebene Daten überwachen.

Aktivieren Sie System-Rollbacks für Ihre Managed Service for Apache Flink-Anwendung

Mit der System-Rollback-Funktion können Sie eine höhere Verfügbarkeit Ihrer laufenden Apache Flink-Anwendung auf Amazon Managed Service for Apache Flink erreichen. Wenn Sie sich für diese Konfiguration entscheiden, kann der Service die Anwendung automatisch auf die zuvor ausgeführte Version zurücksetzen, wenn eine Aktion wie Code UpdateApplication - oder autoscaling Konfigurationsfehler auftritt.

Note

Um die System-Rollback-Funktion nutzen zu können, müssen Sie sich anmelden, indem Sie Ihre Anwendung aktualisieren. Bestehende Anwendungen verwenden standardmäßig nicht automatisch das System-Rollback.

Funktionsweise

Wenn Sie einen Anwendungsvorgang starten, z. B. eine Aktualisierungs- oder Skalierungsaktion, versucht der Amazon Managed Service für Apache Flink zunächst, diesen Vorgang auszuführen. Wenn Probleme erkannt werden, die den Erfolg des Vorgangs verhindern, wie z. B. Codefehler oder unzureichende Berechtigungen, leitet der Service automatisch einen Vorgang ein. RollbackApplication

Beim Rollback wird versucht, die Anwendung auf die vorherige Version, die erfolgreich ausgeführt wurde, zusammen mit dem zugehörigen Anwendungsstatus wiederherzustellen. Wenn das Rollback erfolgreich ist, setzt Ihre Anwendung die Datenverarbeitung mit minimaler Ausfallzeit mit der vorherigen Version fort. Wenn das automatische Rollback ebenfalls fehlschlägt, versetzt Amazon Managed Service for Apache Flink die Anwendung in den READY Status, sodass Sie weitere Maßnahmen ergreifen können, einschließlich der Behebung des Fehlers und der Wiederholung des Vorgangs.

Sie müssen sich für automatische System-Rollbacks anmelden. Ab diesem Zeitpunkt können Sie es über die Konsole oder API für alle Operationen in Ihrer Anwendung aktivieren.

Die folgende Beispielanforderung für die UpdateApplication Aktion ermöglicht System-Rollbacks für eine Anwendung:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 1,
    "ApplicationConfigurationUpdate": {
        "ApplicationSystemRollbackConfigurationUpdate": {
            "RollbackEnabledUpdate": "true"
            }
        }
}
```

Sehen Sie sich gängige Szenarien für automatisches System-Rollback an

Die folgenden Szenarien veranschaulichen, in welchen Bereichen automatische System-Rollbacks von Vorteil sind:

- Anwendungsupdates: Wenn Sie Ihre Anwendung mit neuem Code aktualisieren, der Fehler aufweist, wenn Sie den Flink-Job über die Hauptmethode initialisieren, ermöglicht das automatische Rollback die Wiederherstellung der vorherigen Arbeitsversion. Zu den weiteren Aktualisierungsszenarien, in denen System-Rollbacks hilfreich sind, gehören:
 - Wenn Ihre Anwendung so aktualisiert wurde, dass sie mit einer höheren Parallelität als MaxParallelism ausgeführt wird.
 - Wenn Ihre Anwendung so aktualisiert wird, dass sie mit falschen Subnetzen für eine VPC-Anwendung läuft, führt dies zu einem Fehler beim Start des Flink-Jobs.
- Upgrades der Flink-Version: Wenn Sie auf eine neue Apache Flink-Version aktualisieren und bei der aktualisierten Anwendung ein Snapshot-Kompatibilitätsproblem auftritt, können Sie mit dem System-Rollback automatisch zur vorherigen Flink-Version zurückkehren.
- AutoScaling: Wenn die Anwendung hochskaliert, aber Probleme bei der Wiederherstellung von einem Savepoint auftreten, weil die Operatoren zwischen dem Snapshot und dem Flink-Job-Diagramm nicht übereinstimmen.

Verwenden Sie den Vorgang für System-Rollbacks APIs

Um für mehr Transparenz zu sorgen, bietet Amazon Managed Service für Apache Flink zwei Funktionen, die sich auf Anwendungsvorgänge APIs beziehen und Ihnen helfen können, Fehler und damit verbundene System-Rollbacks nachzuverfolgen.

ListApplicationOperations

Diese API listet alle in der Anwendung ausgeführten Operationen, einschließlich, und anderer UpdateApplication MaintenanceRollbackApplication, in umgekehrter chronologischer Reihenfolge auf. In der folgenden Beispielanforderung für die ListApplicationOperations Aktion werden die ersten 10 Anwendungsvorgänge für die Anwendung aufgeführt:

```
{
    "ApplicationName": "MyApplication",
    "Limit": 10
}
```

Die folgende Beispielanforderung für ListApplicationOperations hilft dabei, die Liste nach früheren Updates für die Anwendung zu filtern:

```
{
    "ApplicationName": "MyApplication",
    "operation": "UpdateApplication"
}
```

DescribeApplicationOperation

Diese API bietet detaillierte Informationen zu einem bestimmten Vorgang, der unter aufgeführt istListApplicationOperations, einschließlich der Fehlerursache, falls zutreffend. Die folgende Beispielanforderung für die DescribeApplicationOperation Aktion listet Details für einen bestimmten Anwendungsvorgang auf:

```
{
    "ApplicationName": "MyApplication",
    "OperationId": "xyzoperation"
}
```

Informationen zur Problembehebung finden Sie unter <u>Bewährte Methoden für das Rollback von</u> Systemen.

Führen Sie eine Managed Service für Apache Flink-Anwendung

aus

Dieser Abschnitt enthält Informationen zum Ausführen eines Managed Service für Apache Flink.

Wenn Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt, ausführen, erstellt der Service einen Apache-Flink-Auftrag. Ein Apache-Flink-Auftrag ist der Ausführungszyklus Ihrer Anwendung, die Managed Service für Apache Flink nutzt. Die Ausführung des Auftrags und die verwendeten Ressourcen werden vom Auftragsmanager verwaltet. Der Auftragsmanager unterteilt die Ausführung der Anwendung in Aufgaben. Jede Aufgabe wird von einem Aufgabenmanager verwaltet. Wenn Sie die Leistung Ihrer Anwendung überwachen, können Sie die Leistung jedes Aufgabenmanagers oder des Auftragsmanagers als Ganzes untersuchen.

Informationen zu Apache Flink-Jobs finden Sie unter <u>Jobs and Scheduling</u> in der Apache Flink-Dokumentation.

Identifizieren Sie den Bewerbungs- und Jobstatus

Sowohl Ihre Anwendung als auch der Auftrag der Anwendung haben einen aktuellen Ausführungsstatus:

- Anwendungsstatus: Ihre Anwendung hat einen aktuellen Status, der die Ausführungsphase beschreibt. Die folgenden Anwendungsstatus sind möglich:
 - Stabile Anwendungsstatus: Ihre Anwendung bleibt in der Regel so lange in diesem Status, bis Sie einen Statuswechsel vornehmen:
 - BEREIT: Eine neue oder angehaltene Anwendung befindet sich im BEREIT-Status, bis Sie sie ausführen.
 - LÄUFT: Eine Anwendung, die erfolgreich gestartet wurde, befindet sich im LÄUFT-Status.
 - Vorübergehende Anwendungsstatus: Eine Anwendung mit einem solchen Status ist in der Regel dabei, in einen anderen Status überzugehen. Wenn eine Anwendung für einen längeren Zeitraum in einem vorübergehenden Status verbleibt, können Sie die Anwendung beenden, indem Sie die <u>StopApplication</u>Aktion verwenden, bei der der Force Parameter auf true gesetzt ist. Diese umfassen u. a. folgende:
 - STARTING: Tritt nach der <u>StartApplication</u>Aktion auf. Die Anwendung wechselt vom Status READY in den Status RUNNING.
 - STOPPING: Tritt nach der <u>StopApplication</u>Aktion auf. Die Anwendung wechselt vom Status RUNNING in den Status READY.

- DELETING: Tritt nach der DeleteApplicationAktion auf. Die Anwendung wird gerade gelöscht.
- UPDATING: Tritt nach der <u>UpdateApplication</u>Aktion auf. Die Anwendung wird gerade aktualisiert und kehrt in den Status RUNNING oder READY zurück.
- AUTOSCALING: Die Anwendung hat die AutoScalingEnabled Eigenschaft auf <u>ParallelismConfigurationg</u>esetzttrue, und der Dienst erhöht die Parallelität der Anwendung. Wenn sich die Anwendung in diesem Status befindet, ist die einzige gültige API-Aktion, die Sie verwenden können, die <u>StopApplication</u>Aktion, deren Force Parameter auf gesetzt ist. true Weitere Informationen zum Auto Scaling finden Sie unter <u>Verwenden Sie die automatische</u> <u>Skalierung in Managed Service für Apache Flink</u>.
- FORCE_STOPPING: Tritt auf, nachdem die <u>StopApplication</u>Aktion aufgerufen wurde und der Force Parameter auf gesetzt isttrue. Die Anwendung wird gerade zwangsweise angehalten. Die Anwendung wechselt vom Status STARTING, UPDATING, STOPPING oder AUTOSCALING in den Status READY.
- ROLLING_BACK: Tritt auf, nachdem die <u>RollbackApplication</u>Aktion aufgerufen wurde. Die Anwendung wird gerade auf eine frühere Version zurückgesetzt. Die Anwendung wechselt vom Status UPDATING oder AUTOSCALING in den Status RUNNING.
- MAINTENANCE: Tritt auf, während Managed Service für Apache Flink Patches auf Ihre Anwendung einspielt. Weitere Informationen finden Sie unter <u>Wartungsaufgaben für Managed</u> Service für Apache Flink verwalten.

Sie können den Status Ihrer Anwendung mithilfe der Konsole oder mithilfe der DescribeApplicationAktion überprüfen.

- Auftragsstatus: Wenn sich Ihre Anwendung im RUNNING-Status befindet, hat Ihr Auftrag einen Status, der die aktuelle Ausführungsphase beschreibt. Ein Auftrag beginnt im CREATED-Status und geht dann in den RUNNING-Satus über, wenn er gestartet wurde. Wenn Fehlerzustände auftreten, wechselt Ihre Anwendung in den folgenden Status:
 - Bei Anwendungen, die Apache Flink 1.11 und höher verwenden, wechselt Ihre Anwendung in den RESTARTING-Status.
 - Bei Anwendungen, die Apache Flink 1.8 und niedriger verwenden, wechselt Ihre Anwendung in den FAILING-Status.

Die Anwendung wechselt dann entweder zum Status RESTARTING oder FAILED, je nachdem, ob der Auftrag neu gestartet werden kann.

Sie können den Status des Jobs überprüfen, indem Sie das CloudWatch Protokoll Ihrer Bewerbung auf Statusänderungen überprüfen.

Batch-Workloads ausführen

Managed Service für Apache Flink unterstützt die Ausführung von Apache-Flink-Batch-Workloads. Wenn in einem Batch-Auftrag ein Apache-Flink-Auftrag den Status ABGESCHLOSSEN erreicht, wird der Anwendungsstatus von Managed Service für Apache Flink auf BEREIT gesetzt. Weitere Informationen zum Status von Flink-Aufträgen finden Sie unter Aufträge und Planung.

Überprüfen Sie die Anwendungsressourcen von Managed Service für Apache Flink

In diesem Abschnitt werden die Systemressourcen beschrieben, die Ihre Anwendung verwendet. Wenn Sie verstehen, wie Managed Service für Apache Flink Ressourcen bereitstellt und verwendet, können Sie eine leistungsstarke und stabile Anwendung mit Managed Service für die Apache Flink entwerfen, erstellen und verwalten.

Ressourcen für Managed Service für Apache Flink-Anwendungen

Managed Service für Apache Flink ist ein AWS Dienst, der eine Umgebung für das Hosten Ihrer Apache Flink-Anwendung schafft. Der Dienst Managed Service for Apache Flink stellt Ressourcen mithilfe von Einheiten bereit, die als Kinesis Processing Units () KPUs bezeichnet werden.

Eine KPU steht für die folgenden Systemressourcen:

- Ein CPU-Kern
- 4 GB Arbeitsspeicher, davon 1 GB systemeigener Speicher und 3 GB Heap-Speicher
- 50 GB freier Festplattenspeicher

KPUs führt Anwendungen in unterschiedlichen Ausführungseinheiten aus, die als Aufgaben und Unteraufgaben bezeichnet werden. Sie können sich eine Unteraufgabe als das Äquivalent eines Threads vorstellen.

Die Anzahl der für eine Anwendung KPUs verfügbaren Dateien entspricht der Parallelism Anwendungseinstellung geteilt durch die ParallelismPerKPU Anwendungseinstellung.

Informationen zur Anwendungsparallelität finden Sie unter Implementieren Sie Anwendungsskalierung.

Ressourcen für die Apache Flink-Anwendung

Die Apache-Flink-Umgebung weist Ressourcen für Ihre Anwendung mithilfe von Einheiten zu, die als Aufgabenslots bezeichnet werden. Wenn Managed Service für Apache Flink Ressourcen für Ihre Anwendung zuweist, weist es einer einzelnen KPU einen oder mehrere Apache-Flink-Aufgabenslots zu. Die Anzahl der Slots, die einer einzelnen KPU zugewiesen sind, entspricht der Einstellung ParallelismPerKPU Ihrer Anwendung. Weitere Informationen zu Task-Slots finden Sie unter Job Scheduling in der Apache Flink-Dokumentation.

Parallelität der Operatoren

Sie können die maximale Anzahl von Unteraufgaben festlegen, die ein Operator verwenden kann. Dieser Wert wird als Operatorenparallelität bezeichnet. Standardmäßig entspricht die Parallelität der einzelnen Operatoren in Ihrer Anwendung der Parallelität der Anwendung. Das bedeutet, dass standardmäßig jeder Operator in Ihrer Anwendung bei Bedarf alle verfügbaren Unteraufgaben in der Anwendung verwenden kann.

Sie können die Parallelität der Operatoren in Ihrer Anwendung mithilfe der setParallelism-Methode festlegen. Mit dieser Methode können Sie die Anzahl der Unteraufgaben steuern, die jeder Operator gleichzeitig verwenden kann.

Weitere Informationen zu Operatoren finden Sie unter <u>Operatoren</u> in der Apache Flink-Dokumentation.

Verkettung von Operatoren

Normalerweise verwendet jeder Operator eine separate Unteraufgabe für die Ausführung, aber wenn mehrere Operatoren immer nacheinander ausgeführt werden, kann die Laufzeit sie alle derselben Aufgabe zuweisen. Dieser Vorgang wird Operatorverkettung genannt.

Mehrere sequenzielle Operatoren können zu einer einzigen Aufgabe verkettet werden, wenn sie alle mit denselben Daten arbeiten. Dies ist eine Auswahl der Kriterien, die erforderlich sind, damit dies zutrifft:

- Die Operatoren führen eine einfache 1:1-Weiterleitung durch.
- Die Operatoren haben alle dieselbe Operatorenparallelität.

Wenn Ihre Anwendung Operatoren zu einer einzigen Unteraufgabe zusammenfasst, werden Systemressourcen geschont, da der Service keine Netzwerkoperationen durchführen und jedem

Operator Unteraufgaben zuweisen muss. Um festzustellen, ob Ihre Anwendung Operatorverkettung verwendet, sehen Sie sich das Auftragsdiagramm in der Konsole von Managed Service für Apache Flink an. Jeder Scheitelpunkt in der Anwendung steht für einen oder mehrere Operatoren. Das Diagramm zeigt Operatoren, die zu einem einzigen Scheitelpunkt verkettet wurden.

Abrechnung pro Sekunde in Managed Service für Apache Flink

Managed Service für Apache Flink wird jetzt in Sekundenschritten abgerechnet. Pro Anwendung fällt eine Mindestgebühr von zehn Minuten an. Die Abrechnung pro Sekunde gilt für Anwendungen, die neu gestartet wurden oder bereits ausgeführt werden. In diesem Abschnitt wird beschrieben, wie Managed Service für Apache Flink Ihre Nutzung misst und Ihnen in Rechnung stellt. Weitere Informationen zu den Preisen von Managed Service for Apache Flink finden Sie unter <u>Amazon</u> <u>Managed Service for Apache Flink</u> — Preise.

Funktionsweise

Managed Service for Apache Flink berechnet Ihnen die Dauer und Anzahl der Kinesis Processing Units (KPUs), die in Sekundenschritten in den unterstützten Versionen abgerechnet werden. AWS-Regionen Eine einzelne KPU umfasst 1 vCPU-Rechenleistung und 4 GB Arbeitsspeicher. Ihnen wird ein Stundensatz berechnet, der auf der Anzahl der Anwendungen basiert, die für die Ausführung Ihrer KPUs Anwendungen verwendet werden.

Beispiel: Für eine Anwendung, die 20 Minuten und 10 Sekunden läuft, werden 20 Minuten und 10 Sekunden berechnet, multipliziert mit den verwendeten Ressourcen. Für eine Anwendung, die 5 Minuten lang ausgeführt wird, wird der Mindestbetrag von zehn Minuten berechnet, multipliziert mit den verwendeten Ressourcen.

Managed Service für Apache Flink gibt die Nutzung in Stunden an. Zum Beispiel entsprechen 15 Minuten 0,25 Stunden.

Für Apache Flink-Anwendungen wird Ihnen eine einzelne zusätzliche KPU pro Anwendung berechnet, die für die Orchestrierung verwendet wird. Anwendungen werden auch für den Betrieb von Speicherplatz und dauerhafte Backups in Rechnung gestellt. Das Ausführen von Anwendungsspeicher wird für die statusbehafteten Verarbeitungsfunktionen in Managed Service for Apache Flink verwendet und wird pro berechnet. GB/month. Durable backups are optional and provide point-in-time recovery for applications, charged per GB/month

Im Streaming-Modus skaliert Managed Service for Apache Flink automatisch die Anzahl der von Ihrer Stream-Verarbeitungsanwendung KPUs benötigten Dateien, wenn die Anforderungen an Speicher
und Rechenleistung schwanken. Sie können wählen, ob Sie Ihrer Anwendung die erforderliche Anzahl von bereitstellen möchten. KPUs

AWS-Region Verfügbarkeit

Note

Derzeit ist die Abrechnung pro Sekunde in den folgenden Regionen nicht verfügbar: AWS GovCloud (USA-Ost), AWS GovCloud (US-West), China (Peking) und China (Ningxia).

Die Abrechnung pro Sekunde ist in den folgenden Ländern verfügbar: AWS-Regionen

- USA Ost (Nord-Virginia) us-east-1
- USA Ost (Ohio) us-east-2
- USA West (Nordkalifornien) us-west-1
- USA West (Oregon) us-west-2
- Afrika (Kapstadt) af-south-1
- Asien-Pazifik (Hongkong) ap-east-1
- Asien-Pazifik (Hyderabad) ap-south-1
- Asien-Pazifik (Jakarta) ap-southeast-3
- Asien-Pazifik (Melbourne) ap-southeast-4
- Asien-Pazifik (Mumbai) ap-south-1
- Asien-Pazifik (Osaka) ap-northeast-3
- Asien-Pazifik (Seoul) ap-northeast-2
- Asien-Pazifik (Singapur) ap-southeast-1
- Asien-Pazifik (Sydney) ap-southeast-2
- Asien-Pazifik (Tokio) ap-northeast-1
- Kanada (Zentral) ca-central-1
- Kanada West (Calgary) ca-west-1
- Europa (Frankfurt) eu-central-1
- Europa (Irland) eu-west-1
- Europa (London) eu-west-2

- Europa (Mailand) eu-south-1
- Europa (Paris) eu-west-3
- Europa (Spanien) eu-south-2
- Europa (Stockholm) eu-north-1
- Europa (Zürich) eu-central-2
- Israel (Tel Aviv) il-central-1
- Naher Osten (Bahrain) me-south-1
- Naher Osten (VAE) me-central-1
- Südamerika (São Paulo) sa-east-1

Beispiele für Preisgestaltung

Preisbeispiele finden Sie auf der Preisseite für Managed Service for Apache Flink. Weitere Informationen finden Sie unter <u>Amazon Managed Service for Apache Flink — Preise</u>. Im Folgenden finden Sie weitere Beispiele mit Abbildungen des jeweiligen Kostennutzungsberichts.

Eine lang andauernde, schwere Arbeitslast

Sie sind ein großer Video-Streaming-Dienst und möchten eine Videoempfehlung in Echtzeit erstellen, die auf den Interaktionen Ihrer Nutzer basiert. Sie verwenden eine Apache Flink-Anwendung in Managed Service für Apache Flink, um kontinuierlich Benutzerinteraktionsereignisse aus mehreren Kinesis-Datenströmen aufzunehmen und Ereignisse in Echtzeit zu verarbeiten, bevor sie an ein nachgeschaltetes System ausgegeben werden. Benutzerinteraktionsereignisse werden mithilfe mehrerer Operatoren transformiert. Dazu gehören die Partitionierung von Daten nach Ereignistyp, die Anreicherung von Daten mit zusätzlichen Metadaten, das Sortieren von Daten nach Zeitstempel und das Zwischenspeichern von Daten für 5 Minuten vor der Auslieferung. Die Anwendung umfasst viele Transformationsschritte, die rechenintensiv und parallelisierbar sind. Ihre Flink-Anwendung ist so konfiguriert, dass sie mit 20 KPUs ausgeführt wird, um der Arbeitslast gerecht zu werden. Ihre Anwendung verwendet täglich 1 GB an dauerhaftem Anwendungs-Backup. Die monatlichen Gebühren für Managed Service für Apache Flink werden wie folgt berechnet:

Monatliche Gebühren

Der Preis in der Region USA Ost (Nord-Virginia) beträgt 0,11\$ pro KPU-Stunde. Managed Service für Apache Flink weist 50 GB Speicher für laufende Anwendungen pro KPU zu und berechnet 0,10 USD pro GB/Monat.

- Monatliche KPU-Gebühren: 24 Stunden x 30 Tage * (20 KPUs + 1 zusätzliche KPU f
 ür Streaming-Anwendungen) * 0,11 USD/Stunde = 1.584,00 USD
- Monatliche Speichergebühren f
 ür laufende Anwendungen: 30 Tage x 20 x 50 Monate = 100,00 USD KPUs GB/KPUs * \$0.10/GB
- Monatliche Speichergebühren f
 ür dauerhafte Anwendungen: 30 Tage * 1 GB * 0,023 GB-Monat = 0,03 USD
- Gesamtkosten: 1.584,00 USD + 100 USD + 0,03 USD = 1.684,03 USD

Kostennutzungsbericht für Managed Service for Apache Flink auf der Billing and Cost Management-Konsole für den Monat

Kinesis-Analytik

- 1.684,03 USD USA Ost (Nord-Virginia)
- Amazon Kinesis Analytics CreateSnapshot
 - 0,023\$ pro GB/Monat an dauerhaften Anwendungs-Backups
 - 1 GB-Monat 0,03 USD
- Amazon Kinesis Analytics StartApplication
 - 0,10\$ pro GB pro Monat laufendem Anwendungsspeicher
 - 1.000 GB pro Monat 100 USD
 - 0,11\$ pro Kinesis Processing Unit-Stunde für Apache Flink-Anwendungen
 - 15.120 KPU-Stunde 1.584 USD

Ein Batch-Workload, der täglich ~15 Minuten lang ausgeführt wird

Sie verwenden eine Apache Flink-Anwendung in Managed Service für Apache Flink, um Protokolldaten in Amazon Simple Storage Service (Amazon S3) im Batch-Modus zu transformieren. Die Protokolldaten werden mithilfe mehrerer Operatoren transformiert. Dazu gehören die Anwendung eines Schemas auf die verschiedenen Protokollereignisse, die Partitionierung der Daten nach Ereignistyp und die Sortierung der Daten nach Zeitstempel. Die Anwendung hat viele Transformationsschritte, aber keiner ist rechenintensiv. Diese Anwendung nimmt in einem Monat mit 30 Tagen täglich Daten mit 2.000 Datensätzen pro Sekunde für 15 Minuten auf. Sie erstellen keine dauerhaften Anwendungs-Backups. Die monatlichen Gebühren für Managed Service für Apache Flink werden wie folgt berechnet:

Monatliche Gebühren

Der Preis in der Region USA Ost (Nord-Virginia) beträgt 0,11\$ pro KPU-Stunde. Managed Service für Apache Flink weist 50 GB Speicher für laufende Anwendungen pro KPU zu und berechnet 0,10 USD pro GB/Monat.

- Batch-Workload: W\u00e4hrend der 15 Minuten pro Tag verarbeitet die Anwendung Managed Service for Apache Flink 2.000 records/second, which takes 2KPUs. 30 days/month * 15 minutes/day = 450 minutes/month
- Monatliche KPU-Gebühren: 450 minutes/month * (2KPUs + 1 additional KPU for streaming application) * \$0.11/hour = 2,48 USD
- Monatliche Speichergebühren f
 ür laufende Anwendungen: 450 minutes/month * 2 KPUs * 50 GB/ KPUs * \$0.10/GB \$ pro Monat = 0,11\$
- Gesamtkosten: 2,48 USD + 0,11 = 2,59 USD

Kostennutzungsbericht für Managed Service for Apache Flink auf der Billing and Cost Management-Konsole für den Monat

Kinesis-Analytik

- 2,59 USD USA Ost (Nord-Virginia)
- Amazon Kinesis Analytics StartApplication
 - 0,10\$ pro GB pro Monat laufender Anwendungs-Backups
 - 1,042 GB-Monat 0,11 USD
 - 0,11\$ pro Kinesis Processing Unit-Stunde für Apache Flink-Anwendungen
 - 22,5 KPU-Stunde 2,48 USD

Eine Testanwendung, die in derselben Stunde kontinuierlich beendet und gestartet wird und für die mehrere Mindestgebühren anfallen

Sie sind eine große E-Commerce-Plattform, die täglich Millionen von Transaktionen verarbeitet. Sie möchten die Betrugserkennung in Echtzeit entwickeln. Sie verwenden eine Apache Flink-Anwendung in Managed Service für Apache Flink, um Transaktionsereignisse aus Kinesis Data Streams aufzunehmen und Ereignisse in Echtzeit mit verschiedenen Transformationsschritten zu verarbeiten. Dazu gehören die Verwendung eines Schiebefensters zur Zusammenfassung von Ereignissen, die Partitionierung von Ereignissen nach Ereignistypen und die Anwendung spezifischer Erkennungsregeln für verschiedene Ereignistypen. Während der Entwicklung starten und beenden Sie Ihre Anwendung mehrmals, um das Verhalten zu testen und zu debuggen. Es gibt Situationen, in denen Ihre Anwendung nur für ein paar Minuten läuft. Es gibt eine Stunde, in der Sie Ihre Anwendung mit 4 testen KPUs und Ihre Anwendung keine dauerhaften Anwendungs-Backups verwendet:

- Um 10:05 Uhr starten Sie Ihre Anwendung, die 30 Minuten lang ausgeführt wird, bevor sie um 10:35 Uhr gestoppt wird.
- Um 10:40 Uhr starten Sie Ihre Anwendung erneut, die 5 Minuten lang ausgeführt wird, bevor sie um 10:45 Uhr gestoppt wird.
- Um 10:50 Uhr starten Sie die Anwendung erneut, die 2 Minuten lang ausgeführt wird, bevor sie um 10:52 Uhr gestoppt wird.

Managed Service für Apache Flink berechnet bei jedem Start einer Anwendung eine Nutzungsdauer von mindestens 10 Minuten. Die monatliche Nutzung von Managed Service for Apache Flink für Ihre Anwendung wird wie folgt berechnet:

- · Ihre Anwendung wird zum ersten Mal gestartet und gestoppt: 30 Minuten Nutzungsdauer
- Beim zweiten Start und Stopp Ihrer Anwendung: 10 Minuten Nutzung (Ihre Anwendung läuft 5 Minuten, aufgerundet auf die Mindestgebühr von 10 Minuten)
- Beim dritten Start und Stopp Ihrer Anwendung: 10 Minuten Nutzung (Ihre Anwendung läuft 2 Minuten, aufgerundet auf die Mindestgebühr von 10 Minuten)

Insgesamt würden Ihrer Anwendung 50 Minuten Nutzungsdauer in Rechnung gestellt. Wenn es in dem Monat keine anderen Zeiten gibt, zu denen Ihre Anwendung ausgeführt wird, werden die monatlichen Gebühren für Managed Service für Apache Flink wie folgt berechnet:

Monatliche Gebühren

Der Preis in der Region USA Ost (Nord-Virginia) beträgt 0,11\$ pro KPU-Stunde. Managed Service für Apache Flink weist 50 GB Speicher für laufende Anwendungen pro KPU zu und berechnet 0,10 USD pro GB/Monat.

- Monatliche KPU-Gebühren: 50 Minuten * (4 KPUs + 1 zusätzliche KPU für Streaming-Anwendungen) * 0,11 USD/Stunde = 0,46 USD (auf den nächsten Cent gerundet)
- Monatliche Speichergebühren f
 ür laufende Anwendungen: 50 Minuten * 4 KPUs * 50 GB/KPUs * \$0.10/GB -Monat = 0,03 USD (auf den n
 ächsten Cent gerundet)
- Gesamtkosten: 0,46 USD + 0,03 = 0,49 USD

Kostennutzungsbericht für Managed Service for Apache Flink auf der Billing and Cost Management-Konsole für den Monat

Kinesis-Analytik

- 0,49 USD USA Ost (Nord-Virginia)
- Amazon Kinesis Analytics StartApplication
 - 0,10\$ pro GB pro Monat laufendem Anwendungsspeicher
 - 0,232 GB-Monat 0,03 USD
 - 0,11\$ pro Kinesis Processing Unit-Stunde für Apache Flink-Anwendungen
 - 4,167 KPU-Stunde 0,46 USD

DataStream API-Komponenten überprüfen

Ihre Apache Flink-Anwendung verwendet die <u>Apache DataStream Flink-API</u>, um Daten in einen Datenstrom umzuwandeln.

In diesem Abschnitt werden die verschiedenen Komponenten beschrieben, die Daten verschieben, transformieren und verfolgen:

- Verwenden Sie Konnektoren, um Daten in Managed Service f
 ür Apache Flink mit der DataStream <u>API zu verschieben</u>: Diese Komponenten verschieben Daten zwischen Ihrer Anwendung und externen Datenquellen und Zielen.
- <u>Transformieren Sie Daten mithilfe von Operatoren in Managed Service f
 ür Apache Flink mit der API</u> <u>DataStream</u>: Diese Komponenten transformieren oder gruppieren Datenelemente innerhalb Ihrer Anwendung.
- <u>Ereignisse in Managed Service f
 ür Apache Flink mithilfe der DataStream API verfolgen</u>: In diesem Thema wird beschrieben, wie Managed Service for Apache Flink Ereignisse bei der Verwendung der DataStream API verfolgt.

Verwenden Sie Konnektoren, um Daten in Managed Service für Apache Flink mit der DataStream API zu verschieben

In der Amazon Managed Service for Apache DataStream Flink-API sind Konnektoren Softwarekomponenten, die Daten in und aus einer Managed Service for Apache Flink-Anwendung übertragen. Konnektoren sind flexible Integrationen, mit denen Sie aus Dateien und Verzeichnissen lesen können. Konnektoren bestehen aus kompletten Modulen für die Interaktion mit Amazon-Services und Systemen von Drittanbietern.

Zu den Konnektoren gehören die folgenden:

- <u>Fügen Sie Streaming-Datenquellen hinzu</u>: Stellen Ihrer Anwendung Daten aus einem Kinesis Data Stream, einer Datei oder einer anderen Datenquelle zur Verfügung.
- <u>Schreiben Sie Daten mithilfe von Senken</u>: Senden Sie Daten aus Ihrer Anwendung an einen Kinesis-Datenstream, Firehose-Stream oder ein anderes Datenziel.
- <u>Verwenden Sie asynchrone I/O</u>: Ermöglicht asynchronen Zugriff auf eine Datenquelle (z. B. eine Datenbank), um Stream-Ereignisse zu bereichern.

Verfügbare Konnektoren

Das Apache-Flink-Framework enthält Konnektoren für den Zugriff auf Daten aus verschiedenen Quellen. Informationen zu den im Apache Flink-Framework verfügbaren Konnektoren finden Sie unter Konnektoren in der Apache Flink-Dokumentation.

🔥 Warning

Wenn Sie Anwendungen haben, die auf Flink 1.6, 1.8, 1.11 oder 1.13 laufen und in den Regionen Naher Osten (VAE), Asien-Pazifik (Hyderabad), Israel (Tel Aviv), Europa (Zürich), Naher Osten (VAE), Asien-Pazifik (Melbourne) oder Asien-Pazifik (Jakarta) laufen möchten, müssen Sie möglicherweise Ihr Anwendungsarchiv mit einem aktualisierten Konnektor neu erstellen oder auf Flink 1.18 aktualisieren.

Apache Flink-Konnektoren werden in ihren eigenen Open-Source-Repositorys gespeichert. Wenn Sie auf Version 1.18 oder höher aktualisieren, müssen Sie Ihre Abhängigkeiten aktualisieren. Informationen zum Zugriff auf das Repository für Apache AWS Flink-Konnektoren finden Sie unter. flink-connector-aws

Die frühere

org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer Kinesis-Quelle wurde eingestellt und könnte mit einer future Version von Flink entfernt werden. Verwenden Sie stattdessen <u>Kinesis Source</u>.

Es besteht keine staatliche Kompatibilität zwischen FlinkKinesisConsumer undKinesisStreamsSource. Einzelheiten finden Sie unter <u>Migration vorhandener Jobs auf</u> <u>eine neue Kinesis Streams-Quelle</u> in der Apache Flink-Dokumentation.

Im Folgenden finden Sie die empfohlenen Richtlinien:

Konnektor-Upgrades		
Flink-Version	Verwendeter Konnektor	Auflösung
1.19, 1.20	Kinesis-Quelle	Stellen Sie beim Upgrade auf Managed Service for Apache Flink Version 1.19 und 1.20 sicher, dass Sie den neuesten Kinesis Data Streams Streams-Q uellconnector verwenden . Das muss eine beliebige Version 5.0.0 oder höher sein. Weitere Informationen finden Sie unter <u>Amazon</u> <u>Kinesis Data Streams</u> <u>Connector</u> .
1.19, 1.20	Kinesis-Spüle	Stellen Sie beim Upgrade auf Managed Service for Apache Flink Version 1.19 und 1.20 sicher, dass Sie den neuesten Kinesis Data Streams Streams-Sink- Connector verwenden. Das muss eine beliebige Version 5.0.0 oder höher sein. Weitere Informationen finden Sie unter <u>Kinesis</u> <u>Streams Sink</u> .

Flink-Version	Verwendeter Konnektor	Auflösung
1.19, 1.20	DynamoDB-Streams-Quelle	Stellen Sie beim Upgrade auf Managed Service for Apache Flink Version 1.19 und 1.20 sicher, dass Sie den neuesten DynamoDB Streams Streams-Q uellconnector verwenden . Das muss eine beliebige Version 5.0.0 oder höher sein. Weitere Informationen finden Sie unter <u>Amazon</u> DynamoDB Connector.
1.19, 1.20	DynamoDB-Senke	Stellen Sie beim Upgrade auf Managed Service for Apache Flink Version 1.19 und 1.20 sicher, dass Sie den neuesten DynamoDB- Sink-Connector verwenden . Das muss eine beliebige Version 5.0.0 oder höher sein. Weitere Informationen finden Sie unter <u>Amazon</u> DynamoDB Connector.

	Flink-Version	Verwendeter Konnektor	Auflösung	
	1.19, 1.20	Amazon SQS SQS-Spüle	Stellen Sie beim Upgrade auf Managed Service für Apache Flink Version 1.19 und 1.20 sicher, dass Sie den neuesten Amazon SQS SQS-Sink-Connector verwenden. Das muss eine beliebige Version 5.0.0 oder höher sein. Weitere Informationen finden Sie unter <u>Amazon SQS Sink</u> .	
	1,19, 1,20	Amazon Managed Service für Prometheus Sink	Stellen Sie beim Upgrade auf Managed Service für Apache Flink Version 1.19 und 1.20 sicher, dass Sie den neuesten Amazon Managed Service for Prometheus Sink Connector verwenden. Das muss eine beliebige Version 1.0.0 oder höher sein. Weitere Informationen finden Sie unter <u>Prometheus</u> Sink.	

Fügen Sie Streaming-Datenquellen zu Managed Service für Apache Flink hinzu

Apache Flink bietet Konnektoren zum Lesen aus Dateien, Sockets, Sammlungen und benutzerdefinierten Quellen. In Ihrem Anwendungscode verwenden Sie eine <u>Apache Flink-Quelle</u>, um Daten aus einem Stream zu empfangen. In diesem Abschnitt werden die Quellen beschrieben, die für Amazon-Services verfügbar sind.

Verwenden Sie Kinesis-Datenstreams

Das KinesisStreamsSource stellt Streaming-Daten aus einem Amazon Kinesis Kinesis-Datenstream für Ihre Anwendung bereit.

Erstellen eines KinesisStreamsSource

Das folgende Code-Beispiel zeigt das Erstellen eines KinesisStreamsSource:

```
// Configure the KinesisStreamsSource
Configuration sourceConfig = new Configuration();
sourceConfig.set(KinesisSourceConfigOptions.STREAM_INITIAL_POSITION,
KinesisSourceConfigOptions.InitialPosition.TRIM_HORIZON); // This is optional, by
default connector will read from LATEST
// Create a new KinesisStreamsSource to read from specified Kinesis Stream.
KinesisStreamsSource<String> kdsSource =
KinesisStreamsSource.<String>builder()
.setStreamArn("arn:aws:kinesis:us-east-1:123456789012:stream/test-
stream")
.setSourceConfig(sourceConfig)
.setDeserializationSchema(new SimpleStringSchema())
.setKinesisShardAssigner(ShardAssignerFactory.uniformShardAssigner()) // This is
optional, by default uniformShardAssigner will be used.
.build();
```

Weitere Informationen zur Verwendung von finden Sie unter <u>Amazon Kinesis Data Streams</u> <u>Connector</u> in der Apache Flink-Dokumentation und in <u>unserem öffentlichen KinesisConnectors</u> <u>Beispiel auf</u> Github. KinesisStreamsSource

Erstellen Sie einen KinesisStreamsSource, der einen EFO-Consumer verwendet

Der unterstützt KinesisStreamsSource jetzt Enhanced Fan-Out (EFO).

Wenn ein Kinesis-Verbraucher EFO verwendet, stellt ihm der Kinesis Data Streams-Service seine eigene dedizierte Bandbreite zur Verfügung, anstatt dass der Verbraucher die feste Bandbreite des Streams mit den anderen Verbrauchern teilt, die aus dem Stream lesen.

Weitere Informationen zur Verwendung von EFO mit Kinesis Consumer finden Sie unter <u>FLIP-128</u>: <u>Verbesserter Lüfterausgang</u> für Kinesis-Verbraucher. AWS Sie aktivieren den EFO-Consumer, indem Sie die folgenden Parameter für den Kinesis-Consumer festlegen:

- READER_TYPE: Setzen Sie diesen Parameter auf EFO, damit Ihre Anwendung einen EFO-Consumer für den Zugriff auf die Kinesis Data Stream-Daten verwendet.
- EFO_CONSUMER_NAME: Setzen Sie diesen Parameter auf einen Zeichenfolgenwert, der unter den Verbrauchern dieses Streams eindeutig ist. Die Wiederverwendung eines Verbrauchernamens in demselben Kinesis Data Stream führt dazu, dass der vorherige Verbraucher, der diesen Namen verwendet hat, beendet wird.

Um einen KinesisStreamsSource für die Verwendung von EFO zu konfigurieren, fügen Sie dem Verbraucher die folgenden Parameter hinzu:

```
sourceConfig.set(KinesisSourceConfigOptions.READER_TYPE,
KinesisSourceConfigOptions.ReaderType.EFO);
sourceConfig.set(KinesisSourceConfigOptions.EFO_CONSUMER_NAME, "my-flink-efo-
consumer");
```

Ein Beispiel für eine Managed Service for Apache Flink-Anwendung, die einen EFO-Consumer verwendet, finden Sie in unserem öffentlichen Kinesis Connectors-Beispiel auf Github.

Verwenden Sie Amazon MSK

Die KafkaSource-Quelle stellt Streaming-Daten aus einem Amazon MSK-Thema für Ihre Anwendung bereit.

Erstellen eines KafkaSource

Das folgende Code-Beispiel zeigt das Erstellen eines KafkaSource:

```
KafkaSource<String> source = KafkaSource.<String>builder()
    .setBootstrapServers(brokers)
    .setTopics("input-topic")
    .setGroupId("my-group")
    .setStartingOffsets(OffsetsInitializer.earliest())
    .setValueOnlyDeserializer(new SimpleStringSchema())
    .build();
```

env.fromSource(source, WatermarkStrategy.noWatermarks(), "Kafka Source");

Weitere Informationen zur Verwendung von KafkaSource finden Sie unter MSK-Replikation.

Schreiben Sie Daten mithilfe von Senken in Managed Service für Apache Flink

In Ihrem Anwendungscode können Sie jeden <u>Apache Flink-Sink-Connector</u> verwenden, um in externe Systeme zu schreiben, einschließlich AWS Dienste wie Kinesis Data Streams und DynamoDB.

Apache Flink bietet auch Senken für Dateien und Sockets, und Sie können benutzerdefinierte Senken implementieren. Unter den verschiedenen unterstützten Senken werden häufig die folgenden verwendet:

Verwenden Sie Kinesis-Datenstreams

Apache Flink bietet Informationen zum <u>Kinesis Data Streams-Konnector</u> in der Apache Flink-Dokumentation.

Ein Beispiel für eine Anwendung, die einen Kinesis Data Stream für Eingabe und Ausgabe verwendet, finden Sie unter <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für</u> Apache Flink.

Verwenden Sie Apache Kafka und Amazon Managed Streaming for Apache Kafka (MSK)

Der <u>Apache Flink Kafka Connector</u> bietet umfassende Unterstützung für die Veröffentlichung von Daten in Apache Kafka und Amazon MSK, einschließlich exakt einmaliger Garantien. Informationen zum Schreiben in Kafka finden Sie in den <u>Beispielen für Kafka Connectors</u> in der Apache Flink-Dokumentation.

Verwenden Sie Amazon S3

Sie können Apache Flink StreamingFileSink verwenden, um Objekte in einen Amazon S3-Bucket zu schreiben.

Ein Beispiel dafür, wie man Objekte in S3 schreibt, finden Sie unter the section called "S3-Senke".

Benutze Firehose

Das FlinkKinesisFirehoseProducer ist eine zuverlässige, skalierbare Apache Flink-Senke zum Speichern von Anwendungsausgaben mithilfe des <u>Firehose-Dienstes</u>. In diesem Abschnitt wird die Einrichtung eines Maven-Projekts beschrieben, um einen FlinkKinesisFirehoseProducer zu erstellen und zu verwenden.

Themen

- Erstellen eines FlinkKinesisFirehoseProducer
- FlinkKinesisFirehoseProducer-Codebeispiel

Erstellen eines FlinkKinesisFirehoseProducer

Das folgende Code-Beispiel zeigt das Erstellen eines FlinkKinesisFirehoseProducer:

```
Properties outputProperties = new Properties();
outputProperties.setProperty(ConsumerConfigConstants.AWS_REGION, region);
FlinkKinesisFirehoseProducer<String> sink = new
FlinkKinesisFirehoseProducer<>(outputStreamName, new SimpleStringSchema(),
outputProperties);
```

FlinkKinesisFirehoseProducer-Codebeispiel

Das folgende Codebeispiel zeigt, wie Sie einen Apache Flink-Datenstream erstellen FlinkKinesisFirehoseProducer und konfigurieren und Daten von diesem an den Firehose senden.

```
package com.amazonaws.services.kinesisanalytics;
import
 com.amazonaws.services.kinesisanalytics.flink.connectors.config.ProducerConfigConstants;
import
 com.amazonaws.services.kinesisanalytics.flink.connectors.producer.FlinkKinesisFirehoseProducer
import com.amazonaws.services.kinesisanalytics.runtime.KinesisAnalyticsRuntime;
import org.apache.flink.api.common.serialization.SimpleStringSchema;
import org.apache.flink.streaming.api.datastream.DataStream;
import org.apache.flink.streaming.api.environment.StreamExecutionEnvironment;
import org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer;
import org.apache.flink.streaming.connectors.kinesis.FlinkKinesisProducer;
import org.apache.flink.streaming.connectors.kinesis.config.ConsumerConfigConstants;
import java.io.IOException;
import java.util.Map;
import java.util.Properties;
public class StreamingJob {
```

```
private static final String region = "us-east-1";
private static final String inputStreamName = "ExampleInputStream";
private static final String outputStreamName = "ExampleOutputStream";
private static DataStream<String>
createSourceFromStaticConfig(StreamExecutionEnvironment env) {
 Properties inputProperties = new Properties();
 inputProperties.setProperty(ConsumerConfigConstants.AWS_REGION, region);
 inputProperties.setProperty(ConsumerConfigConstants.STREAM_INITIAL_POSITION,
"LATEST");
 return env.addSource(new FlinkKinesisConsumer<>(inputStreamName, new
SimpleStringSchema(), inputProperties));
}
private static DataStream<String>
createSourceFromApplicationProperties(StreamExecutionEnvironment env)
  throws IOException {
 Map<String, Properties> applicationProperties =
KinesisAnalyticsRuntime.getApplicationProperties();
 return env.addSource(new FlinkKinesisConsumer<>(inputStreamName, new
SimpleStringSchema(),
   applicationProperties.get("ConsumerConfigProperties")));
}
private static FlinkKinesisFirehoseProducer<String>
createFirehoseSinkFromStaticConfig() {
 /*
  * com.amazonaws.services.kinesisanalytics.flink.connectors.config.
  * ProducerConfigConstants
  * lists of all of the properties that firehose sink can be configured with.
  */
 Properties outputProperties = new Properties();
 outputProperties.setProperty(ConsumerConfigConstants.AWS_REGION, region);
 FlinkKinesisFirehoseProducer<String> sink = new
FlinkKinesisFirehoseProducer<>(outputStreamName,
   new SimpleStringSchema(), outputProperties);
 ProducerConfigConstants config = new ProducerConfigConstants();
 return sink;
}
```

```
private static FlinkKinesisFirehoseProducer<String>
 createFirehoseSinkFromApplicationProperties() throws IOException {
  /*
   * com.amazonaws.services.kinesisanalytics.flink.connectors.config.
   * ProducerConfigConstants
   * lists of all of the properties that firehose sink can be configured with.
   */
  Map<String, Properties> applicationProperties =
 KinesisAnalyticsRuntime.getApplicationProperties();
  FlinkKinesisFirehoseProducer<String> sink = new
 FlinkKinesisFirehoseProducer<>(outputStreamName,
    new SimpleStringSchema(),
    applicationProperties.get("ProducerConfigProperties"));
  return sink;
 }
 public static void main(String[] args) throws Exception {
 // set up the streaming execution environment
  final StreamExecutionEnvironment env =
 StreamExecutionEnvironment.getExecutionEnvironment();
  /*
   * if you would like to use runtime configuration properties, uncomment the
   * lines below
   * DataStream<String> input = createSourceFromApplicationProperties(env);
   */
  DataStream<String> input = createSourceFromStaticConfig(env);
  // Kinesis Firehose sink
  input.addSink(createFirehoseSinkFromStaticConfig());
  // If you would like to use runtime configuration properties, uncomment the
  // lines below
  // input.addSink(createFirehoseSinkFromApplicationProperties());
  env.execute("Flink Streaming Java API Skeleton");
 }
}
```

Ein vollständiges Tutorial zur Verwendung der Firehose-Spüle finden Sie unter<u>the section called</u> <u>"Firehose Senke"</u>.

Verwenden Sie asynchrone I/O in Managed Service für Apache Flink

Ein asynchroner I/O-Operator reichert Stream-Daten mithilfe einer externen Datenquelle wie einer Datenbank an. Managed Service für Apache Flink reichert die Stream-Ereignisse asynchron an, sodass Anfragen zur Steigerung der Effizienz gebündelt werden können.

Weitere Informationen finden Sie unter <u>Asynchrone I/O</u> in der Apache Flink-Dokumentation.

Transformieren Sie Daten mithilfe von Operatoren in Managed Service für Apache Flink mit der API DataStream

Um eingehende Daten in einem Managed Service für Apache Flink umzuwandeln, verwenden Sie einen Apache-Flink-Operator. Ein Apache-Flink-Operator wandelt einen oder mehrere Datenströme in einen neuen Datenstrom um. Der neue Datenstrom enthält modifizierte Daten aus dem ursprünglichen Datenstrom. Apache Flink bietet mehr als 25 vorgefertigte Operatoren zur Stream-Verarbeitung. Weitere Informationen finden Sie unter Operatoren in der Apache Flink-Dokumentation.

Dieses Thema enthält die folgenden Abschnitte:

- Verwenden Sie Transformationsoperatoren
- Verwenden Sie Aggregationsoperatoren

Verwenden Sie Transformationsoperatoren

Im Folgenden finden Sie ein Beispiel für eine einfache Texttransformation in einem der Felder eines JSON-Datenstroms.

Dieser Code erstellt einen transformierten Datenstrom. Der neue Datenstrom enthält dieselben Daten wie der ursprüngliche Stream, wobei die Zeichenfolge "Company" an den Inhalt des TICKER-Felds angehängt wird.

```
DataStream<ObjectNode> output = input.map(
    new MapFunction<ObjectNode, ObjectNode>() {
     @Override
     public ObjectNode map(ObjectNode value) throws Exception {
        return value.put("TICKER", value.get("TICKER").asText() + " Company");
     }
```

);

}

Verwenden Sie Aggregationsoperatoren

Es folgt ein Beispiel für einen Aggregationsoperator. Der Code erstellt einen aggregierten Datenstrom. Der Operator erstellt ein 5-sekündiges rollierendes Fenster und gibt die Summe der PRICE-Werte für die Datensätze im Fenster mit demselben TICKER-Wert zurück.

```
DataStream<ObjectNode> output = input.keyBy(node -> node.get("TICKER").asText())
    .window(TumblingProcessingTimeWindows.of(Time.seconds(5)))
    .reduce((node1, node2) -> {
        double priceTotal = node1.get("PRICE").asDouble() +
        node2.get("PRICE").asDouble();
        node1.replace("PRICE", JsonNodeFactory.instance.numberNode(priceTotal));
        return node1;
});
```

Weitere Codebeispiele finden Sie unter<u>Beispiele für die Erstellung von und die Arbeit mit Managed</u> Service für Apache Flink-Anwendungen.

Ereignisse in Managed Service für Apache Flink mithilfe der DataStream API verfolgen

Managed Service für Apache Flink verfolgt Ereignisse mit den folgenden Zeitstempeln:

- Verarbeitungszeit: Bezieht sich auf die Systemzeit der Maschine, die den jeweiligen Vorgang ausführt.
- Ereigniszeit: Bezieht sich auf die Zeit, zu der jedes einzelne Ereignis auf seinem produzierenden Gerät eingetreten ist.
- Erfassungszeit: Bezieht sich auf den Zeitpunkt, zu dem Ereignisse in den Service von Managed Service f
 ür Apache Flink eingehen.

Sie legen die von der Streaming-Umgebung verwendete Zeit mithilfe von festsetStreamTimeCharacteristic.

```
env.setStreamTimeCharacteristic(TimeCharacteristic.ProcessingTime);
env.setStreamTimeCharacteristic(TimeCharacteristic.IngestionTime);
```

env.setStreamTimeCharacteristic(TimeCharacteristic.EventTime);

Weitere Informationen zu Zeitstempeln finden Sie unter <u>Generieren von Wasserzeichen</u> in der Apache Flink-Dokumentation.

API-Komponenten von Review Table

Ihre Apache-Flink-Anwendung verwendet die <u>Apache Flink Table API</u>, um mithilfe eines relationalen Modells mit Daten in einem Stream zu interagieren. Sie verwenden die Tabellen-API, um mithilfe von Tabellenquellen auf Daten zuzugreifen, und verwenden dann Tabellenfunktionen, um Tabellendaten zu transformieren und zu filtern. Sie können Tabellendaten entweder mithilfe von API-Funktionen oder SQL-Befehlen transformieren und filtern.

In diesem Abschnitt werden folgende Themen behandelt:

- <u>Tabellen-API-Konnektoren</u>: Diese Komponenten verschieben Daten zwischen Ihrer Anwendung und externen Datenquellen und -zielen.
- <u>Zeitattribute der Tabellen-API</u>: In diesem Thema wird beschrieben, wie Managed Service for Apache Flink Ereignisse verfolgt, wenn die Tabellen-API verwendet wird.

Tabellen-API-Konnektoren

Im Apache Flink-Programmiermodell sind Konnektoren Komponenten, die Ihre Anwendung verwendet, um Daten aus externen Quellen, z. B. anderen AWS Diensten, zu lesen oder zu schreiben.

Mit der Apache Flink Table API können Sie die folgenden Arten von Konnektoren verwenden:

- <u>Tabellen-API-Quellen</u>: Sie verwenden Tabellen-API-Quellkonnektoren, um Tabellen innerhalb Ihrer TableEnvironment zu erstellen, indem Sie entweder API-Aufrufe oder SQL-Abfragen verwenden.
- <u>Die Tabellen-API sinkt</u>: Sie verwenden SQL-Befehle, um Tabellendaten in externe Quellen wie ein Amazon-MSK-Thema oder einen Amazon-S3-Bucket zu schreiben.

Tabellen-API-Quellen

Sie erstellen eine Tabellenquelle aus einem Datenstrom. Der folgende Code erstellt eine Tabelle aus einem Amazon-MSK-Thema:

//create the table
final FlinkKafkaConsumer <stockrecord> consumer = new</stockrecord>
<pre>FlinkKafkaConsumer<stockrecord>(kafkaTopic, new KafkaEventDeserializationSchema(),</stockrecord></pre>
kafkaProperties);
<pre>consumer.setStartFromEarliest();</pre>
//Obtain stream
<pre>DataStream<stockrecord> events = env.addSource(consumer);</stockrecord></pre>
Table table = streamTableEnvironment.fromDataStream(events);

Weitere Informationen zu Tabellenquellen finden Sie unter <u>Table & SQL Connectors</u> in der Apache Flink-Dokumentation.

Die Tabellen-API sinkt

Um Tabellendaten in eine Senke zu schreiben, erstellen Sie die Senke in SQL und führen dann die SQL-basierte Senke für das StreamTableEnvironment-Objekt aus.

Das folgende Codebeispiel zeigt, wie Tabellendaten in eine Amazon-S3-Senke geschrieben werden:

```
final String s3Sink = "CREATE TABLE sink_table (" +
    "event_time TIMESTAMP," +
    "ticker STRING," +
    "price DOUBLE," +
    "dt STRING," +
    "hr STRING" +
    ")" +
    " PARTITIONED BY (ticker,dt,hr)" +
    " WITH" +
    "(" +
    " 'connector' = 'filesystem'," +
    " 'path' = '" + s3Path + "'," +
    " 'format' = 'json'" +
    ") ";
    //send to s3
    streamTableEnvironment.executeSql(s3Sink);
    filteredTable.executeInsert("sink_table");
```

Sie können den format-Parameter verwenden, um zu steuern, welches Format Managed Service für Apache Flink verwendet, um die Ausgabe in die Senke zu schreiben. Informationen zu Formaten finden Sie unter Unterstützte Konnektoren in der Apache Flink-Dokumentation.

Benutzerdefinierte Quellen und Senken

Sie können vorhandene Apache-Kafka-Konnektoren verwenden, um Daten zu und von anderen AWS -Services wie Amazon MSK und Amazon S3 zu senden. Für die Interaktion mit anderen Datenquellen und -zielen können Sie Ihre eigenen Quellen und Senken definieren. Weitere Informationen finden Sie unter <u>Benutzerdefinierte Quellen und Senken in der Apache Flink-Dokumentation</u>.

Zeitattribute der Tabellen-API

Jeder Datensatz in einem Datenstrom hat mehrere Zeitstempel, die definieren, wann Ereignisse im Zusammenhang mit dem Datensatz aufgetreten sind:

- Ereigniszeit: Ein benutzerdefinierter Zeitstempel, der definiert, wann das Ereignis eingetreten ist, durch das der Datensatz erstellt wurde.
- Erfassungszeit: Der Zeitpunkt, zu dem Ihre Anwendung den Datensatz aus dem Datenstrom abgerufen hat.
- Verarbeitungszeit: Der Zeitpunkt, zu dem Ihre Anwendung den Datensatz verarbeitet hat.

Wenn die Apache Flink Table API Fenster auf der Grundlage von Rekordzeiten erstellt, definieren Sie mithilfe der Methode, welche dieser Zeitstempel sie verwendet. setStreamTimeCharacteristic

Weitere Informationen zur Verwendung von Zeitstempeln mit der Tabellen-API finden Sie unter <u>Time</u> <u>Attributes</u> and <u>Timely Stream Processing</u> in der Apache Flink-Dokumentation.

Verwenden Sie Python mit Managed Service für Apache Flink

Note

Wenn Sie die Python-Flink-Anwendung auf einem neuen Mac mit Apple Silicon-Chip entwickeln, können einige <u>bekannte Probleme</u> mit den Python-Abhängigkeiten von PyFlink 1.15 auftreten. In diesem Fall empfehlen wir, den Python-Interpreter in Docker auszuführen. step-by-stepAnweisungen finden Sie unter <u>PyFlink 1.15-Entwicklung auf Apple</u> Silicon Mac.

Apache Flink Version 1.20 unterstützt die Erstellung von Anwendungen mit Python Version 3.11. Weitere Informationen finden Sie unter <u>Flink Python Docs</u>. Gehen Sie wie folgt vor, um mithilfe von Python eine Anwendung zu erstellen, die Managed Service für Apache Flink nutzt:

- Erstellen Sie Ihren Python-Anwendungscode als Textdatei mit einer main-Methode.
- Bündeln Sie Ihre Anwendungscodedatei und alle Python- oder Java-Abhängigkeiten in einer ZIP-Datei und laden Sie sie in einen Amazon-S3-Bucket hoch.
- Erstellen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt, und geben Sie dabei Ihren Amazon-S3-Codespeicherort sowie die Anwendungseigenschaften und die Anwendungseinstellungen an.

Auf einer hohen Ebene ist die Python Table API ein Wrapper rund um die Java Table API. Informationen zur Python-Tabellen-API finden Sie im <u>Tabellen-API-Tutorial</u> in der Apache Flink-Dokumentation.

Programmieren Sie Ihre Python-Anwendung Managed Service für Apache Flink

Sie programmieren Ihre Python-Anwendung, die Managed Service für Apache Flink nutzt, mithilfe der Apache Flink Python Table API. Die Apache-Flink-Engine übersetzt Python-Table-API-Anweisungen (die in der Python-VM ausgeführt werden) in Java-Table-API-Anweisungen (die in der Java-VM ausgeführt werden).

Sie verwenden die Python Table API folgendermaßen:

- Erstellen Sie eine Referenz auf die StreamTableEnvironment.
- Erstellen Sie table-Objekte aus Ihren Quell-Streaming-Daten, indem Sie Abfragen für die StreamTableEnvironment-Referenz ausführen.
- Führen Sie Abfragen an Ihren table-Objekten aus, um Ausgabetabellen zu erstellen.
- Schreiben Sie Ihre Ausgabetabellen mit einem StatementSet an Ihre Ziele.

Informationen zu den ersten Schritten mit der Python Table API in Managed Service für Apache Flink finden Sie unter Erste Schritte mit Amazon Managed Service für Apache Flink für Python.

Streaming-Daten lesen und schreiben

Um Streaming-Daten zu lesen und zu schreiben, führen Sie SQL-Abfragen in der Tabellenumgebung aus.

Programmieren Sie Ihre Python-Anwendung

Programmieren Sie Ihre Python-Anwendung

Managed Service für Apache Flink Entwicklerleitfaden

Erstellen einer Tabelle

Das folgende Codebeispiel demonstriert eine benutzerdefinierte Funktion, die eine SQL-Abfrage erstellt. Die SQL-Abfrage erstellt eine Tabelle, die mit einem Kinesis-Stream interagiert:

```
def create_table(table_name, stream_name, region, stream_initpos):
  return """ CREATE TABLE {0} (
                `record_id` VARCHAR(64) NOT NULL,
                `event_time` BIGINT NOT NULL,
                `record_number` BIGINT NOT NULL,
                `num_retries` BIGINT NOT NULL,
                `verified` BOOLEAN NOT NULL
              )
              PARTITIONED BY (record_id)
              WITH (
                'connector' = 'kinesis',
                'stream' = '{1}',
                'aws.region' = '{2}',
                'scan.stream.initpos' = '{3}',
                'sink.partitioner-field-delimiter' = ';',
                'sink.producer.collection-max-count' = '100',
                'format' = 'json',
                'json.timestamp-format.standard' = 'ISO-8601'
              ) """.format(table_name, stream_name, region, stream_initpos)
```

Streaming-Daten lesen

Das folgende Codebeispiel zeigt, wie die vorherige CreateTable-SQL-Abfrage für eine Tabellenumgebungsreferenz zum Lesen von Daten verwendet wird:

```
table_env.execute_sql(create_table(input_table, input_stream, input_region,
stream_initpos))
```

Schreiben Sie Streaming-Daten

Das folgende Codebeispiel zeigt, wie Sie die SQL-Abfrage aus dem CreateTable-Beispiel verwenden, um eine Ausgabetabellenreferenz zu erstellen, und wie Sie ein StatementSet verwenden, um mit den Tabellen zu interagieren und Daten in einen Kinesis-Ziel-Stream zu schreiben:

table_result = table_env.execute_sql("INSERT INTO {0} SELECT * FROM {1}"

.format(output_table_name, input_table_name))

Lesen Sie die Laufzeiteigenschaften

Sie können Laufzeiteigenschaften verwenden, um Ihre Anwendung zu konfigurieren, ohne Ihren Anwendungscode zu ändern.

Sie geben Anwendungseigenschaften für Ihre Anwendung auf die gleiche Weise an wie bei einer Java-Anwendung, die Managed Service für Apache Flink nutzt. Sie können Laufzeiteigenschaften auf folgende Weise angeben:

- Die CreateApplicationAktion verwenden.
- · Die UpdateApplicationAktion verwenden.
- Konfigurieren Ihrer Anwendung mit Hilfe der Konsole.

Sie rufen Anwendungseigenschaften im Code ab, indem Sie eine JSON-Datei mit dem Namen application_properties.json auslesen, die von der Laufzeit von Managed Service for Apache Flink erstellt wird.

Das folgende Codebeispiel zeigt das Lesen von Anwendungseigenschaften aus der Datei application_properties.json:

```
file_path = '/etc/flink/application_properties.json'
    if os.path.isfile(file_path):
        with open(file_path, 'r') as file:
            contents = file.read()
            properties = json.loads(contents)
```

Das folgende Beispiel für einen benutzerdefinierten Funktionscode demonstriert das Lesen einer Eigenschaftsgruppe aus dem Anwendungseigenschaftenobjekt: ruft ab:

```
def property_map(properties, property_group_id):
    for prop in props:
        if prop["PropertyGroupId"] == property_group_id:
            return prop["PropertyMap"]
```

Das folgende Codebeispiel zeigt das Lesen einer Eigenschaft namens INPUT_STREAM_KEY aus einer Eigenschaftsgruppe, die im vorherigen Beispiel zurückgegeben wurde:

input_stream = input_property_map[INPUT_STREAM_KEY]

Erstellen Sie das Codepaket Ihrer Anwendung

Sobald Sie Ihre Python-Anwendung erstellt haben, bündeln Sie Ihre Codedatei und Abhängigkeiten in einer ZIP-Datei.

Ihre ZIP-Datei muss ein Python-Skript mit einer main-Methode enthalten und kann optional Folgendes enthalten:

- Zusätzliche Python-Codedateien
- Benutzerdefinierter Java-Code in JAR-Dateien
- Java-Bibliotheken in JAR-Dateien

Note

Ihre Anwendungs-ZIP-Datei muss alle Abhängigkeiten für Ihre Anwendung enthalten. Sie können für Ihre Anwendung nicht auf Bibliotheken aus anderen Quellen verweisen.

Erstellen Sie Ihre Python-Anwendung Managed Service für Apache Flink

Geben Sie Ihre Codedateien an

Sobald Sie das Codepaket für Ihre Anwendung erstellt haben, laden Sie es in einen Amazon-S3-Bucket hoch. Anschließend erstellen Sie Ihre Anwendung entweder mit der Konsole oder der CreateApplicationAktion.

Wenn Sie Ihre Anwendung mithilfe der <u>CreateApplication</u>Aktion erstellen, geben Sie die Codedateien und Archive in Ihrer ZIP-Datei mithilfe einer speziellen Anwendungseigenschaftengruppe namens ankinesis.analytics.flink.run.options. Sie können die folgenden Dateitypen definieren:

- python: Eine Textdatei, die eine Python-main-Methode enthält.
- jarfile: Eine Java-JAR-Datei, die benutzerdefinierte Java-Funktionen enthält.
- pyFiles: Eine Python-Ressourcendatei, die Ressourcen enthält, die von der Anwendung verwendet werden sollen.
- pyArchives: Eine ZIP-Datei mit Ressourcendateien für die Anwendung.

Weitere Informationen zu Apache Flink-Python-Codedateitypen finden Sie unter Befehlszeilenschnittstelle in der Apache Flink-Dokumentation.

Note

Managed Service für Apache Flink unterstützt nicht die Dateitypen pyModule, pyExecutable oder pyRequirements. Der gesamte Code, die Anforderungen und Abhängigkeiten müssen sich in Ihrer ZIP-Datei befinden. Sie können keine Abhängigkeiten angeben, die mit pip installiert werden sollen.

Der folgende JSON-Beispielausschnitt zeigt, wie Sie Dateispeicherorte in der ZIP-Datei Ihrer Anwendung angeben:

Überwachen Sie Ihre Python-Anwendung Managed Service für Apache Flink

Sie verwenden das CloudWatch Protokoll Ihrer Anwendung, um Ihre Python-Anwendung Managed Service for Apache Flink zu überwachen.

Managed Service für Apache Flink protokolliert die folgenden Meldungen für Python-Anwendungen:

- Nachrichten, die mithilfe von print() in der main-Methode der Anwendung in die Konsole geschrieben wurden.
- Nachrichten, die mithilfe des logging-Pakets in benutzerdefinierten Funktionen gesendet werden.
 Das folgende Codebeispiel zeigt, wie eine benutzerdefinierte Funktion in das Anwendungsprotokoll schreibt:

import logging

```
@udf(input_types=[DataTypes.BIGINT()], result_type=DataTypes.BIGINT())
def doNothingUdf(i):
    logging.info("Got {} in the doNothingUdf".format(str(i)))
    return i
```

Von der Anwendung ausgelöste Fehlermeldungen.

Wenn die Anwendung in der main-Funktion eine Ausnahme auslöst, wird diese in den Protokollen Ihrer Anwendung angezeigt.

Das folgende Beispiel zeigt einen Protokolleintrag für eine Ausnahme, die aus dem Python-Code ausgelöst wurde:

```
2021-03-15 16:21:20.000
                        ----- Python Process Started
 ------
2021-03-15 16:21:21.000
                       Traceback (most recent call last):
2021-03-15 16:21:21.000 " File ""/tmp/flink-
web-6118109b-1cd2-439c-9dcd-218874197fa9/flink-web-upload/4390b233-75cb-4205-
a532-441a2de83db3_code/PythonKinesisSink/PythonUdfUndeclared.py"", line 101, in
<module>"
2021-03-15 16:21:21.000
                           main()
2021-03-15 16:21:21.000
                        " File ""/tmp/flink-
web-6118109b-1cd2-439c-9dcd-218874197fa9/flink-web-upload/4390b233-75cb-4205-
a532-441a2de83db3_code/PythonKinesisSink/PythonUdfUndeclared.py"", line 54, in main"
2021-03-15 16:21:21.000
                            table_env.register_function(""doNothingUdf"",
                        "
doNothingUdf)"
2021-03-15 16:21:21.000
                       NameError: name 'doNothingUdf' is not defined
                        ----- Python Process Exited
2021-03-15 16:21:21.000
 -----
2021-03-15 16:21:21.000
                       Run python process failed
2021-03-15 16:21:21.000
                       Error occurred when trying to start the job
```

Note

Aufgrund von Leistungsproblemen empfehlen wir, während der Anwendungsentwicklung nur benutzerdefinierte Protokollnachrichten zu verwenden.

Logs mit CloudWatch Insights abfragen

Die folgende CloudWatch Insights-Abfrage sucht nach Protokollen, die vom Python-Einstiegspunkt erstellt wurden, während die Hauptfunktion Ihrer Anwendung ausgeführt wird:

fields @timestamp, message
| sort @timestamp asc
| filter logger like /PythonDriver/
| limit 1000

Verwenden Sie Laufzeiteigenschaften in Managed Service für Apache Flink

Sie können Laufzeiteigenschaften verwenden, um Ihre Anwendung zu konfigurieren, ohne Ihren Anwendungscode neu zu kompilieren.

Dieses Thema enthält die folgenden Abschnitte:

- Verwalten Sie Runtime-Eigenschaften mithilfe der Konsole
- Laufzeiteigenschaften mit der CLI verwalten
- Greifen Sie auf Laufzeiteigenschaften in einer Managed Service for Apache Flink-Anwendung zu

Verwalten Sie Runtime-Eigenschaften mithilfe der Konsole

Sie können Runtime-Eigenschaften zu Ihrer Managed Service for Apache Flink-Anwendung hinzufügen, aktualisieren oder entfernen, indem Sie die AWS Management Console.

Note

Wenn Sie eine frühere unterstützte Version von Apache Flink verwenden und Ihre vorhandenen Anwendungen auf Apache Flink 1.19.1 aktualisieren möchten, können Sie dazu direkte Apache Flink-Versionsupgrades verwenden. Mit direkten Versionsupgrades behalten Sie die Rückverfolgbarkeit von Anwendungen anhand eines einzigen ARN für alle Apache Flink-Versionen, einschließlich Snapshots, Logs, Metriken, Tags, Flink-Konfigurationen und mehr. Sie können diese Funktion in jedem beliebigen Bundesstaat verwenden. RUNNING READY Weitere Informationen finden Sie unter <u>Verwenden Sie direkte Versionsupgrades für Apache Flink</u>.

Aktualisieren von Laufzeiteigenschaften für eine Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service for Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt. Wählen Sie Anwendungsdetails aus.
- 3. Wählen Sie auf der Seite für Ihre Anwendung Konfigurieren aus.
- 4. Erweitern Sie den Bereich Eigenschaften.
- Verwenden Sie die Steuerelemente im Abschnitt Eigenschaften, um eine Eigenschaftsgruppe mit Schlüssel-Wert-Paaren zu definieren. Verwenden Sie diese Steuerelemente, um Eigenschaftsgruppen und Laufzeiteigenschaften hinzuzufügen, zu aktualisieren oder zu entfernen.
- 6. Wählen Sie Aktualisieren.

Laufzeiteigenschaften mit der CLI verwalten

Sie können Laufzeiteigenschaften mit der AWS CLI hinzufügen, aktualisieren oder entfernen.

Dieser Abschnitt enthält Beispielanfragen für API-Aktionen zur Konfiguration von Laufzeiteigenschaften für eine Anwendung. Weitere Informationen zur Verwendung einer JSON-Datei für die Eingabe einer API-Aktion finden Sie unter <u>Beispielcode für Managed Service für Apache Flink</u> <u>API</u>.

1 Note

Ersetzen Sie die beispielhafte Konto-ID (*012345678901*) im folgenden Beispiel durch Ihre tatsächliche Konto-ID.

Fügen Sie Runtime-Eigenschaften hinzu, wenn Sie eine Anwendung erstellen

Die folgende Beispielanfrage für die <u>CreateApplication</u>-Aktion fügt zwei Laufzeiteigenschaftsgruppen (ProducerConfigProperties und ConsumerConfigProperties) hinzu, wenn Sie eine Anwendung erstellen:

```
"ApplicationName": "MyApplication",
"ApplicationDescription": "my java test app",
"RuntimeEnvironment": "FLINK-1_19",
"ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
"ApplicationConfiguration": {
    "ApplicationCodeConfiguration": {
        "CodeContent": {
            "S3ContentLocation": {
                "BucketARN": "arn:aws:s3:::ka-app-code-username",
                "FileKey": "java-getting-started-1.0.jar"
            }
        },
        "CodeContentType": "ZIPFILE"
    },
    "EnvironmentProperties": {
     "PropertyGroups": [
        {
           "PropertyGroupId": "ProducerConfigProperties",
           "PropertyMap" : {
                "flink.stream.initpos" : "LATEST",
                "aws.region" : "us-west-2",
                "AggregationEnabled" : "false"
           }
        },
        {
           "PropertyGroupId": "ConsumerConfigProperties",
           "PropertyMap" : {
                "aws.region" : "us-west-2"
           }
        }
     ]
 }
}
```

Fügen Sie Runtime-Eigenschaften in einer vorhandenen Anwendung hinzu und aktualisieren Sie sie

Mit der folgenden Beispielanfrage für die <u>UpdateApplication</u>-Aktion werden Laufzeiteigenschaften für eine bestehende Anwendung hinzugefügt oder aktualisiert:

```
"ApplicationName": "MyApplication",
```

}

{

```
"CurrentApplicationVersionId": 2,
  "ApplicationConfigurationUpdate": {
    "EnvironmentPropertyUpdates": {
      "PropertyGroups": [
        {
          "PropertyGroupId": "ProducerConfigProperties",
          "PropertyMap" : {
            "flink.stream.initpos" : "LATEST",
            "aws.region" : "us-west-2",
            "AggregationEnabled" : "false"
          }
        },
        {
          "PropertyGroupId": "ConsumerConfigProperties",
          "PropertyMap" : {
            "aws.region" : "us-west-2"
          }
        }
      ]
    }
  }
}
```

Note

{

Wenn Sie in einer Eigenschaftsgruppe einen Schlüssel verwenden, für den keine entsprechende Laufzeiteigenschaft vorhanden ist, fügt Managed Service für Apache Flink das Schlüssel-Wert-Paar als neue Eigenschaft hinzu. Wenn Sie einen Schlüssel für eine vorhandene Laufzeiteigenschaft in einer Eigenschaftsgruppe verwenden, aktualisiert Managed Service für Apache Flink den Eigenschaftswert.

Laufzeiteigenschaften entfernen

Mit der folgenden Beispielanfrage für die <u>UpdateApplication</u>-Aktion werden alle Laufzeiteigenschaften und Eigenschaftsgruppen aus einer bestehenden Anwendung entfernt:

```
"ApplicationName": "MyApplication",
"CurrentApplicationVersionId": 3,
"ApplicationConfigurationUpdate": {
```

```
"EnvironmentPropertyUpdates": {
    "PropertyGroups": []
  }
}
```

A Important

Wenn Sie eine vorhandene Eigenschaftsgruppe oder einen vorhandenen Eigenschaftsschlüssel in einer Eigenschaftsgruppe weglassen, wird diese Eigenschaftsgruppe oder Eigenschaft entfernt.

Greifen Sie auf Laufzeiteigenschaften in einer Managed Service for Apache Flink-Anwendung zu

Sie rufen Laufzeiteigenschaften in Ihrem Java-Anwendungscode mithilfe der statischen KinesisAnalyticsRuntime.getApplicationProperties()-Methode ab, die ein Map<String, Properties>-Objekt zurückgibt.

Im folgenden Java-Codebeispiel werden Laufzeiteigenschaften für Ihre Anwendung abgerufen:

```
Map<String, Properties> applicationProperties =
KinesisAnalyticsRuntime.getApplicationProperties();
```

Sie rufen eine Eigenschaftsgruppe (als Java.Util.Properties-Objekt) wie folgt ab:

Properties consumerProperties = applicationProperties.get("ConsumerConfigProperties");

Normalerweise konfigurieren Sie eine Apache-Flink-Quelle oder -Senke, indem Sie das Properties-Objekt übergeben, ohne die einzelnen Eigenschaften abrufen zu müssen. Das folgende Codebeispiel zeigt, wie Sie eine Flink-Quelle erstellen, indem Sie ein Properties-Objekt übergeben, das aus Laufzeiteigenschaften abgerufen wurde:

```
private static FlinkKinesisProducer<String> createSinkFromApplicationProperties()
throws IOException {
   Map<String, Properties> applicationProperties =
   KinesisAnalyticsRuntime.getApplicationProperties();
```

```
FlinkKinesisProducer<String> sink = new FlinkKinesisProducer<String>(new
SimpleStringSchema(),
    applicationProperties.get("ProducerConfigProperties"));
    sink.setDefaultStream(outputStreamName);
    sink.setDefaultPartition("0");
    return sink;
}
```

Codebeispiele finden Sie unter <u>Beispiele für die Erstellung und Arbeit mit Managed Service für</u> <u>Apache Flink-Anwendungen</u>.

Verwenden Sie Apache Flink-Konnektoren mit Managed Service für Apache Flink

Apache Flink-Konnektoren sind Softwarekomponenten, die Daten in und aus einer Amazon Managed Service für Apache Flink-Anwendung übertragen. Konnektoren sind flexible Integrationen, mit denen Sie aus Dateien und Verzeichnissen lesen können. Konnektoren bestehen aus kompletten Modulen für die Interaktion mit Amazon-Services und Systemen von Drittanbietern.

Zu den Konnektoren gehören die folgenden:

- Quellen: Stellen Sie Ihrer Anwendung Daten aus einem Kinesis-Datenstream, einer Datei, einem Apache Kafka-Thema, einer Datei oder anderen Datenquellen bereit.
- Senken: Senden Sie Daten aus Ihrer Anwendung an einen Kinesis-Datenstream, Firehose-Stream, Apache Kafka-Thema oder andere Datenziele.
- Asynchrone I/O: Ermöglicht asynchronen Zugriff auf eine Datenquelle, z. B. eine Datenbank, um Streams anzureichern.

Apache Flink-Konnektoren werden in ihren eigenen Quell-Repositorys gespeichert. Die Version und das Artefakt für Apache Flink-Konnektoren ändern sich je nachdem, welche Apache Flink-Version Sie verwenden und ob Sie die Table- oder DataStream SQL-API verwenden.

Amazon Managed Service für Apache Flink unterstützt über 40 vorgefertigte Apache Flink-Quellund Senken-Konnektoren. Die folgende Tabelle enthält eine Zusammenfassung der beliebtesten Konnektoren und der zugehörigen Versionen. Sie können auch benutzerdefinierte Senken mithilfe des Async-Sink-Frameworks erstellen. Weitere Informationen finden Sie unter <u>The Generic</u> Asynchronous Base Sink in der Apache Flink-Dokumentation.

Informationen zum Zugriff auf das Repository für Apache AWS Flink-Konnektoren finden Sie unter. flink-connector-aws

Anschlüsse für Flink-Versionen

Konnektor	Flink Version 1.15	Flink versie 1.18	Flink-Versionen 1.19	Flink-Versionen 1.20
Kinesis Data Stream — Quell DataStream - und Tabellen- API	flink-connector-ki nesis, 1.15.4	flink-connector-ki nesis, 4,3,0-1,18	flink-connector-ki nesis, 5,0,0-1,19	flink-connector-ki nesis, 5,0,0-1,20
Kinesis Data Stream — Sink DataStream - und Tabellen- API	flink-connector- aws-kinesis- Streams, 1.15.4	flink-connector- aws-kinesis -Streams, 4.3.0-1.18	flink-connector- aws-kinesis -Streams, 5.0.0-1.19	flink-connector- aws-kinesis -Streams, 5.0.0-1.20
Kinesis Data Streams — Quelle/Senke — SQL	flink-sql- connector- kinesis, 1.15.4	flink-sql- connector- kinesis, 4,3,0-1,1 8	flink-sql- connector- kinesis, 5,0,0-1,1 9	flink-sql- connector- kinesis-Streams, 5.0.0-1.20
Kafka — und Tabellen-API DataStream	flink-connector- kafka, 1.15.4	flink-connector- kafka, 3.2.0-1.18	flink-connector- kafka, 3,3,0-1,19	flink-connector- kafka, 3,3,0-1,20
Kafka - SQL	flink-sql- connector-kafka, 1.15.4	flink-sql- connector-kafka, 3.2.0-1.18	flink-sql- connector-kafka, 3,3,0-1,19	flink-sql- connector-kafka, 3,3,0-1,20
Firehose DataStream - und Tabellen- API	flink-connector- aws-kinesis- Firehose, 1.15.4	flink-connector- aws-firehose, 4.3.0-1.18	flink-connector- aws-firehose, 5,0,0-1,19	flink-connector- aws-firehose, 5,0,0-1,20

Konnektor	Flink Version 1.15	Flink versie 1.18	Flink-Versionen 1.19	Flink-Versionen 1.20
Firehose - SQL	flink-sql- connector-aws- Kinesis-Fire hose, 1.15.4	flink-sql- connector-aws- Feuerwehrsch lauch, 4.3.0-1.18	flink-sql- connector-aws- Feuerwehrsch lauch, 5.0.0-1.19	flink-sql- connector-aws- Feuerwehrsch lauch, 5.0.0-1.20
DynamoDB - DataStream und Tabellen-API	flink-connector- dynamodb, 3.0.0-1.15	flink-connector- dynamodb, 4,3,0-1,18	flink-connector- dynamodb, 5,0,0-1,19	flink-connector- dynamodb, 5,0,0-1,20
DynamoDB - SQL	flink-sql- connector- dynamodb, 3.0.0-1.15	flink-sql- connector- dynamodb, 4,3,0-1,18	flink-sql- connector- dynamodb, 5,0,0-1,19	flink-sql- connector- dynamodb, 5,0,0-1,20
OpenSearch - und Tabellen- API DataStream	-	flink-connector- opensearch, 1.2.0-1.18	flink-connector- opensearch, 1,2.0-1,19	flink-connector- opensearch, 1,2.0-1,19
OpenSearch - SQL	-	flink-sql- connector- opensearch, 1.2.0-1.18	flink-sql- connector- opensearch, 1,2.0-1,19	flink-sql- connector- opensearch, 1,2.0-1,19
Amazon Managed Service für Prometheus DataStream	-	flink-sql- connector- opensearch, 1.2.0-1.18	flink-connector- prometheus, 1.0.0-1,19	flink-connector- prometheus, 1.0.0-1,20
Amazon SQS DataStream und Tabellen-API	-	flink-sql- connector- opensearch, 1.2.0-1.18	flink-connector- sqs, 5,0,0-1,19	flink-connector- sqs, 5,0,0-1,20

Weitere Informationen zu Konnektoren in Amazon Managed Service für Apache Flink finden Sie unter:

- DataStream API-Konnektoren
- Tabellen-API-Konnektoren

Bekannte Probleme

Es gibt ein bekanntes Open-Source-Apache Flink-Problem mit dem Apache Kafka-Konnektor in Apache Flink 1.15. Dieses Problem wurde in späteren Versionen von Apache Flink behoben.

Weitere Informationen finden Sie unter the section called "Bekannte Probleme".

Implementieren Sie Fehlertoleranz in Managed Service für Apache Flink

Prüfpunktprüfung ist die Methode, die zur Implementierung von Fehlertoleranz in Amazon Managed Service für Apache Flink verwendet wird. Ein Checkpoint ist ein up-to-date Backup einer laufenden Anwendung, das zur sofortigen Wiederherstellung nach einer unerwarteten Anwendungsunterbrechung oder einem Failover verwendet wird.

Einzelheiten zum Checkpointing in Apache Flink-Anwendungen finden Sie unter <u>Checkpoints</u> in der Apache Flink-Dokumentation.

Ein Snapshot ist ein manuell erstelltes und verwaltetes Backup des Anwendungsstatus. Mit Snapshots können Sie Ihre Anwendung durch einen Aufruf von <u>UpdateApplication</u>in einen früheren Zustand zurückversetzen. Weitere Informationen finden Sie unter <u>Anwendungs-Backups</u> mithilfe von Snapshots verwalten.

Wenn Prüfpunktprüfung für Ihre Anwendung aktiviert ist, bietet der Dienst Fehlertoleranz, indem er bei unerwarteten Anwendungsneustarts Backups der Anwendungsdaten erstellt und lädt. Diese unerwarteten Anwendungsneustarts können durch unerwartete Jobneustarts, Instancefehler usw. verursacht werden. Dadurch erhält die Anwendung dieselbe Semantik wie eine fehlerfreie Ausführung bei diesen Neustarts.

Wenn Snapshots für die Anwendung aktiviert und mithilfe der Snapshots der Anwendung konfiguriert sind, bietet der Dienst bei <u>ApplicationRestoreConfiguration</u>Anwendungsupdates oder während der dienstbezogenen Skalierung oder Wartung die Semantik für die Verarbeitung genau einmal.
Konfigurieren Sie Checkpointing in Managed Service für Apache Flink

Sie können das Prüfpunktprüfungs-Verhalten Ihrer Anwendung konfigurieren. Sie können festlegen, ob sie den Prüfpunktprüfungs-Status beibehält, wie oft sie ihren Status an Prüfpunkten speichert und das Mindestintervall zwischen dem Ende einer Prüfpunkt-Operation und dem Beginn einer anderen.

Sie konfigurieren die folgenden Einstellungen mithilfe der <u>CreateApplication</u>- oder <u>UpdateApplication</u>-API-Operationen:

- CheckpointingEnabled Gibt an, ob Prüfpunktprüfung in der Anwendung aktiviert ist.
- CheckpointInterval Enthält die Zeit in Millisekunden zwischen Prüfpunkt-Vorgängen (Persistenzoperationen).
- ConfigurationType Setzen Sie diesen Wert auf DEFAULT, um das standardmäßige Prüfpunktprüf-Verhalten zu verwenden. Setzen Sie diesen Wert auf CUSTOM, um andere Werte zu konfigurieren.

1 Note

Das Standardverhalten von Prüfpunkten ist wie folgt:

- CheckpointingEnabled: wahr
- CheckpointInterval: 60000
- MinPauseBetweenCheckpoints: 500

Wenn auf gesetzt ConfigurationTypeistDEFAULT, werden die vorherigen Werte verwendet, auch wenn sie entweder mithilfe von oder durch Setzen der AWS Command Line Interface Werte im Anwendungscode auf andere Werte gesetzt wurden.

Note

Ab Flink 1.15 verwendet Managed Service für Apache Flink stop-with-savepoint während der automatischen Snapshot-Erstellung, d. h. beim Aktualisieren, Skalieren oder Stoppen von Anwendungen.

 MinPauseBetweenCheckpoints – Die Mindestzeit in Millisekunden zwischen dem Ende einer Pr
üfpunkt-Operation und dem Beginn einer anderen. Wenn dieser Wert festgelegt ist, verhindert dies, dass die Anwendung fortlaufende Pr
üfpunktpr
üfung durchf
ührt, wenn eine Pr
üfpunkt-Operation l
änger dauert als das CheckpointInterval.

Sehen Sie sich die Beispiele für Checkpoint-APIs an

Dieser Abschnitt enthält Beispielanfragen für API-Aktionen zur Konfiguration von Prüfpunktprüfung für eine Anwendung. Weitere Informationen zur Verwendung einer JSON-Datei als Eingabe für API-Aktionen finden Sie unter Beispielcode für Managed Service für Apache Flink API.

Konfigurieren Sie Checkpointing für eine neue Anwendung

In der folgenden Beispielanforderung für die <u>CreateApplication</u>-Aktion wird Prüfpunktprüfung konfiguriert, wenn Sie eine Anwendung erstellen:

```
{
   "ApplicationName": "MyApplication",
   "RuntimeEnvironment":"FLINK-1_19",
   "ServiceExecutionRole": "arn: aws: iam:: 123456789123: role/myrole",
   "ApplicationConfiguration": {
      "ApplicationCodeConfiguration":{
      "CodeContent":{
        "S3ContentLocation":{
          "BucketARN":"arn:aws:s3:::amzn-s3-demo-bucket",
          "FileKey":"myflink.jar",
          "ObjectVersion": "AbCdEfGhIjKlMnOpQrStUvWxYz12345"
        }
      },
      "FlinkApplicationConfiguration": {
         "CheckpointConfiguration": {
            "CheckpointingEnabled": "true",
            "CheckpointInterval": 20000,
            "ConfigurationType": "CUSTOM",
            "MinPauseBetweenCheckpoints": 10000
         }
      }
}
```

Deaktivieren Sie Checkpointing für eine neue Anwendung

Die folgende Beispielanforderung für die <u>CreateApplication</u>-Aktion deaktiviert Prüfpunktprüfung, wenn Sie eine Anwendung erstellen:

```
"ApplicationName": "MyApplication",
"RuntimeEnvironment":"FLINK-1_19",
```

{

```
"ServiceExecutionRole":"arn:aws:iam::123456789123:role/myrole",
   "ApplicationConfiguration": {
      "ApplicationCodeConfiguration":{
      "CodeContent":{
        "S3ContentLocation":{
          "BucketARN": "arn: aws: s3::: amzn-s3-demo-bucket",
          "FileKey":"myflink.jar",
          "ObjectVersion":"AbCdEfGhIjKlMnOpQrStUvWxYz12345"
        }
      },
      "FlinkApplicationConfiguration": {
         "CheckpointConfiguration": {
            "CheckpointingEnabled": "false"
         }
      }
}
```

Konfigurieren Sie Checkpointing für eine bestehende Anwendung

Die folgende Beispielanforderung für die <u>UpdateApplication</u>-Aktion konfiguriert Prüfpunktprüfung für eine bestehende Anwendung:

```
{
    "ApplicationName": "MyApplication",
    "ApplicationConfigurationUpdate": {
        "FlinkApplicationConfigurationUpdate": {
            "CheckpointConfigurationUpdate": true,
            "CheckpointIntervalUpdate": true,
            "CheckpointIntervalUpdate": 20000,
            "ConfigurationTypeUpdate": "CUSTOM",
            "MinPauseBetweenCheckpointsUpdate": 10000
            }
        }
    }
}
```

Deaktivieren Sie Checkpointing für eine bestehende Anwendung

Die folgende Beispielanforderung für die <u>UpdateApplication</u>-Aktion deaktiviert Prüfpunktprüfung für eine bestehende Anwendung:

{

```
"ApplicationName": "MyApplication",
"ApplicationConfigurationUpdate": {
    "FlinkApplicationConfigurationUpdate": {
        "CheckpointConfigurationUpdate": false,
        "CheckpointingEnabledUpdate": false,
        "CheckpointIntervalUpdate": 20000,
        "ConfigurationTypeUpdate": "CUSTOM",
        "MinPauseBetweenCheckpointsUpdate": 10000
        }
    }
}
```

Anwendungs-Backups mithilfe von Snapshots verwalten

Ein Snapshot ist die Managed Service für Apache Flink-Implementierung eines Apache Flink Savepoint. Ein Snapshot ist ein vom Benutzer oder Service ausgelöstes, erstelltes und verwaltetes Backup des Anwendungsstatus. Informationen zu Apache Flink Savepoints finden Sie unter Savepoints in der Apache <u>Flink-Dokumentation</u>. Mithilfe von Snapshots können Sie eine Anwendung von einem bestimmten Snapshot des Anwendungsstatus aus neu starten.

Note

Wir empfehlen, dass Ihre Anwendung mehrmals täglich einen Snapshot erstellt, um einen ordnungsgemäßen Neustart mit den korrekten Statusdaten zu gewährleisten. Die richtige Häufigkeit für Ihre Snapshots hängt von der Geschäftslogik Ihrer Anwendung ab. Durch häufiges Erstellen von Snapshots können Sie neuere Daten wiederherstellen, was jedoch die Kosten erhöht und mehr Systemressourcen beansprucht.

In Managed Service für Apache Flink verwalten Sie Snapshots mit den folgenden API-Aktionen:

- <u>CreateApplicationSnapshot</u>
- DeleteApplicationSnapshot
- <u>DescribeApplicationSnapshot</u>
- ListApplicationSnapshots

Informationen zur Beschränkung der Anzahl von Snapshots pro Anwendung finden Sie unter <u>Managed Service für Apache Flink und Studio Notebook-Kontingent</u>. Wenn Ihre Anwendung das Limit für Snapshots erreicht, schlägt das manuelle Erstellen eines Snapshots mit einer LimitExceededException fehl.

Managed Service für Apache Flink löscht Snapshots niemals. Sie müssen die Snapshots mit der Aktion <u>DeleteApplicationSnapshot</u> manuell löschen.

Um beim Starten einer Anwendung einen gespeicherten Snapshot des Anwendungsstatus zu laden, verwenden Sie den <u>ApplicationRestoreConfiguration</u>-Parameter der <u>StartApplication</u>-oder <u>UpdateApplication</u>-Aktion.

Dieses Thema enthält die folgenden Abschnitte:

- Verwalten Sie die automatische Erstellung von Snapshots
- · Wiederherstellung aus einem Snapshot, der inkompatible Statusdaten enthält
- Sehen Sie sich die Snapshot-API-Beispiele

Verwalten Sie die automatische Erstellung von Snapshots

Wenn true in der <u>ApplicationSnapshotConfiguration</u>für die Anwendung auf gesetzt SnapshotsEnabled ist, erstellt und verwendet Managed Service for Apache Flink automatisch Snapshots, wenn die Anwendung aktualisiert, skaliert oder gestoppt wird, um eine Semantik für die Verarbeitung exakt einmal bereitzustellen.

Note

Die Einstellung von ApplicationSnapshotConfiguration::SnapshotsEnabled auf false führt bei Anwendungsupdates zu Datenverlust.

Note

Managed Service für Apache Flink löst Zwischen-Savepoints während der Snapshoterstellung aus. Bei Flink Version 1.15 oder höher haben Zwischen-Savepoints keine Nebenwirkungen mehr. <u>Siehe Savepoints auslösen.</u>

Automatisch erstellte Snapshots haben die folgenden Eigenschaften:

- Der Snapshot wird vom Service verwaltet, aber Sie können den Snapshot mithilfe der Aktion sehen. <u>ListApplicationSnapshots</u> Automatisch erstellte Snapshots werden auf Ihr Snapshot-Limit angerechnet.
- Wenn Ihre Anwendung das Snapshot-Limit überschreitet, schlagen manuell erstellte Snapshots fehl, aber der Managed Service für Apache Flink-Service erstellt weiterhin erfolgreich Snapshots, wenn die Anwendung aktualisiert, skaliert oder gestoppt wird. Sie müssen Snapshots mithilfe der <u>DeleteApplicationSnapshot</u>Aktion manuell löschen, bevor Sie weitere Snapshots manuell erstellen können.

Wiederherstellung aus einem Snapshot, der inkompatible Statusdaten enthält

Da Snapshots Informationen über Operatoren enthalten, kann das Wiederherstellen von Zustandsdaten aus einem Snapshot für einen Operator, der sich seit der vorherigen Anwendungsversion geändert hat, zu unerwarteten Ergebnissen führen. Eine Anwendung schlägt fehl, wenn sie versucht, Zustandsdaten aus einem Snapshot wiederherzustellen, der nicht dem aktuellen Operator entspricht. Die fehlerhafte Anwendung bleibt entweder im UPDATING- oder STOPPING-Status hängen.

Um einer Anwendung die Wiederherstellung aus einem Snapshot zu ermöglichen, der inkompatible Statusdaten enthält, setzen Sie true mithilfe der <u>UpdateApplication</u>Aktion den AllowNonRestoredState Parameter FlinkRunConfigurationauf.

Wenn eine Anwendung aus einem veralteten Snapshot wiederhergestellt wird, tritt das folgende Verhalten auf:

- Operator hinzugefügt: Wenn ein neuer Operator hinzugefügt wird, hat der Savepoint keine Statusdaten für den neuen Operator. Es tritt kein Fehler auf und es ist nicht nötig, AllowNonRestoredState festzulegen.
- Operator gelöscht: Wenn ein vorhandener Operator gelöscht wird, enthält der Savepoint Statusdaten für den fehlenden Operator. Es tritt ein Fehler auf, sofern AllowNonRestoredState nicht auf true festgelegt ist.
- Operator geändert: Wenn kompatible Änderungen vorgenommen werden, z. B. wenn der Typ eines Parameters in einen kompatiblen Typ geändert wird, kann die Anwendung die Daten aus dem veralteten Snapshot wiederherstellen. Weitere Informationen zur Wiederherstellung aus Snapshots finden Sie unter Savepoints in der Apache Flink-Dokumentation. Eine Anwendung, die

Apache Flink Version 1.8 oder höher verwendet, kann möglicherweise aus einem Snapshot mit einem anderen Schema wiederhergestellt werden. Eine Anwendung, die Apache Flink Version 1.6 verwendet, kann nicht wiederhergestellt werden. Für two-phase-commit Datenspeicher empfehlen wir die Verwendung eines System-Snapshots (SWs) anstelle eines vom Benutzer erstellten Snapshots (). CreateApplicationSnapshot

Für Flink löst Managed Service für Apache Flink während der Snapshot-Erstellung Zwischen-Savepoints aus. Ab Flink 1.15 haben Zwischen-Savepoints keine Nebenwirkungen mehr. Siehe Savepoints auslösen.

Wenn Sie eine Anwendung fortsetzen müssen, die mit vorhandenen Savepoint-Daten nicht kompatibel ist, empfehlen wir, die Wiederherstellung aus dem Snapshot zu überspringen, indem Sie den ApplicationRestoreType Aktionsparameter auf setzen. <u>StartApplication</u>SKIP_RESTORE_FROM_SNAPSHOT

Weitere Informationen darüber, wie Apache Flink mit inkompatiblen Statusdaten umgeht, finden Sie unter State Schema Evolution in der Apache Flink-Dokumentation.

Sehen Sie sich die Snapshot-API-Beispiele

Dieser Abschnitt enthält Beispielanfragen für API-Aktionen zur Verwendung von Snapshots mit einer Anwendung. Weitere Informationen zur Verwendung einer JSON-Datei als Eingabe für API-Aktionen finden Sie unter Beispielcode für Managed Service für Apache Flink API.

Aktivieren Sie Snapshots für eine Anwendung

In der folgenden Beispiel-Anfrage für die Aktion <u>UpdateApplication</u> werden Tags für eine Anwendung aktiviert:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 1,
    "ApplicationConfigurationUpdate": {
        "ApplicationSnapshotConfigurationUpdate": {
            "SnapshotsEnabledUpdate": "true"
            }
        }
}
```

Snapshot erstellen

Die folgende Beispielanforderung für die <u>CreateApplicationSnapshot</u>-Aktion erstellt einen Snapshot des aktuellen Anwendungsstatus:

```
{
    "ApplicationName": "MyApplication",
    "SnapshotName": "MyCustomSnapshot"
}
```

Listet Snapshots für eine Anwendung auf

In der folgenden Beispielanforderung für die <u>ListApplicationSnapshots</u>-Aktion werden die ersten 50 Snapshots für den aktuellen Anwendungsstatus aufgeführt:

```
{
    "ApplicationName": "MyApplication",
    "Limit": 50
}
```

Listet Details für einen Anwendungs-Snapshot auf

In der folgenden Beispiel-Anfrage für die Aktion <u>DescribeApplicationSnapshot</u> werden Details für eines bestimmten Anwendungssnapshot aufgelistet:

```
{
    "ApplicationName": "MyApplication",
    "SnapshotName": "MyCustomSnapshot"
}
```

Löschen eines Snapshots

Die folgende Beispielanforderung für die <u>DeleteApplicationSnapshot</u>-Aktion löscht einen zuvor gespeicherten Snapshot. Sie können den SnapshotCreationTimestamp-Wert entweder mit <u>ListApplicationSnapshots</u> oder <u>DeleteApplicationSnapshot</u> abrufen:

```
"ApplicationName": "MyApplication",
"SnapshotName": "MyCustomSnapshot",
"SnapshotCreationTimestamp": 12345678901.0,
```

{

}

Starten Sie eine Anwendung mithilfe eines benannten Snapshots neu

Mit der folgenden Beispielanforderung für die <u>StartApplication</u>-Aktion wird die Anwendung mit dem gespeicherten Status eines bestimmten Snapshots gestartet:

```
{
    "ApplicationName": "MyApplication",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_CUSTOM_SNAPSHOT",
            "SnapshotName": "MyCustomSnapshot"
        }
    }
}
```

Starten Sie eine Anwendung mit dem neuesten Snapshot neu

Mit der folgenden Beispielanforderung für die <u>StartApplication</u>-Aktion wird die Anwendung mit dem neuesten Snapshot gestartet:

```
{
    "ApplicationName": "MyApplication",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
        }
    }
}
```

Starten Sie eine Anwendung neu, die keinen Snapshot verwendet

Mit der folgenden Beispielanforderung für die <u>StartApplication</u>-Aktion wird die Anwendung gestartet, ohne den Anwendungsstatus zu laden, auch wenn ein Snapshot vorhanden ist:

```
{
    "ApplicationName": "MyApplication",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
        "
        "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
        "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
        "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
        "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
        "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
         "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
         "ApplicationRestoreType": "SKIP_RESTORE_FROM_SNAPSHOT"
         "
          "ApplicationRestoreType"
         "ApplicAtionProstoreType"
```

}

}

Verwenden Sie direkte Versionsupgrades für Apache Flink

Mit direkten Versionsupgrades für Apache Flink behalten Sie die Rückverfolgbarkeit von Anwendungen anhand eines einzigen ARN für alle Apache Flink-Versionen aufrecht. Dazu gehören Snapshots, Protokolle, Metriken, Tags, Flink-Konfigurationen, Erhöhungen von Ressourcenlimits und mehr. VPCs

Sie können direkte Versions-Upgrades für Apache Flink durchführen, um bestehende Anwendungen auf eine neue Flink-Version in Amazon Managed Service for Apache Flink zu aktualisieren. Um diese Aufgabe auszuführen, können Sie das AWS CLI AWS CloudFormation, AWS SDK oder das verwenden. AWS Management Console

Note

Sie können keine direkten Versionsupgrades für Apache Flink mit Amazon Managed Service für Apache Flink Studio verwenden.

Dieses Thema enthält die folgenden Abschnitte:

- <u>Aktualisieren Sie Anwendungen mithilfe von direkten Versionsupgrades für Apache Flink</u>
- Aktualisieren Sie Ihre Anwendung auf eine neue Apache Flink-Version
- Machen Sie Anwendungs-Upgrades rückgängig
- Allgemeine bewährte Methoden und Empfehlungen für Anwendungs-Upgrades
- Vorsichtsmaßnahmen und bekannte Probleme bei Anwendungsupgrades

Aktualisieren Sie Anwendungen mithilfe von direkten Versionsupgrades für Apache Flink

Bevor Sie beginnen, empfehlen wir Ihnen, sich dieses Video anzusehen: Direkte Versionsupgrades.

Um direkte Versionsupgrades für Apache Flink durchzuführen, können Sie das AWS CLI, AWS CloudFormation, AWS SDK oder das verwenden. AWS Management Console Sie können diese

Funktion mit allen vorhandenen Anwendungen verwenden, die Sie mit Managed Service for Apache Flink im Status oder verwenden. READY RUNNING Es verwendet die UpdateApplication API, um die Möglichkeit hinzuzufügen, die Flink-Laufzeit zu ändern.

Vor dem Upgrade: Aktualisieren Sie Ihre Apache Flink-Anwendung

Wenn Sie Ihre Flink-Anwendungen schreiben, bündeln Sie sie mit ihren Abhängigkeiten in einer Anwendungs-JAR und laden die JAR in Ihren Amazon S3 S3-Bucket hoch. Von dort aus führt Amazon Managed Service für Apache Flink den Job in der neuen Flink-Laufzeit aus, die Sie ausgewählt haben. Möglicherweise müssen Sie Ihre Anwendungen aktualisieren, um die Kompatibilität mit der Flink-Laufzeit zu erreichen, auf die Sie ein Upgrade durchführen möchten. Es kann Inkonsistenzen zwischen den Flink-Versionen geben, die dazu führen, dass das Versionsupgrade fehlschlägt. Am häufigsten wird dies mit Konnektoren für Quellen (Ingress) oder Destinationen (Sinks, Egress) und Scala-Abhängigkeiten geschehen. Flink 1.15 und spätere Versionen in Managed Service for Apache Flink sind Scala-unabhängig, und Ihr JAR muss die Version von Scala enthalten, die Sie verwenden möchten.

Um Ihre Anwendung zu aktualisieren

- 1. Lesen Sie die Ratschläge der Flink-Community zur Aktualisierung von Anwendungen mit State. Siehe Aktualisieren von Anwendungen und Flink-Versionen.
- 2. Lesen Sie die Liste der bekannten Probleme und Einschränkungen. Siehe Vorsichtsmaßnahmen und bekannte Probleme bei Anwendungsupgrades.
- Aktualisieren Sie Ihre Abhängigkeiten und testen Sie Ihre Anwendungen lokal. Diese Abhängigkeiten sind in der Regel:
 - 1. Die Flink-Laufzeit und die API.
 - 2. Für die neue Flink-Laufzeit werden Konnektoren empfohlen. Sie finden diese unter <u>Release-Versionen</u> für die spezifische Laufzeit, auf die Sie aktualisieren möchten.
 - 3. Scala Apache Flink ist ab und einschließlich Flink 1.15 Scala-agnostisch. Sie müssen die Scala-Abhängigkeiten, die Sie verwenden möchten, in Ihre Anwendungs-JAR aufnehmen.
- Erstellen Sie eine neue Anwendungs-JAR auf einer Zip-Datei und laden Sie sie auf Amazon S3 hoch. Wir empfehlen, dass Sie einen anderen Namen als die vorherige JAR-/Zip-Datei verwenden. Wenn Sie ein Rollback durchführen müssen, verwenden Sie diese Informationen.
- 5. Wenn Sie statusbehaftete Anwendungen ausführen, empfehlen wir Ihnen dringend, einen Snapshot Ihrer aktuellen Anwendung zu erstellen. Auf diese Weise können Sie statusabhängig ein Rollback durchführen, falls während oder nach dem Upgrade Probleme auftreten.

Aktualisieren Sie Ihre Anwendung auf eine neue Apache Flink-Version

Sie können Ihre Flink-Anwendung aktualisieren, indem Sie die UpdateApplicationAktion verwenden.

Sie können die UpdateApplication API auf verschiedene Arten aufrufen:

- Verwenden Sie den vorhandenen Konfigurationsworkflow auf dem AWS Management Console.
 - Gehen Sie zu Ihrer App-Seite auf der AWS Management Console.
 - Wählen Sie Konfigurieren aus.
 - Wählen Sie die neue Laufzeit und den Snapshot aus, von dem aus Sie beginnen möchten. Dies wird auch als Wiederherstellungskonfiguration bezeichnet. Verwenden Sie die neueste Einstellung als Wiederherstellungskonfiguration, um die App vom neuesten Snapshot aus zu starten. Zeigen Sie auf die neue aktualisierte Anwendung Jar/Zip auf Amazon S3.
- Verwenden Sie die Aktion "Anwendung AWS CLI aktualisieren".
- Verwenden Sie AWS CloudFormation (CFN).
 - Aktualisieren Sie das <u>RuntimeEnvironment</u>Feld. Zuvor wurde die Anwendung AWS CloudFormation gelöscht und eine neue erstellt, wodurch Ihre Schnappschüsse und andere App-Historien verloren gingen. AWS CloudFormation Aktualisiert jetzt Ihr RuntimeEnvironment vorhandenes Dokument und löscht Ihre Anwendung nicht.
- Verwenden Sie das AWS SDK.
 - Die Programmiersprache Ihrer Wahl finden Sie in der SDK-Dokumentation. Siehe UpdateApplication.

Sie können das Upgrade durchführen, während sich die Anwendung im RUNNING Status befindet oder während die Anwendung im READY Status gestoppt ist. Amazon Managed Service für Apache Flink validiert, um die Kompatibilität zwischen der ursprünglichen Runtime-Version und der Ziel-Runtime-Version zu überprüfen. Diese Kompatibilitätsprüfung wird ausgeführt, wenn Sie diese durchführen, <u>UpdateApplication</u>während Sie sich im RUNNING Status befinden, oder beim nächsten Mal, <u>StartApplication</u>wenn Sie ein Upgrade durchführen, während Sie sich im READY Status befinden.

Führen Sie ein Upgrade für eine Anwendung im aktuellen RUNNING Status durch

Das folgende Beispiel zeigt das Upgrade einer App im RUNNING Bundesstaat Flink 1.18 in US East (Nord-Virginia) mithilfe von AWS CLI und das Starten der aktualisierten App aus dem neuesten Snapshot. UpgradeTest

```
aws --region us-east-1 kinesisanalyticsv2 update-application \
--application-name UpgradeTest --runtime-environment-update "FLINK-1_18" \
--application-configuration-update '{"ApplicationCodeConfigurationUpdate": '\
'{"CodeContentUpdate": {"S3ContentLocationUpdate": '\
'{"FileKeyUpdate": "flink_1_18_app.jar"}}}' \
--run-configuration-update '{"ApplicationRestoreConfiguration": '\
'{"ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"}}' \
--current-application-version-id ${current_application_version}
```

- Wenn Sie Service-Snapshots aktiviert haben und die Anwendung vom letzten Snapshot aus fortsetzen möchten, überprüft Amazon Managed Service für Apache Flink, ob die Laufzeit der aktuellen RUNNING Anwendung mit der ausgewählten Ziellaufzeit kompatibel ist.
- Wenn Sie einen Snapshot angegeben haben, von dem aus die Ziellaufzeit fortgesetzt werden soll, überprüft Amazon Managed Service für Apache Flink, ob die Ziellaufzeit mit dem angegebenen Snapshot kompatibel ist. Schlägt die Kompatibilitätsprüfung fehl, wird Ihre Aktualisierungsanfrage abgelehnt und Ihre Anwendung bleibt unverändert. RUNNING
- Wenn Sie Ihre Anwendung ohne Snapshot starten möchten, führt Amazon Managed Service für Apache Flink keine Kompatibilitätsprüfungen durch.
- Wenn Ihre aktualisierte Anwendung fehlschlägt oder in einem transitiven UPDATING Zustand hängen bleibt, folgen Sie den Anweisungen im <u>Machen Sie Anwendungs-Upgrades rückgängig</u> Abschnitt, um zum fehlerfreien Zustand zurückzukehren.

Prozessablauf für die Ausführung von Statusanwendungen



Führen Sie ein Upgrade einer Anwendung im Status READY durch

Das folgende Beispiel zeigt das Upgrade einer App im READY Bundesstaat UpgradeTest Flink 1.18 in USA Ost (Nord-Virginia) mithilfe von. AWS CLI Es gibt keinen angegebenen Snapshot zum Starten der App, da die Anwendung nicht ausgeführt wird. Sie können einen Snapshot angeben, wenn Sie die Anfrage zum Starten der Anwendung stellen.

```
aws --region us-east-1 kinesisanalyticsv2 update-application \
--application-name UpgradeTest --runtime-environment-update "FLINK-1_18" \
--application-configuration-update '{"ApplicationCodeConfigurationUpdate": '\
'{"CodeContentUpdate": {"S3ContentLocationUpdate": '\
'{"FileKeyUpdate": "flink_1_18_app.jar"}}}' \
--current-application-version-id ${current_application_version}}
```

- Sie können die Laufzeit Ihrer Anwendungen im READY Status auf eine beliebige Flink-Version aktualisieren. Amazon Managed Service f
 ür Apache Flink f
 ührt keine Pr
 üfungen durch, bis Sie Ihre Anwendung starten.
- Amazon Managed Service f
 ür Apache Flink f
 ührt nur Kompatibilit
 ätspr
 üfungen f
 ür den Snapshot durch, den Sie zum Starten der App ausgew
 ählt haben. Dies sind grundlegende Kompatibilit
 ätspr
 üfungen, die der <u>Flink-Kompatibilit
 ätstabelle</u> folgen. Sie
 überpr
 üfen nur die Flink-Version, mit der der Snapshot erstellt wurde, und die Flink-Version, auf die Sie abzielen. Wenn die Flink-Laufzeit des ausgew
 ählten Snapshots nicht mit der neuen Laufzeit der App kompatibel ist, wird die Startanfrage m
 öglicherweise abgelehnt.

Prozessablauf für Ready-State-Anwendungen



Machen Sie Anwendungs-Upgrades rückgängig

Wenn Sie Probleme mit Ihrer Anwendung haben oder Inkonsistenzen in Ihrem Anwendungscode zwischen den Flink-Versionen feststellen, können Sie ein Rollback mit dem AWS CLI, AWS CloudFormation, AWS SDK oder dem durchführen. AWS Management Console Die folgenden Beispiele zeigen, wie ein Rollback in verschiedenen Fehlerszenarien aussieht.

Das Runtime-Upgrade war erfolgreich, die Anwendung befindet sich im **RUNNING** Status, aber der Job schlägt fehl und wird ständig neu gestartet

Angenommen, Sie versuchen, eine statusbehaftete Anwendung mit TestApplication dem Namen Flink 1.15 auf Flink 1.18 in USA Ost (Nord-Virginia) zu aktualisieren. Die aktualisierte Flink 1.18-Anwendung kann jedoch nicht gestartet werden oder wird ständig neu gestartet, obwohl sich die Anwendung im Status befindet. RUNNING Dies ist ein häufiges Fehlerszenario. Um weitere Ausfallzeiten zu vermeiden, empfehlen wir, dass Sie Ihre Anwendung sofort auf die vorherige laufende Version (Flink 1.15) zurücksetzen und das Problem später diagnostizieren.

Verwenden Sie den AWS CLI Befehl rollback-application oder die API-Aktion, um die <u>Anwendung</u> auf die zuvor ausgeführte Version zurückzusetzen. <u>RollbackApplication</u> Diese API-Aktion macht die Änderungen rückgängig, die Sie vorgenommen haben und die zur neuesten Version geführt haben. Anschließend wird Ihre Anwendung mit dem letzten erfolgreichen Snapshot neu gestartet.

Wir empfehlen dringend, dass Sie einen Snapshot mit Ihrer vorhandenen App erstellen, bevor Sie versuchen, ein Upgrade durchzuführen. Dies hilft, Datenverlust oder die Notwendigkeit einer erneuten Verarbeitung von Daten zu vermeiden.

In diesem Fehlerszenario AWS CloudFormation wird die Anwendung nicht für Sie zurückgesetzt. Sie müssen die CloudFormation Vorlage so aktualisieren, dass sie auf die vorherige Laufzeit und auf den vorherigen Code verweist, um die Aktualisierung der Anwendung CloudFormation zu erzwingen. Andernfalls CloudFormation wird davon ausgegangen, dass Ihre Anwendung aktualisiert wurde, wenn sie in den RUNNING Status wechselt.

Eine Anwendung, die feststeckt, wird rückgängig gemacht UPDATING

Wenn Ihre Anwendung nach einem Upgrade-Versuch im AUTOSCALING Status UPDATING oder hängen bleibt, bietet Amazon Managed Service für Apache Flink den AWS CLI Befehl <u>rollback-applications</u> oder die <u>RollbackApplications</u>API-Aktion an, mit der die Anwendung auf die Version vor dem Status "blockiert" oder "blockiert" zurückgesetzt werden kann. UPDATING AUTOSCALING Diese

API macht die Änderungen rückgängig, die Sie vorgenommen haben und die dazu geführt haben, dass die Anwendung in UPDATING einem transitiven Zustand hängengeblieben ist. AUTOSCALING

Allgemeine bewährte Methoden und Empfehlungen für Anwendungs-Upgrades

- Testen Sie den neuen Job/die neue Laufzeit ohne Status in einer Produktionsumgebung, bevor Sie ein Produktionsupgrade versuchen.
- Erwägen Sie, das statusbehaftete Upgrade zunächst mit einer Anwendung zu testen, die nicht zur Produktion gehört.
- Stellen Sie sicher, dass Ihr neuer Job Graph einen kompatiblen Status mit dem Snapshot aufweist, den Sie zum Starten Ihrer aktualisierten Anwendung verwenden werden.
 - Stellen Sie sicher, dass die in den Operatorstatus gespeicherten Typen gleich bleiben. Wenn sich der Typ geändert hat, kann Apache Flink den Operatorstatus nicht wiederherstellen.
 - Stellen Sie sicher, dass der Operator, den IDs Sie mit der uid Methode festgelegt haben, derselbe bleibt. Apache Flink empfiehlt ausdrücklich, Operatoren eindeutig IDs zuzuweisen. Weitere Informationen finden Sie unter <u>Zuweisen von Operatoren IDs</u> in der Apache Flink-Dokumentation.

Wenn Sie Ihren Operatoren nichts IDs zuweisen, generiert Flink sie automatisch. In diesem Fall hängen sie möglicherweise von der Programmstruktur ab und können, wenn sie geändert werden, zu Kompatibilitätsproblemen führen. Flink verwendet Operator IDs, um den Status im Snapshot dem Operator zuzuordnen. Eine Änderung des Operators IDs führt dazu, dass die Anwendung nicht gestartet wird oder der im Snapshot gespeicherte Status gelöscht wird und der neue Operator ohne Status startet.

- Ändern Sie nicht den Schlüssel, der zum Speichern des eingegebenen Status verwendet wurde.
- Ändern Sie nicht den Eingabetyp von statusbehafteten Operatoren wie Window oder Join. Dadurch wird implizit der Typ des internen Zustands des Operators geändert, was zu einer Zustandsinkompatibilität führt.

Vorsichtsmaßnahmen und bekannte Probleme bei Anwendungsupgrades

Kafka Commit beim Checkpointing schlägt nach einem Neustart des Brokers wiederholt fehl

Es gibt ein bekanntes Open-Source-Apache Flink-Problem mit dem Apache Kafka-Konnektor in Flink Version 1.15, das durch einen kritischen Open-Source-Fehler im Kafka-Client 2.8.1 verursacht wurde. Weitere Informationen finden Sie unter <u>Kafka Commit on Checkpointing schlägt nach einem Neustart</u> <u>des Brokers wiederholt fehl und kann die Verbindung zum Gruppenkoordinator nach einer</u> Ausnahme nicht KafkaConsumer wiederherstellen. commitOffsetAsync

Um dieses Problem zu vermeiden, empfehlen wir, Apache Flink 1.18 oder höher in Amazon Managed Service für Apache Flink zu verwenden.

Bekannte Einschränkungen der staatlichen Kompatibilität

- Wenn Sie die Tabellen-API verwenden, garantiert Apache Flink keine Statuskompatibilität zwischen Flink-Versionen. Weitere Informationen finden Sie unter <u>Stateful Upgrades and Evolution</u> in der Apache Flink-Dokumentation.
- Die Status von Flink 1.6 sind nicht mit Flink 1.18 kompatibel. Die API lehnt Ihre Anfrage ab, wenn Sie versuchen, ein Upgrade von 1.6 auf 1.18 und höher mit State durchzuführen. Sie können ein Upgrade auf 1.8, 1.11, 1.13 und 1.15 durchführen und einen Snapshot erstellen und dann auf 1.18 und höher aktualisieren. Weitere Informationen finden Sie unter <u>Upgraden von Anwendungen und</u> Flink-Versionen in der Apache Flink-Dokumentation.

Bekannte Probleme mit dem Flink Kinesis Connector

 Wenn Sie Flink 1.11 oder eine frühere Version verwenden und den amazon-kinesisconnector-flink Connector für die Enhanced-fan-out (EFO) -Unterstützung verwenden, müssen Sie zusätzliche Schritte für ein Stateful-Upgrade auf Flink 1.13 oder höher durchführen. Dies liegt an der Änderung des Paketnamens des Connectors. Weitere Informationen finden Sie unter amazon-kinesis-connector-flink.

Der amazon-kinesis-connector-flink Anschluss für Flink 1.11 und frühere Versionen verwendet die Verpackungsoftware.amazon.kinesis, wohingegen der Kinesis-Anschluss für Flink 1.13 und höher verwendet.org.apache.flink.streaming.connectors.kinesis Verwenden Sie dieses Tool, um Ihre Migration zu unterstützen: -state-migrator. amazon-kinesisconnector-flink Wenn Sie Flink 1.13 oder früher mit Flink 1.15 oder höher verwenden FlinkKinesisProducer und ein Upgrade auf Flink 1.15 oder höher durchführen, müssen Sie für ein Stateful-Upgrade weiterhin Flink 1.15 oder höher verwenden, FlinkKinesisProducer anstatt das neuere. KinesisStreamsSink Wenn Sie jedoch bereits ein benutzerdefiniertes uid Set auf Ihrer Spüle haben, sollten Sie in der Lage sein, zu diesem zu wechseln, weil der Status nicht beibehalten wird. KinesisStreamsSink FlinkKinesisProducer Flink behandelt ihn als denselben Operator, da ein benutzerdefinierter Operator festgelegt uid ist.

In Scala geschriebene Flink-Anwendungen

- Ab Flink 1.15 beinhaltet Apache Flink Scala nicht mehr in der Runtime. Sie müssen die Version von Scala, die Sie verwenden möchten, und andere Scala-Abhängigkeiten in Ihren Code JAR/ZIP aufnehmen, wenn Sie auf Flink 1.15 oder höher aktualisieren. Weitere Informationen finden Sie unter Amazon Managed Service für Apache Flink für die Version Apache Flink 1.15.2.
- Wenn Ihre Anwendung Scala verwendet und Sie sie von Flink 1.11 oder früher (Scala 2.11) auf Flink 1.13 (Scala 2.12) aktualisieren, stellen Sie sicher, dass Ihr Code Scala 2.12 verwendet. Andernfalls kann Ihre Flink 1.13-Anwendung möglicherweise keine Scala 2.11-Klassen in der Flink 1.13-Laufzeit finden.

Dinge, die Sie beim Downgrade der Flink-Anwendung beachten sollten

- Ein Downgrade von Flink-Anwendungen ist möglich, aber auf Fälle beschränkt, in denen die Anwendung zuvor mit der älteren Flink-Version ausgeführt wurde. Für ein Stateful-Upgrade benötigt Managed Service für Apache Flink die Verwendung eines Snapshots, der mit einer entsprechenden oder früheren Version für das Downgrade erstellt wurde
- Wenn Sie Ihre Runtime von Flink 1.13 oder höher auf Flink 1.11 oder früher aktualisieren und Ihre App das HashMap State-Backend verwendet, schlägt Ihre Anwendung kontinuierlich fehl.

Implementieren Sie die Anwendungsskalierung in Managed Service für Apache Flink

Sie können die parallele Ausführung von Aufgaben und die Zuweisung von Ressourcen für Amazon Managed Service für Apache Flink konfigurieren, um die Skalierung zu implementieren. Informationen darüber, wie Apache Flink parallel Instanzen von Aufgaben plant, finden Sie unter <u>Parallele</u> Ausführung in der Apache Flink-Dokumentation.

Themen

- Konfigurieren Sie Anwendungsparallelität und KPU ParallelismPer
- Kinesis-Verarbeitungseinheiten zuweisen
- <u>Aktualisieren Sie die Parallelität Ihrer Anwendung</u>
- Verwenden Sie die automatische Skalierung in Managed Service für Apache Flink
- <u>Überlegungen zu maxParallelism</u>

Konfigurieren Sie Anwendungsparallelität und KPU ParallelismPer

Sie konfigurieren die parallele Ausführung der Aufgaben Ihrer mit Managed Service für Apache Flink erstellten Anwendung (wie das Lesen aus einer Quelle oder das Ausführen eines Operators) mithilfe der folgenden <u>ParallelismConfiguration</u>-Eigenschaften:

- Parallelism Verwenden Sie diese Eigenschaft, um die Standardparallelität der Apache-Flink-Anwendung festzulegen. Alle Operatoren, Quellen und Senken werden mit dieser Parallelität ausgeführt, sofern sie nicht im Anwendungscode überschrieben werden. Der Standardwert beträgt 1; der voreingestellte Maximalwert beträgt 256.
- ParallelismPerKPU Verwenden Sie diese Eigenschaft, um die Anzahl der parallelen Aufgaben festzulegen, die pro Kinesis Processing Unit (KPU) Ihrer Anwendung geplant werden können. Der Standardwert ist 1 und der Maximalwert ist 8. Bei Anwendungen mit blockierenden Vorgängen (z. B. E/A) führt ein höherer ParallelismPerKPU-Wert zu einer Vollauslastung der KPU-Ressourcen.

Note

Der Grenzwert für Parallelism entspricht dem ParallelismPerKPU Mehrfachen des Grenzwerts für KPUs (der standardmäßig 64 ist). Das KPUs Limit kann erhöht werden, indem eine Erhöhung des Limits beantragt wird. Anweisungen zum Anfordern einer Erhöhung dieses Grenzwerts finden Sie unter "So fordern Sie eine Erhöhung des Grenzwerts an" unter <u>Service Quotas</u>.

Informationen zum Einstellen der Aufgabenparallelität für einen bestimmten Operator finden Sie unter <u>Setting the Parallelism: Operator</u> in der Apache Flink-Dokumentation.

Kinesis-Verarbeitungseinheiten zuweisen

Managed Service für Apache Flink stellt Kapazität bereit als. KPUs Eine einzelne KPU bietet Ihnen 1 vCPU und 4 GB Arbeitsspeicher. Für jede zugewiesene KPU werden außerdem 50 GB Speicher für laufende Anwendungen bereitgestellt.

Managed Service for Apache Flink berechnet KPUs die für die Ausführung Ihrer Anwendung erforderlichen Werte anhand der ParallelismPerKPU Eigenschaften Parallelism und wie folgt:

Allocated KPUs for the application = Parallelism/ParallelismPerKPU

Managed Service für Apache Flink stellt Ihren Anwendungen schnell Ressourcen zur Verfügung, um auf Spitzen im Durchsatz oder bei der Verarbeitungsaktivität zu reagieren. Es entfernt Ressourcen schrittweise aus Ihrer Anwendung, nachdem die Aktivitätsspitze vorüber ist. Um die automatische Zuweisung von Ressourcen zu deaktivieren, setzen Sie den Wert von AutoScalingEnabled auf false, wie weiter unten unter <u>Aktualisieren Sie die Parallelität</u> Ihrer Anwendung beschrieben.

Das Standardlimit KPUs für Ihre Anwendung ist 64. Anweisungen zum Anfordern einer Erhöhung dieses Grenzwerts finden Sie unter "So fordern Sie eine Erhöhung des Grenzwerts an" unter <u>Service</u> <u>Quotas</u>.

Note

Für Orchestrierungszwecke wird eine zusätzliche KPU berechnet. Weitere Informationen finden Sie unter Managed Service für Apache Flink – Preise.

Aktualisieren Sie die Parallelität Ihrer Anwendung

Dieser Abschnitt enthält Beispielanfragen für API-Aktionen, die die Parallelität einer Anwendung festlegen. Weitere Beispiele und Anweisungen zur Verwendung von Anforderungsblöcken mit API-Aktionen finden Sie unter <u>Beispielcode für Managed Service für Apache Flink API</u>.

Die folgende Beispielanforderung für die <u>CreateApplication</u>-Aktion legt die Parallelität fest, wenn Sie eine Anwendung erstellen:

```
{
    "ApplicationName": "string",
    "RuntimeEnvironment":"FLINK-1_18",
    "ServiceExecutionRole":"arn:aws:iam::123456789123:role/myrole",
```

```
"ApplicationConfiguration": {
      "ApplicationCodeConfiguration":{
      "CodeContent":{
         "S3ContentLocation":{
            "BucketARN": "arn: aws: s3::: amzn-s3-demo-bucket",
            "FileKey":"myflink.jar",
            "ObjectVersion": "AbCdEfGhIjKlMnOpQrStUvWxYz12345"
            }
         },
      "CodeContentType":"ZIPFILE"
   },
      "FlinkApplicationConfiguration": {
         "ParallelismConfiguration": {
            "AutoScalingEnabled": "true",
            "ConfigurationType": "CUSTOM",
            "Parallelism": 4,
            "ParallelismPerKPU": 4
         }
      }
   }
}
```

Die folgende Beispielanforderung für die <u>UpdateApplication</u>-Aktion legt die Parallelität für eine bestehende Anwendung fest:

Die folgende Beispielanforderung für die <u>UpdateApplication</u>-Aktion deaktiviert die Parallelität für eine bestehende Anwendung:

Verwenden Sie die automatische Skalierung in Managed Service für Apache Flink

Managed Service für Apache Flink skaliert die Parallelität Ihrer Anwendung elastisch, um dem Datendurchsatz Ihrer Quelle und der Komplexität Ihres Operators in den meisten Szenarien Rechnung zu tragen. Die automatische Skalierung ist standardmäßig aktiviert. Managed Service für Apache Flink überwacht die Ressourcenauslastung (CPU-Auslastung) Ihrer Anwendung und skaliert die Parallelität Ihrer Anwendung entsprechend elastisch nach oben oder unten:

- Ihre Anwendung containerCPUUtilization wird skaliert (erhöht die Parallelität), wenn das CloudWatch metrische Maximum 15 Minuten lang mehr als 75 Prozent oder mehr beträgt. Das bedeutet, dass die ScaleUp Aktion ausgelöst wird, wenn es 15 aufeinanderfolgende Datenpunkte mit einem Zeitraum von 1 Minute gibt, der 75 Prozent oder mehr entspricht. Eine ScaleUp Aktion verdoppelt den Wert Ihrer AnwendungCurrentParallelism. ParallelismPerKPUwird nicht geändert. Infolgedessen verdoppelt sich KPUs auch die Anzahl der zugewiesenen Personen.
- Ihre Anwendung wird herunterskaliert (Parallelität wird verringert), wenn die CPU-Auslastung sechs Stunden lang unter 10 Prozent bleibt. Das bedeutet, dass die ScaleDown Aktion ausgelöst wird, wenn 360 aufeinanderfolgende Datenpunkte mit einem Zeitraum von 1 Minute weniger als 10 Prozent vorhanden sind. Eine ScaleDown Aktion halbiert (aufgerundet) die Parallelität der Anwendung. ParallelismPerKPUwird nicht verändert, und die Anzahl der zugewiesenen Personen halbiert sich KPUs ebenfalls (aufgerundet).

Note

Es kann auf ein Maximum von containerCPUUtilization mehr als 1 Minute verwiesen werden, um die Korrelation mit einem Datenpunkt zu ermitteln, der für die Skalierungsaktion verwendet wird. Es ist jedoch nicht erforderlich, den genauen Zeitpunkt wiederzugeben, zu dem die Aktion initialisiert wird.

Managed Service für Apache Flink reduziert den CurrentParallelism-Wert Ihrer Anwendung nicht auf weniger als die Parallelism-Einstellung Ihrer Anwendung.

Wenn der Service von Managed Service für Apache Flink Ihre Anwendung skaliert, befindet er sich im Status AUTOSCALING. Sie können Ihren aktuellen Anwendungsstatus mithilfe der <u>DescribeApplication</u>Aktionen oder überprüfen. <u>ListApplications</u> Während der Service Ihre Anwendung skaliert, können Sie die einzige gültige API-Aktion verwenden, wenn der Force Parameter auf gesetzt ist <u>StopApplicationtrue</u>.

Sie können die Eigenschaft AutoScalingEnabled (Teil von <u>FlinkApplicationConfiguration</u>) verwenden, um das Auto-Scaling-Verhalten zu aktivieren oder zu deaktivieren. Ihr AWS Konto wird für KPUs die Bereitstellung von Managed Service for Apache Flink belastet, was von Ihren Anwendungen parallelism und parallelismPerKPU Einstellungen abhängt. Eine Aktivitätsspitze erhöht Ihre Kosten für Managed Service für Apache Flink.

Weitere Informationen finden Sie unter Amazon Managed Service für Apache Flink – Preise.

Beachten Sie Folgendes im Zusammenhang mit der Anwendungsskalierung:

- Die automatische Skalierung ist standardmäßig aktiviert.
- Skalierung gilt nicht für Studio-Notebooks. Wenn Sie ein Studio-Notebook jedoch als Anwendung mit dauerhaftem Zustand bereitstellen, gilt die Skalierung für die bereitgestellte Anwendung.
- Ihre Anwendung hat ein Standardlimit von KPUs 64. Weitere Informationen finden Sie unter Managed Service für Apache Flink und Studio Notebook-Kontingent.
- Wenn Auto Scaling die Anwendungsparallelität aktualisiert, kommt es bei der Anwendung zu Ausfallzeiten. Gehen Sie wie folgt vor, um diese Ausfallzeit zu vermeiden:
 - Deaktivieren der automatischen Skalierung
 - Konfigurieren Sie das parallelism und parallelismPerKPU mit der UpdateApplicationAktion Ihrer Anwendung. Weitere Informationen zum Festlegen der

Parallelitätseinstellungen Ihrer Anwendung finden Sie unter. <u>the section called "Aktualisieren Sie</u> die Parallelität Ihrer Anwendung"

 Überwachen Sie regelmäßig den Ressourcenverbrauch Ihrer Anwendung, um sicherzustellen, dass Ihre Anwendung über die richtigen Parallelitätseinstellungen für ihren Workload verfügt.
 Weitere Informationen über die Überwachung des Ressourcenverbrauchs finden Sie unter <u>the</u> section called "Metriken und Dimensionen in Managed Service für Apache Flink".

Implementieren Sie benutzerdefiniertes Autoscaling

Wenn Sie eine genauere Kontrolle über die automatische Skalierung wünschen oder andere Trigger-Metriken als verwenden möchtencontainerCPUUtilization, können Sie dieses Beispiel verwenden:

AutoScaling

Dieses Beispiel zeigt, wie Sie Ihre Managed Service for Apache Flink-Anwendung mithilfe einer anderen CloudWatch Metrik als der Apache Flink-Anwendung skalieren können, einschließlich Metriken aus Amazon MSK und Amazon Kinesis Data Streams, die als Quellen oder Senken verwendet werden.

Weitere Informationen finden Sie unter Verbesserte Überwachung und automatische Skalierung für Apache Flink.

Implementieren Sie die geplante automatische Skalierung

Wenn Ihre Arbeitslast im Laufe der Zeit einem vorhersehbaren Profil folgt, ziehen Sie es möglicherweise vor, Ihre Apache Flink-Anwendung präventiv zu skalieren. Dadurch wird Ihre Anwendung zu einem geplanten Zeitpunkt skaliert, anstatt reaktiv auf der Grundlage einer Metrik zu skalieren. Um das Hoch- und Herunterskalieren zu festen Tageszeiten einzurichten, können Sie dieses Beispiel verwenden:

<u>ScheduledScaling</u>

Überlegungen zu maxParallelism

Die maximale Parallelität, die ein Flink-Job skalieren kann, ist durch das Minimum maxParallelism für alle Operatoren des Jobs begrenzt. Wenn Sie beispielsweise einen einfachen Job mit nur einer

Quelle und einer Senke haben und die Quelle einen Wert maxParallelism von 16 und die Senke einen Wert von 8 hat, kann die Anwendung nicht über die Parallelität 8 hinaus skalieren.

Informationen darüber, wie die Standardeinstellung maxParallelism eines Operators berechnet wird und wie Sie die Standardeinstellung überschreiben können, finden Sie unter <u>Setting the</u> Maximum Parallelism in der Apache Flink-Dokumentation.

Als Grundregel gilt: Wenn Sie maxParallelism für keinen Operator definieren und Ihre Anwendung mit einer Parallelität von weniger als oder gleich 128 starten, haben alle Operatoren einen Wert von 128. maxParallelism

Note

Die maximale Parallelität des Jobs ist die Obergrenze der Parallelität für die Skalierung Ihrer Anwendung unter Beibehaltung des Status.

Wenn Sie eine bestehende Anwendung ändern, kann die Anwendung nicht maxParallelism von einem früheren Snapshot aus neu gestartet werden, der mit der alten erstellt wurde. maxParallelism Sie können die Anwendung nur ohne Snapshot neu starten.

Wenn Sie planen, Ihre Anwendung auf eine Parallelität von mehr als 128 zu skalieren, müssen Sie dies maxParallelism in Ihrer Anwendung explizit festlegen.

- Die Autoscaling-Logik verhindert, dass ein Flink-Job auf eine Parallelität skaliert wird, die die maximale Parallelität des Jobs überschreitet.
- Wenn Sie eine benutzerdefinierte automatische Skalierung oder eine geplante Skalierung verwenden, konfigurieren Sie sie so, dass sie die maximale Parallelität des Jobs nicht überschreiten.
- Wenn Sie Ihre Anwendung manuell über die maximale Parallelität hinaus skalieren, kann die Anwendung nicht gestartet werden.

Hinzufügen von Tags zu Managed Service für Apache Flink-Anwendungen

In diesem Abschnitt wird beschrieben, wie Sie Schlüssel-Wert-Metadaten-Tags zu Anwendungen, die Managed Service für Apache Flink nutzen, hinzufügen. Diese Tags können für die folgenden Zwecke verwendet werden:

- Festlegen der Abrechnung f
 ür einzelne Anwendungen, die Managed Service f
 ür Apache Flink nutzen. Weitere Informationen finden Sie unter <u>Verwendung von Kostenzuordnungs-Tags</u> im Benutzerhandbuch Fakturierungs- und Kostenverwaltung.
- Steuern des Zugriffs auf Anwendungsressourcen basierend auf Tags. Weitere Informationen finden Sie unter <u>Zugriffssteuerung mit Tags</u> im AWS Identity and Access Management Benutzerhandbuch.
- Benutzerdefinierte Zwecke. Sie können die Anwendungsfunktionalität basierend auf dem Vorhandensein von Benutzer-Tags definieren.

Bitte beachten Sie die folgenden Informationen über Tagging:

- Die maximale Anzahl an Anwendungs-Tags enthält System-Tags. Die maximale Anzahl an benutzerdefinierten Anwendungs-Tags ist 50.
- Wenn eine Aktion eine Tag-Liste beinhaltet, die doppelte Key-Werte enthält, löst der Service eine InvalidArgumentException aus.

Dieses Thema enthält die folgenden Abschnitte:

- Fügen Sie Tags hinzu, wenn eine Anwendung erstellt wird
- Fügen Sie Tags für eine bestehende Anwendung hinzu oder aktualisieren Sie sie
- Tags für eine Anwendung auflisten
- Entfernen Sie Tags aus einer Anwendung

Fügen Sie Tags hinzu, wenn eine Anwendung erstellt wird

Sie fügen Tags hinzu, wenn Sie eine Anwendung mithilfe des tags CreateApplicationAktionsparameters erstellen.

Das folgende Beispiel zeigt den Tags-Knoten für eine CreateApplication-Anforderung:

"Tags": [{

```
"Key": "Key1",
    "Value": "Value1"
},
{
    Key": "Key2",
    "Value": "Value2"
}
```

Fügen Sie Tags für eine bestehende Anwendung hinzu oder aktualisieren Sie sie

Mithilfe der <u>TagResource</u>Aktion fügen Sie einer Anwendung Tags hinzu. Mithilfe der <u>UpdateApplication</u>Aktion können Sie einer Anwendung keine Tags hinzufügen.

Fügen Sie zum Aktualisieren eines vorhandenen Tags ein Tag mit demselben Schlüssel wie das vorhandene Tag hinzu.

In der folgenden Beispiel-Anfrage für die AktionTagResource werden neue Tags hinzugefügt oder vorhandene Tags aktualisiert:

```
{
    "ResourceARN": "string",
    "Tags": [
        {
            "Key": "NewTagKey",
            "Value": "NewTagValue"
        },
        {
            "Key": "ExistingKeyOfTagToUpdate",
            "Value": "NewValueForExistingTag"
        }
    ]
}
```

Tags für eine Anwendung auflisten

Um vorhandene Tags aufzulisten, verwenden Sie die ListTagsForResourceAktion.

In der folgenden Beispiel-Anfrage für die Aktion ListTagsForResource werden Tags für eine Anwendung aufgelistet:

```
{
    "ResourceARN": "arn:aws:kinesisanalyticsus-west-2:012345678901:application/
MyApplication"
}
```

Entfernen Sie Tags aus einer Anwendung

Um Tags aus einer Anwendung zu entfernen, verwenden Sie die UntagResourceAktion.

In der folgenden Beispiel-Anfrage für die Aktion UntagResource werden Tags aus einer Anwendung entfernt:

```
{
    "ResourceARN": "arn:aws:kinesisanalyticsus-west-2:012345678901:application/
MyApplication",
    "TagKeys": [ "KeyOfFirstTagToRemove", "KeyOfSecondTagToRemove" ]
}
```

Verwendung CloudFormation mit Managed Service für Apache Flink

Die folgende Übung zeigt, wie Sie eine Flink-Anwendung starten, die AWS CloudFormation mit einer Lambda-Funktion im selben Stack erstellt wurde.

Bevor Sie beginnen

Bevor Sie mit dieser Übung beginnen, folgen Sie den Schritten zum Erstellen einer Flink-Anwendung mithilfe von at. AWS CloudFormation AWS::KinesisAnalytics::Application

Schreiben Sie eine Lambda-Funktion

Um eine Flink-Anwendung nach der Erstellung oder Aktualisierung zu starten, verwenden wir die kinesisanalyticsv2 <u>start-application</u> API. Der Aufruf wird durch ein AWS CloudFormation Ereignis nach der Erstellung der Flink-Anwendung ausgelöst. Wir werden später in dieser Übung besprechen, wie der Stack so eingerichtet wird, dass er die Lambda-Funktion auslöst, aber zuerst konzentrieren wir uns auf die Lambda-Funktionsdeklaration und ihren Code. In diesem Beispiel verwenden wir die Python3.8-Laufzeit.

```
StartApplicationLambda:
```

```
Type: AWS::Lambda::Function
   DependsOn: StartApplicationLambdaRole
   Properties:
     Description: Starts an application when invoked.
     Runtime: python3.8
     Role: !GetAtt StartApplicationLambdaRole.Arn
     Handler: index.lambda_handler
     Timeout: 30
     Code:
        ZipFile: |
          import logging
         import cfnresponse
         import boto3
         logger = logging.getLogger()
         logger.setLevel(logging.INF0)
         def lambda_handler(event, context):
            logger.info('Incoming CFN event {}'.format(event))
           try:
              application_name = event['ResourceProperties']['ApplicationName']
              # filter out events other than Create or Update,
              # you can also omit Update in order to start an application on Create
only.
             if event['RequestType'] not in ["Create", "Update"]:
                logger.info('No-op for Application {} because CFN RequestType {} is
filtered'.format(application_name, event['RequestType']))
                cfnresponse.send(event, context, cfnresponse.SUCCESS, {})
                return
              # use kinesisanalyticsv2 API to start an application.
              client_kda = boto3.client('kinesisanalyticsv2',
region_name=event['ResourceProperties']['Region'])
              # get application status.
              describe_response =
client_kda.describe_application(ApplicationName=application_name)
              application_status = describe_response['ApplicationDetail']
['ApplicationStatus']
              # an application can be started from 'READY' status only.
```

```
if application_status != 'READY':
               logger.info('No-op for Application {} because ApplicationStatus {} is
filtered'.format(application_name, application_status))
               cfnresponse.send(event, context, cfnresponse.SUCCESS, {})
               return
             # create RunConfiguration.
             run_configuration = {
               'ApplicationRestoreConfiguration': {
                 'ApplicationRestoreType': 'RESTORE_FROM_LATEST_SNAPSHOT',
               }
             }
             logger.info('RunConfiguration for Application {}:
{}'.format(application_name, run_configuration))
             # this call doesn't wait for an application to transfer to 'RUNNING'
state.
             client_kda.start_application(ApplicationName=application_name,
RunConfiguration=run_configuration)
             logger.info('Started Application: {}'.format(application_name))
             cfnresponse.send(event, context, cfnresponse.SUCCESS, {})
           except Exception as err:
             logger.error(err)
             cfnresponse.send(event,context, cfnresponse.FAILED, {"Data": str(err)})
```

Im vorherigen Code verarbeitet Lambda eingehende AWS CloudFormation Ereignisse, filtert alles andere heraus Create und ruft den Anwendungsstatus ab und startet ihnUpdate, falls der Status vorhanden istREADY. Um den Anwendungsstatus abzurufen, müssen Sie die Lambda-Rolle erstellen, wie im Folgenden gezeigt.

Eine Lambda-Rolle erstellen

Sie erstellen eine Rolle für Lambda, um erfolgreich mit der Anwendung zu kommunizieren und Protokolle zu schreiben. Diese Rolle verwendet standardmäßig verwaltete Richtlinien, aber Sie sollten sie möglicherweise auf die Verwendung benutzerdefinierter Richtlinien einschränken.

```
StartApplicationLambdaRole:
    Type: AWS::IAM::Role
    DependsOn: TestFlinkApplication
```

```
Properties:
Description: A role for lambda to use while interacting with an application.
AssumeRolePolicyDocument:
Version: '2012-10-17'
Statement:
- Effect: Allow
Principal:
Service:
- lambda.amazonaws.com
Action:
- sts:AssumeRole
ManagedPolicyArns:
- arn:aws:iam::aws:policy/Amazonmanaged-flinkFullAccess
- arn:aws:iam::aws:policy/CloudWatchLogsFullAccess
Path: /
```

Beachten Sie, dass die Lambda-Ressourcen nach der Erstellung der Flink-Anwendung im selben Stack erstellt werden, da sie davon abhängen.

Aufrufen der Lambda-Funktion

Jetzt müssen Sie nur noch die Lambda-Funktion aufrufen. Sie tun dies, indem Sie eine benutzerdefinierte Ressource verwenden.

```
StartApplicationLambdaInvoke:
    Description: Invokes StartApplicationLambda to start an application.
    Type: AWS::CloudFormation::CustomResource
    DependsOn: StartApplicationLambda
    Version: "1.0"
    Properties:
        ServiceToken: !GetAtt StartApplicationLambda.Arn
        Region: !Ref AWS::Region
        ApplicationName: !Ref TestFlinkApplication
```

Das ist alles, was Sie benötigen, um Ihre Flink-Anwendung mit Lambda zu starten. Sie sind jetzt bereit, Ihren eigenen Stack zu erstellen oder anhand des vollständigen Beispiels unten zu sehen, wie all diese Schritte in der Praxis funktionieren.

Sehen Sie sich ein erweitertes Beispiel an

Das folgende Beispiel ist eine leicht erweiterte Version der vorherigen Schritte mit einer zusätzlichen RunConfiguration Anpassung über <u>Vorlagenparameter</u>. Dies ist ein funktionierender Stack, den Sie ausprobieren können. Lesen Sie unbedingt die beigefügten Hinweise:

stack.yaml

```
Description: 'kinesisanalyticsv2 CloudFormation Test Application'
Parameters:
  ApplicationRestoreType:
    Description: ApplicationRestoreConfiguration option, can
 be SKIP_RESTORE_FROM_SNAPSHOT, RESTORE_FROM_LATEST_SNAPSHOT or
 RESTORE_FROM_CUSTOM_SNAPSHOT.
    Type: String
    Default: SKIP_RESTORE_FROM_SNAPSHOT
    AllowedValues: [ SKIP_RESTORE_FROM_SNAPSHOT, RESTORE_FROM_LATEST_SNAPSHOT,
 RESTORE_FROM_CUSTOM_SNAPSHOT ]
  SnapshotName:
    Description: ApplicationRestoreConfiguration option, name of a snapshot to restore
 to, used with RESTORE_FROM_CUSTOM_SNAPSHOT ApplicationRestoreType.
    Type: String
    Default: ''
  AllowNonRestoredState:
    Description: FlinkRunConfiguration option, can be true or false.
    Default: true
    Type: String
    AllowedValues: [ true, false ]
  CodeContentBucketArn:
    Description: ARN of a bucket with application code.
    Type: String
  CodeContentFileKey:
    Description: A jar filename with an application code inside a bucket.
    Type: String
Conditions:
  IsSnapshotNameEmpty: !Equals [ !Ref SnapshotName, '' ]
Resources:
  TestServiceExecutionRole:
    Type: AWS::IAM::Role
    Properties:
      AssumeRolePolicyDocument:
        Version: '2012-10-17'
        Statement:
```

```
- Effect: Allow
          Principal:
            Service:
              - kinesisanlaytics.amazonaws.com
          Action: sts:AssumeRole
    ManagedPolicyArns:
      - arn:aws:iam::aws:policy/AmazonKinesisFullAccess
      - arn:aws:iam::aws:policy/AmazonS3FullAccess
    Path: /
InputKinesisStream:
  Type: AWS::Kinesis::Stream
  Properties:
    ShardCount: 1
OutputKinesisStream:
  Type: AWS::Kinesis::Stream
  Properties:
    ShardCount: 1
TestFlinkApplication:
  Type: 'AWS::kinesisanalyticsv2::Application'
  Properties:
    ApplicationName: 'CFNTestFlinkApplication'
    ApplicationDescription: 'Test Flink Application'
    RuntimeEnvironment: 'FLINK-1_18'
    ServiceExecutionRole: !GetAtt TestServiceExecutionRole.Arn
    ApplicationConfiguration:
      EnvironmentProperties:
        PropertyGroups:
          - PropertyGroupId: 'KinesisStreams'
            PropertyMap:
              INPUT_STREAM_NAME: !Ref InputKinesisStream
              OUTPUT_STREAM_NAME: !Ref OutputKinesisStream
              AWS_REGION: !Ref AWS::Region
      FlinkApplicationConfiguration:
        CheckpointConfiguration:
          ConfigurationType: 'CUSTOM'
          CheckpointingEnabled: True
          CheckpointInterval: 1500
          MinPauseBetweenCheckpoints: 500
        MonitoringConfiguration:
          ConfigurationType: 'CUSTOM'
          MetricsLevel: 'APPLICATION'
          LogLevel: 'INFO'
        ParallelismConfiguration:
          ConfigurationType: 'CUSTOM'
```

Managed Service für Apache Flink

```
Parallelism: 1
          ParallelismPerKPU: 1
          AutoScalingEnabled: True
      ApplicationSnapshotConfiguration:
        SnapshotsEnabled: True
      ApplicationCodeConfiguration:
        CodeContent:
          S3ContentLocation:
            BucketARN: !Ref CodeContentBucketArn
            FileKey: !Ref CodeContentFileKey
        CodeContentType: 'ZIPFILE'
StartApplicationLambdaRole:
  Type: AWS::IAM::Role
  DependsOn: TestFlinkApplication
  Properties:
    Description: A role for lambda to use while interacting with an application.
    AssumeRolePolicyDocument:
      Version: '2012-10-17'
      Statement:
        - Effect: Allow
          Principal:
            Service:
              - lambda.amazonaws.com
          Action:
            - sts:AssumeRole
    ManagedPolicyArns:
      - arn:aws:iam::aws:policy/Amazonmanaged-flinkFullAccess
      - arn:aws:iam::aws:policy/CloudWatchLogsFullAccess
    Path: /
StartApplicationLambda:
  Type: AWS::Lambda::Function
  DependsOn: StartApplicationLambdaRole
  Properties:
    Description: Starts an application when invoked.
    Runtime: python3.8
    Role: !GetAtt StartApplicationLambdaRole.Arn
    Handler: index.lambda_handler
    Timeout: 30
    Code:
      ZipFile: |
        import logging
        import cfnresponse
        import boto3
```
```
logger = logging.getLogger()
          logger.setLevel(logging.INF0)
          def lambda_handler(event, context):
            logger.info('Incoming CFN event {}'.format(event))
            try:
              application_name = event['ResourceProperties']['ApplicationName']
              # filter out events other than Create or Update,
              # you can also omit Update in order to start an application on Create
only.
             if event['RequestType'] not in ["Create", "Update"]:
                logger.info('No-op for Application {} because CFN RequestType {} is
filtered'.format(application_name, event['RequestType']))
                cfnresponse.send(event, context, cfnresponse.SUCCESS, {})
                return
              # use kinesisanalyticsv2 API to start an application.
              client_kda = boto3.client('kinesisanalyticsv2',
region_name=event['ResourceProperties']['Region'])
              # get application status.
              describe_response =
client_kda.describe_application(ApplicationName=application_name)
              application_status = describe_response['ApplicationDetail']
['ApplicationStatus']
              # an application can be started from 'READY' status only.
              if application_status != 'READY':
                logger.info('No-op for Application {} because ApplicationStatus {} is
filtered'.format(application_name, application_status))
                cfnresponse.send(event, context, cfnresponse.SUCCESS, {})
                return
              # create RunConfiguration from passed parameters.
              run_configuration = {
                'FlinkRunConfiguration': {
                  'AllowNonRestoredState': event['ResourceProperties']
['AllowNonRestoredState'] == 'true'
                },
                'ApplicationRestoreConfiguration': {
```

```
'ApplicationRestoreType': event['ResourceProperties']
['ApplicationRestoreType'],
                }
             }
              # add SnapshotName to RunConfiguration if specified.
              if event['ResourceProperties']['SnapshotName'] != '':
                run_configuration['ApplicationRestoreConfiguration']['SnapshotName'] =
event['ResourceProperties']['SnapshotName']
              logger.info('RunConfiguration for Application {}:
{}'.format(application_name, run_configuration))
              # this call doesn't wait for an application to transfer to 'RUNNING'
state.
              client_kda.start_application(ApplicationName=application_name,
RunConfiguration=run_configuration)
              logger.info('Started Application: {}'.format(application_name))
              cfnresponse.send(event, context, cfnresponse.SUCCESS, {})
            except Exception as err:
              logger.error(err)
              cfnresponse.send(event,context, cfnresponse.FAILED, {"Data": str(err)})
 StartApplicationLambdaInvoke:
    Description: Invokes StartApplicationLambda to start an application.
    Type: AWS::CloudFormation::CustomResource
    DependsOn: StartApplicationLambda
    Version: "1.0"
    Properties:
      ServiceToken: !GetAtt StartApplicationLambda.Arn
      Region: !Ref AWS::Region
     ApplicationName: !Ref TestFlinkApplication
     ApplicationRestoreType: !Ref ApplicationRestoreType
      SnapshotName: !Ref SnapshotName
      AllowNonRestoredState: !Ref AllowNonRestoredState
```

Auch hier sollten Sie ggf. die Rollen für Lambda sowie eine Anwendung selbst anpassen.

Vergessen Sie nicht, Ihre Parameter anzugeben, bevor Sie den obigen Stack erstellen.

parameters.json

```
{
    "ParameterKey": "CodeContentBucketArn",
    "ParameterValue": "YOUR_BUCKET_ARN"
  },
  {
    "ParameterKey": "CodeContentFileKey",
    "ParameterValue": "YOUR_JAR"
  },
  ſ
    "ParameterKey": "ApplicationRestoreType",
    "ParameterValue": "SKIP_RESTORE_FROM_SNAPSHOT"
  },
  {
    "ParameterKey": "AllowNonRestoredState",
    "ParameterValue": "true"
  }
]
```

Ersetzen Sie YOUR_BUCKET_ARN und YOUR_JAR durch Ihre spezifischen Anforderungen. Sie können dieser <u>Anleitung</u> folgen, um einen Amazon-S3-Bucket und ein Anwendungs-Jar zu erstellen.

Erstellen Sie nun den Stack (ersetzen Sie YOUR_REGION durch eine Region Ihrer Wahl, z. B. useast-1):

```
aws cloudformation create-stack --region YOUR_REGION --template-body "file://
stack.yaml" --parameters "file://parameters.json" --stack-name "TestManaged Service for
Apache FlinkStack" --capabilities CAPABILITY_NAMED_IAM
```

Sie können jetzt zu <u>https://console.aws.amazon.com/cloudformation</u> navigieren und sich den Fortschritt ansehen. Nach der Erstellung sollte Ihre Flink-Anwendung im Starting-Zustand angezeigt werden. Es kann einige Minuten dauern, bis es Running startet.

Weitere Informationen finden Sie hier:

- <u>Vier Möglichkeiten zum Abrufen beliebiger AWS Service-Eigenschaften mithilfe von AWS</u> CloudFormation (Teil 1 von 3).
- Exemplarische Vorgehensweise: Amazon Machine Image IDs nachschlagen.

Verwenden Sie das Apache Flink Dashboard mit Managed Service für Apache Flink

Sie können das Apache Flink-Dashboard Ihrer Anwendung verwenden, um den Zustand Ihres Managed Service für Apache Flink-Anwendung zu überwachen. Das Dashboard Ihrer Anwendung zeigt die folgenden Informationen an:

- Verwendete Ressourcen, einschließlich Task-Managern und Task-Slots.
- Informationen zu Jobs, einschließlich laufender, abgeschlossener, abgebrochener und fehlgeschlagener Jobs.

Informationen zu Apache Flink Task Managern, Task Slots und Jobs finden Sie unter <u>Apache Flink</u> Architektur auf der Apache Flink-Website.

Beachten Sie Folgendes zur Verwendung des Apache Flink-Dashboards mit Managed Service für Apache Flink-Anwendungen:

- Das Apache Flink Dashboard f
 ür Managed Service f
 ür Apache Flink-Anwendungen ist schreibgesch
 ützt. Sie k
 önnen mit dem Apache Flink Dashboard keine
 Änderungen an Ihrem Managed Service f
 ür Apache Flink-Anwendung vornehmen.
- Das Apache Flink Dashboard ist nicht mit Microsoft Internet Explorer kompatibel.

Greifen Sie auf das Apache Flink Dashboard Ihrer Anwendung zu

Sie können auf das Apache Flink-Dashboard Ihrer Anwendung entweder über den Managed Service für Apache Flink-Konsole zugreifen oder indem Sie über die CLI einen sicheren URL-Endpunkt anfordern.

Greifen Sie über die Managed Service for Apache Flink-Konsole auf das Apache Flink-Dashboard Ihrer Anwendung zu

Um von der Konsole aus auf das Apache Flink Dashboard Ihrer Anwendung zuzugreifen, wählen Sie Apache Flink Dashboard auf der Seite Ihrer Anwendung.

Note

Wenn Sie das Dashboard von dem Managed Service für Apache Flink-Konsole aus öffnen, ist die von der Konsole generierte URL 12 Stunden lang gültig.

Greifen Sie mit dem Managed Service für Apache Flink CLI auf das Apache Flink-Dashboard Ihrer Anwendung zu

Sie können den Managed Services für Apache Flink CLI verwenden, um eine URL für den Zugriff auf Ihr Anwendungs-Dashboard zu generieren. Die URL, die Sie generieren, ist für eine bestimmte Zeit gültig.

Note

Wenn Sie nicht innerhalb von drei Minuten auf die generierte URL zugreifen, ist sie nicht mehr gültig.

Sie generieren Ihre Dashboard-URL mithilfe der <u>CreateApplicationPresignedUrl</u>Aktion. Sie können die folgenden Werte für die Aktion angeben:

- Den Anwendungsnamen
- Die Zeit in Sekunden, über die hinweg wird die URL gültig sein
- Sie geben FLINK_DASHBOARD_URL als URL-Typ an.

Release-Versionen

Dieses Thema enthält Informationen zu den unterstützten Features und den empfohlenen Komponentenversionen für die einzelnen Versionen von Managed Service für Apache Flink.

Note

Wenn Sie eine veraltete Version von Apache Flink verwenden, empfehlen wir Ihnen, Ihre Anwendung mithilfe der <u>Verwenden Sie direkte Versionsupgrades für Apache Flink</u> Funktion in Managed Service for Apache Flink auf die neueste unterstützte Flink-Version zu aktualisieren.

Apache Flink-Version	Status — Amazon Managed Service für Apache Flink	Status — Apache Flink-Gemeinschaft	Link
1.20.0	Unterstützt	Unterstützt	Amazon Managed Service für Apache Flink 1.20
1.19.1	Unterstützt	Unterstützt	Amazon Managed Service für Apache Flink 1.19
1.18.1	Unterstützt	Unterstützt	Amazon Managed Service für Apache Flink 1.18
1.15.2	Unterstützt	Nicht unterstützt	Amazon Managed Service für Apache Flink 1.15
1.13.1	Unterstützt	Nicht unterstützt	Erste Schritte: Flink 1.13.2
1.11.1	Abwertend	Nicht unterstützt	Informationen zu früheren Versionen für

Apache Flink-Version	Status — Amazon Managed Service für Apache Flink	Status — Apache Flink-Gemeinschaft	Link
			Managed Service für Apache Flink(Diese Version wird ab Februar 2025 nicht mehr unterstützt)
1.8.2	Veraltet	Nicht unterstützt	Informationen zu früheren Versionen für Managed Service für Apache Flink(Diese Version wird ab Februar 2025 nicht mehr unterstützt)
1.6.2	Veraltet	Nicht unterstützt	Informationen zu früheren Versionen für Managed Service für Apache Flink(Diese Version wird ab Februar 2025 nicht mehr unterstützt)

Themen

- Amazon Managed Service für Apache Flink 1.20
- Amazon Managed Service für Apache Flink 1.19
- <u>Amazon Managed Service für Apache Flink 1.18</u>
- Amazon Managed Service für Apache Flink 1.15
- Informationen zu früheren Versionen für Managed Service für Apache Flink

Amazon Managed Service für Apache Flink 1.20

Managed Service für Apache Flink unterstützt jetzt Apache Flink Version 1.20.0. In diesem Abschnitt werden die wichtigsten neuen Funktionen und Änderungen vorgestellt, die mit der Unterstützung von Apache Flink 1.20.0 durch Managed Service for Apache Flink eingeführt wurden. Apache Flink 1.20 wird voraussichtlich die letzte Version der Version 1.x und eine Flink Long-Term Support (LTS) -Version sein. Weitere Informationen finden Sie unter <u>FLIP-458: Langfristiger Support für die</u> endgültige Version von Apache Flink 1.x Line.

Note

Wenn Sie eine frühere unterstützte Version von Apache Flink verwenden und Ihre vorhandenen Anwendungen auf Apache Flink 1.20.0 aktualisieren möchten, können Sie dazu direkte Apache Flink-Versionsupgrades verwenden. Weitere Informationen finden Sie unter <u>Verwenden Sie direkte Versionsupgrades für Apache Flink</u>. Mit direkten Versionsupgrades behalten Sie die Rückverfolgbarkeit von Anwendungen anhand eines einzigen ARN für alle Apache Flink-Versionen, einschließlich Snapshots, Logs, Metriken, Tags, Flink-Konfigurationen und mehr.

Unterstützte Features

Apache Flink 1.20.0 führt Verbesserungen im SQL- APIs, im und im Flink-Dashboard ein. DataStream APIs

Unterstützte Funktionen und zugehörige Dokumentation

Unterstützte Features	Beschreibung	Referenz zur Apache Flink- Dokumentation
Klausel DISTRIBUTED BY hinzufügen	Viele SQL-Engines machen die Konzepte von Partition ing Bucketing , oder verfügbarClustering . Flink 1.20 führt das Konzept von Bucketing to Flink ein.	FLIP-376: Klausel DISTRIBUT ED BY hinzugefügt

Unterstützte Features	Beschreibung	Referenz zur Apache Flink- Dokumentation
DataStream API: Support vollständige Partitionsverarbei tung	Flink 1.20 bietet integrierte Unterstützung für Aggregati onen von Streams ohne Schlüssel über die API. FullPartitionWindow	FLIP-380: Support die vollständige Partition sverarbeitung ohne Schlüssel DataStream
Zeigen Sie den Wert für Datenverzerrungen im Flink- Dashboard an	Das Flink 1.20-Dashboard zeigt jetzt Informationen zur Datenverzerrung an. Jeder Operator auf der Flink-Job graph-Benutzeroberfläche zeigt einen zusätzlichen Wert für Datenverzerrungen an.	<u>FLIP-418: Zeigt den Wert für</u> <u>Datenverzerrungen im Flink-</u> <u>Dashboard an</u>

Die Versionsdokumentation zu Apache Flink 1.20.0 finden Sie unter Apache Flink Documentation v1.20.0. Die Versionshinweise zu Flink 1.20 finden Sie unter Versionshinweise — Flink 1.20

Komponenten

Komponenten von Flink 1.20

Komponente	Version
Java	11 (empfohlen)
Python	3.11
Kinesis Data Analytics Flink Runtime () aws- kinesisanalytics-runtime	1.2.0
Konnektoren	Informationen zu verfügbaren Konnektoren finden Sie unter Apache Flink-Konnektoren.

Komponente	Version
Apache Beam (nur Beam-Anwendungen)	Es gibt keinen kompatiblen Apache Flink Runner für Flink 1.20. Weitere Informationen finden Sie unter <u>Flink-Versionskompatibilität</u> .

Bekannte Probleme

Apache Beam

Derzeit gibt es in Apache Beam keinen kompatiblen Apache Flink Runner für Flink 1.20. Weitere Informationen finden Sie unter Flink-Versionskompatibilität.

Amazon Managed Service für Apache Flink Studio

Amazon Managed Service for Apache Flink Studio verwendet Apache Zeppelin-Notebooks, um eine zentrale Benutzeroberfläche für die Entwicklung, das Debuggen von Code und die Ausführung von Apache Flink-Stream-Verarbeitungsanwendungen bereitzustellen. Für den Flink Interpreter von Zeppelin ist ein Upgrade erforderlich, um die Unterstützung von Flink 1.20 zu aktivieren. Diese Arbeit ist mit der Zeppelin-Community geplant. Wir werden diese Hinweise aktualisieren, sobald diese Arbeiten abgeschlossen sind. Sie können Flink 1.15 weiterhin mit Amazon Managed Service für Apache Flink Studio verwenden. Weitere Informationen finden Sie unter <u>Ein Studio-Notizbuch erstellen</u>.

Rückportierte Fehlerkorrekturen

Amazon Managed Service for Apache Flink portiert Korrekturen aus der Flink-Community für kritische Probleme zurück. Im Folgenden finden Sie eine Liste der Bugfixes, die wir zurückportiert haben:

Rückportierte Fehlerkorrekturen

Apache Flink JIRA-Link	Beschreibung
<u>FLINK-35886</u>	Mit diesem Fix wird ein Problem behoben, das dazu führte, dass Zeitüberschreitungen beim Leerlauf von Wasserzeichen falsch verbucht wurden, wenn eine Unteraufgabe gesperrt oder blockiert wurde.

Amazon Managed Service für Apache Flink 1.19

Managed Service für Apache Flink unterstützt jetzt Apache Flink Version 1.19.1. In diesem Abschnitt werden die wichtigsten neuen Funktionen und Änderungen vorgestellt, die mit der Unterstützung von Apache Flink 1.19.1 durch Managed Service for Apache Flink eingeführt wurden.

1 Note

Wenn Sie eine frühere unterstützte Version von Apache Flink verwenden und Ihre vorhandenen Anwendungen auf Apache Flink 1.19.1 aktualisieren möchten, können Sie dazu direkte Apache Flink-Versionsupgrades verwenden. Weitere Informationen finden Sie unter <u>Verwenden Sie direkte Versionsupgrades für Apache Flink</u>. Mit direkten Versionsupgrades behalten Sie die Rückverfolgbarkeit von Anwendungen anhand eines einzigen ARN für alle Apache Flink-Versionen, einschließlich Snapshots, Logs, Metriken, Tags, Flink-Konfigurationen und mehr.

Unterstützte Features

Apache Flink 1.19.1 führt Verbesserungen in der SQL-API ein, wie z. B. benannte Parameter, benutzerdefinierte Quellparallelität und unterschiedliche Status für verschiedene Flink-Operatoren. TTLs

Unterstützte Funktionen und zugehörige Dokumentation

Unterstützte Features	Beschreibung	Referenz zur Apache Flink- Dokumentation
SQL-API: Support Konfigura tion verschiedener Zustände TTLs mithilfe eines SQL-Hints	Benutzer können jetzt State- TTL für reguläre Stream-Jo ins und Gruppenaggregate konfigurieren.	FLIP-373: Konfiguration verschiedener Zustände TTLs mithilfe eines SQL-Hints
SQL-API: Support benannte Parameter für Funktionen und Aufrufprozeduren	Benutzer können jetzt benannte Parameter in Funktionen verwenden, anstatt sich auf die Reihenfolge der Parameter zu verlassen.	FLIP-378: Support benannte Parameter für Funktionen und Aufrufprozeduren

Managed Service für Apache Flink

Managed Service für Apache Flink Entwicklerleitfaden

Unterstützte Features	Beschreibung	Referenz zur Apache Flink- Dokumentation
SQL-API: Einstellung der Parallelität für SQL-Quellen	Benutzer können jetzt Paralleli tät für SQL-Quellen angeben.	FLIP-367: Support das Einstellen der Parallelität für Tabellen-/SQL-Quellen
SQL API: Support des Sitzungsfensters TVF	Benutzer können jetzt Tabellenwertfunktionen im Sitzungsfenster verwenden.	FLINK-24024: Unterstüt zungssitzung Window TVF
SQL-API: Die Fenster-T VF-Aggregation unterstützt Changelog-Eingaben	Benutzer können jetzt Fensteraggregation für Changelog-Eingaben durchführen.	FLINK-20281: Die Fensterag gregation unterstützt die Eingabe von Changelog- Streams
Support Sie Python 3.11	Flink unterstützt jetzt Python 3.11, was im Vergleich zu Python 3.10 10-60% schneller ist. Weitere Informationen finden Sie unter <u>Was ist neu in</u> <u>Python 3.11</u> .	FLINK-33030: Unterstützung für Python 3.11 hinzufügen
Stellen Sie Metriken für TwoPhaseCommitting Sink bereit	Benutzer können Statistik en über den Status von Committern in zwei Phasen der Committer-Senken einsehen.	FLIP-371: Stellen Sie den Initialisierungskontext für die Committer-Erstellung bereit in TwoPhaseCommittingSink

Unterstützte Features	Beschreibung	Referenz zur Apache Flink- Dokumentation
Trace-Reporter für Job-Neust art und Checkpointing	Benutzer können nun die Traces rund um die Dauer von Checkpoints und die Wiederherstellungstrends überwachen. In Amazon Managed Service für Apache Flink aktivieren wir standardm äßig Slf4j-Trace-Reporter, sodass Benutzer Checkpoin t- und Job-Traces anhand von Anwendungsprotokol len überwachen können. CloudWatch	FLIP-384: Führen Sie es ein TraceReporter und verwenden Sie es, um Checkpoint- und Wiederherstellungs-Traces zu erstellen

Note

Sie können sich für die folgenden Funktionen entscheiden, indem Sie eine Support-Anfrage einreichen:

Opt-in-Funktionen und zugehörige Dokumentation

Opt-in-Funktionen	Beschreibung	Referenz zur Apache Flink- Dokumentation
Support bei Verwendung eines größeren Checkpoint-Interva Ils, wenn die Quelle Backlog verarbeitet	Dies ist eine optionale Funktion, da Benutzer die Konfiguration an ihre spezifisc hen Jobanforderungen anpassen müssen.	FLIP-309: Support bei Verwendung eines größeren Checkpoint-Intervalls, wenn die Quelle Backlog verarbeitet
Leiten Sie System.out und System.err zu Java-Prot okollen um	Dies ist eine Opt-in-Funktion. Bei Amazon Managed Service für Apache Flink besteht das	FLIP-390: Das Unterstüt zungssystem ist ausgefallen

Opt-in-Funktionen	Beschreibung	Referenz zur Apache Flink- Dokumentation
	Standardverhalten darin, die Ausgabe von System.out und System.err zu ignorieren, da die beste Vorgehensweise in der Produktion darin besteht, den nativen Java-Logger zu verwenden.	und der Fehler wird zu LOG umgeleitet oder verworfen

Die Versionsdokumentation zu Apache Flink 1.19.1 finden Sie unter Apache Flink Documentation v1.19.1.

Änderungen in Amazon Managed Service für Apache Flink 1.19.1

Logging Trace Reporter ist standardmäßig aktiviert

Mit Apache Flink 1.19.1 wurden Checkpoint- und Recovery Traces eingeführt, sodass Benutzer Probleme mit Checkpoint- und Job Recovery besser debuggen können. In Amazon Managed Service für Apache Flink werden diese Traces im CloudWatch Protokollstream protokolliert, sodass Benutzer die für die Auftragsinitialisierung aufgewendete Zeit aufschlüsseln und die historische Größe von Checkpoints aufzeichnen können.

Die Standardstrategie für einen Neustart ist jetzt exponentielle Verzögerung

In Apache Flink 1.19.1 gibt es erhebliche Verbesserungen an der Neustartstrategie mit exponentieller Verzögerung. In Amazon Managed Service für Apache Flink ab Flink 1.19.1 verwenden Flink-Jobs standardmäßig die Neustartstrategie mit exponentieller Verzögerung. Das bedeutet, dass Benutzerjobs nach vorübergehenden Fehlern schneller wiederhergestellt werden, externe Systeme jedoch nicht überlastet werden, wenn die Jobs weiterhin neu gestartet werden.

Fehlerkorrekturen wurden zurückportiert

Amazon Managed Service for Apache Flink portiert Korrekturen aus der Flink-Community für kritische Probleme zurück. Das bedeutet, dass sich die Laufzeit von der Version Apache Flink 1.19.1 unterscheidet. Im Folgenden finden Sie eine Liste der Bugfixes, die wir zurückportiert haben:

Rückportierte Fehlerkorrekturen

Apache Flink JIRA-Link	Beschreibung
<u>FLINK-35531</u>	Dieser Fix behebt den in 1.17.0 eingeführ ten Leistungsrückgang, der zu langsameren Schreibvorgängen auf HDFS führt.
<u>FLINK-35157</u>	Dieser Fix behebt das Problem, dass Flink-Job s nicht mehr funktionieren, wenn Quellen mit Wasserzeichenausrichtung auf abgeschlossene Unteraufgaben stoßen.
FLINK-34252	Dieser Fix behebt das Problem bei der Generierung von Wasserzeichen, das zu einem fehlerhaften IDLE-Wasserzeichenstatus führt.
<u>FLINK-34252</u>	Mit diesem Fix wird der Leistungsrückgang bei der Generierung von Wasserzeichen behoben, indem die Anzahl von Systemaufrufen reduziert wird.
<u>FLINK-33936</u>	Dieser Fix behebt das Problem mit doppelten Datensätzen bei der Mini-Batch-Aggregation in der Tabellen-API.
<u>FLINK-35498</u>	Dieser Fix behebt das Problem mit Argumentn amenkonflikten bei der Definition benannter Parameter in der Tabellen-API. UDFs
<u>FLINK-33192</u>	Mit diesem Fix wird das Problem behoben, dass bei Fensteroperatoren aufgrund einer unsachgemäßen Timer-Bereinigung ein Speicherverlust aufgetreten ist.
FLINK-35069	Dieser Fix behebt das Problem, dass ein Flink- Job hängen bleibt und am Ende eines Fensters einen Timer auslöst.

Apache Flink JIRA-Link	Beschreibung
FLINK-35832	Dieser Fix behebt das Problem, wenn IFNULL falsche Ergebnisse zurückgibt.
<u>FLINK-35886</u>	Mit diesem Fix wird das Problem behoben, dass Aufgaben, bei denen ein Gegendruck entsteht, als inaktiv betrachtet werden.

Komponenten

Komponente	Version
Java	11 (empfohlen)
Python	3.11
Kinesis Data Analytics Flink Runtime () aws- kinesisanalytics-runtime	1.2.0
Konnektoren	Informationen zu verfügbaren Konnektoren finden Sie unter <u>Apache Flink-Konnektoren</u> .
Apache Beam (nur Beam-Anwendungen)	Ab Version 2.61.0. Weitere Informationen finden Sie unter Flink-Versionskompatibilität.

Bekannte Probleme

Amazon Managed Service für Apache Flink Studio

Studio verwendet Apache Zeppelin-Notebooks, um die Entwicklung, das Debuggen von Code und die Ausführung von Apache Flink-Stream-Verarbeitungsanwendungen über eine einzige Benutzeroberfläche zu ermöglichen. Für den Flink Interpreter von Zeppelin ist ein Upgrade erforderlich, um die Unterstützung von Flink 1.19 zu aktivieren. Diese Arbeit ist mit der Zeppelin-Community geplant und wir werden diese Hinweise aktualisieren, sobald sie abgeschlossen sind. Sie können Flink 1.15 weiterhin mit Amazon Managed Service für Apache Flink Studio verwenden. Weitere Informationen finden Sie unter Ein Studio-Notizbuch erstellen.

Amazon Managed Service für Apache Flink 1.18

Managed Service für Apache Flink unterstützt jetzt Apache Flink Version 1.18.1. Erfahren Sie mehr über die wichtigsten neuen Funktionen und Änderungen, die mit der Unterstützung von Apache Flink 1.18.1 durch Managed Service for Apache Flink eingeführt wurden.

Note

Wenn Sie eine frühere unterstützte Version von Apache Flink verwenden und Ihre vorhandenen Anwendungen auf Apache Flink 1.18.1 aktualisieren möchten, können Sie dazu direkte Apache Flink-Versionsupgrades verwenden. Mit direkten Versionsupgrades behalten Sie die Rückverfolgbarkeit von Anwendungen anhand eines einzigen ARN für alle Apache Flink-Versionen, einschließlich Snapshots, Logs, Metriken, Tags, Flink-Konfigurationen und mehr. Sie können diese Funktion in jedem beliebigen Bundesstaat verwenden. RUNNING READY Weitere Informationen finden Sie unter <u>Verwenden Sie direkte Versionsupgrades für Apache Flink</u>.

Unterstützte Funktionen	Beschreibung	Referenz zur Apache Flink- Dokumentation
Opensearch-Konnektor	Dieser Anschluss enthält eine Spüle, die at-least-once Garantien bietet.	github: Opensearch-Konnektor
Amazon DynamoDB DynamoDB-Konnektor	Dieser Anschluss enthält eine Senke, die Garantien bietet at- least-once.	Amazon DynamoDB-Senke
MongoDB-Anschluss	Dieser Konnektor umfasst eine Quelle und eine Senke, die at- least-once Garantien bieten.	MongoDB-Konnektor
Entkoppeln Sie Hive mit Flink Planner	Sie können den Hive-Dialekt direkt ohne zusätzlichen JAR- Swapping verwenden.	FLINK-26603: Entkoppeln Sie Hive mit dem Flink-Planer

Unterstützte Funktionen mit Referenzen zur Apache Flink-Dokumentation

Managed Service für Apache Flink

Managed Service für Apache Flink Entwicklerleitfaden

Unterstützte Funktionen	Beschreibung	Referenz zur Apache Flink- Dokumentation
Deaktiviere WAL in DBWrite BatchWrapper Rocks standardmäßig	Dies bietet schnellere Wiederherstellungszeiten.	FLINK-32326: WAL in Rocks standardmäßig deaktivieren DBWrite BatchWrapper
Verbessern Sie die Leistung der Wasserzeichen-Aggr egation, wenn Sie die Wasserzeichenausrichtung aktivieren	Verbessert die Leistung der Wasserzeichen-Aggregation, wenn die Wasserzeichenausri chtung aktiviert wird, und fügt den entsprechenden Benchmark hinzu.	FLINK-32524: Leistung der Wasserzeichen-Aggregation
Machen Sie die Ausrichtung von Wasserzeichen bereit für den Produktionseinsatz	Beseitigt das Risiko einer Überlastung großer Aufträge JobManager	FLINK-32548: Bereitet die Ausrichtung der Wasserzei chen vor
Konfigurierbar für RateLimit ingStratey Async Sink	RateLimitingStrategy ermöglicht es Ihnen, die Entscheidung darüber zu konfigurieren, was, wann und in welchem Umfang skaliert werden soll.	FLIP-242: Führen Sie konfiguri erbar RateLimitingStrategy für Async Sink ein
Tabellen- und Spaltenst atistiken in großen Mengen abrufen	Verbesserte Abfrageleistung.	FLIP-247: Massenabruf von Tabellen- und Spaltenst atistiken für bestimmte Partitionen

Die Dokumentation zur Veröffentlichung von Apache Flink 1.18.1 finden Sie in der Ankündigung der Veröffentlichung von Apache Flink 1.18.1.

Änderungen in Amazon Managed Service für Apache Flink mit Apache Flink 1.18

Akka wurde durch Pekko ersetzt

Apache Flink ersetzte Akka in Apache Flink 1.18 durch Pekko. Diese Änderung wird in Managed Service für Apache Flink ab Apache Flink 1.18.1 und höher vollständig unterstützt. Sie müssen Ihre Anwendungen aufgrund dieser Änderung nicht ändern. Weitere Informationen finden Sie unter FLINK-32468: Ersetzen Sie Akka durch Pekko.

Support PyFlink Runtime-Ausführung im Thread-Modus

Diese Apache Flink-Änderung führt einen neuen Ausführungsmodus für das Pyflink Runtime-Framework ein, den Prozessmodus. Der Prozessmodus kann jetzt benutzerdefinierte Python-Funktionen im selben Thread ausführen, anstatt in einem separaten Prozess.

Rückportierte Fehlerkorrekturen

Amazon Managed Service for Apache Flink portiert Korrekturen aus der Flink-Community für kritische Probleme zurück. Das bedeutet, dass sich die Laufzeit von der Version Apache Flink 1.18.1 unterscheidet. Im Folgenden finden Sie eine Liste der Bugfixes, die wir zurückportiert haben:

Rückportierte Fehlerkorrekturen

Apache Flink JIRA-Link	Beschreibung
FLINK-33863	Mit diesem Fix wird das Problem behoben, dass eine Statuswiederherstellung für komprimierte Snapshots fehlschlägt.
FLINK-34063	Dieser Fix behebt das Problem, dass Quell-Operatoren Splits verlieren, wenn die Snapshot-Komprimierung aktiviert ist. Apache Flink bietet optionale Komprimierung (Standardeinstellung: aus) für alle Checkpoin ts und Savepoints. Apache Flink identifiz ierte einen Fehler in Flink 1.18.1, bei dem der Operatorstatus nicht korrekt wiederher gestellt werden konnte, wenn die Snapshot- Komprimierung aktiviert war. Dies könnte entweder zu Datenverlust oder zur Unfähigke it der Wiederherstellung vom Checkpoint aus führen.

Apache Flink JIRA-Link	Beschreibung
<u>FLINK-35069</u>	Dieser Fix behebt das Problem, dass ein Flink- Job hängen bleibt und am Ende eines Fensters einen Timer auslöst.
<u>FLINK-35097</u>	Mit diesem Fix wird das Problem doppelter Datensätze in einem Tabellen-API-Datei system-Konnektor im Rohformat behoben.
<u>FLINK-34379</u>	Mit diesem Fix wird das Problem behoben, das OutOfMemoryError bei der Aktivierung der dynamischen Tabellenfilterung auftritt.
<u>FLINK-28693</u>	Mit diesem Fix wird das Problem behoben, dass die Tabellen-API kein Diagramm generieren kann, wenn das Wasserzeichen einen ColumnBy-Ausdruck enthält.
FLINK-35217	Dieser Fix behebt das Problem eines beschädigten Checkpoints während eines bestimmten Fehlermodus bei einem Flink-Job.

Komponenten

Komponente	Version
Java	11 (empfohlen)
Scala	Seit Version 1.15 ist Flink SCALA-agnostisch. Als Referenz wurde MSF Flink 1.18 gegen Scala 3.3 (LTS) verifiziert.
Verwalteter Dienst für Apache Flink Flink Runtime () aws-kinesisanalytics-runtime	1.2.0

Komponente	Version
AWS Kinesis Connector (flink-connector-k inesis) [Quelle]	4.2.0-1.18
AWS Kinesis-Anschluss (flink-connector-k inesis) [Senke]	4.2.0-1.18
Apache Beam (nur Beam-Anwendungen)	Ab Version 2.57.0. Weitere Informationen finden Sie unter Flink-Versionskompatibilität.

Bekannte Probleme

Amazon Managed Service für Apache Flink Studio

Studio verwendet Apache Zeppelin-Notebooks, um die Entwicklung, das Debuggen von Code und die Ausführung von Apache Flink-Stream-Verarbeitungsanwendungen über eine einzige Benutzeroberfläche zu ermöglichen. Für den Flink Interpreter von Zeppelin ist ein Upgrade erforderlich, um die Unterstützung von Flink 1.18 zu aktivieren. Diese Arbeit ist mit der Zeppelin-Community geplant und wir werden diese Hinweise aktualisieren, sobald sie abgeschlossen sind. Sie können Flink 1.15 weiterhin mit Amazon Managed Service für Apache Flink Studio verwenden. Weitere Informationen finden Sie unter Ein Studio-Notizbuch erstellen.

Falsches Leerlaufen des Wasserzeichens, wenn die Unteraufgabe mit einem Gegendruck belastet wird

Es gibt ein bekanntes Problem bei der Generierung von Wasserzeichen, wenn eine Unteraufgabe unter Druck gesetzt wird. Dieses Problem wurde ab Flink 1.19 und höher behoben. Dies kann sich in einem Anstieg der Anzahl verspäteter Datensätze zeigen, wenn ein Flink-Job-Diagramm unter Druck gesetzt wird. Wir empfehlen Ihnen, auf die neueste Flink-Version zu aktualisieren, um diesen Fix zu installieren. Weitere Informationen finden Sie unter <u>Fehlerhafte Abrechnung des Leerlaufzeitlimits für</u> Wasserzeichen, wenn die Unteraufgabe im Hintergrund steht/blockiert ist.

Amazon Managed Service für Apache Flink 1.15

Managed Service für Apache Flink unterstützt die folgenden neuen Funktionen in Apache 1.15.2:

Funktion	Beschreibung	Apache-FLIP-Referenz
Asynchrone Senke	Ein AWS unterstütztes Framework für die Erstellun g asynchroner Ziele, das es Entwicklern ermöglich t, benutzerdefinierte AWS Konnektoren mit weniger als der Hälfte des bisherige n Aufwands zu erstellen. Weitere Informationen finden Sie unter <u>Die generische</u> asynchrone Basissenke.	FLIP-171: Asynchrone Senke.
Kinesis Data Firehose Senke	AWS hat mithilfe des Async- Frameworks einen neuen Amazon Kinesis Firehose Sink beigesteuert.	Amazon Kinesis Data Firehose Senke.
Anhalten mit Savepoint	Anhalten mit Savepoint sorgt für einen sauberen Anhaltevo rgang und unterstützt vor allem die Exakt-einmal-Seman tik für Kunden, die sich darauf verlassen.	FLIP-34: Auftrag mit Savepoint beenden/aussetzen.
Scala-Entkopplung	Benutzer können die Java- API jetzt von jeder Scala-Ver sion aus nutzen, einschlie ßlich Scala 3. Kunden müssen die Scala-Standardbibliothek ihrer Wahl in ihren Scala-Anw endungen bündeln.	<u>FLIP-28: Langfristiges Ziel,</u> flink-table Scala-frei zu machen.
Scala	Siehe Scala-Entkopplung oben	FLIP-28: Langfristiges Ziel, flink-table Scala-frei zu machen.

Funktion	Beschreibung	Apache-FLIP-Referenz
Einheitliche Konnektor- Metriken	Flink hat <u>Standardmetriken</u> für Aufträge, Aufgaben und Operatoren definiert. Managed Service für Apache Flink wird weiterhin Senken- und Quell-Metriken unterstützen und in 1.15 numRestarts parallel zu fullRestarts für Verfügbarkeitsmetriken einführen.	FLIP-33: Konnektor-Metriken standardisieren und FLIP-179: Standardisierte Operator- Metriken verfügbar machen.
Checkpointing von abgeschlo ssenen Aufgaben	Dieses Feature ist in Flink 1.15 standardmäßig aktiviert und ermöglicht es, weiterhin Checkpoints durchzufü hren, auch wenn Teile des Auftragsdiagramms die Verarbeitung aller Daten abgeschlossen haben, was passieren kann, wenn er gebundene (Batch-)Quellen enthält.	<u>FLIP-147: Checkpoints nach</u> <u>Abschluss von Aufgaben</u> <u>unterstützen</u> .

Änderungen in Amazon Managed Service für Apache Flink mit Apache Flink 1.15

Studio-Notebooks

Managed Service für Apache Flink Studio unterstützt jetzt Apache Flink 1.15. Managed Service für Apache Flink Studio nutzt Apache-Zeppelin-Notebooks, um eine zentrale Benutzeroberfläche für die Entwicklung, das Debuggen von Code und die Ausführung von Apache-Flink-Streamverarbeitungsanwendungen bereitzustellen. Weitere Informationen über Managed Service für Apache Flink Studio und die ersten Schritte finden Sie unter <u>Verwenden Sie ein Studio-Notebook mit</u> Managed Service für Apache Flink.

EFO-Konnektor

Stellen Sie beim Upgrade auf Managed Service für Apache Flink Version 1.15 sicher, dass Sie den neuesten EFO-Konnektor verwenden, d. h. eine beliebige Version 1.15.3 oder neuer. Weitere Informationen zu den Gründen finden Sie unter FLINK-29324.

Scala-Entkopplung

Ab Flink 1.15.2 müssen Sie die Scala-Standardbibliothek Ihrer Wahl in Ihren Scala-Anwendungen bündeln.

Kinesis Data Firehose Senke

Stellen Sie beim Upgrade auf Managed Service für Apache Flink Version 1.15 sicher, dass Sie die neueste Amazon Kinesis Data Firehose Senke verwenden.

Kafka-Konnektoren

Stellen Sie beim Upgrade auf Amazon Managed Service for Apache Flink for Apache Flink Version 1.15 sicher, dass Sie den neuesten Kafka-Connector verwenden. APIs Apache Flink ist veraltet <u>FlinkKafkaConsumer</u>und <u>FlinkKafkaProducer</u>diese APIs für die Kafka-Senke können sich nicht auf Kafka für Flink 1.15 festlegen. Stellen Sie sicher, dass Sie KafkaSourceund KafkaSinkverwenden.

Komponenten

Komponente	Version
Java	11 (empfohlen)
Scala	2.12
Verwalteter Dienst für Apache Flink Flink Runtime () aws-kinesisanalytics-runtime	1.2.0
AWS Kinesis-Anschluss () flink-connector-ki nesis	1.15.4
Apache Beam (nur Beam-Anwendungen)	2.33.0, mit Jackson-Version 2.12.2

Bekannte Probleme

Kafka Commit beim Checkpointing schlägt nach einem Neustart des Brokers wiederholt fehl

Es gibt ein bekanntes Open-Source-Apache Flink-Problem mit dem Apache Kafka-Konnektor in Flink Version 1.15, das durch einen kritischen Open-Source-Fehler im Kafka-Client 2.8.1 verursacht wurde. Weitere Informationen finden Sie unter <u>Kafka Commit on Checkpointing schlägt nach einem Neustart</u> <u>des Brokers wiederholt fehl und kann die Verbindung zum Gruppenkoordinator nach einer</u> Ausnahme nicht KafkaConsumer wiederherstellen. commitOffsetAsync

Um dieses Problem zu vermeiden, empfehlen wir, Apache Flink 1.18 oder höher in Amazon Managed Service für Apache Flink zu verwenden.

Informationen zu früheren Versionen für Managed Service für Apache Flink

1 Note

Die Apache Flink-Versionen 1.6, 1.8 und 1.11 werden seit über drei Jahren nicht mehr von der Apache Flink-Community unterstützt. Wir planen nun, die Unterstützung für diese Versionen in Amazon Managed Service für Apache Flink zu beenden. Ab dem 5. November 2024 können Sie keine neuen Anwendungen für diese Flink-Versionen erstellen. Sie können bestehende Anwendungen derzeit weiter ausführen.

Für alle Regionen mit Ausnahme der Regionen China und der ab dem AWS GovCloud (US) Regions24. Februar 2025 können Sie keine Anwendungen mehr mit diesen Versionen von Apache Flink in Amazon Managed Service für Apache Flink erstellen, starten oder ausführen. Für die Regionen China und die AWS GovCloud (US) Regions ab dem 19. März 2025 können Sie mit diesen Versionen von Apache Flink in Amazon Managed Service für Apache Flink keine Anwendungen mehr erstellen, starten oder ausführen.

Mithilfe der Funktion für direkte Versionsupgrades in Managed Service für Apache Flink können Sie Ihre Anwendungen statusmäßig aktualisieren. Weitere Informationen finden Sie unter <u>Verwenden Sie direkte Versionsupgrades für Apache Flink</u>.

1 Note

Apache Flink Version 1.13 wird seit über drei Jahren nicht mehr von der Apache Flink-Community unterstützt. Wir planen nun, den Support für diese Version in Amazon Managed Service für Apache Flink am 16. Oktober 2025 einzustellen. Nach diesem Datum können Sie keine Anwendungen mehr mit Apache Flink Version 1.13 in Amazon Managed Service für Apache Flink erstellen, starten oder ausführen.

Mithilfe der Funktion für direkte Versionsupgrades in Managed Service for Apache Flink können Sie Ihre Anwendungen statusmäßig aktualisieren. Weitere Informationen finden Sie unter Verwenden Sie direkte Versionsupgrades für Apache Flink.

Version 1.15.2 wird von Managed Service für Apache Flink unterstützt, von der Apache Flink-Community jedoch nicht mehr unterstützt.

Dieses Thema enthält die folgenden Abschnitte:

- Verwenden des Apache Flink Kinesis Streams-Konnektor mit früheren Apache Flink-Versionen
- <u>Anwendungen mit Apache Flink 1.8.2 erstellen</u>
- Anwendungen mit Apache Flink 1.6.2 erstellen
- Aktualisieren von Anwendungen
- Verfügbare Konnektoren in Apache Flink 1.6.2 und 1.8.2
- Erste Schritte: Flink 1.13.2
- Erste Schritte: Flink 1.11.1 veraltet
- Erste Schritte: Flink 1.8.2 veraltet
- Erste Schritte: Flink 1.6.2 veraltet
- Beispiele für frühere Versionen (ältere Versionen) für Managed Service für Apache Flink

Verwenden des Apache Flink Kinesis Streams-Konnektor mit früheren Apache Flink-Versionen

Der Apache Flink Kinesis Streams-Konnektor war vor Version 1.11 nicht in Apache Flink enthalten. Damit Ihre Anwendung den Apache Flink Kinesis-Konnektor mit früheren Versionen von Apache Flink verwenden kann, müssen Sie die Version von Apache Flink, die Ihre Anwendung verwendet, herunterladen, kompilieren und installieren. Dieser Konnektor wird verwendet, um Daten aus einem Kinesis Stream zu konsumieren, der als Anwendungsquelle verwendet wird, oder um Daten in einen Kinesis Stream zu schreiben, der für die Anwendungsausgabe verwendet wird.

Note

Stellen Sie sicher, dass Sie den Konnektor mit <u>KPL-Version 0.14.0</u> oder höher erstellen.

Gehen Sie wie folgt vor, um den Quellcode von Apache Flink Version 1.8.2 herunterzuladen und zu installieren:

 Stellen Sie sicher, dass Sie <u>Apache Maven</u> installiert haben und dass Ihre JAVA_HOME Umgebungsvariable auf ein JDK und nicht auf eine JRE verweist. Sie können Ihre Apache Maven-Installation mit dem folgenden Befehl testen:

mvn -version

2. Laden Sie den Quellcode von Apache Flink Version 1.8.2 herunter:

wget https://archive.apache.org/dist/flink/flink-1.8.2/flink-1.8.2-src.tgz

3. Dekomprimieren Sie den Apache Flink-Quellcode:

tar -xvf flink-1.8.2-src.tgz

4. Wechseln Sie in das Apache Flink-Quellcodeverzeichnis:

cd flink-1.8.2

5. Kompilieren und installieren Sie Apache Flink:

mvn clean install -Pinclude-kinesis -DskipTests

Note

Wenn Sie Flink unter Microsoft Windows kompilieren, müssen Sie den -Drat.skip=true Parameter hinzufügen.

Anwendungen mit Apache Flink 1.8.2 erstellen

Dieser Abschnitt enthält Informationen über Komponenten, die Sie für die Erstellung von Managed Service für Apache Flink-Anwendungen verwenden, die mit Apache Flink 1.8.2 funktionieren.

Verwenden Sie die folgenden Komponentenversionen für Managed Service für Apache Flink-Anwendungen:

Komponente	Version
Java	1.8 (empfohlen)
Apache Flink	1.8.2
Managed Service für Apache Flink für Flink Laufzeit () aws-kinesisanalytics-runtime	1.0.1
Managed Service für Apache Flink Flink-Kon nektoren () aws-kinesisanalytics-flink	1.0.1
Apache Maven	3.1

Um eine Anwendung mit Apache Flink 1.8.2 zu kompilieren, führen Sie Maven mit dem folgenden Parameter aus:

```
mvn package -Dflink.version=1.8.2
```

Ein Beispiel für eine pom.xml-Datei für eine Managed Service für Apache Flink-Anwendung, die Apache Flink Version 1.8.2 verwendet, finden Sie in der <u>Managed Service für Apache Flink 1.8.2</u> Erste Schritte-Anwendung.

Informationen zum Erstellen und Verwenden von Anwendungscode für eine Managed Service für Apache Flink-Anwendung finden Sie unter Erstellen einer Anwendung.

Anwendungen mit Apache Flink 1.6.2 erstellen

Dieser Abschnitt enthält Informationen über Komponenten, die Sie für die Erstellung von Managed Service für Apache Flink-Anwendungen verwenden, die mit Apache Flink 1.6.2 funktionieren. Verwenden Sie die folgenden Komponentenversionen für Managed Service für Apache Flink-Anwendungen:

Komponente	Version
Java	1.8 (empfohlen)
AWS Java-SDK	1.11.379
Apache Flink	1.6.2
Managed Service für Apache Flink für Flink Laufzeit () aws-kinesisanalytics-runtime	1.0.1
Managed Service für Apache Flink Flink-Kon nektoren () aws-kinesisanalytics-flink	1.0.1
Apache Maven	3.1
Apache Beam	Wird mit Apache Flink 1.6.2 nicht unterstützt.

1 Note

Wenn Sie Managed Service für Apache Flink Laufzeit Version 1.0.1 verwenden, geben Sie die Version von Apache Flink in Ihrer pom.xml-Datei an, anstatt den -Dflink.version-Parameter beim Kompilieren Ihres Anwendungscodes zu verwenden.

Ein Beispiel für eine pom.xml-Datei für eine Managed Service für Apache Flink-Anwendung, die Apache Flink Version 1.6.2 verwendet, finden Sie in der <u>Managed Service für Apache Flink 1.6.2</u> Erste Schritte-Anwendung.

Informationen zum Erstellen und Verwenden von Anwendungscode für eine Managed Service für Apache Flink-Anwendung finden Sie unter Erstellen einer Anwendung.

Aktualisieren von Anwendungen

Um die Apache Flink-Version einer Amazon Managed Service for Apache Flink-Anwendung zu aktualisieren, verwenden Sie die direkte Apache Flink-Versionsupgrade-Funktion mit dem AWS CLI,

AWS SDK, AWS CloudFormation oder dem. AWS Management Console Weitere Informationen finden Sie unter Verwenden Sie direkte Versionsupgrades für Apache Flink.

Sie können diese Funktion mit allen vorhandenen Anwendungen verwenden, die Sie mit Amazon Managed Service für Apache Flink in READY oder in einem anderen RUNNING Bundesstaat verwenden.

Verfügbare Konnektoren in Apache Flink 1.6.2 und 1.8.2

Das Apache Flink Framework enthält Konnektoren für den Zugriff auf Daten aus verschiedenen Quellen.

- Informationen zu den im Apache Flink 1.6.2-Framework verfügbaren Konnektoren finden Sie unter Konnektoren (1.6.2) in der Apache Flink-Dokumentation (1.6.2).
- Informationen zu den im Apache Flink 1.8.2-Framework verfügbaren Konnektoren finden Sie unter Konnektoren (1.8.2) in der Apache Flink-Dokumentation (1.8.2).

Erste Schritte: Flink 1.13.2

In diesem Abschnitt werden Ihnen die grundlegenden Konzepte von Managed Service for Apache Flink und der DataStream API vorgestellt. Es werden die verfügbaren Optionen für die Erstellung und das Testen von Anwendungen beschrieben. Er enthält auch Anweisungen zur Installation der Tools, die Sie benötigen, um die Tutorials in diesem Handbuch abzuschließen und Ihre erste Anwendung zu erstellen.

Themen

- Komponenten der Anwendung Managed Service für Apache Flink
- Voraussetzungen für das Abschließen der Übungen
- <u>Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers</u>
- <u>Nächster Schritt</u>
- Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)
- Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung
- <u>Schritt 4: Bereinigen von AWS Ressourcen</u>
- <u>Schritt 5: Nächste Schritte</u>

Komponenten der Anwendung Managed Service für Apache Flink

Zur Verarbeitung von Daten verwendet Ihre Managed Service für Apache Flink-Anwendung eine Java/Apache Maven- oder Scala-Anwendung, die mithilfe der Apache Flink-Laufzeit Eingaben verarbeitet und Ausgaben erzeugt.

Die Anwendung Managed Service für Apache Flink besteht aus folgenden Komponenten:

- Runtime-Eigenschaften: Sie können Runtime-Eigenschaften verwenden, um Ihre Anwendung zu konfigurieren, ohne Ihren Anwendungscode neu kompilieren zu müssen.
- Quelle: Die Anwendung verwendet Daten mithilfe einer Quelle. Ein Quell-Connector liest Daten aus einem Kinesis Data Stream, einem Amazon S3-Bucket usw. Weitere Informationen finden Sie unter <u>Fügen Sie Streaming-Datenquellen hinzu</u>.
- Operatoren: Die Anwendung verarbeitet Daten mithilfe eines oder mehrerer Operatoren. Ein Operator kann Daten transformieren, anreichern oder aggregieren. Weitere Informationen finden Sie unter <u>Operatoren</u>.
- Senke: Die Anwendung erzeugt Daten f
 ür externe Quellen mithilfe von Senken. Ein Senken-Connector schreibt Daten in einen Kinesis Data Stream, einen Firehose-Stream, einen Amazon S3 S3-Bucket usw. Weitere Informationen finden Sie unter <u>Schreiben Sie Daten mithilfe von Senken</u>.

Nachdem Sie Ihren Anwendungscode erstellt, kompiliert und verpackt haben, laden Sie das Codepaket in einen Amazon Simple Storage Service (Amazon S3)-Bucket hoch. Anschließend erstellen Sie eine Managed Service für Apache Flink-Anwendung. Sie übergeben den Speicherort des Codepakets, einen Kinesis Data Stream als Streaming-Datenquelle und in der Regel einen Streaming- oder Dateispeicherort, der die verarbeiteten Daten der Anwendung empfängt.

Voraussetzungen für das Abschließen der Übungen

Zur Durchführung der Schritte in dieser Anleitung benötigen Sie Folgendes:

- Java Development Kit (JDK) version 11. Legen Sie die JAVA_HOME Umgebungsvariable so fest, dass sie auf Ihren JDK-Installationsspeicherort weist.
- Wir empfehlen die Verwendung einer Entwicklungsumgebung (wie <u>Eclipse Java Neon</u> oder <u>IntelliJ</u> <u>Idea</u>), um Ihre Anwendung zu entwickeln und zu kompilieren.
- Git-Client. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben.
- <u>Apache Maven-Compiler-Plugin</u>. Maven muss sich in Ihrem Arbeitspfad befinden. Zum Testen Ihrer Apache Maven-Installation geben Sie Folgendes ein:

\$ mvn -version

Um zu beginnen, gehen Sie zu <u>Richten Sie ein AWS Konto ein und erstellen Sie einen</u> Administratorbenutzer.

Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers

Registrieren bei AWS-Konto

Wenn Sie kein haben AWS-Konto, führen Sie die folgenden Schritte zum Erstellen durch.

Sich für ein () registrieren AWS-Konto

- 1. Öffnen Sie https://portal.aws.amazon.com/billing/die Anmeldung.
- 2. Folgen Sie den Online-Anweisungen.

Bei der Anmeldung müssen Sie auch einen Telefonanruf entgegennehmen und einen Verifizierungscode über die Telefontasten eingeben.

Wenn Sie sich für eine anmelden AWS-Konto, Root-Benutzer des AWS-Kontoswird eine erstellt. Der Root-Benutzer hat Zugriff auf alle AWS-Services und Ressourcen des Kontos. Als bewährte Sicherheitsmethode weisen Sie einem Administratorbenutzer Administratorzugriff zu und verwenden Sie nur den Root-Benutzer, um Aufgaben auszuführen, die Root-Benutzerzugriff erfordern.

AWS sendet Ihnen eine Bestätigungs-E-Mail, sobald die Registrierung abgeschlossen ist. Sie können jederzeit Ihre aktuelle Kontoaktivität ansehen und Ihr Konto verwalten. Rufen Sie dazu auf und klicken Sie auf <u>https://aws.amazon.comMy</u> Account (Mein Konto).

Erstellen eines Benutzers mit Administratorzugriff

Nachdem Sie sich für ein angemeldet haben AWS-Konto, sichern Sie Ihr Root-Benutzer des AWS-Kontos AWS IAM Identity Center, aktivieren Sie und erstellen Sie einen administrativen Benutzer, damit Sie nicht den Root-Benutzer für alltägliche Aufgaben verwenden.

Sichern Sie Ihre Root-Benutzer des AWS-Kontos

 Melden Sie sich bei der <u>AWS Management Console</u>als Kontoinhaber an, indem Sie Root user (Stammbenutzer) auswählen und die AWS-Konto E-Mail-Adresse Ihres eingeben. Geben Sie auf der nächsten Seite Ihr Passwort ein.

Hilfe bei der Anmeldung mit dem Root-Benutzer finden Sie unter <u>Anmelden als Root-Benutzer</u> im AWS-Anmeldung Benutzerhandbuch zu.

2. Aktivieren Sie die Multi-Faktor-Authentifizierung (MFA) für den Root-Benutzer.

Anweisungen dazu finden Sie unter <u>Aktivieren eines virtuellen MFA-Geräts für den AWS-Konto</u> <u>Root-Benutzer Ihres (Konsole)</u> im IAM-Benutzerhandbuch.

Erstellen eines Benutzers mit Administratorzugriff

1. Aktivieren Sie das IAM Identity Center.

Anweisungen finden Sie unter <u>Aktivieren AWS IAM Identity Center</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Gewähren Sie einem Administratorbenutzer im IAM Identity Center Benutzerzugriff.

Ein Tutorial zur Verwendung von IAM-Identity-Center-Verzeichnis als Identitätsquelle finden Sie IAM-Identity-Center-Verzeichnis im Benutzerhandbuch unter <u>Benutzerzugriff mit der</u> <u>Standardeinstellung konfigurieren</u>.AWS IAM Identity Center

Anmelden als Administratorbenutzer

 Um sich mit Ihrem IAM-Identity-Center-Benutzer anzumelden, verwenden Sie die Anmelde-URL, die an Ihre E-Mail-Adresse gesendet wurde, als Sie den IAM-Identity-Center-Benutzer erstellt haben.

Hilfestellung zur Anmeldung mit einem IAM-Identity-Center-Benutzer finden Sie unter <u>Anmelden</u> beim AWS -Zugangsportal im AWS-Anmeldung Benutzerhandbuch zu.

Weiteren Benutzern Zugriff zuweisen

1. Erstellen Sie im IAM-Identity-Center einen Berechtigungssatz, der den bewährten Vorgehensweisen für die Anwendung von geringsten Berechtigungen folgt. Anweisungen hierzu finden Sie unter <u>Berechtigungssatz erstellen</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Weisen Sie Benutzer einer Gruppe zu und weisen Sie der Gruppe dann Single Sign-On-Zugriff zu.

Eine genaue Anleitung finden Sie unter <u>Gruppen hinzufügen</u> im AWS IAM Identity Center Benutzerhandbuch.

Erteilen programmgesteuerten Zugriffs

Benutzer benötigen programmgesteuerten Zugriff, wenn sie AWS außerhalb der AWS Management Console mit interagieren möchten. Die Vorgehensweise, um programmgesteuerten Zugriff zu gewähren, hängt davon ab, welcher Benutzertyp auf zugreift AWS.

Um Benutzern programmgesteuerten Zugriff zu gewähren, wählen Sie eine der folgenden Optionen.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
Mitarbeiteridentität (Benutzer, die in IAM Identity Center verwaltet werden)	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen zu den AWS CLI finden Sie <u>unter</u> Konfiguration der AWS CLI zur Verwendung AWS IAM Identity Center im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs Tools und AWS APIs finden Sie unter IAM Identity Center-Authentifizierung im Referenzhandbuch AWS

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
		SDKs und im Tools-Ref erenzhandbuch.
IAM	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	Folgen Sie den Anweisungen unter <u>Verwenden temporäre</u> <u>r Anmeldeinformationen mit</u> <u>AWS Ressourcen</u> im IAM- Benutzerhandbuch.
	(Nicht empfohlen) Verwenden Sie langfristige Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen dazu AWS CLI finden Sie unter <u>Authentifizierung mithilfe</u> von IAM-Benutzeranmeld einformationen im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs und Tools finden Sie unter <u>Authentifizieren mit</u> <u>langfristigen Anmeldein</u> formationen im Referenzh andbuch AWS SDKs und im Tools-Referenzhandbuch. Weitere Informationen finden Sie unter <u>Verwaltun</u> g von Zugriffsschlüsseln für <u>IAM-Benutzer</u> im IAM-Benut zerhandbuch. AWS APIs

Nächster Schritt

Richten Sie das AWS Command Line Interface ()AWS CLI ein

Nächster Schritt

Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)

Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)

In diesem Schritt laden Sie die herunter und konfigurieren sie für die AWS CLI Verwendung mit Amazon Managed Service für Apache Flink.

1 Note

Bei allen Erste-Schritte-Übungen in diesem Handbuch wird davon ausgegangen, dass Sie in Ihrem Konto Administrator-Anmeldeinformationen (adminuser) verwenden, um die Operationen auszuführen.

Note

Wenn Sie die bereits AWS CLI installiert haben, müssen Sie möglicherweise ein Upgrade durchführen, um die neuesten Funktionen zu erhalten. Weitere Informationen finden Sie unter <u>Installieren der AWS Command Line Interface</u> im AWS Command Line Interface - Benutzerhandbuch. Führen Sie den folgenden Befehl aus AWS CLI, um die Version von zu überprüfen:

```
aws --version
```

Für die Übungen in diesem Tutorial ist die folgende AWS CLI Version oder höher erforderlich:

aws-cli/1.16.63

Um das einzurichten AWS CLI

1. Herunterladen und Konfigurieren von AWS CLI. Eine Anleitung finden Sie unter den folgenden Themen im AWS Command Line Interface -Benutzerhandbuch:
- Installieren des AWS Command Line Interface
- Konfigurieren von AWS CLI
- Fügen Sie ein benanntes Profil für den Administratorbenutzer in der AWS CLI config Datei hinzu. Verwenden Sie dieses Profil beim Ausführen von AWS CLI -Befehlen. Weitere Informationen zu benannten Profilen finden Sie unter <u>Benannte Profile</u> im AWS Command Line Interface Benutzerhandbuch.

```
[profile adminuser]
aws_access_key_id = adminuser access key ID
aws_secret_access_key = adminuser secret access key
region = aws-region
```

Eine Liste der verfügbaren AWS Regionen finden Sie unter <u>Regionen und Endpunkte</u> in der Allgemeine Amazon Web Services-Referenz.

Note

Der Beispielcode und die Befehle in diesem Tutorial verwenden die Region USA West (Oregon). Um eine andere Region zu verwenden, ändern Sie die Region im Code und in den Befehlen für dieses Tutorial in die Region, die Sie verwenden möchten.

3. Überprüfen Sie die Einrichtung, indem Sie die folgenden Hilfebefehle in die Befehlszeile eingeben:

aws help

Nachdem Sie ein AWS -Konto und die einrichten AWS CLI, können Sie die nächste Übung ausprobieren, in der Sie eine Beispielanwendung konfigurieren und die end-to-end Einrichtung testen.

Nächster Schritt

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink mit Datenströmen als Quelle und Senke.

Dieser Abschnitt enthält die folgenden Schritte:

- Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams
- <u>Schreiben Sie Beispieldatensätze in den Eingabestream</u>
- Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- <u>Nächster Schritt</u>

Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream). Ihre Anwendung verwendet diese Streams für die Quell- und Ziel-Streams der Anwendung.

Sie können diese Streams mithilfe der Amazon-Kinesis-Konsole oder des folgenden AWS CLI -Befehls erstellen. Anweisungen für die Konsole finden Sie unter <u>Erstellen und Aktualisieren von</u> Datenströmen im Amazon Kinesis Data Streams Entwicklerhandbuch.

So erstellen Sie die Daten-Streams (AWS CLI)

 Verwenden Sie den folgenden Amazon Kinesis create-stream AWS CLI -Befehl, um den ersten Stream (ExampleInputStream) zu erstellen.

```
$ aws kinesis create-stream \
--stream-name ExampleInputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

 Um den zweiten Stream zu erstellen, den die Anwendung zum Schreiben der Ausgabe verwendet, führen Sie denselben Befehl aus und ändern den Stream-Namen in ExampleOutputStream.

```
$ aws kinesis create-stream \
--stream-name ExampleOutputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

```
    Note
```

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
   return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'price': round(random.random() * 100, 2)}
def generate(stream_name, kinesis_client):
   while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
            PartitionKey="partitionkey")
```

```
if __name__ == '__main__':
    generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Im weiteren Verlauf des Tutorials führen Sie das stock.py-Skript zum Senden von Daten an die Anwendung aus.

```
$ python stock.py
```

Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

1. Klonen Sie das Remote-Repository, indem Sie den folgenden Befehl verwenden:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/ GettingStarted Verzeichnis.

Beachten Sie Folgendes zum Anwendungscode:

- Eine <u>Project Object Model (pom.xml)</u> Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.
- Die BasicStreamingJob.java-Datei enthält die main-Methode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

- Ihre Anwendung erstellt Quell- und Senkenkonnektoren f
 ür den Zugriff auf externe Ressourcen, indem ein StreamExecutionEnvironment-Objekt verwendet wird.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit statischen Eigenschaften. Zum Verwenden dynamischer Anwendungseigenschaften verwenden Sie die Methoden createSourceFromApplicationProperties und

createSinkFromApplicationProperties, um die Konnektoren zu erstellen. Diese Methoden lesen die Eigenschaften der Anwendung zum Konfigurieren der Konnektoren.

Weitere Informationen zu Laufzeiteigenschaften finden Sie unter <u>Verwenden Sie</u> Laufzeiteigenschaften.

Kompilieren Sie den Anwendungscode

In diesem Abschnitt verwenden Sie den Apache Maven-Compiler zum Erstellen des Java-Codes für die Anwendung. Weitere Informationen zum Installieren von Apache Maven und des Java Development Kit (JDK) finden Sie unter Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen.

Kompilieren des Anwendungscodes

- 1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code auf zwei Arten kompilieren und packen:
 - Verwenden Sie das Befehlszeilen-Maven-Tool. Erstellen Sie Ihre JAR-Datei, indem Sie den folgenden Befehl in dem Verzeichnis ausführen, das die pom.xml-Datei enthält:

mvn package -Dflink.version=1.13.2

• Verwenden Sie Ihre Entwicklungsumgebung. Weitere Informationen finden Sie in der Dokumentation Ihrer Entwicklungsumgebung.

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken aus Java 11.

Sie können Ihr Paket als JAR-Datei hochladen oder komprimieren und als ZIP-Datei hochladen. Wenn Sie Ihre Anwendung mit dem erstellen AWS CLI, geben Sie Ihren Codeinhaltstyp (JAR oder ZIP) an.

2. Wenn während der Erstellung Fehler aufgetreten sind, überprüfen Sie, ob Ihre JAVA_HOME-Umgebungsvariable richtig eingestellt ist.

Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/aws-kinesis-analytics-java-apps-1.0.jar

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt erstellen Sie einen Amazon Simple Storage Service (Amazon S3)-Bucket und laden Ihren Anwendungscode hoch.

So laden Sie den Anwendungscode hoch

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Create Bucket (Bucket erstellen) aus.
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben. Wählen Sie Weiter aus.
- 9. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder AWS CLI erstellen und ausführen.

1 Note

Wenn Sie die Anwendung mithilfe der Konsole erstellen, werden die Ressourcen AWS Identity and Access Management (IAM) und Amazon CloudWatch Logs für Sie erstellt. Bei der Erstellung der AWS CLI erstellen Sie separat die folgenden Ressourcen.

Themen

- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen Sie die Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My java test app ein.
 - Wählen Sie für Runtime (Laufzeit) die Option Apache Flink aus.
 - Behalten Sie im Pulldown-Menü die Version Apache Flink Version 1.13 bei.
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

1 Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
              "s3:GetObject",
              "s3:GetObject",
              "s3:GetObjectVersion"
        ],
        "Resource": [
             "arn:aws:s3::::ka-app-code-username/aws-kinesis-analytics-java-
apps-1.0.jar"
```

```
1
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ]
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            1
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
```

```
"Action": "kinesis:*",
    "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
    }
]
}
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert aws-kinesis-analytics-javaapps-1.0.jar ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	flink.inputstream. initpos	LATEST
ProducerConfigProp erties	aws.region	us-west-2
ProducerConfigProp erties	AggregationEnabled	false

- 5. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 6. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 7. Wählen Sie Aktualisieren.

1 Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Stoppt die Anwendung

Wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Aktualisieren der Anwendung

Mithilfe der Konsole können Sie Anwendungseinstellungen wie beispielsweise Anwendungseigenschaften, Überwachungseinstellungen und den Speicherort oder den Dateinamen der JAR-Anwendungsdatei aktualisieren. Außerdem können Sie die JAR-Anwendungsdatei erneut aus dem Amazon-S3-Bucket laden, wenn Sie den Anwendungscode aktualisieren müssen.

Wählen Sie auf der MyApplicationSeite Configure aus. Aktualisieren Sie die Anwendungseinstellungen und klicken Sie auf Aktualisieren.

Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

In diesem Abschnitt verwenden Sie, AWS CLI um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen. Anwendungen von Managed Service für Apache Flink verwendet den kinesisanalyticsv2 AWS CLI Befehl, um Managed-Service-für-Apache-Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

Note

Sie müssen eine Berechtigungsrichtlinie und eine Rolle für Ihre Anwendung erstellen. Wenn Sie diese IAM-Ressourcen nicht erstellen, kann Ihre Anwendung nicht auf ihre Daten- und Protokollstreams zugreifen.

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die read-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die write-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie *username* durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "S3",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": ["arn:aws:s3:::ka-app-code-username",
                "arn:aws:s3:::ka-app-code-username/*"
            ]
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
```

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: <u>Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie</u> im IAM-Benutzerhandbuch.

Note

Um auf andere Amazon-Services zuzugreifen, können Sie AWS SDK für Java verwenden. Managed Service für Apache Flink setzt die vom SDK benötigten Anmeldeinformationen automatisch auf die der IAM-Rolle für die Dienstausführung, die mit Ihrer Anwendung verknüpft ist. Es sind keine weiteren Schritte erforderlich.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.

- 2. Wählen Sie im Navigationsbereich Roles (Rollen) und Create Role (Rolle erstellen) aus.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus. Wählen Sie unter Select your use case (Wählen Sie Ihren Anwendungsfall aus) die Option Kinesis Analytics aus.

Wählen Sie Weiter: Berechtigungen aus.

- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 5. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle.

6. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt erstellt haben, <u>the section called "Erstellen einer</u> <u>Berechtigungsrichtlinie"</u>.

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.
- d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter Erstellen einer IAM-Rolle (Konsole) im IAM-Benutzerhandbuch.

Erstellen Sie die Anwendung Managed Service für Apache Flink

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (*username*) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (*012345678901*) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
{
    "ApplicationName": "test",
    "ApplicationDescription": "my java test app",
    "RuntimeEnvironment": "FLINK-1_15",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "aws-kinesis-analytics-java-apps-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "flink.stream.initpos" : "LATEST",
                    "aws.region" : "us-west-2",
                    "AggregationEnabled" : "false"
               }
            },
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2"
               }
            }
         ]
```

```
}
}
```

 Führen Sie die <u>CreateApplication</u>-Aktion mit der vorherigen Anforderung zum Erstellen der Anwendung aus:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://
create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

Starten der Anwendung

In diesem Abschnitt verwenden Sie die StartApplication-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{
    "ApplicationName": "test",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
            }
    }
}
```

2. Führen Sie die <u>StartApplication</u>-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppen der Anwendung

In diesem Abschnitt verwenden Sie die <u>StopApplication</u>-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "test"
}
```

2. Führen Sie die <u>StopApplication</u>-Aktion mit der folgenden Anforderung zum Stoppen der Anwendung aus:

```
aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json
```

Die Anwendung wird nun gestoppt.

Eine CloudWatch Protokollierungs-Option hinzufügen

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter<u>the section called "Anwendungsprotokollierung in Managed</u> Service für Apache Flink einrichten".

Umgebungseigenschaften aktualisieren

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.

```
{"ApplicationName": "test",
    "CurrentApplicationVersionId": 1,
    "ApplicationConfigurationUpdate": {
```

```
"EnvironmentPropertyUpdates": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "flink.stream.initpos" : "LATEST",
                    "aws.region" : "us-west-2",
                    "AggregationEnabled" : "false"
               }
            },
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2"
               }
            }
         ]
      }
   }
}
```

2. Führen Sie die <u>UpdateApplication</u>-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Aktualisieren Sie den Anwendungscode

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die UpdateApplication AWS CLI Aktion.

Note

Um eine neue Version des Anwendungscodes mit demselben Dateinamen zu laden, müssen Sie die neue Objektversion angeben. Weitere Informationen zur Verwendung von Amazon S3-Objektversionen finden Sie unter Versionsverwaltung aktivieren oder deaktivieren.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication dabei denselben Amazon S3 S3-Bucket und Objektnamen sowie die neue Objektversion an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (*<username>*) mit dem Suffix, das Sie im -Abschnitt ausgewählt haben. <u>the section</u> called "Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams"

Nächster Schritt

Schritt 4: Bereinigen von AWS Ressourcen

Schritt 4: Bereinigen von AWS Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Erste Schritte erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- So löschen Sie Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen

- CloudWatch Löschen Sie Ihre Ressourcen
- Nächster Schritt

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen MyApplicationSie im Bereich Managed Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

So löschen Sie Kinesis Data Streams

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username>*Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.

- 7. Wählen Sie die Rolle kinesis-analytics--west-2 MyApplication aus.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Nächster Schritt

Schritt 5: Nächste Schritte

Schritt 5: Nächste Schritte

Nachdem Sie nun eine grundlegende Managed Service für Apache Flink-Anwendung erstellt und ausgeführt haben, finden Sie in den folgenden Ressourcen erweiterte Managed Service für Apache Flink-Lösungen.

- Die neueste AWS -Streaming-Datenlösung für Amazon Kinesis: Die neueste AWS -Streaming-Datenlösung für Amazon Kinesis konfiguriert automatisch die AWS -Services, die für die einfache Erfassung, Speicherung, Verarbeitung und Bereitstellung von Streaming-Daten erforderlich sind. Die Lösung bietet mehrere Optionen zur Lösung von Anwendungsfällen mit Streaming-Daten. Die Option Managed Service für Apache Flink bietet ein end-to-end Streaming-ETL-Beispiel, das eine reale Anwendung demonstriert, die analytische Operationen mit simulierten Taxidaten aus New York ausführt. Die Lösung richtet alle erforderlichen AWS -Ressourcen wie IAM-Rollen und -Richtlinien, ein CloudWatch Dashboard und CloudWatch Alarme ein.
- <u>AWS Streaming Data Solution for Amazon MSK</u>: Die AWS Streaming Data Solution for Amazon MSK stellt AWS CloudFormation -Vorlagen bereit, bei denen Daten durch Produzenten, Streaming-Speicher, Verbraucher und Ziele fließen.
- <u>Clickstream Lab mit Apache Flink und Apache Kafka</u>: Ein End-to-End-Lab f
 ür Clickstream-Anwendungsf
 älle mit Amazon Managed Streaming for Apache Kafka als Streaming-Speicher und Managed Service f
 ür Apache Flink f
 ür Apache Flink-Anwendungen zur Stream-Verarbeitung.
- <u>Amazon Managed Service für Apache Flink Workshop</u>: In diesem Workshop entwickeln Sie eine end-to-end Streaming-Architektur, um Streaming-Daten nahezu in Echtzeit aufzunehmen,

zu analysieren und zu visualisieren. Sie haben sich vorgenommen, den Betrieb eines Taxiunternehmens in New York City zu verbessern. Sie analysieren die Telemetriedaten einer Taxiflotte in New York City nahezu in Echtzeit, um deren Flottenbetrieb zu optimieren.

 Lernen Sie Flink kennen: Praktisches Training: Offizielle Apache Flink-Einführungsschulung, die Ihnen den Einstieg in die Entwicklung skalierbarer Streaming-ETL-, Analyse- und ereignisgesteuerter Anwendungen ermöglicht.

Note

Beachten Sie, dass Managed Service für Apache Flink die in dieser Schulung verwendete Apache Flink-Version (1.12) nicht unterstützt. Sie können Flink 1.15.2 in Flink Managed Service für Apache Flink verwenden.

Erste Schritte: Flink 1.11.1 — veraltet

Note

Die Apache Flink-Versionen 1.6, 1.8 und 1.11 wurden seit über drei Jahren nicht mehr von der Apache Flink-Community unterstützt. Wir planen, diese Versionen in Amazon Managed Service für Apache Flink am 5. November 2024 als veraltet anzusehen. Ab diesem Datum können Sie keine neuen Anwendungen für diese Flink-Versionen erstellen. Sie können bestehende Anwendungen zu diesem Zeitpunkt weiter ausführen. Sie können Ihre Anwendungen mithilfe der Funktion für direkte Versionsupgrades in Amazon Managed Service for Apache Flink statual aktualisieren. Weitere Informationen finden Sie unter. Verwenden Sie direkte Versionsupgrades für Apache Flink

Dieses Thema enthält eine Version des <u>Tutorial: Erste Schritte mit der DataStream API in Managed</u> <u>Service für Apache Flink</u> -Tutorials, die Apache Flink 1.11.1 verwendet.

In diesem Abschnitt werden Ihnen die grundlegenden Konzepte von Managed Service for Apache Flink und der DataStream API vorgestellt. Es werden die verfügbaren Optionen für die Erstellung und das Testen von Anwendungen beschrieben. Er enthält auch Anweisungen zur Installation der Tools, die Sie benötigen, um die Tutorials in diesem Handbuch abzuschließen und Ihre erste Anwendung zu erstellen.

Themen

- Komponenten der Anwendung Managed Service für Apache Flink
- Voraussetzungen für das Abschließen der Übungen
- Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers
- Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)
- Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung
- <u>Schritt 4: Bereinigen von AWS Ressourcen</u>
- Schritt 5: Nächste Schritte

Komponenten der Anwendung Managed Service für Apache Flink

Zur Verarbeitung von Daten verwendet Ihre Managed Service für Apache Flink-Anwendung eine Java/Apache Maven- oder Scala-Anwendung, die mithilfe der Apache Flink-Laufzeit Eingaben verarbeitet und Ausgaben erzeugt.

Eine Anwendung Managed Service für Apache Flink besteht aus folgenden Komponenten:

- Runtime-Eigenschaften: Sie können Runtime-Eigenschaften verwenden, um Ihre Anwendung zu konfigurieren, ohne Ihren Anwendungscode neu kompilieren zu müssen.
- Quelle: Die Anwendung verwendet Daten mithilfe einer Quelle. Ein Quell-Connector liest Daten aus einem Kinesis Data Stream, einem Amazon S3-Bucket usw. Weitere Informationen finden Sie unter Fügen Sie Streaming-Datenquellen hinzu.
- Operatoren: Die Anwendung verarbeitet Daten mithilfe eines oder mehrerer Operatoren. Ein Operator kann Daten transformieren, anreichern oder aggregieren. Weitere Informationen finden Sie unter <u>Operatoren</u>.
- Senke: Die Anwendung erzeugt Daten f
 ür externe Quellen mithilfe von Senken. Ein Senken-Connector schreibt Daten in einen Kinesis Data Stream, einen Firehose-Stream, einen Amazon S3 S3-Bucket usw. Weitere Informationen finden Sie unter Schreiben Sie Daten mithilfe von Senken.

Nachdem Sie Ihren Anwendungscode erstellt, kompiliert und verpackt haben, laden Sie das Codepaket in einen Amazon Simple Storage Service (Amazon S3)-Bucket hoch. Anschließend erstellen Sie eine Managed Service für Apache Flink-Anwendung. Sie übergeben den Speicherort des Codepakets, einen Kinesis Data Stream als Streaming-Datenquelle und in der Regel einen Streaming- oder Dateispeicherort, der die verarbeiteten Daten der Anwendung empfängt.

Voraussetzungen für das Abschließen der Übungen

Zur Durchführung der Schritte in dieser Anleitung benötigen Sie Folgendes:

- Java Development Kit (JDK) version 11. Legen Sie die JAVA_HOME Umgebungsvariable so fest, dass sie auf Ihren JDK-Installationsspeicherort weist.
- Wir empfehlen die Verwendung einer Entwicklungsumgebung (wie <u>Eclipse Java Neon</u> oder <u>IntelliJ</u> <u>Idea</u>), um Ihre Anwendung zu entwickeln und zu kompilieren.
- Git-Client. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben.
- <u>Apache Maven-Compiler-Plugin</u>. Maven muss sich in Ihrem Arbeitspfad befinden. Zum Testen Ihrer Apache Maven-Installation geben Sie Folgendes ein:

\$ mvn -version

Um zu beginnen, gehen Sie zu <u>Richten Sie ein AWS Konto ein und erstellen Sie einen</u> Administratorbenutzer.

Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers

Registrieren bei AWS-Konto

Wenn Sie kein haben AWS-Konto, führen Sie die folgenden Schritte zum Erstellen durch.

Sich für ein () registrieren AWS-Konto

- 1. Öffnen Sie https://portal.aws.amazon.com/billing/die Anmeldung.
- 2. Folgen Sie den Online-Anweisungen.

Bei der Anmeldung müssen Sie auch einen Telefonanruf entgegennehmen und einen Verifizierungscode über die Telefontasten eingeben.

Wenn Sie sich für eine anmelden AWS-Konto, Root-Benutzer des AWS-Kontoswird eine erstellt. Der Root-Benutzer hat Zugriff auf alle AWS-Services und Ressourcen des Kontos. Als bewährte Sicherheitsmethode weisen Sie einem Administratorbenutzer Administratorzugriff zu und verwenden Sie nur den Root-Benutzer, um Aufgaben auszuführen, die Root-Benutzerzugriff erfordern.

AWS sendet Ihnen eine Bestätigungs-E-Mail, sobald die Registrierung abgeschlossen ist. Sie können jederzeit Ihre aktuelle Kontoaktivität ansehen und Ihr Konto verwalten. Rufen Sie dazu auf und klicken Sie auf https://aws.amazon.comMy Account (Mein Konto).

Erstellen eines Benutzers mit Administratorzugriff

Nachdem Sie sich für ein angemeldet haben AWS-Konto, sichern Sie Ihr Root-Benutzer des AWS-Kontos AWS IAM Identity Center, aktivieren Sie und erstellen Sie einen administrativen Benutzer, damit Sie nicht den Root-Benutzer für alltägliche Aufgaben verwenden.

Sichern Sie Ihre Root-Benutzer des AWS-Kontos

 Melden Sie sich bei der <u>AWS Management Console</u>als Kontoinhaber an, indem Sie Root user (Stammbenutzer) auswählen und die AWS-Konto E-Mail-Adresse Ihres eingeben. Geben Sie auf der nächsten Seite Ihr Passwort ein.

Hilfe bei der Anmeldung mit dem Root-Benutzer finden Sie unter <u>Anmelden als Root-Benutzer</u> im AWS-Anmeldung Benutzerhandbuch zu.

2. Aktivieren Sie die Multi-Faktor-Authentifizierung (MFA) für den Root-Benutzer.

Anweisungen dazu finden Sie unter <u>Aktivieren eines virtuellen MFA-Geräts für den AWS-Konto</u> <u>Root-Benutzer Ihres (Konsole)</u> im IAM-Benutzerhandbuch.

Erstellen eines Benutzers mit Administratorzugriff

1. Aktivieren Sie das IAM Identity Center.

Anweisungen finden Sie unter <u>Aktivieren AWS IAM Identity Center</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Gewähren Sie einem Administratorbenutzer im IAM Identity Center Benutzerzugriff.

Ein Tutorial zur Verwendung von IAM-Identity-Center-Verzeichnis als Identitätsquelle finden Sie IAM-Identity-Center-Verzeichnis im Benutzerhandbuch unter <u>Benutzerzugriff mit der</u> Standardeinstellung konfigurieren.AWS IAM Identity Center

Anmelden als Administratorbenutzer

 Um sich mit Ihrem IAM-Identity-Center-Benutzer anzumelden, verwenden Sie die Anmelde-URL, die an Ihre E-Mail-Adresse gesendet wurde, als Sie den IAM-Identity-Center-Benutzer erstellt haben.

Hilfestellung zur Anmeldung mit einem IAM-Identity-Center-Benutzer finden Sie unter <u>Anmelden</u> beim AWS -Zugangsportal im AWS-Anmeldung Benutzerhandbuch zu.

Weiteren Benutzern Zugriff zuweisen

1. Erstellen Sie im IAM-Identity-Center einen Berechtigungssatz, der den bewährten Vorgehensweisen für die Anwendung von geringsten Berechtigungen folgt.

Anweisungen hierzu finden Sie unter <u>Berechtigungssatz erstellen</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Weisen Sie Benutzer einer Gruppe zu und weisen Sie der Gruppe dann Single Sign-On-Zugriff zu.

Eine genaue Anleitung finden Sie unter <u>Gruppen hinzufügen</u> im AWS IAM Identity Center Benutzerhandbuch.

Erteilen programmgesteuerten Zugriffs

Benutzer benötigen programmgesteuerten Zugriff, wenn sie AWS außerhalb der AWS Management Console mit interagieren möchten. Die Vorgehensweise, um programmgesteuerten Zugriff zu gewähren, hängt davon ab, welcher Benutzertyp auf zugreift AWS.

Um Benutzern programmgesteuerten Zugriff zu gewähren, wählen Sie eine der folgenden Optionen.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
Mitarbeiteridentität (Benutzer, die in IAM Identity Center verwaltet werden)	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
		 Informationen zu den AWS CLI finden Sie <u>unter</u> Konfiguration der AWS CLI zur Verwendung AWS IAM Identity Center im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs Tools und AWS APIs finden Sie unter <u>IAM Identity</u> <u>Center-Authentifizierung</u> im Referenzhandbuch AWS SDKs und im Tools-Ref erenzhandbuch.
IAM	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	Folgen Sie den Anweisungen unter <u>Verwenden temporäre</u> <u>r Anmeldeinformationen mit</u> <u>AWS Ressourcen</u> im IAM- Benutzerhandbuch.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
	(Nicht empfohlen) Verwenden Sie langfristige Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen dazu AWS CLI finden Sie unter <u>Authentifizierung mithilfe</u> von IAM-Benutzeranmeld einformationen im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs und Tools finden Sie unter <u>Authentifizieren mit</u> langfristigen Anmeldein formationen im Referenzh andbuch AWS SDKs und im Tools-Referenzhandbuch. Weitere Informationen finden Sie unter <u>Verwaltun</u> g von Zugriffsschlüsseln für IAM-Benutzer im IAM-Benut zerhandbuch. AWS APIs

Nächster Schritt

Richten Sie das AWS Command Line Interface ()AWS CLI ein

Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)

In diesem Schritt laden Sie die herunter und konfigurieren sie für die AWS CLI Verwendung mit Amazon Managed Service für Apache Flink.

Note

Bei allen Erste-Schritte-Übungen in diesem Handbuch wird davon ausgegangen, dass Sie in Ihrem Konto Administrator-Anmeldeinformationen (adminuser) verwenden, um die Operationen auszuführen.

Note

Wenn Sie die bereits AWS CLI installiert haben, müssen Sie möglicherweise ein Upgrade durchführen, um die neuesten Funktionen zu erhalten. Weitere Informationen finden Sie unter <u>Installieren der AWS Command Line Interface</u> im AWS Command Line Interface - Benutzerhandbuch. Führen Sie den folgenden Befehl aus AWS CLI, um die Version von zu überprüfen:

aws --version

Für die Übungen in diesem Tutorial ist die folgende AWS CLI Version oder höher erforderlich:

aws-cli/1.16.63

Um das einzurichten AWS CLI

- 1. Herunterladen und Konfigurieren von AWS CLI. Eine Anleitung finden Sie unter den folgenden Themen im AWS Command Line Interface -Benutzerhandbuch:
 - Installieren des AWS Command Line Interface
 - Konfigurieren von AWS CLI
- Fügen Sie ein benanntes Profil für den Administratorbenutzer in der AWS CLI config Datei hinzu. Verwenden Sie dieses Profil beim Ausführen von AWS CLI -Befehlen. Weitere Informationen zu benannten Profilen finden Sie unter <u>Benannte Profile</u> im AWS Command Line Interface Benutzerhandbuch.

```
[profile adminuser]
aws_access_key_id = adminuser access key ID
aws_secret_access_key = adminuser secret access key
```

region = aws-region

Eine Liste der verfügbaren AWS Regionen finden Sie unter <u>Regionen und Endpunkte</u> in der Allgemeine Amazon Web Services-Referenz.

Note

Der Beispielcode und die Befehle in diesem Tutorial verwenden die Region USA West (Oregon). Um eine andere Region zu verwenden, ändern Sie die Region im Code und in den Befehlen für dieses Tutorial in die Region, die Sie verwenden möchten.

3. Überprüfen Sie die Einrichtung, indem Sie die folgenden Hilfebefehle in die Befehlszeile eingeben:

aws help

Nachdem Sie ein AWS -Konto und die einrichten AWS CLI, können Sie die nächste Übung ausprobieren, in der Sie eine Beispielanwendung konfigurieren und die end-to-end Einrichtung testen.

Nächster Schritt

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink mit Datenströmen als Quelle und Senke.

Dieser Abschnitt enthält die folgenden Schritte:

- Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams
- <u>Schreiben Sie Beispieldatensätze in den Eingabestream</u>
- Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes

- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Nächster Schritt

Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream). Ihre Anwendung verwendet diese Streams für die Quell- und Ziel-Streams der Anwendung.

Sie können diese Streams mithilfe der Amazon-Kinesis-Konsole oder des folgenden AWS CLI -Befehls erstellen. Anweisungen für die Konsole finden Sie unter <u>Erstellen und Aktualisieren von</u> Datenströmen im Amazon Kinesis Data Streams Entwicklerhandbuch.

So erstellen Sie die Daten-Streams (AWS CLI)

1. Verwenden Sie den folgenden Amazon Kinesis create-stream AWS CLI-Befehl, um den ersten Stream (ExampleInputStream) zu erstellen.

```
$ aws kinesis create-stream \
--stream-name ExampleInputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

 Um den zweiten Stream zu erstellen, den die Anwendung zum Schreiben der Ausgabe verwendet, führen Sie denselben Befehl aus und ändern den Stream-Namen in ExampleOutputStream.

```
$ aws kinesis create-stream \
--stream-name ExampleOutputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        "EVENT_TIME": datetime.datetime.now().isoformat(),
        "TICKER": random.choice(["AAPL", "AMZN", "MSFT", "INTC", "TBV"]),
        "PRICE": round(random.random() * 100, 2),
    }
def generate(stream_name, kinesis_client):
   while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name, Data=json.dumps(data),
 PartitionKey="partitionkey"
        )
if __name__ == "__main__":
    generate(STREAM_NAME, boto3.client("kinesis"))
```

2. Im weiteren Verlauf des Tutorials führen Sie das stock.py-Skript zum Senden von Daten an die Anwendung aus.

\$ python stock.py

Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

1. Klonen Sie das Remote-Repository, indem Sie den folgenden Befehl verwenden:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/ GettingStarted Verzeichnis.

Beachten Sie Folgendes zum Anwendungscode:

- Eine <u>Project Object Model (pom.xml)</u> Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.
- Die BasicStreamingJob.java-Datei enthält die main-Methode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

- Ihre Anwendung erstellt Quell- und Senkenkonnektoren für den Zugriff auf externe Ressourcen, indem ein StreamExecutionEnvironment-Objekt verwendet wird.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit statischen Eigenschaften. Zum Verwenden dynamischer Anwendungseigenschaften verwenden Sie die Methoden createSourceFromApplicationProperties und createSinkFromApplicationProperties, um die Konnektoren zu erstellen. Diese Methoden lesen die Eigenschaften der Anwendung zum Konfigurieren der Konnektoren.

Weitere Informationen zu Laufzeiteigenschaften finden Sie unter <u>Verwenden Sie</u> Laufzeiteigenschaften. Kompilieren Sie den Anwendungscode

In diesem Abschnitt verwenden Sie den Apache Maven-Compiler zum Erstellen des Java-Codes für die Anwendung. Weitere Informationen zum Installieren von Apache Maven und des Java Development Kit (JDK) finden Sie unter Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen.

Kompilieren des Anwendungscodes

- 1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code auf zwei Arten kompilieren und packen:
 - Verwenden Sie das Befehlszeilen-Maven-Tool. Erstellen Sie Ihre JAR-Datei, indem Sie den folgenden Befehl in dem Verzeichnis ausführen, das die pom.xml-Datei enthält:

mvn package -Dflink.version=1.11.3

 Verwenden Sie Ihre Entwicklungsumgebung. Weitere Informationen finden Sie in der Dokumentation Ihrer Entwicklungsumgebung.

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken aus Java 11. Stellen Sie sicher, dass die Java-Version Ihres Projekts 11 ist.

Sie können Ihr Paket als JAR-Datei hochladen oder komprimieren und als ZIP-Datei hochladen. Wenn Sie Ihre Anwendung mit dem erstellen AWS CLI, geben Sie Ihren Codeinhaltstyp (JAR oder ZIP) an.

2. Wenn während der Erstellung Fehler aufgetreten sind, überprüfen Sie, ob Ihre JAVA_HOME-Umgebungsvariable richtig eingestellt ist.

Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/aws-kinesis-analytics-java-apps-1.0.jar

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt erstellen Sie einen Amazon Simple Storage Service (Amazon S3)-Bucket und laden Ihren Anwendungscode hoch.

So laden Sie den Anwendungscode hoch

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Create Bucket (Bucket erstellen) aus.
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben. Wählen Sie Weiter aus.
- 9. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder AWS CLI erstellen und ausführen.

Note

Wenn Sie die Anwendung mithilfe der Konsole erstellen, werden die Ressourcen AWS Identity and Access Management (IAM) und Amazon CloudWatch Logs für Sie erstellt. Bei der Erstellung der AWS CLI erstellen Sie separat die folgenden Ressourcen.

Themen

• Erstellen und Ausführen der Anwendung (Konsole)

• Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My java test app ein.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.
 - Behalten Sie im Pulldown-Menü für die Version Apache Flink Version 1.11 (empfohlene Version) bei.
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2
Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-username/aws-kinesis-analytics-java-
apps-1.0.jar"
            ]
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
```

```
"Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            1
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ٦
        },
        ſ
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        ſ
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):

- Geben Sie f
 ür Amazon-S3-Bucket ka-app-code-<username> ein.
- Geben Sie als Pfad zum Amazon-S3-Objekt den Wert aws-kinesis-analytics-javaapps-1.0.jar ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Geben Sie unter Eigenschaften für Gruppen-ID den Text **ProducerConfigProperties** ein.
- 5. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	flink.inputstream. initpos	LATEST
ProducerConfigProp erties	aws.region	us-west-2
ProducerConfigProp erties	AggregationEnabled	false

- 6. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 7. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 8. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Stoppt die Anwendung

Wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Aktualisieren der Anwendung

Mithilfe der Konsole können Sie Anwendungseinstellungen wie beispielsweise Anwendungseigenschaften, Überwachungseinstellungen und den Speicherort oder den Dateinamen der JAR-Anwendungsdatei aktualisieren. Außerdem können Sie die JAR-Anwendungsdatei erneut aus dem Amazon-S3-Bucket laden, wenn Sie den Anwendungscode aktualisieren müssen.

Wählen Sie auf der MyApplicationSeite Configure aus. Aktualisieren Sie die Anwendungseinstellungen und klicken Sie auf Aktualisieren.

Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

In diesem Abschnitt verwenden Sie AWS CLI zum Erstellen und Ausführen der Anwendung Managed Service für Apache Flink. Ein Managed Service für apache Flink verwendet den kinesisanalyticsv2 AWS CLI Befehl, um Managed-Service-für-Apache-Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

Note

Sie müssen eine Berechtigungsrichtlinie und eine Rolle für Ihre Anwendung erstellen. Wenn Sie diese IAM-Ressourcen nicht erstellen, kann Ihre Anwendung nicht auf ihre Daten- und Protokollstreams zugreifen.

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die read-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die write-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle Managed Service für Apache Flink

übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie *username* durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "S3",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": ["arn:aws:s3:::ka-app-code-username",
                "arn:aws:s3:::ka-app-code-username/*"
            ]
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: <u>Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie</u> im IAM-Benutzerhandbuch.

1 Note

Um auf andere Amazon-Services zuzugreifen, können Sie AWS SDK für Java verwenden. Managed Service für Apache Flink setzt die vom SDK benötigten Anmeldeinformationen automatisch auf die der IAM-Rolle für die Dienstausführung, die mit Ihrer Anwendung verknüpft ist. Es sind keine weiteren Schritte erforderlich.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Roles (Rollen) und Create Role (Rolle erstellen) aus.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus. Wählen Sie unter Select your use case (Wählen Sie Ihren Anwendungsfall aus) die Option Kinesis Analytics aus.

Wählen Sie Weiter: Berechtigungen aus.

- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 5. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle.

6. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt erstellt haben, <u>the section called "Erstellen einer</u> <u>Berechtigungsrichtlinie"</u>.

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.
- d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter <u>Erstellen einer IAM-Rolle</u> (Konsole) im IAM-Benutzerhandbuch.

Erstellen Sie die Anwendung Managed Service für Apache Flink

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (*username*) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (*012345678901*) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
"ApplicationName": "test",
```

{

```
"ApplicationDescription": "my java test app",
"RuntimeEnvironment": "FLINK-1_11",
"ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
"ApplicationConfiguration": {
    "ApplicationCodeConfiguration": {
        "CodeContent": {
            "S3ContentLocation": {
                "BucketARN": "arn:aws:s3:::ka-app-code-username",
                "FileKey": "aws-kinesis-analytics-java-apps-1.0.jar"
            }
        },
        "CodeContentType": "ZIPFILE"
   },
    "EnvironmentProperties": {
     "PropertyGroups": [
        {
           "PropertyGroupId": "ProducerConfigProperties",
           "PropertyMap" : {
                "flink.stream.initpos" : "LATEST",
                "aws.region" : "us-west-2",
                "AggregationEnabled" : "false"
           }
        },
        {
           "PropertyGroupId": "ConsumerConfigProperties",
           "PropertyMap" : {
                "aws.region" : "us-west-2"
           }
        }
     ]
 }
}
```

2. Führen Sie die <u>CreateApplication</u>-Aktion mit der vorherigen Anforderung zum Erstellen der Anwendung aus:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://
create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

}

Starten der Anwendung

In diesem Abschnitt verwenden Sie die <u>StartApplication</u>-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{
    "ApplicationName": "test",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
            }
    }
}
```

2. Führen Sie die <u>StartApplication</u>-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

```
aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json
```

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die <u>StopApplication</u>-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "test"
}
```

2. Führen Sie die <u>StopApplication</u>-Aktion mit der folgenden Anforderung zum Stoppen der Anwendung aus:

aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter<u>the section called "Anwendungsprotokollierung in Managed</u> <u>Service für Apache Flink einrichten"</u>.

Aktualisieren von Umgebungseigenschaften

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.

```
{"ApplicationName": "test",
   "CurrentApplicationVersionId": 1,
   "ApplicationConfigurationUpdate": {
      "EnvironmentPropertyUpdates": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "flink.stream.initpos" : "LATEST",
                    "aws.region" : "us-west-2",
                    "AggregationEnabled" : "false"
               }
            },
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2"
               }
```

```
]
}
}
```

}

2. Führen Sie die <u>UpdateApplication</u>-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die UpdateApplication AWS CLI Aktion.

1 Note

Um eine neue Version des Anwendungscodes mit demselben Dateinamen zu laden, müssen Sie die neue Objektversion angeben. Weitere Informationen zur Verwendung von Amazon S3-Objektversionen finden Sie unter Versionsverwaltung aktivieren oder deaktivieren.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication dabei denselben Amazon S3 S3-Bucket und Objektnamen sowie die neue Objektversion an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (*<username>*) mit dem Suffix, das Sie im -Abschnitt ausgewählt haben. <u>the section</u> called "Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams"

```
{
```

```
"ApplicationName": "test",
"CurrentApplicationVersionId": 1,
```

Nächster Schritt

Schritt 4: Bereinigen von AWS Ressourcen

Schritt 4: Bereinigen von AWS Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Erste Schritte erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- So löschen Sie Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen
- Nächster Schritt

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

So löschen Sie Kinesis Data Streams

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username*>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics--west-2 MyApplication aus.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Nächster Schritt

Schritt 5: Nächste Schritte

Schritt 5: Nächste Schritte

Nachdem Sie nun eine grundlegende Managed Service für Apache Flink-Anwendung erstellt und ausgeführt haben, finden Sie in den folgenden Ressourcen erweiterte Managed Service für Apache Flink-Lösungen.

- Die neueste AWS -Streaming-Datenlösung für Amazon Kinesis: Die neueste AWS -Streaming-Datenlösung für Amazon Kinesis konfiguriert automatisch die AWS -Services, die für die einfache Erfassung, Speicherung, Verarbeitung und Bereitstellung von Streaming-Daten erforderlich sind. Die Lösung bietet mehrere Optionen zur Lösung von Anwendungsfällen mit Streaming-Daten. Die Option Managed Service für Apache Flink bietet ein end-to-end Streaming-ETL-Beispiel, das eine reale Anwendung demonstriert, die analytische Operationen mit simulierten Taxidaten aus New York ausführt. Die Lösung richtet alle erforderlichen AWS -Ressourcen wie IAM-Rollen und -Richtlinien, ein CloudWatch Dashboard und CloudWatch Alarme ein.
- <u>AWS Streaming Data Solution for Amazon MSK</u>: Die AWS Streaming Data Solution for Amazon MSK stellt AWS CloudFormation -Vorlagen bereit, bei denen Daten durch Produzenten, Streaming-Speicher, Verbraucher und Ziele fließen.
- <u>Clickstream Lab mit Apache Flink und Apache Kafka</u>: Ein End-to-End-Lab für Clickstream-Anwendungsfälle mit Amazon Managed Streaming for Apache Kafka als Streaming-Speicher und Managed Service für Apache Flink für Apache Flink-Anwendungen zur Stream-Verarbeitung.
- <u>Amazon Managed Service für Apache Flink Workshop</u>: In diesem Workshop entwickeln Sie eine end-to-end Streaming-Architektur, um Streaming-Daten nahezu in Echtzeit aufzunehmen, zu analysieren und zu visualisieren. Sie haben sich vorgenommen, den Betrieb eines Taxiunternehmens in New York City zu verbessern. Sie analysieren die Telemetriedaten einer Taxiflotte in New York City nahezu in Echtzeit, um deren Flottenbetrieb zu optimieren.
- Lernen Sie Flink kennen: Praktisches Training: Offizielle Apache Flink-Einführungsschulung, die Ihnen den Einstieg in die Entwicklung skalierbarer Streaming-ETL-, Analyse- und ereignisgesteuerter Anwendungen ermöglicht.

Note

Beachten Sie, dass Managed Service für Apache Flink die in dieser Schulung verwendete Apache Flink-Version (1.12) nicht unterstützt. Sie können Flink 1.15.2 in Flink Managed Service für Apache Flink verwenden.

 <u>Apache-Flink-Codebeispiele</u>: Ein GitHub Repository mit einer Vielzahl von Apache-Flink-Anwendungsbeispielen.

Erste Schritte: Flink 1.8.2 - veraltet

1 Note

Die Apache Flink-Versionen 1.6, 1.8 und 1.11 wurden seit über drei Jahren nicht mehr von der Apache Flink-Community unterstützt. Wir planen, diese Versionen in Amazon Managed Service für Apache Flink am 5. November 2024 als veraltet anzusehen. Ab diesem Datum können Sie keine neuen Anwendungen für diese Flink-Versionen erstellen. Sie können bestehende Anwendungen zu diesem Zeitpunkt weiter ausführen. Sie können Ihre Anwendungen mithilfe der Funktion für direkte Versionsupgrades in Amazon Managed Service for Apache Flink statual aktualisieren. Weitere Informationen finden Sie unter. Verwenden Sie direkte Versionsupgrades für Apache Flink

Dieses Thema enthält eine Version des <u>Tutorial: Erste Schritte mit der DataStream API in Managed</u> <u>Service für Apache Flink</u> -Tutorials, die Apache Flink 1.8.2 verwendet.

Themen

- Komponenten der Anwendung Managed Service für Apache Flink
- Voraussetzungen für das Abschließen der Übungen
- <u>Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers</u>
- Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)
- Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung
- Schritt 4: Bereinigen von AWS Ressourcen

Komponenten der Anwendung Managed Service für Apache Flink

Zur Verarbeitung von Daten verwendet Ihre Managed Service für Apache Flink-Anwendung eine Java/Apache Maven- oder Scala-Anwendung, die mithilfe der Apache Flink-Laufzeit Eingaben verarbeitet und Ausgaben erzeugt.

Eine Anwendung Managed Service für Apache Flink besteht aus folgenden Komponenten:

- Runtime-Eigenschaften: Sie können Runtime-Eigenschaften verwenden, um Ihre Anwendung zu konfigurieren, ohne Ihren Anwendungscode neu kompilieren zu müssen.
- Quelle: Die Anwendung verwendet Daten mithilfe einer Quelle. Ein Quell-Connector liest Daten aus einem Kinesis Data Stream, einem Amazon S3-Bucket usw. Weitere Informationen finden Sie unter <u>Fügen Sie Streaming-Datenquellen hinzu</u>.
- Operatoren: Die Anwendung verarbeitet Daten mithilfe eines oder mehrerer Operatoren. Ein Operator kann Daten transformieren, anreichern oder aggregieren. Weitere Informationen finden Sie unter <u>Operatoren</u>.
- Senke: Die Anwendung erzeugt Daten f
 ür externe Quellen mithilfe von Senken. Ein Senken-Connector schreibt Daten in einen Kinesis Data Stream, einen Firehose-Stream, einen Amazon S3 S3-Bucket usw. Weitere Informationen finden Sie unter <u>Schreiben Sie Daten mithilfe von Senken</u>.

Nachdem Sie Ihren Anwendungscode erstellt, kompiliert und verpackt haben, laden Sie das Codepaket in einen Amazon Simple Storage Service (Amazon S3)-Bucket hoch. Anschließend erstellen Sie eine Managed Service für Apache Flink-Anwendung. Sie übergeben den Speicherort des Codepakets, einen Kinesis Data Stream als Streaming-Datenquelle und in der Regel einen Streaming- oder Dateispeicherort, der die verarbeiteten Daten der Anwendung empfängt.

Voraussetzungen für das Abschließen der Übungen

Zur Durchführung der Schritte in dieser Anleitung benötigen Sie Folgendes:

- Java Development Kit (JDK), Version 8. Legen Sie die JAVA_HOME Umgebungsvariable so fest, dass sie auf Ihren JDK-Installationsspeicherort weist.
- Um den Apache Flink Kinesis Connector in diesem Tutorial verwenden zu können, müssen Sie Apache Flink herunterladen und installieren. Details hierzu finden Sie unter <u>Verwenden des Apache</u> Flink Kinesis Streams-Konnektor mit früheren Apache Flink-Versionen.
- Wir empfehlen die Verwendung einer Entwicklungsumgebung (wie <u>Eclipse Java Neon</u> oder <u>IntelliJ</u> Idea), um Ihre Anwendung zu entwickeln und zu kompilieren.

- Git-Client. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben.
- <u>Apache Maven-Compiler-Plugin</u>. Maven muss sich in Ihrem Arbeitspfad befinden. Zum Testen Ihrer Apache Maven-Installation geben Sie Folgendes ein:

\$ mvn -version

Um zu beginnen, gehen Sie zu <u>Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines</u> Administrator-Benutzers.

Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers

Registrieren bei AWS-Konto

Wenn Sie kein haben AWS-Konto, führen Sie die folgenden Schritte zum Erstellen durch.

Sich für ein () registrieren AWS-Konto

- 1. Öffnen Sie https://portal.aws.amazon.com/billing/die Anmeldung.
- 2. Folgen Sie den Online-Anweisungen.

Bei der Anmeldung müssen Sie auch einen Telefonanruf entgegennehmen und einen Verifizierungscode über die Telefontasten eingeben.

Wenn Sie sich für eine anmelden AWS-Konto, Root-Benutzer des AWS-Kontoswird eine erstellt. Der Root-Benutzer hat Zugriff auf alle AWS-Services und Ressourcen des Kontos. Als bewährte Sicherheitsmethode weisen Sie einem Administratorbenutzer Administratorzugriff zu und verwenden Sie nur den Root-Benutzer, um Aufgaben auszuführen, die Root-Benutzerzugriff erfordern.

AWS sendet Ihnen eine Bestätigungs-E-Mail, sobald die Registrierung abgeschlossen ist. Sie können jederzeit Ihre aktuelle Kontoaktivität ansehen und Ihr Konto verwalten. Rufen Sie dazu auf und klicken Sie auf <u>https://aws.amazon.comMy</u> Account (Mein Konto).

Erstellen eines Benutzers mit Administratorzugriff

Nachdem Sie sich für ein angemeldet haben AWS-Konto, sichern Sie Ihr Root-Benutzer des AWS-Kontos AWS IAM Identity Center, aktivieren Sie und erstellen Sie einen administrativen Benutzer, damit Sie nicht den Root-Benutzer für alltägliche Aufgaben verwenden.

Sichern Sie Ihre Root-Benutzer des AWS-Kontos

 Melden Sie sich bei der <u>AWS Management Console</u>als Kontoinhaber an, indem Sie Root user (Stammbenutzer) auswählen und die AWS-Konto E-Mail-Adresse Ihres eingeben. Geben Sie auf der nächsten Seite Ihr Passwort ein.

Hilfe bei der Anmeldung mit dem Root-Benutzer finden Sie unter <u>Anmelden als Root-Benutzer</u> im AWS-Anmeldung Benutzerhandbuch zu.

2. Aktivieren Sie die Multi-Faktor-Authentifizierung (MFA) für den Root-Benutzer.

Anweisungen dazu finden Sie unter <u>Aktivieren eines virtuellen MFA-Geräts für den AWS-Konto</u> <u>Root-Benutzer Ihres (Konsole)</u> im IAM-Benutzerhandbuch.

Erstellen eines Benutzers mit Administratorzugriff

1. Aktivieren Sie das IAM Identity Center.

Anweisungen finden Sie unter <u>Aktivieren AWS IAM Identity Center</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Gewähren Sie einem Administratorbenutzer im IAM Identity Center Benutzerzugriff.

Ein Tutorial zur Verwendung von IAM-Identity-Center-Verzeichnis als Identitätsquelle finden Sie IAM-Identity-Center-Verzeichnis im Benutzerhandbuch unter <u>Benutzerzugriff mit der</u> <u>Standardeinstellung konfigurieren</u>.AWS IAM Identity Center

Anmelden als Administratorbenutzer

 Um sich mit Ihrem IAM-Identity-Center-Benutzer anzumelden, verwenden Sie die Anmelde-URL, die an Ihre E-Mail-Adresse gesendet wurde, als Sie den IAM-Identity-Center-Benutzer erstellt haben.

Hilfestellung zur Anmeldung mit einem IAM-Identity-Center-Benutzer finden Sie unter <u>Anmelden</u> beim AWS -Zugangsportal im AWS-Anmeldung Benutzerhandbuch zu.

Weiteren Benutzern Zugriff zuweisen

1. Erstellen Sie im IAM-Identity-Center einen Berechtigungssatz, der den bewährten Vorgehensweisen für die Anwendung von geringsten Berechtigungen folgt. Anweisungen hierzu finden Sie unter <u>Berechtigungssatz erstellen</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Weisen Sie Benutzer einer Gruppe zu und weisen Sie der Gruppe dann Single Sign-On-Zugriff zu.

Eine genaue Anleitung finden Sie unter <u>Gruppen hinzufügen</u> im AWS IAM Identity Center Benutzerhandbuch.

Erteilen programmgesteuerten Zugriffs

Benutzer benötigen programmgesteuerten Zugriff, wenn sie AWS außerhalb der AWS Management Console mit interagieren möchten. Die Vorgehensweise, um programmgesteuerten Zugriff zu gewähren, hängt davon ab, welcher Benutzertyp auf zugreift AWS.

Um Benutzern programmgesteuerten Zugriff zu gewähren, wählen Sie eine der folgenden Optionen.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
Mitarbeiteridentität (Benutzer, die in IAM Identity Center verwaltet werden)	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen zu den AWS CLI finden Sie <u>unter</u> Konfiguration der AWS CLI zur Verwendung AWS IAM Identity Center im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs Tools und AWS APIs finden Sie unter IAM Identity Center-Authentifizierung im Referenzhandbuch AWS

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
		SDKs und im Tools-Ref erenzhandbuch.
IAM	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	Folgen Sie den Anweisungen unter <u>Verwenden temporäre</u> <u>r Anmeldeinformationen mit</u> <u>AWS Ressourcen</u> im IAM- Benutzerhandbuch.
IAM	(Nicht empfohlen) Verwenden Sie langfristige Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen dazu AWS CLI finden Sie unter <u>Authentifizierung mithilfe</u> von IAM-Benutzeranmeld einformationen im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs und Tools finden Sie unter <u>Authentifizieren mit</u> <u>langfristigen Anmeldein</u> formationen im Referenzh andbuch AWS SDKs und im Tools-Referenzhandbuch. Weitere Informationen finden Sie unter <u>Verwaltun</u> g von Zugriffsschlüsseln für <u>IAM-Benutzer</u> im IAM-Benut zerhandbuch. AWS APIs

Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)

In diesem Schritt laden Sie die herunter und konfigurieren sie für die AWS CLI Verwendung mit Amazon Managed Service für Apache Flink.

Note

Bei allen Erste-Schritte-Übungen in diesem Handbuch wird davon ausgegangen, dass Sie in Ihrem Konto Administrator-Anmeldeinformationen (adminuser) verwenden, um die Operationen auszuführen.

1 Note

Wenn Sie die bereits AWS CLI installiert haben, müssen Sie möglicherweise ein Upgrade durchführen, um die neuesten Funktionen zu erhalten. Weitere Informationen finden Sie unter <u>Installieren der AWS Command Line Interface</u> im AWS Command Line Interface - Benutzerhandbuch. Führen Sie den folgenden Befehl aus AWS CLI, um die Version von zu überprüfen:

aws --version

Für die Übungen in diesem Tutorial ist die folgende AWS CLI Version oder höher erforderlich:

```
aws-cli/1.16.63
```

Um das einzurichten AWS CLI

- 1. Herunterladen und Konfigurieren von AWS CLI. Eine Anleitung finden Sie unter den folgenden Themen im AWS Command Line Interface -Benutzerhandbuch:
 - Installieren des AWS Command Line Interface
 - Konfigurieren von AWS CLI
- Fügen Sie ein benanntes Profil für den Administratorbenutzer in der AWS CLI config Datei hinzu. Verwenden Sie dieses Profil beim Ausführen von AWS CLI -Befehlen. Weitere Informationen zu benannten Profilen finden Sie unter <u>Benannte Profile</u> im AWS Command Line Interface Benutzerhandbuch.

[profile adminuser]
aws_access_key_id = adminuser access key ID
aws_secret_access_key = adminuser secret access key
region = aws-region

Eine Liste der verfügbaren Regionen finden Sie unter <u>Regionen und Endpunkte</u> in Allgemeine Amazon Web Services-Referenz.

Note

Der Beispielcode und die Befehle in diesem Tutorial verwenden die Region USA West (Oregon). Um eine andere AWS Region zu verwenden, ändern Sie die Region im Code und in den Befehlen für dieses Tutorial in die Region, die Sie verwenden möchten.

3. Überprüfen Sie die Einrichtung, indem Sie die folgenden Hilfebefehle in die Befehlszeile eingeben:

aws help

Nachdem Sie ein AWS -Konto und die einrichten AWS CLI, können Sie die nächste Übung ausprobieren, in der Sie eine Beispielanwendung konfigurieren und die end-to-end Einrichtung testen.

Nächster Schritt

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink mit Datenströmen als Quelle und Senke.

Dieser Abschnitt enthält die folgenden Schritte:

- Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Nächster Schritt

Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream). Ihre Anwendung verwendet diese Streams für die Quell- und Ziel-Streams der Anwendung.

Sie können diese Streams mithilfe der Amazon-Kinesis-Konsole oder des folgenden AWS CLI -Befehls erstellen. Anweisungen für die Konsole finden Sie unter <u>Erstellen und Aktualisieren von</u> Datenströmen im Amazon Kinesis Data Streams Entwicklerhandbuch.

So erstellen Sie die Daten-Streams (AWS CLI)

 Verwenden Sie den folgenden Amazon Kinesis create-stream AWS CLI -Befehl, um den ersten Stream (ExampleInputStream) zu erstellen.

```
$ aws kinesis create-stream \
--stream-name ExampleInputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

 Um den zweiten Stream zu erstellen, den die Anwendung zum Schreiben der Ausgabe verwendet, führen Sie denselben Befehl aus und ändern den Stream-Namen in ExampleOutputStream.

```
$ aws kinesis create-stream \
--stream-name ExampleOutputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        "EVENT_TIME": datetime.datetime.now().isoformat(),
        "TICKER": random.choice(["AAPL", "AMZN", "MSFT", "INTC", "TBV"]),
        "PRICE": round(random.random() * 100, 2),
   }
def generate(stream_name, kinesis_client):
   while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name, Data=json.dumps(data),
PartitionKey="partitionkey"
        )
if __name__ == "__main__":
    generate(STREAM_NAME, boto3.client("kinesis"))
```

2. Im weiteren Verlauf des Tutorials führen Sie das stock.py-Skript zum Senden von Daten an die Anwendung aus.

\$ python stock.py

Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

1. Klonen Sie das Remote-Repository, indem Sie den folgenden Befehl verwenden:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/ GettingStarted_1_8 Verzeichnis.

Beachten Sie Folgendes zum Anwendungscode:

- Eine <u>Project Object Model (pom.xml)</u> Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.
- Die BasicStreamingJob.java-Datei enthält die main-Methode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

- Ihre Anwendung erstellt Quell- und Senkenkonnektoren für den Zugriff auf externe Ressourcen, indem ein StreamExecutionEnvironment-Objekt verwendet wird.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit statischen Eigenschaften. Zum Verwenden dynamischer Anwendungseigenschaften verwenden Sie die Methoden createSourceFromApplicationProperties und createSinkFromApplicationProperties, um die Konnektoren zu erstellen. Diese Methoden lesen die Eigenschaften der Anwendung zum Konfigurieren der Konnektoren.

Weitere Informationen zu Laufzeiteigenschaften finden Sie unter Verwenden Sie Laufzeiteigenschaften.

Kompilieren Sie den Anwendungscode

In diesem Abschnitt verwenden Sie den Apache Maven-Compiler zum Erstellen des Java-Codes für die Anwendung. Weitere Informationen zum Installieren von Apache Maven und des Java Development Kit (JDK) finden Sie unter Voraussetzungen für das Abschließen der Übungen.

Note

Um den Kinesis-Connector mit Versionen von Apache Flink vor 1.11 verwenden zu können, müssen Sie Apache Maven herunterladen, erstellen und installieren. Weitere Informationen finden Sie unter <u>the section called "Verwenden des Apache Flink Kinesis Streams-Konnektor</u> mit früheren Apache Flink-Versionen".

Kompilieren des Anwendungscodes

- 1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code auf zwei Arten kompilieren und packen:
 - Verwenden Sie das Befehlszeilen-Maven-Tool. Erstellen Sie Ihre JAR-Datei, indem Sie den folgenden Befehl in dem Verzeichnis ausführen, das die pom.xml-Datei enthält:

```
mvn package -Dflink.version=1.8.2
```

• Verwenden Sie Ihre Entwicklungsumgebung. Weitere Informationen finden Sie in der Dokumentation Ihrer Entwicklungsumgebung.

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken aus Java 1.8. Stellen Sie sicher, dass die Java-Version Ihres Projekts 1.8 ist.

Sie können Ihr Paket als JAR-Datei hochladen oder komprimieren und als ZIP-Datei hochladen. Wenn Sie Ihre Anwendung mit dem erstellen AWS CLI, geben Sie Ihren Codeinhaltstyp (JAR oder ZIP) an.

2. Wenn während der Erstellung Fehler aufgetreten sind, überprüfen Sie, ob Ihre JAVA_HOME-Umgebungsvariable richtig eingestellt ist.

Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/aws-kinesis-analytics-java-apps-1.0.jar

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt erstellen Sie einen Amazon Simple Storage Service (Amazon S3)-Bucket und laden Ihren Anwendungscode hoch.

So laden Sie den Anwendungscode hoch

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Create Bucket (Bucket erstellen) aus.
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- 7. Wählen Sie in der Amazon S3 S3-Konsole den *<username>* Bucket ka-app-code- und wählen Sie Upload aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben. Wählen Sie Weiter aus.
- 9. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder AWS CLI erstellen und ausführen.

1 Note

Wenn Sie die Anwendung mithilfe der Konsole erstellen, werden die Ressourcen AWS Identity and Access Management (IAM) und Amazon CloudWatch Logs für Sie erstellt. Bei der Erstellung der AWS CLI erstellen Sie separat die folgenden Ressourcen.

Themen

- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- Geben Sie auf der Seite Managed Service f
 ür Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My java test app ein.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.
 - Behalten Sie im Pulldown-Menü die Option Apache Flink 1.8 (empfohlene Version) bei.

- Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
            "s3:Get0bject",
            "s1:Get
```

```
"s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-username/aws-kinesis-analytics-java-
apps-1.0.jar"
            1
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ]
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ]
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert aws-kinesis-analytics-javaapps-1.0.jar ein.
- Wählen Sie unter Zugriff auf Anwendungsressourcen f
 ür Zugriffsberechtigungen die Option IAM-Rolle kinesis-analytics-MyApplication-us-west-2 erstellen/aktualisieren aus.
- 4. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	flink.inputstream. initpos	LATEST
ProducerConfigProp erties	aws.region	us-west-2
ProducerConfigProp erties	AggregationEnabled	false

- 5. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 6. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 7. Wählen Sie Aktualisieren.

1 Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

- 1. Wählen Sie auf der MyApplicationSeite die Option Ausführen aus. Bestätigen Sie die Aktion.
- 2. Wenn die Anwendung ausgeführt wird, aktualisieren Sie die Seite. Die Konsole zeigt den Application graph (Anwendungs-Graph) an.

Stoppt die Anwendung

Wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Aktualisieren der Anwendung

Mithilfe der Konsole können Sie Anwendungseinstellungen wie beispielsweise Anwendungseigenschaften, Überwachungseinstellungen und den Speicherort oder den Dateinamen der JAR-Anwendungsdatei aktualisieren. Außerdem können Sie die JAR-Anwendungsdatei erneut aus dem Amazon-S3-Bucket laden, wenn Sie den Anwendungscode aktualisieren müssen.

Wählen Sie auf der MyApplicationSeite Configure aus. Aktualisieren Sie die Anwendungseinstellungen und klicken Sie auf Aktualisieren.

Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

In diesem Abschnitt verwenden Sie, AWS CLI um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen. Anwendungen von Managed Service für Apache Flink verwendet den kinesisanalyticsv2 AWS CLI Befehl, um Managed-Service-für-Apache-Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

Note

Sie müssen eine Berechtigungsrichtlinie und eine Rolle für Ihre Anwendung erstellen. Wenn Sie diese IAM-Ressourcen nicht erstellen, kann Ihre Anwendung nicht auf ihre Daten- und Protokollstreams zugreifen.

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die read-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die write-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie *username* durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "S3",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": ["arn:aws:s3:::ka-app-code-username",
                "arn:aws:s3:::ka-app-code-username/*"
            ]
        },
        {
            "Sid": "ReadInputStream",
```

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie im IAM-Benutzerhandbuch.

Note

Um auf andere Amazon-Services zuzugreifen, können Sie AWS SDK für Java verwenden. Managed Service für Apache Flink setzt die vom SDK benötigten Anmeldeinformationen automatisch auf die der IAM-Rolle für die Dienstausführung, die mit Ihrer Anwendung verknüpft ist. Es sind keine weiteren Schritte erforderlich.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Roles (Rollen) und Create Role (Rolle erstellen) aus.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus. Wählen Sie unter Select your use case (Wählen Sie Ihren Anwendungsfall aus) die Option Kinesis Analytics aus.

Wählen Sie Weiter: Berechtigungen aus.

- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 5. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle.

6. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt erstellt haben, <u>the section called "Erstellen einer</u> <u>Berechtigungsrichtlinie"</u>.

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.
- d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter Erstellen einer IAM-Rolle (Konsole) im IAM-Benutzerhandbuch.

Erstellen Sie die Anwendung Managed Service für Apache Flink

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (*username*) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (*012345678901*) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
{
    "ApplicationName": "test",
    "ApplicationDescription": "my java test app",
    "RuntimeEnvironment": "FLINK-1_8",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "aws-kinesis-analytics-java-apps-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
       },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "flink.stream.initpos" : "LATEST",
                    "aws.region" : "us-west-2",
                    "AggregationEnabled" : "false"
               }
            },
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2"
```
}

}

```
)
}
}
```

2. Führen Sie die <u>CreateApplication</u>-Aktion mit der vorherigen Anforderung zum Erstellen der Anwendung aus:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://
create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

Starten der Anwendung

In diesem Abschnitt verwenden Sie die <u>StartApplication</u>-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{
    "ApplicationName": "test",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
            }
    }
}
```

2. Führen Sie die <u>StartApplication</u>-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die <u>StopApplication</u>-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "test"
}
```

2. Führen Sie die <u>StopApplication</u>-Aktion mit der folgenden Anforderung zum Stoppen der Anwendung aus:

```
aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json
```

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter<u>the section called "Anwendungsprotokollierung in Managed</u> Service für Apache Flink einrichten".

Aktualisieren von Umgebungseigenschaften

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.



2. Führen Sie die <u>UpdateApplication</u>-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die <u>UpdateApplication</u> AWS CLI Aktion.

Note

Um eine neue Version des Anwendungscodes mit demselben Dateinamen zu laden, müssen Sie die neue Objektversion angeben. Weitere Informationen zur Verwendung von Amazon S3-Objektversionen finden Sie unter Versionsverwaltung aktivieren oder deaktivieren.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication dabei denselben Amazon S3 S3-Bucket und Objektnamen sowie die neue Objektversion an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (*<username>*) mit dem Suffix, das Sie im -Abschnitt ausgewählt haben. <u>the section</u> <u>called "Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams"</u>

Nächster Schritt

Schritt 4: Bereinigen von AWS Ressourcen

Schritt 4: Bereinigen von AWS Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Erste Schritte erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- So löschen Sie Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie Konfigurieren aus.
- 4. Wählen Sie im Abschnitt Snapshots die Option Deaktivieren und anschließend Aktualisieren aus.
- 5. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie den Löschvorgang.

So löschen Sie Kinesis Data Streams

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.

- 2. Wählen Sie den <username>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Erste Schritte: Flink 1.6.2 - veraltet

1 Note

Die Apache Flink-Versionen 1.6, 1.8 und 1.11 wurden seit über drei Jahren nicht mehr von der Apache Flink-Community unterstützt. Wir planen, diese Versionen in Amazon Managed Service für Apache Flink am 5. November 2024 als veraltet anzusehen. Ab diesem Datum können Sie keine neuen Anwendungen für diese Flink-Versionen erstellen. Sie können bestehende Anwendungen zu diesem Zeitpunkt weiter ausführen. Sie können Ihre Anwendungen mithilfe der Funktion für direkte Versionsupgrades in Amazon Managed Service for Apache Flink statual aktualisieren. Weitere Informationen finden Sie unter. Verwenden Sie direkte Versionsupgrades für Apache Flink Dieses Thema enthält eine Version des <u>Tutorial: Erste Schritte mit der DataStream API in Managed</u> <u>Service für Apache Flink</u> -Tutorials, die Apache Flink 1.6.2 verwendet.

Themen

- Komponenten der Anwendung Managed Service für Apache Flink
- Voraussetzungen für das Abschließen der Übungen
- Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers
- Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)
- Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung
- <u>Schritt 4: Bereinigen von AWS Ressourcen</u>

Komponenten der Anwendung Managed Service für Apache Flink

Zur Verarbeitung von Daten verwendet Ihre Managed Service für Apache Flink-Anwendung eine Java/Apache Maven- oder Scala-Anwendung, die mithilfe der Apache Flink-Laufzeit Eingaben verarbeitet und Ausgaben erzeugt.

Ein Managed Service für Apache Flink besteht aus den folgenden Komponenten:

- Runtime-Eigenschaften: Sie können Runtime-Eigenschaften verwenden, um Ihre Anwendung zu konfigurieren, ohne Ihren Anwendungscode neu kompilieren zu müssen.
- Quelle: Die Anwendung verwendet Daten mithilfe einer Quelle. Ein Quell-Connector liest Daten aus einem Kinesis Data Stream, einem Amazon S3-Bucket usw. Weitere Informationen finden Sie unter Fügen Sie Streaming-Datenquellen hinzu.
- Operatoren: Die Anwendung verarbeitet Daten mithilfe eines oder mehrerer Operatoren. Ein Operator kann Daten transformieren, anreichern oder aggregieren. Weitere Informationen finden Sie unter <u>Operatoren</u>.
- Senke: Die Anwendung erzeugt Daten f
 ür externe Quellen mithilfe von Senken. Ein Senken-Connector schreibt Daten in einen Kinesis Data Stream, einen Firehose-Stream, einen Amazon S3 S3-Bucket usw. Weitere Informationen finden Sie unter <u>Schreiben Sie Daten mithilfe von Senken</u>.

Nachdem Sie Ihre Anwendung erstellt, kompiliert und verpackt haben, laden Sie das Codepaket in einen Amazon Simple Storage Service (Amazon S3)-Bucket hoch. Anschließend erstellen Sie eine Managed Service für Apache Flink-Anwendung. Sie übergeben den Speicherort des Codepakets, einen Kinesis Data Stream als Streaming-Datenquelle und in der Regel einen Streaming- oder Dateispeicherort, der die verarbeiteten Daten der Anwendung empfängt.

Voraussetzungen für das Abschließen der Übungen

Zur Durchführung der Schritte in dieser Anleitung benötigen Sie Folgendes:

- Java Development Kit (JDK), Version 8. Legen Sie die JAVA_HOME Umgebungsvariable so fest, dass sie auf Ihren JDK-Installationsspeicherort weist.
- Wir empfehlen die Verwendung einer Entwicklungsumgebung (wie <u>Eclipse Java Neon</u> oder <u>IntelliJ</u> <u>Idea</u>), um Ihre Anwendung zu entwickeln und zu kompilieren.
- Git-Client. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben.
- <u>Apache Maven-Compiler-Plugin</u>. Maven muss sich in Ihrem Arbeitspfad befinden. Zum Testen Ihrer Apache Maven-Installation geben Sie Folgendes ein:

\$ mvn -version

Um zu beginnen, gehen Sie zu <u>Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines</u> Administrator-Benutzers.

Schritt 1: Einrichten eines AWS -Kontos und Erstellen eines Administrator-Benutzers

Registrieren bei AWS-Konto

Wenn Sie kein haben AWS-Konto, führen Sie die folgenden Schritte zum Erstellen durch.

Sich für ein () registrieren AWS-Konto

- 1. Öffnen Sie https://portal.aws.amazon.com/billing/die Anmeldung.
- 2. Folgen Sie den Online-Anweisungen.

Bei der Anmeldung müssen Sie auch einen Telefonanruf entgegennehmen und einen Verifizierungscode über die Telefontasten eingeben.

Wenn Sie sich für eine anmelden AWS-Konto, Root-Benutzer des AWS-Kontoswird eine erstellt. Der Root-Benutzer hat Zugriff auf alle AWS-Services und Ressourcen des Kontos. Als bewährte Sicherheitsmethode weisen Sie einem Administratorbenutzer Administratorzugriff zu und verwenden Sie nur den Root-Benutzer, um Aufgaben auszuführen, die Root-Benutzerzugriff erfordern.

AWS sendet Ihnen eine Bestätigungs-E-Mail, sobald die Registrierung abgeschlossen ist. Sie können jederzeit Ihre aktuelle Kontoaktivität ansehen und Ihr Konto verwalten. Rufen Sie dazu auf und klicken Sie auf https://aws.amazon.comMy Account (Mein Konto).

Erstellen eines Benutzers mit Administratorzugriff

Nachdem Sie sich für ein angemeldet haben AWS-Konto, sichern Sie Ihr Root-Benutzer des AWS-Kontos AWS IAM Identity Center, aktivieren Sie und erstellen Sie einen administrativen Benutzer, damit Sie nicht den Root-Benutzer für alltägliche Aufgaben verwenden.

Sichern Sie Ihre Root-Benutzer des AWS-Kontos

 Melden Sie sich bei der <u>AWS Management Console</u>als Kontoinhaber an, indem Sie Root user (Stammbenutzer) auswählen und die AWS-Konto E-Mail-Adresse Ihres eingeben. Geben Sie auf der nächsten Seite Ihr Passwort ein.

Hilfe bei der Anmeldung mit dem Root-Benutzer finden Sie unter <u>Anmelden als Root-Benutzer</u> im AWS-Anmeldung Benutzerhandbuch zu.

2. Aktivieren Sie die Multi-Faktor-Authentifizierung (MFA) für den Root-Benutzer.

Anweisungen dazu finden Sie unter <u>Aktivieren eines virtuellen MFA-Geräts für den AWS-Konto</u> <u>Root-Benutzer Ihres (Konsole)</u> im IAM-Benutzerhandbuch.

Erstellen eines Benutzers mit Administratorzugriff

1. Aktivieren Sie das IAM Identity Center.

Anweisungen finden Sie unter <u>Aktivieren AWS IAM Identity Center</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Gewähren Sie einem Administratorbenutzer im IAM Identity Center Benutzerzugriff.

Ein Tutorial zur Verwendung von IAM-Identity-Center-Verzeichnis als Identitätsquelle finden Sie IAM-Identity-Center-Verzeichnis im Benutzerhandbuch unter <u>Benutzerzugriff mit der</u> <u>Standardeinstellung konfigurieren</u>.AWS IAM Identity Center

Anmelden als Administratorbenutzer

 Um sich mit Ihrem IAM-Identity-Center-Benutzer anzumelden, verwenden Sie die Anmelde-URL, die an Ihre E-Mail-Adresse gesendet wurde, als Sie den IAM-Identity-Center-Benutzer erstellt haben.

Hilfestellung zur Anmeldung mit einem IAM-Identity-Center-Benutzer finden Sie unter <u>Anmelden</u> beim AWS -Zugangsportal im AWS-Anmeldung Benutzerhandbuch zu.

Weiteren Benutzern Zugriff zuweisen

1. Erstellen Sie im IAM-Identity-Center einen Berechtigungssatz, der den bewährten Vorgehensweisen für die Anwendung von geringsten Berechtigungen folgt.

Anweisungen hierzu finden Sie unter <u>Berechtigungssatz erstellen</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Weisen Sie Benutzer einer Gruppe zu und weisen Sie der Gruppe dann Single Sign-On-Zugriff zu.

Eine genaue Anleitung finden Sie unter <u>Gruppen hinzufügen</u> im AWS IAM Identity Center Benutzerhandbuch.

Erteilen programmgesteuerten Zugriffs

Benutzer benötigen programmgesteuerten Zugriff, wenn sie AWS außerhalb der AWS Management Console mit interagieren möchten. Die Vorgehensweise, um programmgesteuerten Zugriff zu gewähren, hängt davon ab, welcher Benutzertyp auf zugreift AWS.

Um Benutzern programmgesteuerten Zugriff zu gewähren, wählen Sie eine der folgenden Optionen.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
Mitarbeiteridentität (Benutzer, die in IAM Identity Center verwaltet werden)	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
		 Informationen zu den AWS CLI finden Sie <u>unter</u> Konfiguration der AWS CLI zur Verwendung AWS IAM Identity Center im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs Tools und AWS APIs finden Sie unter <u>IAM Identity</u> <u>Center-Authentifizierung</u> im Referenzhandbuch AWS SDKs und im Tools-Ref erenzhandbuch.
IAM	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	Folgen Sie den Anweisungen unter <u>Verwenden temporäre</u> <u>r Anmeldeinformationen mit</u> <u>AWS Ressourcen</u> im IAM- Benutzerhandbuch.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
	(Nicht empfohlen) Verwenden Sie langfristige Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen dazu AWS CLI finden Sie unter <u>Authentifizierung mithilfe</u> von IAM-Benutzeranmeld einformationen im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs und Tools finden Sie unter <u>Authentifizieren mit</u> langfristigen Anmeldein formationen im Referenzh andbuch AWS SDKs und im Tools-Referenzhandbuch. Weitere Informationen finden Sie unter <u>Verwaltun</u> g von Zugriffsschlüsseln für IAM-Benutzer im IAM-Benut zerhandbuch. AWS APIs

Schritt 2: Einrichten der AWS Command Line Interface (AWS CLI)

In diesem Schritt laden Sie die herunter und konfigurieren sie für AWS CLI die Verwendung mit einem Managed Service für Apache Flink.

Note

Bei allen Erste-Schritte-Übungen in diesem Handbuch wird davon ausgegangen, dass Sie in Ihrem Konto Administrator-Anmeldeinformationen (adminuser) verwenden, um die Operationen auszuführen.

Note

Wenn Sie die bereits AWS CLI installiert haben, müssen Sie möglicherweise ein Upgrade durchführen, um die neuesten Funktionen zu erhalten. Weitere Informationen finden Sie unter <u>Installieren der AWS Command Line Interface</u> im AWS Command Line Interface - Benutzerhandbuch. Führen Sie den folgenden Befehl aus AWS CLI, um die Version von zu überprüfen:

aws --version

Für die Übungen in diesem Tutorial ist die folgende AWS CLI Version oder höher erforderlich:

aws-cli/1.16.63

Um das einzurichten AWS CLI

- 1. Herunterladen und Konfigurieren von AWS CLI. Eine Anleitung finden Sie unter den folgenden Themen im AWS Command Line Interface -Benutzerhandbuch:
 - Installieren des AWS Command Line Interface
 - Konfigurieren von AWS CLI
- Fügen Sie ein benanntes Profil für den Administratorbenutzer in der AWS CLI config Datei hinzu. Verwenden Sie dieses Profil beim Ausführen von AWS CLI -Befehlen. Weitere Informationen zu benannten Profilen finden Sie unter <u>Benannte Profile</u> im AWS Command Line Interface Benutzerhandbuch.

```
[profile adminuser]
aws_access_key_id = adminuser access key ID
aws_secret_access_key = adminuser secret access key
```

region = aws-region

Eine Liste der verfügbaren AWS Regionen finden Sie unter <u>Regionen und Endpunkte</u> in der Allgemeine Amazon Web Services-Referenz.

Note

Der Beispielcode und die Befehle in diesem Tutorial verwenden die Region USA West (Oregon). Um eine andere Region zu verwenden, ändern Sie die Region im Code und in den Befehlen für dieses Tutorial in die Region, die Sie verwenden möchten.

3. Überprüfen Sie die Einrichtung, indem Sie die folgenden Hilfebefehle in die Befehlszeile eingeben:

aws help

Nachdem Sie ein AWS -Konto und die einrichten AWS CLI, können Sie die nächste Übung ausprobieren, in der Sie eine Beispielanwendung konfigurieren und die end-to-end Einrichtung testen.

Nächster Schritt

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

Schritt 3: Erstellen und Ausführen eines Managed Service für die Apache Flink-Anwendung

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink mit Datenströmen als Quelle und Senke.

Dieser Abschnitt enthält die folgenden Schritte:

- Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und f
 ühren Sie die Anwendung Managed Service f
 ür Apache Flink aus

Managed Service für Apache Flink

Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream). Ihre Anwendung verwendet diese Streams für die Quell- und Ziel-Streams der Anwendung.

Sie können diese Streams mithilfe der Amazon-Kinesis-Konsole oder des folgenden AWS CLI -Befehls erstellen. Anweisungen für die Konsole finden Sie unter <u>Erstellen und Aktualisieren von</u> Datenströmen im Amazon Kinesis Data Streams Entwicklerhandbuch.

So erstellen Sie die Daten-Streams (AWS CLI)

 Verwenden Sie den folgenden Amazon Kinesis create-stream AWS CLI -Befehl, um den ersten Stream (ExampleInputStream) zu erstellen.

```
$ aws kinesis create-stream \
--stream-name ExampleInputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

 Um den zweiten Stream zu erstellen, den die Anwendung zum Schreiben der Ausgabe verwendet, führen Sie denselben Befehl aus und ändern den Stream-Namen in ExampleOutputStream.

```
$ aws kinesis create-stream \
--stream-name ExampleOutputStream \
--shard-count 1 \
--region us-west-2 \
--profile adminuser
```

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        "EVENT_TIME": datetime.datetime.now().isoformat(),
        "TICKER": random.choice(["AAPL", "AMZN", "MSFT", "INTC", "TBV"]),
        "PRICE": round(random.random() * 100, 2),
    }
def generate(stream_name, kinesis_client):
    while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name, Data=json.dumps(data),
 PartitionKey="partitionkey"
        )
if ___name___ == "___main___":
    generate(STREAM_NAME, boto3.client("kinesis"))
```

2. Im weiteren Verlauf des Tutorials führen Sie das stock.py-Skript zum Senden von Daten an die Anwendung aus.

\$ python stock.py

Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

1. Klonen Sie das Remote-Repository, indem Sie den folgenden Befehl verwenden:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/ GettingStarted_1_6 Verzeichnis.

Beachten Sie Folgendes zum Anwendungscode:

- Eine <u>Project Object Model (pom.xml)</u> Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.
- Die BasicStreamingJob.java-Datei enthält diemain -Methode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

- Ihre Anwendung erstellt Quell- und Senkenkonnektoren f
 ür den Zugriff auf externe Ressourcen, indem ein StreamExecutionEnvironment-Objekt verwendet wird.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit statischen Eigenschaften. Zum Verwenden dynamischer Anwendungseigenschaften verwenden Sie die Methoden createSourceFromApplicationProperties und createSinkFromApplicationProperties, um die Konnektoren zu erstellen. Diese Methoden lesen die Eigenschaften der Anwendung zum Konfigurieren der Konnektoren.

Weitere Informationen zu Laufzeiteigenschaften finden Sie unter <u>Verwenden Sie</u> Laufzeiteigenschaften.

Kompilieren Sie den Anwendungscode

In diesem Abschnitt verwenden Sie den Apache Maven-Compiler zum Erstellen des Java-Codes für die Anwendung. Weitere Informationen zum Installieren von Apache Maven und des Java Development Kit (JDK) finden Sie unter Voraussetzungen für das Abschließen der Übungen.

1 Note

Zur Nutzung des Kinesis-Konnektors für Versionen von Apache Flink vor 1.11, müssen Sie den Quellcode für den Konnektor herunterladen und ihn erstellen. Einzelheiten dazu finden Sie in der Apache-Flink-Dokumentation.

Kompilieren des Anwendungscodes

- 1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code auf zwei Arten kompilieren und packen:
 - Verwenden Sie das Befehlszeilen-Maven-Tool. Erstellen Sie Ihre JAR-Datei, indem Sie den folgenden Befehl in dem Verzeichnis ausführen, das die pom.xml-Datei enthält:

mvn package

1 Note

Der Parameter -Dflink.version ist für Managed Service für Apache Flink Laufzeit Version 1.0.1 nicht erforderlich; er ist nur für Version 1.1.0 und höher erforderlich. Weitere Informationen finden Sie unter <u>the section called "Geben Sie die Apache Flink-</u> Version Ihrer Anwendung an".

• Verwenden Sie Ihre Entwicklungsumgebung. Weitere Informationen finden Sie in der Dokumentation Ihrer Entwicklungsumgebung.

Sie können Ihr Paket als JAR-Datei hochladen oder komprimieren und als ZIP-Datei hochladen. Wenn Sie Ihre Anwendung mit dem erstellen AWS CLI, geben Sie Ihren Codeinhaltstyp (JAR oder ZIP) an.

2. Wenn während der Erstellung Fehler aufgetreten sind, überprüfen Sie, ob Ihre JAVA_HOME-Umgebungsvariable richtig eingestellt ist.

Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/aws-kinesis-analytics-java-apps-1.0.jar

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt erstellen Sie einen Amazon Simple Storage Service (Amazon S3)-Bucket und laden Ihren Anwendungscode hoch.

So laden Sie den Anwendungscode hoch

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Create Bucket (Bucket erstellen) aus.
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben. Wählen Sie Weiter aus.
- 9. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert. Wählen Sie Weiter aus.
- Lassen Sie im Schritt Eigenschaften festlegen die Einstellungen unverändert. Klicken Sie auf Upload.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder AWS CLI erstellen und ausführen.

1 Note

Wenn Sie die Anwendung mithilfe der Konsole erstellen, werden die Ressourcen AWS Identity and Access Management (IAM) und Amazon CloudWatch Logs für Sie erstellt. Bei der Erstellung der AWS CLI erstellen Sie separat die folgenden Ressourcen.

Themen

- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My java test app ein.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.

Note

Managed Service für Apache Flink verwendet Apache Flink Version 1.8.2 oder 1.6.2.

- Ändern Sie den Versions-Pulldown auf Apache Flink 1.6.
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

1 Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
               "s3:GetObject",
               "s3:GetObject",
               "s3:GetObjectVersion"
        ],
        "Resource": [
               "arn:aws:s3::::ka-app-code-username/java-getting-started-1.0.jar"
        ]
```

```
},
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ٦
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ٦
        },
        ſ
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **java-getting-started-1.0.jar** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	flink.inputstream. initpos	LATEST
ProducerConfigProp erties	aws.region	us-west-2
ProducerConfigProp erties	AggregationEnabled	false

- 5. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 6. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 7. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

- 1. Wählen Sie auf der MyApplicationSeite die Option Ausführen aus. Bestätigen Sie die Aktion.
- 2. Wenn die Anwendung ausgeführt wird, aktualisieren Sie die Seite. Die Konsole zeigt den Application graph (Anwendungs-Graph) an.

Stoppt die Anwendung

Wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Aktualisieren der Anwendung

Mithilfe der Konsole können Sie Anwendungseinstellungen wie beispielsweise Anwendungseigenschaften, Überwachungseinstellungen und den Speicherort oder den Dateinamen der JAR-Anwendungsdatei aktualisieren. Außerdem können Sie die JAR-Anwendungsdatei erneut aus dem Amazon-S3-Bucket laden, wenn Sie den Anwendungscode aktualisieren müssen.

Wählen Sie auf der MyApplicationSeite Configure aus. Aktualisieren Sie die Anwendungseinstellungen und klicken Sie auf Aktualisieren.

Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

In diesem Abschnitt verwenden Sie, AWS CLI um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen. Anwendungen von Managed Service für Apache Flink verwendet den kinesisanalyticsv2 AWS CLI Befehl, um Managed-Service-für-Apache-Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die read-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die write-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie *username* durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "S3",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": ["arn:aws:s3:::ka-app-code-username",
                "arn:aws:s3:::ka-app-code-username/*"
            ]
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
```

}

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie im IAM-Benutzerhandbuch.

Note

]

Um auf andere Amazon-Services zuzugreifen, können Sie AWS SDK für Java verwenden. Managed Service für Apache Flink setzt die vom SDK benötigten Anmeldeinformationen automatisch auf die der IAM-Rolle für die Dienstausführung, die mit Ihrer Anwendung verknüpft ist. Es sind keine weiteren Schritte erforderlich.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Roles (Rollen) und Create Role (Rolle erstellen) aus.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus. Wählen Sie unter Select your use case (Wählen Sie Ihren Anwendungsfall aus) die Option Kinesis Analytics aus.

Wählen Sie Weiter: Berechtigungen aus.

- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 5. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle.

6. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt erstellt haben, <u>the section called "Erstellen einer Berechtigungsrichtlinie"</u>.

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.
- d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter <u>Erstellen einer IAM-Rolle</u> (Konsole) im IAM-Benutzerhandbuch.

Erstellen Sie die Anwendung Managed Service für Apache Flink

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN f
ür die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (*username*) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (*012345678901*) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
{
    "ApplicationName": "test",
    "ApplicationDescription": "my java test app",
    "RuntimeEnvironment": "FLINK-1_6",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "java-getting-started-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "flink.stream.initpos" : "LATEST",
                    "aws.region" : "us-west-2",
                    "AggregationEnabled" : "false"
               }
            },
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2"
               }
            }
         ]
      }
    }
}
```

2. Führen Sie die <u>CreateApplication</u>-Aktion mit der vorherigen Anforderung zum Erstellen der Anwendung aus:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://
create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

Starten der Anwendung

In diesem Abschnitt verwenden Sie die StartApplication-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{
    "ApplicationName": "test",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
            }
        }
}
```

2. Führen Sie die <u>StartApplication</u>-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die <u>StopApplication</u>-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "test"
}
```

2. Führen Sie die <u>StopApplication</u>-Aktion mit der folgenden Anforderung zum Stoppen der Anwendung aus:

```
aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json
```

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter<u>the section called "Anwendungsprotokollierung in Managed</u> Service für Apache Flink einrichten".

Aktualisieren von Umgebungseigenschaften

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.

2. Führen Sie die <u>UpdateApplication</u>-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die <u>UpdateApplication</u> AWS CLI Aktion.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication sie auf. Geben Sie dabei denselben Amazon S3 S3-Bucket und Objektnamen an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (*<username>*) mit dem Suffix, das Sie im -Abschnitt ausgewählt haben. <u>the section</u> <u>called "Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams"</u>

```
"ApplicationName": "test",
"CurrentApplicationVersionId": 1,
"ApplicationConfigurationUpdate": {
```

{

```
"ApplicationCodeConfigurationUpdate": {
    "CodeContentUpdate": {
        "S3ContentLocationUpdate": {
            "BucketARNUpdate": "arn:aws:s3:::ka-app-code-username",
            "FileKeyUpdate": "java-getting-started-1.0.jar"
        }
    }
}
```

Schritt 4: Bereinigen von AWS Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Erste Schritte erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Kinesis-Konsole unter. <u>https://console.aws.amazon.com/kinesis</u>.
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie Konfigurieren aus.
- 4. Wählen Sie im Abschnitt Snapshots die Option Deaktivieren und anschließend Aktualisieren aus.
- 5. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink

- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username*>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiele für frühere Versionen (ältere Versionen) für Managed Service für Apache Flink

1 Note

Aktuelle Beispiele finden Sie unter Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-Anwendungen.

Dieser Abschnitt enthält Beispiele für das Erstellen und Arbeiten mit Anwendungen im Managed Service für Apache Flink. Sie enthalten Beispielcode und step-by-step Anweisungen, die Sie beim Erstellen von Managed Service für Apache Flink-Anwendungen und Testen der Ergebnisse unterstützen.

Bevor Sie sich mit diesen Beispielen befassen, empfehlen wir Ihnen, zunächst Folgendes zu lesen:

- Funktionsweise
- Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink

Note

In diesen Beispielen wird vorausgesetzt, dass Sie die Region USA West (Oregon) (uswest-2) verwenden. Wenn Sie eine andere Region verwenden, aktualisieren Sie Ihren Anwendungscode, Ihre Befehle und IAM-Rollen entsprechend.

Themen

- DataStream API-Beispiele
- Python-Beispiele
- Scala-Beispiele

DataStream API-Beispiele

In den folgenden Beispielen wird die Erstellung von Anwendungen über die Apache DataStream Flink-API gezeigt.

Themen

- Beispiel: Rolierendes Fenster
- Beispiel: Gleitendes Fenster
- Beispiel: Schreiben in einen Amazon-S3-Bucket schreiben
- <u>Tutorial: Verwenden einer Managed Service f
 ür Apache Flink-Anwendung zum Replizieren von</u> Daten von einem Thema in einem MSK-Cluster zu einem anderen in einer VPC
- Beispiel: Verwenden Sie einen EFO-Verbraucher mit einem Kinesis-Daten-Stream
- Beispiel: Schreiben an Firehose
- Beispiel: Aus einem Kinesis-Stream in einem anderen Konto lesen
- Tutorial: Einen benutzerdefinierten Truststore mit Amazon MSK verwenden

Beispiel: Rolierendes Fenster

Note

Aktuelle Beispiele finden Sie unter<u>Beispiele für die Erstellung von und die Arbeit mit Managed</u> Service für Apache Flink-Anwendungen.

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink, die Daten in einem rollierenden Fenster aggregiert. Die Aggregation ist in Flink standardmäßig aktiviert. Um sie deaktivieren, verwenden Sie Folgendes:

sink.producer.aggregation-enabled' = 'false'

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream

- Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Bereinigen von AWS -Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream)
- Einen Amazon S3-Bucket zum Speichern des Codes der Anwendung (ka-appcode-<username>)

Sie können die Kinesis Streams und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihren Data Stream ExampleInputStream und ExampleOutputStream.
- <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:
```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
   return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'price': round(random.random() * 100, 2)}
def generate(stream_name, kinesis_client):
   while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
            PartitionKey="partitionkey")
if __name__ == '__main__':
    generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Führen Sie das stock.pySkript aus:

```
$ python stock.py
```

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

```
git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git
```

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/ TumblingWindow Verzeichnis.

Der Anwendungscode befindet sich in der TumblingWindowStreamingJob.java-Datei. Beachten Sie Folgendes zum Anwendungscode:

• Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

• Fügen Sie die folgende Importanweisung hinzu:

```
import
    org.apache.flink.streaming.api.windowing.assigners.TumblingProcessingTimeWindows; //
flink 1.13 onward
```

 Die Anwendung verwendet den timeWindow-Operator, um die Anzahl der Werte f
ür jedes Aktionssymbol
über ein rollierendes Fenster von 5 Sekunden zu ermitteln. Der folgende Code erstellt den Operator und sendet die aggregierten Daten an eine neue Kinesis Data Streams Senke:

<pre>input.flatMap(new</pre>	Tokenizer()) // Tokenizer for generating words
	<pre>.keyBy(0) // Logically partition the stream for each word</pre>
Flink 1.13 onward	.window(TumblingProcessingTimeWindows.of(Time.seconds(5))) //
	.sum(1) // Sum the number of words per partition .map(value -> value.f0 + "," + value.f1.toString() + "\n") .addSink(createSinkFromStaticConfig());

Kompilieren Sie den Anwendungscode

Zum Kompilieren der Anwendung gehen Sie wie folgt vor:

- Installieren Sie Java und Maven, wenn das noch nicht geschehen ist. Weitere Informationen finden Sie unter <u>Erfüllen Sie die erforderlichen Voraussetzungen</u> im <u>Tutorial: Erste Schritte mit</u> der DataStream API in Managed Service f
 ür Apache Flink Tutorial.
- 2. Kompilieren Sie die Anwendung mit dem folgenden Befehl:

mvn package -Dflink.version=1.15.3

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11.

Beim Kompilieren der Anwendung wird die JAR-Datei der Anwendung (target/aws-kinesisanalytics-java-apps-1.0.jar) erstellt.

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in das Amazon S3-Bucket hoch, das Sie im Erstellen Sie abhängige Ressourcen Abschnitt erstellt haben.

- Wählen Sie in der Amazon S3 S3-Konsole den *<username>* Bucket ka-app-code- und wählen Sie Upload aus.
- Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 3. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink

- Wählen Sie im Dashboard Managed Service f
 ür Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.

Note

Managed Service für Apache Flink verwendet Apache Flink Version 1.15.2.

- Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

1 Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.

Managed Service für Apache Flink

- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- 4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "logs:DescribeLogGroups",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*",
                "arn:aws:s3:::ka-app-code-<username>/aws-kinesis-analytics-java-
apps-1.0.jar"
            1
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": "logs:DescribeLogStreams",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:*"
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": "logs:PutLogEvents",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
```

```
"Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            1
        },
        ſ
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        ſ
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert aws-kinesis-analytics-javaapps-1.0.jar ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 5. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 6. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Führen Sie die Anwendung aus.

- 1. Wählen Sie auf der MyApplicationSeite die Option Ausführen aus. Lassen Sie die Option Ohne Snapshot ausführen aktiviert und bestätigen Sie die Aktion.
- 2. Wenn die Anwendung ausgeführt wird, aktualisieren Sie die Seite. Die Konsole zeigt den Application graph (Anwendungs-Graph) an.

Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Rollierendes Fenster-Tutorial erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den <username>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Gleitendes Fenster

Note

Aktuelle Beispiele finden Sie unter<u>Beispiele für die Erstellung von und die Arbeit mit Managed</u> Service für Apache Flink-Anwendungen.

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Bereinigen von AWS Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis-Datenströme (ExampleInputStream und ExampleOutputStream).
- Einen Amazon S3-Bucket zum Speichern des Codes der Anwendung (ka-appcode-<username>)

Sie können die Kinesis Streams und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihre Data Streams ExampleInputStream und ExampleOutputStream.
- <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        "EVENT_TIME": datetime.datetime.now().isoformat(),
        "TICKER": random.choice(["AAPL", "AMZN", "MSFT", "INTC", "TBV"]),
        "PRICE": round(random.random() * 100, 2),
```

}

```
def generate(stream_name, kinesis_client):
    while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name, Data=json.dumps(data),
PartitionKey="partitionkey"
        )

if __name__ == "__main__":
    generate(STREAM_NAME, boto3.client("kinesis"))
```

2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/ SlidingWindow Verzeichnis.

Der Anwendungscode befindet sich in der SlidingWindowStreamingJobWithParallelism.java-Datei. Beachten Sie Folgendes zum Anwendungscode: • Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

- Die Anwendung verwendet den timeWindow-Operator, um in einem 10-Sekunden-Fenster, das um 5 Sekunden verschoben wird, den Mindestwert f
 ür jedes Aktionssymbol zu ermitteln. Der folgende Code erstellt den Operator und sendet die aggregierten Daten an eine neue Kinesis Data Streams Senke:
- Fügen Sie die folgende Importanweisung hinzu:

```
import
    org.apache.flink.streaming.api.windowing.assigners.TumblingProcessingTimeWindows; //
flink 1.13 onward
```

 Die Anwendung verwendet den timeWindow-Operator, um die Anzahl der Werte f
ür jedes Aktionssymbol
über ein rollierendes Fenster von 5 Sekunden zu ermitteln. Der folgende Code erstellt den Operator und sendet die aggregierten Daten an eine neue Kinesis Data Streams Senke:

```
input.flatMap(new Tokenizer()) // Tokenizer for generating words
        .keyBy(0) // Logically partition the stream for each word
    .window(TumblingProcessingTimeWindows.of(Time.seconds(5))) //Flink 1.13 onward
        .sum(1) // Sum the number of words per partition
        .map(value -> value.f0 + "," + value.f1.toString() + "\n")
        .addSink(createSinkFromStaticConfig());
```

Kompilieren Sie den Anwendungscode

Zum Kompilieren der Anwendung gehen Sie wie folgt vor:

- Installieren Sie Java und Maven, wenn das noch nicht geschehen ist. Weitere Informationen finden Sie unter Erfüllen Sie die erforderlichen Voraussetzungen im <u>Tutorial: Erste Schritte mit</u> der DataStream API in Managed Service f
 ür Apache Flink Tutorial.
- 2. Kompilieren Sie die Anwendung mit dem folgenden Befehl:

mvn package -Dflink.version=1.15.3

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11.

Beim Kompilieren der Anwendung wird die JAR-Datei der Anwendung (target/aws-kinesisanalytics-java-apps-1.0.jar) erstellt.

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in den Amazon S3-Bucket hoch, den Sie im Abschnitt Erstellen Sie abhängige Ressourcen erstellt haben.

- Wählen Sie in der Amazon S3 S3-Konsole den *<username>* Bucket ka-app-code- und wählen Sie dann Upload aus.
- Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 3. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.

- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.
 - Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "logs:DescribeLogGroups",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*",
                "arn:aws:s3::::ka-app-code-<username>/aws-kinesis-analytics-java-
apps-1.0.jar"
            ٦
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": "logs:DescribeLogStreams",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:*"
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": "logs:PutLogEvents",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "ReadInputStream",
```

```
"Effect": "Allow",
    "Action": "kinesis:*",
    "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
    },
    {
        "Sid": "WriteOutputStream",
        "Effect": "Allow",
        "Action": "kinesis:*",
        "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
    }
]
]
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert aws-kinesis-analytics-javaapps-1.0.jar ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 5. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 6. Wählen Sie Aktualisieren.

1 Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Konfigurieren Sie die Anwendungsparallelität

Dieses Anwendungsbeispiel verwendet die parallele Ausführung von Aufgaben. Der folgende Anwendungscode legt die Parallelität des Operators min fest:

.setParallelism(3) // Set parallelism for the min operator

Die Anwendungsparallelität kann nicht größer sein als die bereitgestellte Parallelität, die den Standardwert 1 hat. Verwenden Sie die folgende AWS CLI -Aktion, um die Parallelität Ihrer Anwendung zu erhöhen:

```
aws kinesisanalyticsv2 update-application
        --application-name MyApplication
        --current-application-version-id <VersionId>
        --application-configuration-update "{\"FlinkApplicationConfigurationUpdate
\": { \"ParallelismConfigurationUpdate\": {\"ParallelismUpdate\": 5,
        \"ConfigurationTypeUpdate\": \"CUSTOM\" }}"
```

Sie können die aktuelle Versions-ID der Anwendung mithilfe der Aktionen <u>DescribeApplication</u>oder ListApplicationsabrufen.

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Gleitendes Fenster erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. <u>https://console.aws.amazon.com/kinesis</u>.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den **<username>**Bucket ka-app-code -.

3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Schreiben in einen Amazon-S3-Bucket schreiben

In dieser Übung erstellen Sie einen Managed Service für Apache Flink, der einen Kinesis Data Stream als Quelle und einen Amazon S3-Bucket als Senke hat. Mithilfe der Senke können Sie die Ausgabe der Anwendung in der Amazon S3-Konsole überprüfen.

1 Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Modifizieren Sie den Anwendungscode
- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- <u>Überprüfen der Anwendungsausgabe</u>
- Optional: Passen Sie Quelle und Senke an
- Bereinigen von AWS Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung einen Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Einen Kinesis Data Stream (ExampleInputStream).
- Einen Amazon S3-Bucket zum Speichern des Codes und der Ausgabe der Anwendung (ka-appcode-<username>)

Note

Managed Service für Apache Flink kann keine Daten auf Amazon S3 schreiben, wenn die serverseitige Verschlüsselung auf Managed Service für Apache Flink aktiviert ist.

Sie können den Kinesis-Stream und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihren Data Stream ExampleInputStream.
- Wie erstelle ich einen S3-Bucket? im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>. Erstellen Sie zwei Ordner (code und data) im Amazon S3-Bucket.

Die Anwendung erstellt die folgenden CloudWatch Ressourcen, sofern diese nicht bereits vorhanden ist:

- Eine Protokollgruppe namens /AWS/KinesisAnalytics-java/MyApplication.
- Einen Protokollstream mit dem Namen kinesis-analytics-log-stream.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'price': round(random.random() * 100, 2)}
def generate(stream_name, kinesis_client):
    while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
```

```
PartitionKey="partitionkey")
```

if __name__ == '__main__':
 generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))

2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/S3Sink Verzeichnis.

Der Anwendungscode befindet sich in der S3StreamingSinkJob.java-Datei. Beachten Sie Folgendes zum Anwendungscode:

 Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

• Sie müssen die folgende Import-Anweisung hinzufügen.

import

org.apache.flink.streaming.api.windowing.assigners.TumblingProcessingTimeWindows;

• Die Anwendung verwendet eine Apache Flink S3-Senke, um auf Amazon S3 zu schreiben.

Die Senke liest Nachrichten in einem rollierenden Fenster, kodiert Nachrichten in S3-Bucket-Objekte und sendet die codierten Objekte an die S3-Senke. Der folgende Code kodiert Objekte für das Senden an Amazon S3:

```
input.map(value -> { // Parse the JSON
        JsonNode jsonNode = jsonParser.readValue(value, JsonNode.class);
        return new Tuple2<>(jsonNode.get("ticker").toString(), 1);
    }).returns(Types.TUPLE(Types.STRING, Types.INT))
    .keyBy(v -> v.f0) // Logically partition the stream for each word
    .window(TumblingProcessingTimeWindows.of(Time.minutes(1)))
    .sum(1) // Count the appearances by ticker per partition
    .map(value -> value.f0 + " count: " + value.f1.toString() + "\n")
    .addSink(createS3SinkFromStaticConfig());
```

Note

Die Anwendung verwendet ein StreamingFileSink-Flink-Objekt, um in Amazon S3 zu schreiben. Weitere Informationen zu finden Sie <u>StreamingFileSink</u>in der StreamingFileSink <u>Apache Flink-Dokumentation</u>.

Modifizieren Sie den Anwendungscode

In diesem Abschnitt ändern Sie den Anwendungscode, um die Ausgabe in Ihren Amazon S3-Bucket zu schreiben.

Aktualisieren Sie die folgende Zeile mit Ihrem Benutzernamen, um den Ausgabespeicherort der Anwendung anzugeben:

```
private static final String s3SinkPath = "s3a://ka-app-code-<username>/data";
```

Kompilieren Sie den Anwendungscode

Zum Kompilieren der Anwendung gehen Sie wie folgt vor:

 Installieren Sie Java und Maven, wenn das noch nicht geschehen ist. Weitere Informationen finden Sie unter <u>Erfüllen Sie die erforderlichen Voraussetzungen</u> im <u>Tutorial: Erste Schritte mit</u> der DataStream API in Managed Service f
ür Apache Flink Tutorial.

2. Kompilieren Sie die Anwendung mit dem folgenden Befehl:

```
mvn package -Dflink.version=1.15.3
```

Beim Kompilieren der Anwendung wird die JAR-Datei der Anwendung (target/aws-kinesisanalytics-java-apps-1.0.jar) erstellt.

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11.

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in das Amazon S3-Bucket hoch, das Sie im Erstellen Sie abhängige Ressourcen Abschnitt erstellt haben.

- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- aus, navigieren Sie zum Code-Ordner und wählen Sie Upload.
- Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 3. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.

- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.
 - Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Geben Sie als Anwendungsname ein MyApplication.
- Wählen Sie für Laufzeit die Option Apache Flink aus.
- Belassen Sie die Version als Apache Flink Version 1.15.2 (empfohlene Version).
- 6. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 7. Wählen Sie Create application aus.

Note

Beim Erstellen eines Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

• Richtlinie: kinesis-analytics-service-MyApplication-us-west-2

Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Kinesis Data Stream.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (*012345678901*) mit Ihrer Konto-ID. Ersetzen Sie <username> durch Ihren Benutzernamen.

```
{
            "Sid": "S3",
            "Effect": "Allow",
            "Action": [
                "s3:Abort*",
                "s3:DeleteObject*",
                "s3:GetObject*",
                "s3:GetBucket*",
                "s3:List*",
                "s3:ListBucket",
                "s3:PutObject"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-<username>",
                "arn:aws:s3:::ka-app-code-<username>/*"
            ]
          },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
```

```
],
            "Resource": [
                "arn:aws:logs:region:account-id:log-group:*"
            ]
        },
        {
            "Sid": "ListCloudwatchLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:region:account-id:log-group:%LOG_GROUP_PLACEHOLDER
%:log-stream:*"
            ]
        },
        {
            "Sid": "PutCloudwatchLogs",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:region:account-id:log-group:%LOG_GROUP_PLACEHOLDER
%:log-stream:%LOG_STREAM_PLACEHOLDER%"
            ]
        }
        ,
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
    ]
}
```

Konfigurieren der Anwendung

1. Wählen Sie auf der MyApplicationSeite Configure aus.

- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert code/aws-kinesis-analyticsjava-apps-1.0.jar ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 5. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 6. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Führen Sie die Anwendung aus.

- 1. Wählen Sie auf der MyApplicationSeite die Option Ausführen aus. Lassen Sie die Option Ohne Snapshot ausführen aktiviert und bestätigen Sie die Aktion.
- 2. Wenn die Anwendung ausgeführt wird, aktualisieren Sie die Seite. Die Konsole zeigt den Application graph (Anwendungs-Graph) an.

Überprüfen der Anwendungsausgabe

Öffnen Sie in der Amazon S3-Konsole den Ordner Daten in Ihrem S3-Bucket.

Nach einigen Minuten werden Objekte angezeigt, die aggregierte Daten aus der Anwendung enthalten.

1 Note

Die Aggregation ist in Flink standardmäßig aktiviert. Um sie deaktivieren, verwenden Sie Folgendes:

sink.producer.aggregation-enabled' = 'false'

Optional: Passen Sie Quelle und Senke an

In diesem Abschnitt passen Sie die Einstellungen für die Quell- und Senkenobjekte an.

Note

Nachdem Sie die in den folgenden Abschnitten beschriebenen Codeabschnitte geändert haben, gehen Sie wie folgt vor, um den Anwendungscode neu zu laden:

- Wiederholen Sie die Schritte im <u>the section called "Kompilieren Sie den Anwendungscode"</u>-Abschnitt, um den aktualisierten Anwendungscode zu kompilieren.
- Wiederholen Sie die Schritte im <u>the section called "Hochladen des Apache Flink-Streaming-Java-Codes"</u>-Abschnitt, um den aktualisierten Anwendungscode hochzuladen.
- Wählen Sie auf der Seite der Anwendung in der Konsole Konfigurieren und anschließend Aktualisieren aus, um den aktualisierten Anwendungscode erneut in Ihre Anwendung zu laden.

Dieser Abschnitt umfasst die folgenden Abschnitte:

- Konfigurieren der Datenpartitionierung
- Konfigurieren der Lesehäufigkeit
- Konfigurieren der Schreibpufferung

Konfigurieren der Datenpartitionierung

In diesem Abschnitt konfigurieren Sie die Namen der Ordner, die die Streaming-Dateisenke im S3-Bucket erstellt. Dies geschieht, indem Sie der Streaming-Dateisenke einen Bucket-Assigner hinzufügen.

Gehen Sie wie folgt vor, um die im S3-Bucket erstellten Ordnernamen anzupassen:

1. Fügen Sie am Anfang der S3StreamingSinkJob.java-Datei die folgenden Importanweisungen hinzu:

```
import
  org.apache.flink.streaming.api.functions.sink.filesystem.rollingpolicies.DefaultRollingPol
  import
  org.apache.flink.streaming.api.functions.sink.filesystem.bucketassigners.DateTimeBucketAss
```

 Aktualisieren Sie die createS3SinkFromStaticConfig()-Methode im Code so, dass sie wie folgt aussieht:

```
private static StreamingFileSink<String> createS3SinkFromStaticConfig() {
    final StreamingFileSink<String> sink = StreamingFileSink
        .forRowFormat(new Path(s3SinkPath), new
    SimpleStringEncoder<String>("UTF-8"))
        .withBucketAssigner(new DateTimeBucketAssigner("yyyy-MM-dd--HH"))
        .withRollingPolicy(DefaultRollingPolicy.create().build())
        .build();
    return sink;
}
```

Im vorherigen Codebeispiel wird DateTimeBucketAssigner mit einem benutzerdefinierten Datumsformat verwendet, um Ordner im S3-Bucket zu erstellen. Der DateTimeBucketAssigner verwendet die aktuelle Systemzeit, um Bucket-Namen zu erstellen. Wenn Sie einen benutzerdefinierten Bucket-Assigner erstellen möchten, um die erstellten Ordnernamen weiter anzupassen, können Sie eine Klasse erstellen, die diese implementiert. <u>BucketAssigner</u> Sie implementieren Ihre benutzerdefinierte Logik mithilfe der Methode getBucketId. Eine benutzerdefinierte Implementierung von BucketAssigner kann den <u>Kontext</u>-Parameter verwenden, um weitere Informationen zu einem Datensatz abzurufen und seinen Zielordner zu bestimmen.

Konfigurieren der Lesehäufigkeit

In diesem Abschnitt konfigurieren Sie die Häufigkeit von Lesevorgängen im Quellstream.

Der Kinesis Streams-Consumer liest standardmäßig fünfmal pro Sekunde aus dem Quell-Stream. Diese Häufigkeit führt zu Problemen, wenn mehr als ein Client aus dem Stream liest oder wenn die Anwendung erneut versuchen muss, einen Datensatz zu lesen. Sie können diese Probleme vermeiden, indem Sie die Lesehäufigkeit des Benutzers festlegen.

Um die Lesehäufigkeit des Kinesis-Consumers festzulegen, legen Sie die Einstellung SHARD_GETRECORDS_INTERVAL_MILLIS fest.

Im folgenden Codebeispiel wird die SHARD_GETRECORDS_INTERVAL_MILLIS-Einstellung auf eine Sekunde festgelegt:

kinesisConsumerConfig.setProperty(ConsumerConfigConstants.SHARD_GETRECORDS_INTERVAL_MILLIS, "1000");

Konfigurieren der Schreibpufferung

In diesem Abschnitt konfigurieren Sie die Schreibfrequenz und andere Einstellungen der Senke.

Standardmäßig schreibt die Anwendung jede Minute in den Ziel-Bucket. Sie können dieses Intervall und andere Einstellungen ändern, indem Sie das DefaultRollingPolicy-Objekt konfigurieren.

Note

Die Apache Flink-Streaming-Dateisenke schreibt jedes Mal in ihren Ausgabe-Bucket, wenn die Anwendung einen Prüfpunkt erstellt. Die Anwendung erstellt standardmäßig jede Minute einen Prüfpunkt. Um das Schreibintervall der S3-Senke zu erhöhen, müssen Sie auch das Prüfpunkt-Intervall erhöhen.

Führen Sie zur Konfiguration des DefaultRollingPolicy-Objekts folgende Schritte aus:

1. Erhöhen Sie die CheckpointInterval-Einstellung der Anwendung. Die folgende Eingabe für die UpdateApplicationAktion legt das Prüfpunkt-Intervall auf 10 Minuten fest:

Geben Sie die aktuelle Anwendungsversion an, um den vorherigen Code zu verwenden. Sie können die Anwendungsversion mithilfe der ListApplicationsAktion abrufen.

2. Fügen Sie am Anfang der S3StreamingSinkJob.java-Datei die folgende Importanweisung hinzu:

```
import java.util.concurrent.TimeUnit;
```

3. Aktualisieren Sie die createS3SinkFromStaticConfig-Methode in der S3StreamingSinkJob.java-Datei so, dass sie wie folgt aussieht:

```
private static StreamingFileSink<String> createS3SinkFromStaticConfig() {
    final StreamingFileSink<String> sink = StreamingFileSink
        .forRowFormat(new Path(s3SinkPath), new
SimpleStringEncoder<String>("UTF-8"))
        .withBucketAssigner(new DateTimeBucketAssigner("yyyy-MM-dd--HH"))
        .withRollingPolicy(
            DefaultRollingPolicy.create()
            .withRolloverInterval(TimeUnit.MINUTES.toMillis(8))
        .withInactivityInterval(TimeUnit.MINUTES.toMillis(5))
        .withMaxPartSize(1024 * 1024 * 1024)
        .build();
    return sink;
}
```

Im vorherigen Codebeispiel wird die Häufigkeit von Schreibvorgängen in den Amazon S3-Bucket auf 8 Minuten festgelegt.

Weitere Informationen zur Konfiguration der Apache Flink-Streaming-Dateisenke finden Sie unter Reihencodierte Formate in der Apache Flink-Dokumentation.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zur Bereinigung von AWS -Ressourcen, die Sie im Amazon S3 S3-Tutorial erstellt haben.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- So löschen Sie den Kinesis Data Stream
- Löschen Ihrer Amazon-S3-Objekte und Buckets
- So löschen Sie die IAM-Ressourcen
- <u>CloudWatch Löschen Sie Ihre Ressourcen</u>

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

So löschen Sie den Kinesis Data Stream

- 1. Öffnen Sie die Kinesis-Konsole unter. <u>https://console.aws.amazon.com/kinesis</u>.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Amazon-S3-Objekte und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username>*Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Richtlinien aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Rollen aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie auf der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Tutorial: Verwenden einer Managed Service für Apache Flink-Anwendung zum Replizieren von Daten von einem Thema in einem MSK-Cluster zu einem anderen in einer VPC

1 Note

Aktuelle Beispiele finden Sie unter. Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-Anwendungen Das folgende Tutorial zeigt, wie Sie eine Amazon VPC mit einem Amazon MSK-Cluster und zwei Themen erstellen und wie Sie eine Managed Service für Apache Flink-Anwendung erstellen, die aus einem Amazon MSK-Thema liest und in ein anderes schreibt.

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Übung ab.

Dieses Tutorial enthält die folgenden Abschnitte:

- Erstellen einer Amazon VPC mit einem Amazon-MSK-Cluster
- Erstellen Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen der Anwendung
- Konfigurieren der Anwendung
- Führen Sie die Anwendung aus.
- Testen der Anwendung

Erstellen einer Amazon VPC mit einem Amazon-MSK-Cluster

Folgen Sie dem Tutorial <u>Erste Schritte mit Amazon MSK</u>, um eine Beispiel-VPC und Amazon MSK-Cluster für den Zugriff über eine Managed Service für Apache Flink-Anwendung zu erstellen.

Beachten Sie beim Abschluss des Tutorials Folgendes:

• Wiederholen Sie in <u>Schritt 3: Thema erstellen</u> den Befehl kafka-topics.sh --create, um ein Zielthema mit dem Namen AWSKafkaTutorialTopicDestination zu erstellen:

bin/kafka-topics.sh --create --zookeeper ZooKeeperConnectionString --replicationfactor 3 --partitions 1 --topic AWS KafkaTutorialTopicDestination

 Notieren Sie sich die Bootstrap-Serverliste f
ür Ihren Cluster. Sie k
önnen die Liste der Bootstrap-Server mit dem folgenden Befehl abrufen (ersetzen Sie durch *ClusterArn* die ARN Ihres MSK-Clusters):

```
aws kafka get-bootstrap-brokers --region us-west-2 --cluster-arn ClusterArn
{...
    "BootstrapBrokerStringTls": "b-2.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,b-1.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,b-3.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,b-3.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,"
}
```

 Wenn Sie den Schritten in den Tutorials folgen, achten Sie darauf, dass Sie die von Ihnen gewählte AWS -Region in Ihrem Code, Ihren Befehlen und Ihren Konsoleneinträgen verwenden.

Erstellen Sie den Anwendungscode

In diesem Abschnitt laden Sie die Anwendungs-JAR-Datei herunter und kompilieren sie. Wir empfehlen die Verwendung von Java 11.

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

- Der Anwendungscode befindet sich in der amazon-kinesis-data-analytics-javaexamples/KafkaConnectors/KafkaGettingStartedJob.java-Datei. Sie können den Code untersuchen, um sich mit der Struktur des Anwendungscodes von Managed Service für Apache Flink vertraut zu machen.
- Verwenden Sie entweder das Befehlszeilentool Maven oder Ihre bevorzugte Entwicklungsumgebung, um die JAR-Datei zu erstellen. Um die JAR-Datei mit dem Maven-Befehlszeilentool zu kompilieren, geben Sie Folgendes ein:

mvn package -Dflink.version=1.15.3

Wenn der Build erfolgreich ist, wird die folgende Datei erstellt:

target/KafkaGettingStartedJob-1.0.jar
Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11. Wenn Sie eine Entwicklungsumgebung verwenden,

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in den Amazon S3-Bucket hoch, den Sie im <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u> Tutorial erstellt haben.

Note

Wenn Sie den Amazon S3-Bucket aus dem Tutorial Erste Schritte gelöscht haben, führen Sie den Schritt <u>the section called "Laden Sie die JAR-Datei mit dem Anwendungscode hoch"</u> erneut aus.

- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 2. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der KafkaGettingStartedJob-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 3. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink.
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:

- Geben Sie als Anwendungsname ein MyApplication.
- Wählen Sie für Laufzeit die Option Apache Flink 1.15.2 aus.
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert KafkaGettingStartedJob-1.0.jar ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.

Note

Wenn Sie Anwendungsressourcen mithilfe der Konsole angeben (z. B. CloudWatch Logs oder eine Amazon VPC), ändert die Konsole Ihre Anwendungsausführungsrolle, um die Berechtigung für den Zugriff auf diese Ressourcen zu gewähren.

4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus. Geben Sie die folgenden Eigenschaften ein:

Gruppen-ID	Schlüssel	Value (Wert)
KafkaSource	Thema	AWS KafkaTutorialTopic
KafkaSource	bootstrap.servers	The bootstrap server list you saved previously
KafkaSource	security.protocol	SSL
KafkaSource	ssl.truststore.location	/usr/lib/jvm/java-11-amazon- corretto/lib/security/cacerts
KafkaSource	ssl.truststore.passwort	changeit

Note

Das ssl.truststore.password für das Standardzertifikat ist "changeit". Sie müssen diesen Wert nicht ändern, wenn Sie das Standardzertifikat verwenden.

Wählen Sie erneut Gruppe hinzufügen. Geben Sie die folgenden Eigenschaften ein:

Gruppen-ID	Schlüssel	Value (Wert)
KafkaSink	Thema	AWS KafkaTutorialTopic Destination
KafkaSink	bootstrap.servers	The bootstrap server list you saved previously
KafkaSink	security.protocol	SSL

Gruppen-ID	Schlüssel	Value (Wert)
KafkaSink	ssl.truststore.location	/usr/lib/jvm/java-11-amazon- corretto/lib/security/cacerts
KafkaSink	ssl.truststore.passwort	changeit
KafkaSink	transaction.timeout.ms	1000

Der Anwendungscode liest die oben genannten Anwendungseigenschaften, um die Quelle und Senke zu konfigurieren, die für die Interaktion mit Ihrer VPC und Ihrem Amazon MSK-Cluster verwendet werden. Weitere Informationen zur Verwendung von Eigenschaften finden Sie unter Verwenden Sie Laufzeiteigenschaften.

- 5. Wählen Sie unter Snapshots die Option Deaktivieren aus. Dadurch wird es einfacher, die Anwendung zu aktualisieren, ohne ungültige Anwendungsstatusdaten zu laden.
- 6. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 7. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren.
- 8. Wählen Sie im Abschnitt Virtual Private Cloud (VPC) die VPC aus, die mit Ihrer Anwendung verknüpft werden soll. Wählen Sie die mit Ihrer VPC verknüpften Subnetze und Sicherheitsgruppe aus, die die Anwendung für den Zugriff auf VPC-Ressourcen verwenden soll.
- 9. Wählen Sie Aktualisieren.

1 Note

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet.

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Testen der Anwendung

In diesem Abschnitt schreiben Sie Datensätze zum Quellthema. Die Anwendung liest Datensätze aus dem Quellthema und schreibt sie in das Zielthema. Sie überprüfen, ob die Anwendung funktioniert, indem Sie Datensätze in das Quellthema schreiben und Datensätze aus dem Zielthema lesen.

Um Datensätze aus den Themen zu schreiben und zu lesen, folgen Sie den Schritten in <u>Schritt 6:</u> Daten produzieren und verwenden im Tutorial Erste Schritte mit Amazon MSK.

Um aus dem Zielthema zu lesen, verwenden Sie in Ihrer zweiten Verbindung zum Cluster den Namen des Zielthemas anstelle des Quellthemas:

bin/kafka-console-consumer.sh --bootstrap-server BootstrapBrokerString -consumer.config client.properties --topic AWS KafkaTutorialTopicDestination --frombeginning

Wenn im Zielthema keine Datensätze angezeigt werden, lesen Sie den Abschnitt Auf Ressourcen in einer VPC kann nicht zugegriffen werden im Thema Problembehandlung bei Managed Service für Apache Flink.

Beispiel: Verwenden Sie einen EFO-Verbraucher mit einem Kinesis-Daten-Stream

Note

Aktuelle Beispiele finden Sie unter. <u>Beispiele für die Erstellung von und die Arbeit mit</u> Managed Service für Apache Flink-Anwendungen

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink, die mithilfe eines <u>Enhanced Fan-Out- (EFO)</u> -Verbrauchers aus einem Kinesis Data Stream liest. Wenn ein Kinesis-Verbraucher EFO verwendet, stellt ihm der Kinesis Data Streams-Service seine eigene dedizierte Bandbreite zur Verfügung, anstatt dass der Verbraucher die feste Bandbreite des Streams mit den anderen Verbrauchern teilt, die aus dem Stream lesen.

Weitere Informationen zur Verwendung von EFO mit dem Kinesis Consumer finden Sie unter FLIP-128: Verbesserte Verteilung für Kinesis-Verbraucher.

Die Anwendung, die Sie in diesem Beispiel erstellen, verwendet AWS Kinesis Connector (flinkconnector-kinesis) 1.15.3.

1 Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Bereinigen von AWS -Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream)
- Einen Amazon S3-Bucket zum Speichern des Codes der Anwendung (ka-appcode-<username>)

Sie können die Kinesis Streams und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihren Data Stream ExampleInputStream und ExampleOutputStream.
- <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'price': round(random.random() * 100, 2)}
def generate(stream_name, kinesis_client):
   while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
            PartitionKey="partitionkey")
if __name__ == '__main__':
    generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/EfoConsumer Verzeichnis.

Der Anwendungscode befindet sich in der EfoApplication.java-Datei. Beachten Sie Folgendes zum Anwendungscode:

- Sie aktivieren den EFO-Consumer, indem Sie die folgenden Parameter f
 ür den Kinesis-Consumer festlegen:
 - RECORD_PUBLISHER_TYPE: Setzen Sie diesen Parameter auf EFO, damit Ihre Anwendung einen EFO-Consumer für den Zugriff auf die Kinesis Data Stream-Daten verwendet.
 - EFO_CONSUMER_NAME: Setzen Sie diesen Parameter auf einen Zeichenfolgenwert, der unter den Verbrauchern dieses Streams eindeutig ist. Die Wiederverwendung eines Verbrauchernamens in demselben Kinesis Data Stream führt dazu, dass der vorherige Verbraucher, der diesen Namen verwendet hat, beendet wird.
- Das folgende Codebeispiel zeigt, wie den Consumer-Konfigurationseigenschaften Werte zugewiesen werden, um einen EFO-Consumer zum Lesen aus dem Quell-Stream zu verwenden:

consumerConfig.putIfAbsent(RECORD_PUBLISHER_TYPE, "EFO"); consumerConfig.putIfAbsent(EFO_CONSUMER_NAME, "basic-efo-flink-app"); Kompilieren Sie den Anwendungscode

Zum Kompilieren der Anwendung gehen Sie wie folgt vor:

- Installieren Sie Java und Maven, wenn das noch nicht geschehen ist. Weitere Informationen finden Sie unter <u>Erfüllen Sie die erforderlichen Voraussetzungen</u> im <u>Tutorial: Erste Schritte mit</u> der DataStream API in Managed Service f
 ür Apache Flink Tutorial.
- 2. Kompilieren Sie die Anwendung mit dem folgenden Befehl:

mvn package -Dflink.version=1.15.3



Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11.

Beim Kompilieren der Anwendung wird die JAR-Datei der Anwendung (target/aws-kinesisanalytics-java-apps-1.0.jar) erstellt.

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in das Amazon S3-Bucket hoch, das Sie im Erstellen Sie abhängige Ressourcen Abschnitt erstellt haben.

- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der aws-kinesis-analytics-java-apps-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 3. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.

Note

Managed Service für Apache Flink verwendet Apache Flink Version 1.15.2.

- Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- 4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (*012345678901*) mit Ihrer Konto-ID.

Diese Berechtigungen gewähren der Anwendung die Möglichkeit, auf den EFO-Consumer zuzugreifen.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "logs:DescribeLogGroups",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*",
                "arn:aws:s3::::ka-app-code-<username>/aws-kinesis-analytics-java-
apps-1.0.jar"
            1
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": "logs:DescribeLogStreams",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:*"
        },
        {
```

```
"Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": "logs:PutLogEvents",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "AllStreams",
            "Effect": "Allow",
            "Action": [
                "kinesis:ListShards",
                "kinesis:ListStreamConsumers",
                "kinesis:DescribeStreamSummary"
            ],
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/*"
        },
        {
            "Sid": "Stream",
            "Effect": "Allow",
            "Action": [
                "kinesis:DescribeStream",
                "kinesis:RegisterStreamConsumer",
                "kinesis:DeregisterStreamConsumer"
            ],
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        },
```

```
{
            "Sid": "Consumer",
            "Effect": "Allow",
            "Action": [
                "kinesis:DescribeStreamConsumer",
                "kinesis:SubscribeToShard"
            ],
            "Resource": [
                "arn:aws:kinesis:us-west-2:012345678901:stream/ExampleInputStream/
consumer/my-efo-flink-app",
                "arn:aws:kinesis:us-west-2:012345678901:stream/ExampleInputStream/
consumer/my-efo-flink-app:*"
            7
        }
    ]
}
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert aws-kinesis-analytics-javaapps-1.0.jar ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe erstellen aus.
- 5. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
ConsumerConfigProp erties	flink.stream.recor dpublisher	EFO
ConsumerConfigProp erties	flink.stream.efo.c onsumername	basic-efo-flink-app

Gruppen-ID	Schlüssel	Value (Wert)
ConsumerConfigProp erties	INPUT_STREAM	ExampleInputStream
ConsumerConfigProp erties	flink.inputstream. initpos	LATEST
ConsumerConfigProp erties	AWS_REGION	us-west-2

- 6. Wählen Sie unter Eigenschaften die Option Gruppe erstellen aus.
- 7. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	OUTPUT_STREAM	ExampleOutputStream
ProducerConfigProp erties	AWS_REGION	us-west-2
ProducerConfigProp erties	AggregationEnabled	false

- 8. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 9. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 10. Wählen Sie Aktualisieren.

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Sie können auch in der Kinesis Data Streams-Konsole in der Registerkarte Verbesserte Verteilung des Data Streams nach dem Namen Ihres Verbrauchers suchen () basic-efo-flink-app.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im efo-Fenster-Tutorial erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen von Amazon-S3-Objekten und -Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen von Amazon-S3-Objekten und -Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username>*Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Schreiben an Firehose

Note

Aktuelle Beispiele finden Sie unter. Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-Anwendungen

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink, die einen Kinesis Data Stream als Quelle und einen Firehose-Bereitstellungs-Stream als Senke hat. Mithilfe der Senke können Sie die Ausgabe der Anwendung in einem Amazon-S3-Bucket überprüfen.

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Übung ab.

Dieser Abschnitt enthält die folgenden Schritte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode
- · Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Bereinigen von AWS -Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung einen Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Einen Kinesis Data Stream (ExampleInputStream)
- Ein Firehose-Stream, in den die Anwendung die Ausgabe schreibt (ExampleDeliveryStream).

 Einen Amazon S3-Bucket zum Speichern des Codes der Anwendung (ka-appcode-<username>)

Sie können den Kinesis-Stream, die Amazon S3 S3-Buckets und den Firehose-Stream mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihren Data Stream ExampleInputStream.
- <u>Erstellen eines Amazon Kinesis Data Firehose Firehose-Bereitstellungsdatenstroms</u> im Amazon Data Firehose-Entwicklerhandbuch. Nennen Sie Ihren Firehose-Stream**ExampleDeliveryStream**. Wenn Sie den Firehose-Stream erstellen, erstellen Sie auch das S3-Ziel und die IAM-Rolle des Firehose-Streams.
- <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service-Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
  import json
  import random
  import boto3
  STREAM_NAME = "ExampleInputStream"
  def get_data():
```

```
return {
    'event_time': datetime.datetime.now().isoformat(),
    'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
    'price': round(random.random() * 100, 2)}

def generate(stream_name, kinesis_client):
    while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
            PartitionKey="partitionkey")

if __name__ == '__main__':
    generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

1. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/FirehoseSink Verzeichnis.

Der Anwendungscode befindet sich in der FirehoseSinkStreamingJob.java-Datei. Beachten Sie Folgendes zum Anwendungscode:

 Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

• Die Anwendung verwendet eine Firehose-Senke, um Daten in einen Firehose-Stream zu schreiben. Der folgende Codeausschnitt erstellt die Firehose-Senke:

```
private static KinesisFirehoseSink<String> createFirehoseSinkFromStaticConfig() {
    Properties sinkProperties = new Properties();
    sinkProperties.setProperty(AWS_REGION, region);

    return KinesisFirehoseSink.<String>builder()
        .setFirehoseClientProperties(sinkProperties)
        .setSerializationSchema(new SimpleStringSchema())
        .setDeliveryStreamName(outputDeliveryStreamName)
        .build();
}
```

Kompilieren Sie den Anwendungscode

Zum Kompilieren der Anwendung gehen Sie wie folgt vor:

- Installieren Sie Java und Maven, wenn das noch nicht geschehen ist. Weitere Informationen finden Sie unter <u>Erfüllen Sie die erforderlichen Voraussetzungen</u> im <u>Tutorial: Erste Schritte mit</u> der DataStream API in Managed Service f
 ür Apache Flink Tutorial.
- Um den Kinesis-Konnektor f
 ür die folgende Anwendung verwenden zu k
 önnen, m
 üssen Sie Apache Maven herunterladen, erstellen und installieren. Weitere Informationen finden Sie unter the section called "Verwenden des Apache Flink Kinesis Streams-Konnektor mit fr
 üheren Apache Flink-Versionen".
- 3. Kompilieren Sie die Anwendung mit dem folgenden Befehl:

```
mvn package -Dflink.version=1.15.3
```

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11.

Beim Kompilieren der Anwendung wird die JAR-Datei der Anwendung (target/aws-kinesisanalytics-java-apps-1.0.jar) erstellt.

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in den Amazon S3-Bucket hoch, den Sie im Abschnitt Erstellen Sie abhängige Ressourcen erstellt haben.

So laden Sie den Anwendungscode hoch

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- Wählen Sie in der Konsole den <username> Bucket ka-app-code- und wählen Sie dann Upload aus.
- 3. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der java-getting-started-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 4. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder AWS CLI erstellen und ausführen.

1 Note

Wenn Sie die Anwendung mithilfe der Konsole erstellen, werden die Ressourcen AWS Identity and Access Management (IAM) und Amazon CloudWatch Logs für Sie erstellt. Bei der Erstellung der AWS CLI erstellen Sie separat die folgenden Ressourcen.

Themen

- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My java test app ein.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.

Note

Managed Service für Apache Flink verwendet Apache Flink Version 1.15.2.

- Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen der Anwendung mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Die Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Kinesis Data Stream und den Firehose-Stream.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie alle Instances des Beispielkontos IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3::::ka-app-code-username/java-getting-started-1.0.jar"
            ]
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
```

```
"Action": [
                "logs:DescribeLogStreams"
           ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ]
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ٦
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        ſ
            "Sid": "WriteDeliveryStream",
            "Effect": "Allow",
            "Action": "firehose:*",
            "Resource": "arn:aws:firehose:us-west-2:012345678901:deliverystream/
ExampleDeliveryStream"
        }
    ]
}
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):

- Geben Sie f
 ür Amazon-S3-Bucket ka-app-code-<username> ein.
- Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **java-getting-started-1.0.jar** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 5. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 6. Wählen Sie Aktualisieren.

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Stoppt die Anwendung

Wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Aktualisieren der Anwendung

Mithilfe der Konsole können Sie Anwendungseinstellungen wie beispielsweise Anwendungseigenschaften, Überwachungseinstellungen und den Speicherort oder den Dateinamen der JAR-Anwendungsdatei aktualisieren.

Wählen Sie auf der MyApplicationSeite Configure aus. Aktualisieren Sie die Anwendungseinstellungen und klicken Sie auf Aktualisieren.

Um den Code der Anwendung auf der Konsole zu aktualisieren, müssen Sie entweder den Objektnamen der JAR ändern, einen anderen S3-Bucket verwenden oder den AWS CLI wie im Abschnitt beschrieben verwenden. <u>the section called "Den Anwendungscode</u> <u>aktualisieren"</u> Wenn sich der Dateiname oder der Bucket nicht ändert, wird der Anwendungscode nicht neu geladen, wenn Sie auf der Seite "Konfigurieren" die Option "Aktualisieren" wählen.

Erstellen Sie die Anwendung und führen Sie sie aus (AWS CLI)

In diesem Abschnitt verwenden Sie, AWS CLI um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen.

Erstellen einer Berechtigungsrichtlinie

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die read-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die write-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. *username*Ersetzen Sie durch den Benutzernamen, den Sie verwenden werden, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "S3",
            "Effect": "Allow",
            "Action": [
               "s3:GetObject",
               "s3:GetObjectVersion"
        ],
            "Resource": ["arn:aws:s3:::ka-app-code-username",
               "arn:aws:s3:::ka-app-code-username/*"
```

```
]
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteDeliveryStream",
            "Effect": "Allow",
            "Action": "firehose:*",
            "Resource": "arn:aws:firehose:us-west-2:012345678901:deliverystream/
ExampleDeliveryStream"
        }
    ]
}
```

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: <u>Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie</u> im IAM-Benutzerhandbuch.

Note

Um auf andere Amazon-Services zuzugreifen, können Sie AWS SDK für Java verwenden. Managed Service für Apache Flink setzt die vom SDK benötigten Anmeldeinformationen automatisch auf die der IAM-Rolle für die Dienstausführung, die mit Ihrer Anwendung verknüpft ist. Es sind keine weiteren Schritte erforderlich.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle. Die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Roles (Rollen) und Create Role (Rolle erstellen) aus.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus. Wählen Sie unter Select your use case (Wählen Sie Ihren Anwendungsfall aus) die Option Kinesis Analytics aus.

Wählen Sie Weiter: Berechtigungen aus.

- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 5. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle.

6. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt erstellt haben, <u>the section called "Erstellen einer</u> Berechtigungsrichtlinie".

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.

d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwenden wird. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter <u>Erstellen einer IAM-Rolle</u> (Konsole) im IAM-Benutzerhandbuch.

Erstellen Sie die Anwendung Managed Service für Apache Flink

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix mit dem Suffix, das Sie im <u>the</u> <u>section called "Erstellen Sie abhängige Ressourcen"</u>-Abschnitt (ka-app-code-<username>) gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (012345678901) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
{
    "ApplicationName": "test",
    "ApplicationDescription": "my java test app",
    "RuntimeEnvironment": "FLINK-1_15",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "java-getting-started-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        }
      }
    }
}
```

 Führen Sie die <u>CreateApplication</u>-Aktion mit der vorherigen Anforderung zum Erstellen der Anwendung aus:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://
create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

Starten der Anwendung

In diesem Abschnitt verwenden Sie die StartApplication-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{
    "ApplicationName": "test",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
        }
}
```

2. Führen Sie die <u>StartApplication</u>-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die <u>StopApplication</u>-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "test"
}
```

2. Führen Sie die <u>StopApplication</u>-Aktion mit der folgenden Anforderung zum Stoppen der Anwendung aus:

```
aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json
```

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter<u>the section called "Anwendungsprotokollierung in Managed</u> <u>Service für Apache Flink einrichten"</u>.

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die UpdateApplication AWS CLI Aktion.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication dabei denselben Amazon S3 S3-Bucket und Objektnamen an.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (< username >) mit dem Suffix, das Sie im -Abschnitt ausgewählt haben. <u>the section</u> called "Erstellen Sie abhängige Ressourcen"

```
"ApplicationName": "test",
"CurrentApplicationVersionId": 1,
```

{

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Erste Schritte erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- · Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- So löschen Sie den Kinesis Data Stream
- So löschen Sie den Firehose-Stream
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- Löschen Sie Ihre Ressourcen CloudWatch

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie Konfigurieren aus.
- 4. Wählen Sie im Abschnitt Snapshots die Option Deaktivieren und anschließend Aktualisieren aus.
- 5. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie den Löschvorgang.

So löschen Sie den Kinesis Data Stream

- 1. Öffnen Sie die Kinesis-Konsole unter. <u>https://console.aws.amazon.com/kinesis</u>.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.

So löschen Sie den Firehose-Stream

- 1. Öffnen Sie die Kinesis-Konsole unter. <u>https://console.aws.amazon.com/kinesis</u>.
- 2. Wählen ExampleDeliveryStreamSie im Firehose-Bedienfeld.
- 3. Wählen Sie auf der ExampleDeliveryStreamSeite Delete Firehose stream aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username>*Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.
- 4. Wenn Sie einen Amazon S3 S3-Bucket für das Ziel Ihres Firehose-Streams erstellt haben, löschen Sie auch diesen Bucket.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wenn Sie eine neue Richtlinie für Ihren Firehose-Stream erstellt haben, löschen Sie auch diese Richtlinie.
- 7. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 8. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 9. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

 Wenn Sie eine neue Rolle f
ür Ihren Firehose-Stream erstellt haben, l
öschen Sie auch diese Rolle.

Löschen Sie Ihre Ressourcen CloudWatch

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Aus einem Kinesis-Stream in einem anderen Konto lesen

1 Note

Aktuelle Beispiele finden Sie unter<u>Beispiele für die Erstellung von und die Arbeit mit Managed</u> Service für Apache Flink-Anwendungen.

Dieses Beispiel zeigt, wie Sie eine Managed Service für Apache Flink-Anwendung erstellen, die Daten aus einem Kinesis Stream in einem anderen Konto liest. In diesem Beispiel verwenden Sie ein Konto für den Kinesis-Quellstream und ein zweites Konto für die Anwendung Managed Service für Apache Flink und den Senk-Kinesis-Stream.

Dieses Thema enthält die folgenden Abschnitte:

- Voraussetzungen
- Aufstellen
- Kinesis-Quellstream erstellen
- IAM-Rollen und -Richtlinien erstellen und aktualisieren
- <u>Aktualisieren Sie das Python-Skript</u>
- <u>Aktualisieren der Java-Anwendung</u>
- Erstellen Sie die Anwendung, laden Sie sie hoch und führen Sie sie aus

Voraussetzungen

- In diesem Tutorial ändern Sie das Erste Schritte-Beispiel, um Daten aus einem Kinesis Stream in einem anderen Konto zu lesen. Schließen Sie das <u>Tutorial: Erste Schritte mit der DataStream API</u> in Managed Service f
 ür Apache Flink-Tutorial ab, bevor Sie fortfahren.
- Sie benötigen zwei AWS -Konten, um dieses Tutorial abzuschließen: eines für den Quellstream und eines für die Anwendung und den Senken-Stream. Verwenden Sie das AWS Konto, das Sie für das Tutorial Erste Schritte verwendet haben, für die Anwendung und den Senken-Stream. Verwenden Sie ein anderes AWS -Konto für den Quellstream.

Aufstellen

Sie greifen mithilfe von benannten Profilen auf Ihre beiden AWS -Konten zu. Ändern Sie Ihre AWS -Anmeldeinformationen und Konfigurationsdateien so, dass sie zwei Profile enthalten, die die Regionsund Verbindungsinformationen für Ihre beiden Konten enthalten.

Die folgende Beispieldatei mit Anmeldeinformationen enthält zwei benannte Profile, ka-sourcestream-account-profile und ka-sink-stream-account-profile. Verwenden Sie das Konto, das Sie für das Tutorial Erste Schritte verwendet haben, für das Senken-Stream-Konto.

```
[ka-source-stream-account-profile]
aws_access_key_id=AKIAIOSFODNN7EXAMPLE
aws_secret_access_key=wJalrXUtnFEMI/K7MDENG/bPxRfiCYEXAMPLEKEY
[ka-sink-stream-account-profile]
aws_access_key_id=AKIAI44QH8DHBEXAMPLE
aws_secret_access_key=je7MtGbClwBF/2Zp9Utk/h3yCo8nvbEXAMPLEKEY
```

Die folgende Beispielkonfigurationsdatei enthält die gleichen benannten Profile mit Regions- und Ausgabeformatinformationen.

```
[profile ka-source-stream-account-profile]
region=us-west-2
output=json
[profile ka-sink-stream-account-profile]
region=us-west-2
output=json
```

In diesem Tutorial wird das ka-sink-stream-account-profile nicht verwendet. Es ist als Beispiel für den Zugriff auf zwei verschiedene AWS -Konten mit Profilen enthalten.

Weitere Informationen zur Verwendung von benannten Profilen mit dem AWS CLI finden Sie in der AWS Command Line InterfaceDokumentation unter Benannte Profile.

Kinesis-Quellstream erstellen

In diesem Abschnitt erstellen Sie den Kinesis Stream im Quellkonto.

Geben Sie den folgenden Befehl ein, um den Kinesis Stream zu erstellen, den die Anwendung für die Eingabe verwendet. Beachten Sie, dass der --profile-Parameter angibt, welches Kontoprofil verwendet werden soll.

```
$ aws kinesis create-stream \
--stream-name SourceAccountExampleInputStream \
--shard-count 1 \
--profile ka-source-stream-account-profile
```

IAM-Rollen und -Richtlinien erstellen und aktualisieren

Um den AWS -kontenübergreifenden Zugriff auf Objekte zu ermöglichen, erstellen Sie eine IAM-Rolle und -Richtlinie im Quellkonto. Anschließend ändern Sie die IAM-Richtlinie im Senkenkonto. Weitere Informationen zum Erstellen und Verwalten von IAM-Rollen und -Richtlinien finden Sie in den folgenden Themen im AWS Identity and Access Management -Benutzerhandbuch:

- Erstellen von IAM-Rollen
- Erstellen von IAM-Richtlinien

Rollen und Richtlinien für Sink-Accounts

 Bearbeiten Sie die Richtlinie kinesis-analytics-service-MyApplication-us-west-2 aus dem Tutorial Erste Schritte. Mit dieser Richtlinie kann die Rolle im Quellkonto übernommen werden, um den Quellstream zu lesen.
Wenn Sie die Konsole verwenden, um Ihre Anwendung zu erstellen, erstellt die Konsole eine Richtlinie mit dem Namen kinesis-analyticsservice-<application name>-<application region> und eine Rolle namens kinesisanalytics-<application name>-<application region>.

Fügen Sie der Richtlinie den unten hervorgehobenen Abschnitt hinzu. Ersetzen Sie die Beispielkonto-ID (*S0URCE01234567*) mit der ID des Kontos, das Sie für den Quellstream verwenden werden.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AssumeRoleInSourceAccount",
            "Effect": "Allow",
            "Action": "sts:AssumeRole",
            "Resource": "arn:aws:iam::SOURCE01234567:role/KA-Source-Stream-Role"
        },
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-username/aws-kinesis-analytics-java-
apps-1.0.jar"
            1
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:SINK012345678:log-group:*"
```

```
1
        },
        {
            "Sid": "ListCloudwatchLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:SINK012345678:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ٦
        },
        {
            "Sid": "PutCloudwatchLogs",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:SINK012345678:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ٦
        }
    ]
}
```

 Öffnen Sie die Rolle kinesis-analytics-MyApplication-us-west-2 und notieren Sie sich ihren Amazon-Ressourcennamen (ARN). Sie brauchen diesen im nächsten Abschnitt. Der Rollen-ARN sieht wie folgt aus.

```
arn:aws:iam::SINK012345678:role/service-role/kinesis-analytics-MyApplication-us-
west-2
```

Rollen und Richtlinien des Quellkontos

 Erstellen Sie eine Richtlinie im Quellkonto mit dem Namen KA-Source-Stream-Policy. Verwenden Sie die folgende JSON-Datei f
ür die Richtlinie. Ersetzen Sie die Beispielkontonummer durch die Kontonummer des Quellkontos.

{

```
"Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": [
                "kinesis:DescribeStream",
                "kinesis:GetRecords",
                "kinesis:GetShardIterator",
                "kinesis:ListShards"
            ],
            "Resource":
               "arn:aws:kinesis:us-west-2:SOURCE123456784:stream/
SourceAccountExampleInputStream"
        }
    ]
}
```

- 2. Erstellen Sie eine Rolle in dem Quellkonto namens MF-Source-Stream-Role. Gehen Sie wie folgt vor, um die Rolle mithilfe des Managed Flink-Anwendungsfalls zu erstellen:
 - 1. Wählen Sie in der IAM-Managementkonsole die Option Rolle erstellen aus.
 - 2. Wählen Sie auf der Seite Rolle erstellen AWS -Service aus. Wählen Sie in der Serviceliste Kinesis aus.
 - 3. Wählen Sie im Abschnitt Wählen Sie Ihren Anwendungsfall aus die Option Managed Service für Apache Flink aus.
 - 4. Wählen Sie Weiter: Berechtigungen aus.
 - 5. Fügen Sie die KA-Source-Stream-Policy-Berechtigungsrichtlinie hinzu, die Sie im vorherigen Schritt erstellt haben. Wählen Sie Weiter: Tags aus.
 - 6. Wählen Sie Weiter: Prüfen aus.
 - 7. Benennen Sie die Rolle KA-Source-Stream-Role. Ihre Anwendung verwendet diese Rolle für den Zugriff auf den Quellstream.
- 3. Fügen Sie die ARN kinesis-analytics-MyApplication-us-west-2 aus dem Senken-Konto zur Vertrauensstellung der KA-Source-Stream-Role-Rolle im Quellkonto hinzu:
 - 1. Öffnen Sie die KA-Source-Stream-Role in der IAM-Konsole.
 - 2. Wählen Sie die Registerkarte Trust Relationships.
 - 3. Wählen Sie Edit Trust Relationship (Vertrauensstellungen bearbeiten).

 Verwenden Sie den folgenden Code f
ür die Vertrauensstellung. Ersetzen Sie die beispielhafte Konto-ID (*SINK012345678*) mit Ihrer Senken-Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
          "Effect": "Allow",
          "Principal": {
              "AWS": "arn:aws:iam::SINK012345678:role/service-role/kinesis-analytics-
MyApplication-us-west-2"
        },
        "Action": "sts:AssumeRole"
        }
    ]
}
```

Aktualisieren Sie das Python-Skript

In diesem Abschnitt aktualisieren Sie das Python-Skript, das Beispieldaten generiert, um das Quellkontoprofil zu verwenden.

Aktualisieren Sie das stock.py-Skript mit den folgenden hervorgehobenen Änderungen.

```
import json
import boto3
import random
import datetime
import os
os.environ['AWS_PROFILE'] ='ka-source-stream-account-profile'
os.environ['AWS_DEFAULT_REGION'] = 'us-west-2'
kinesis = boto3.client('kinesis')
def getReferrer():
    data = {}
    now = datetime.datetime.now()
    str_now = now.isoformat()
    data['event_time'] = str_now
    data['ticker'] = random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV'])
    price = random.random() * 100
```

```
data['price'] = round(price, 2)
return data
while True:
    data = json.dumps(getReferrer())
    print(data)
    kinesis.put_record(
        StreamName="SourceAccountExampleInputStream",
        Data=data,
        PartitionKey="partitionkey")
```

Aktualisieren der Java-Anwendung

In diesem Abschnitt aktualisieren Sie den Java-Anwendungscode, sodass er beim Lesen aus dem Quellstream die Rolle des Quellkontos übernimmt.

Führen Sie die folgenden Änderungen an der Datei BasicStreamingJob.java durch. Ersetzen Sie die Beispiel-Quellkontonummer (*SOURCE01234567*) mit Ihrer Quellkontonummer.

```
package com.amazonaws.services.managed-flink;
import com.amazonaws.services.managed-flink.runtime.KinesisAnalyticsRuntime;
import org.apache.flink.api.common.serialization.SimpleStringSchema;
import org.apache.flink.streaming.api.datastream.DataStream;
import org.apache.flink.streaming.api.environment.StreamExecutionEnvironment;
import org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer;
import org.apache.flink.streaming.connectors.kinesis.FlinkKinesisProducer;
import org.apache.flink.streaming.connectors.kinesis.config.ConsumerConfigConstants;
import org.apache.flink.streaming.connectors.kinesis.config.AWSConfigConstants;
import java.io.IOException;
import java.util.Map;
import java.util.Properties;
 /**
 * A basic Managed Service for Apache Flink for Java application with Kinesis data
 streams
 * as source and sink.
 */
public class BasicStreamingJob {
    private static final String region = "us-west-2";
    private static final String inputStreamName = "SourceAccountExampleInputStream";
    private static final String outputStreamName = ExampleOutputStream;
```

```
private static final String roleArn = "arn:aws:iam::SOURCE01234567:role/KA-Source-
Stream-Role";
    private static final String roleSessionName = "ksassumedrolesession";
    private static DataStream<String>
 createSourceFromStaticConfig(StreamExecutionEnvironment env) {
        Properties inputProperties = new Properties();
        inputProperties.setProperty(AWSConfigConstants.AWS_CREDENTIALS_PROVIDER,
 "ASSUME_ROLE");
        inputProperties.setProperty(AWSConfigConstants.AWS_ROLE_ARN, roleArn);
        inputProperties.setProperty(AWSConfigConstants.AWS_ROLE_SESSION_NAME,
 roleSessionName);
        inputProperties.setProperty(ConsumerConfigConstants.AWS_REGION, region);
        inputProperties.setProperty(ConsumerConfigConstants.STREAM_INITIAL_POSITION,
 "LATEST");
        return env.addSource(new FlinkKinesisConsumer<>(inputStreamName, new
 SimpleStringSchema(), inputProperties));
    }
    private static KinesisStreamsSink<String> createSinkFromStaticConfig() {
        Properties outputProperties = new Properties();
        outputProperties.setProperty(AWSConfigConstants.AWS_REGION, region);
        return KinesisStreamsSink.<String>builder()
                .setKinesisClientProperties(outputProperties)
                .setSerializationSchema(new SimpleStringSchema())
                .setStreamName(outputProperties.getProperty("OUTPUT_STREAM",
 "ExampleOutputStream"))
                .setPartitionKeyGenerator(element ->
 String.valueOf(element.hashCode()))
                .build();
    }
    public static void main(String[] args) throws Exception {
        // set up the streaming execution environment
        final StreamExecutionEnvironment env =
 StreamExecutionEnvironment.getExecutionEnvironment();
        DataStream<String> input = createSourceFromStaticConfig(env);
        input.addSink(createSinkFromStaticConfig());
        env.execute("Flink Streaming Java API Skeleton");
```

}

}

Erstellen Sie die Anwendung, laden Sie sie hoch und führen Sie sie aus

Um die Anwendung zu aktualisieren und auszuführen, führen Sie Folgendes aus:

1. Erstellen Sie die Anwendung erneut, indem Sie folgenden Befehl im Verzeichnis mit der Datei pom.xml ausführen.

```
mvn package -Dflink.version=1.15.3
```

- Löschen Sie die vorherige JAR-Datei aus Ihrem Amazon Simple Storage Service (Amazon S3)-Bucket und laden Sie dann die neue aws-kinesis-analytics-java-apps-1.0.jar Datei in den S3-Bucket hoch.
- 3. Wählen Sie auf der Seite der Anwendung in der Managed Service für Apache Flink-Konsole die Optionen Konfigurieren, Aktualisieren aus, um die JAR-Datei der Anwendung neu zu laden.
- 4. Führen Sie das stock.py-Skript aus, um Daten an den Quellstream zu senden.

python stock.py

Die Anwendung liest jetzt Daten aus dem Kinesis Stream in dem anderen Konto.

Sie können überprüfen, ob die Anwendung funktioniert, indem Sie die PutRecords.Bytes-Metrik des ExampleOutputStream-Streams überprüfen. Wenn im Ausgabestrom Aktivität vorhanden ist, funktioniert die Anwendung ordnungsgemäß.

Tutorial: Einen benutzerdefinierten Truststore mit Amazon MSK verwenden

Note

Aktuelle Beispiele finden Sie unter. Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-Anwendungen

Aktuelle Datenquelle APIs

Wenn Sie die aktuelle Datenquelle verwenden APIs, kann Ihre Anwendung das <u>hier</u> beschriebene Serviceprogramm Amazon MSK Config Providers nutzen. Dadurch kann Ihre KafkaSource Funktion auf Ihren Keystore und Truststore für gegenseitiges TLS in Amazon S3 zugreifen.

```
. . .
// define names of config providers:
builder.setProperty("config.providers", "secretsmanager,s3import");
// provide implementation classes for each provider:
builder.setProperty("config.providers.secretsmanager.class",
 "com.amazonaws.kafka.config.providers.SecretsManagerConfigProvider");
builder.setProperty("config.providers.s3import.class",
 "com.amazonaws.kafka.config.providers.S3ImportConfigProvider");
String region = appProperties.get(Helpers.S3_BUCKET_REGION_KEY).toString();
String keystoreS3Bucket = appProperties.get(Helpers.KEYSTORE_S3_BUCKET_KEY).toString();
String keystoreS3Path = appProperties.get(Helpers.KEYSTORE_S3_PATH_KEY).toString();
String truststoreS3Bucket =
 appProperties.get(Helpers.TRUSTSTORE_S3_BUCKET_KEY).toString();
String truststoreS3Path = appProperties.get(Helpers.TRUSTSTORE_S3_PATH_KEY).toString();
String keystorePassSecret =
 appProperties.get(Helpers.KEYSTORE_PASS_SECRET_KEY).toString();
String keystorePassSecretField =
 appProperties.get(Helpers.KEYSTORE_PASS_SECRET_FIELD_KEY).toString();
// region, etc..
builder.setProperty("config.providers.s3import.param.region", region);
// properties
builder.setProperty("ssl.truststore.location", "${s3import:" + region + ":" +
 truststoreS3Bucket + "/" + truststoreS3Path + "}");
builder.setProperty("ssl.keystore.type", "PKCS12");
builder.setProperty("ssl.keystore.location", "${s3import:" + region + ":" +
 keystoreS3Bucket + "/" + keystoreS3Path + "}");
builder.setProperty("ssl.keystore.password", "${secretsmanager:" + keystorePassSecret +
 ":" + keystorePassSecretField + "}");
builder.setProperty("ssl.key.password", "${secretsmanager:" + keystorePassSecret + ":"
 + keystorePassSecretField + "}");
. . .
```

Weitere Informationen und einen Walkthrough finden Sie hier.

Vermächtnis SourceFunction APIs

Wenn Sie die Legacyversion verwenden SourceFunction APIs, verwendet Ihre Anwendung benutzerdefinierte Serialisierungs- und Deserialisierungsschemas, die die open Methode zum Laden des benutzerdefinierten Truststores überschreiben. Dadurch steht der Truststore der Anwendung zur Verfügung, nachdem die Anwendung Threads neu gestartet oder ersetzt hat.

Der benutzerdefinierte Truststore wird mithilfe des folgenden Codes abgerufen und gespeichert:

```
public static void initializeKafkaTruststore() {
    ClassLoader classLoader = Thread.currentThread().getContextClassLoader();
    URL inputUrl = classLoader.getResource("kafka.client.truststore.jks");
    File dest = new File("/tmp/kafka.client.truststore.jks");
    try {
        FileUtils.copyURLToFile(inputUrl, dest);
    } catch (Exception ex) {
        throw new FlinkRuntimeException("Failed to initialize Kakfa truststore", ex);
    }
}
```

1 Note

Für Apache Flink muss der Truststore im JKS-Format sein.

1 Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Übung ab.

Das folgende Tutorial zeigt, wie eine sichere Verbindung (Verschlüsselung bei der Übertragung) zu einem Kafka-Cluster hergestellt wird, der Serverzertifikate verwendet, die von einer benutzerdefinierten, privaten oder sogar selbst gehosteten Zertifizierungsstelle (CA) ausgestellt wurden.

Um einen Kafka-Client sicher über TLS mit einem Kafka-Cluster zu verbinden, muss der Kafka-Client (wie die Flink-Beispielanwendung) der gesamten Vertrauenskette vertrauen, die durch die Serverzertifikate des Kafka-Clusters dargestellt wird (von der ausstellenden CA bis zur Root-Level-CA). Als Beispiel für einen benutzerdefinierten Truststore verwenden wir einen Amazon MSK-Cluster mit aktivierter gegenseitiger TLS (MTLS) -Authentifizierung. Dies bedeutet, dass die MSK-Clusterknoten Serverzertifikate verwenden, die von einer -Certificate AWS Certificate Manager Private Certificate Authority (ACM Private CA) ausgestellt wurden, die für Ihr Konto und Ihre Region privat ist und der daher vom Standard-Truststore der Java Virtual Machine (JVM), die die Flink-Anwendung ausführt, nicht vertraut wird.

- Note
 - Ein Keystore wird verwendet, um private Schlüssel und Identitätszertifikate zu speichern, die eine Anwendung sowohl dem Server als auch dem Client zur Überprüfung vorlegen sollte.
 - Ein Truststore wird verwendet, um Zertifikate von zertifizierten Stellen (CA) zu speichern, die das vom Server in einer SSL-Verbindung vorgelegte Zertifikat verifizieren.

Sie können die in diesem Tutorial beschriebene Technik auch für Interaktionen zwischen einer Managed Service für Apache Flink-Anwendung und anderen Apache Kafka-Quellen verwenden, z. B.:

- Ein benutzerdefinierter Apache Kafka-Cluster, der in AWS (<u>Amazon EC2 oder Amazon EKS</u>) gehostet wird
- Ein Confluent-Kafka-Cluster, gehostet in AWS
- Einem lokalen Kafka-Cluster, auf den über AWS Direct Connect oder VPN zugegriffen wird

Dieses Tutorial enthält die folgenden Abschnitte:

- Erstellen einer VPC mit einem Amazon-MSK-Cluster
- Erstellen Sie einen benutzerdefinierten Truststore und wenden Sie ihn auf Ihren Cluster an
- Erstellen Sie den Anwendungscode
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen der Anwendung
- Konfigurieren der Anwendung
- Führen Sie die Anwendung aus.

Testen der Anwendung

Erstellen einer VPC mit einem Amazon-MSK-Cluster

Folgen Sie dem Tutorial Erste Schritte mit Amazon MSK, um eine Beispiel-VPC und Amazon MSK-Cluster für den Zugriff über eine Managed Service für Apache Flink-Anwendung zu erstellen.

Wenn Sie das Tutorial abgeschlossen haben, gehen Sie auch folgendermaßen vor:

• Wiederholen Sie in <u>Schritt 3: Thema erstellen</u> den Befehl kafka-topics.sh --create, um ein Zielthema mit dem Namen AWS KafkaTutorialTopicDestination zu erstellen:

bin/kafka-topics.sh --create --bootstrap-server ZooKeeperConnectionString -replication-factor 3 --partitions 1 --topic AWSKafkaTutorialTopicDestination

Note

Wenn der kafka-topics.sh-Befehl eine ZooKeeperClientTimeoutException zurückgibt, stellen Sie sicher, dass die Sicherheitsgruppe des Kafka-Clusters über eine Regel für eingehenden Datenverkehr verfügt, die den gesamten Datenverkehr von der privaten IP-Adresse der Client-Instance zulässt.

 Notieren Sie sich die Bootstrap-Serverliste f
ür Ihren Cluster. Sie k
önnen die Liste der Bootstrap-Server mit dem folgenden Befehl abrufen (ersetzen Sie durch *ClusterArn* die ARN Ihres MSK-Clusters):

```
aws kafka get-bootstrap-brokers --region us-west-2 --cluster-arn ClusterArn
{...
    "BootstrapBrokerStringTls": "b-2.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,b-1.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,b-3.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,b-3.awskafkatutorialcluste.t79r6y.c4.kafka.us-
west-2.amazonaws.com:9094,b-3.awskafkatutorialcluste.t79r6y.c4.kafka.us-
```

 Wenn Sie den Schritten in diesem Tutorial und den Voraussetzungs-Tutorials folgen, achten Sie darauf, dass Sie Ihre gewählte AWS -Region in Ihrem Code, Ihren Befehlen und Konsoleneinträgen verwenden. Erstellen Sie einen benutzerdefinierten Truststore und wenden Sie ihn auf Ihren Cluster an

In diesem Abschnitt erstellen Sie eine benutzerdefinierte Zertifizierungsstelle (CA), verwenden sie, um einen benutzerdefinierten Truststore zu generieren, und wenden sie auf Ihren MSK-Cluster an.

Folgen Sie dem Tutorial zur <u>Client-Authentifizierung</u> im Amazon Managed Streaming für Apache Kafka Entwicklerhandbuch, um Ihren benutzerdefinierten Truststore zu erstellen und anzuwenden.

Erstellen Sie den Anwendungscode

In diesem Abschnitt laden Sie die JAR-Datei der Anwendung herunter und kompilieren sie.

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

- Der Anwendungscode befindet sich in amazon-kinesis-data-analytics-javaexamples/CustomKeystore. Sie können den Code untersuchen, um sich mit der Struktur des Managed Service für Apache Flink-Codes vertraut zu machen.
- 4. Verwenden Sie entweder das Befehlszeilen-Maven-Tool oder Ihre bevorzugte Entwicklungsumgebung, um die JAR-Datei zu erstellen. Geben Sie Folgendes ein, um die JAR-Datei mit dem Befehlszeilen-Maven-Tool zu kompilieren:

mvn package -Dflink.version=1.15.3

Wenn der Build erfolgreich ist, wird die folgende Datei erstellt:

target/flink-app-1.0-SNAPSHOT.jar

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11.

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in den Amazon S3-Bucket hoch, den Sie im <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u>-Tutorial erstellt haben.

Note

Wenn Sie den Amazon S3-Bucket aus dem Tutorial Erste Schritte gelöscht haben, führen Sie den Schritt <u>the section called "Laden Sie die JAR-Datei mit dem Anwendungscode hoch"</u> erneut aus.

- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 2. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der flink-app-1.0-SNAPSHOT.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 3. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink 1.15.2 aus.
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Beim Erstellen eines Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **flink-app-1.0-SNAPSHOT.jar** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.

Note

Wenn Sie Anwendungsressourcen mithilfe der Konsole angeben (z. B. Protokolle oder eine VPC), ändert die Konsole Ihre Anwendungsausführungsrolle, um die Berechtigung für den Zugriff auf diese Ressourcen zu gewähren.

4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus. Geben Sie die folgenden Eigenschaften ein:

Gruppen-ID	Schlüssel	Value (Wert)
KafkaSource	Thema	AWS KafkaTutorialTopic

Gruppen-ID	Schlüssel	Value (Wert)
KafkaSource	bootstrap.servers	The bootstrap server list you saved previously
KafkaSource	security.protocol	SSL
KafkaSource	ssl.truststore.location	/usr/lib/jvm/java-11-amazon- corretto/lib/security/cacerts
KafkaSource	ssl.truststore.passwort	changeit

Das ssl.truststore.password für das Standardzertifikat ist "changeit". Sie müssen diesen Wert nicht ändern, wenn Sie das Standardzertifikat verwenden.

Wählen Sie erneut Gruppe hinzufügen. Geben Sie die folgenden Eigenschaften ein:

Gruppen-ID	Schlüssel	Value (Wert)
KafkaSink	Thema	AWS KafkaTutorialTopic Destination
KafkaSink	bootstrap.servers	The bootstrap server list you saved previously
KafkaSink	security.protocol	SSL
KafkaSink	ssl.truststore.location	/usr/lib/jvm/java-11-amazon- corretto/lib/security/cacerts
KafkaSink	ssl.truststore.passwort	changeit
KafkaSink	transaction.timeout.ms	1000

Der Anwendungscode liest die oben genannten Anwendungseigenschaften, um die Quelle und Senke zu konfigurieren, die für die Interaktion mit Ihrer VPC und Ihrem Amazon MSK-Cluster verwendet werden. Weitere Informationen zur Verwendung von Eigenschaften finden Sie unter Verwenden Sie Laufzeiteigenschaften.

- 5. Wählen Sie unter Snapshots die Option Deaktivieren aus. Dadurch wird es einfacher, die Anwendung zu aktualisieren, ohne ungültige Anwendungsstatusdaten zu laden.
- 6. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 7. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 8. Wählen Sie im Abschnitt Virtual Private Cloud (VPC) die VPC aus, die mit Ihrer Anwendung verknüpft werden soll. Wählen Sie die mit Ihrer VPC verknüpften Subnetze und Sicherheitsgruppe aus, die die Anwendung für den Zugriff auf VPC-Ressourcen verwenden soll.
- 9. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet.

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Testen der Anwendung

In diesem Abschnitt schreiben Sie Datensätze zum Quellthema. Die Anwendung liest Datensätze aus dem Quellthema und schreibt sie in das Zielthema. Sie überprüfen, ob die Anwendung funktioniert, indem Sie Datensätze in das Quellthema schreiben und Datensätze aus dem Zielthema lesen.

Um Datensätze aus den Themen zu schreiben und zu lesen, folgen Sie den Schritten in <u>Schritt 6:</u> Daten produzieren und verwenden im Tutorial Erste Schritte mit Amazon MSK.

Um aus dem Zielthema zu lesen, verwenden Sie in Ihrer zweiten Verbindung zum Cluster den Namen des Zielthemas anstelle des Quellthemas:

```
bin/kafka-console-consumer.sh --bootstrap-server BootstrapBrokerString --
consumer.config client.properties --topic AWS KafkaTutorialTopicDestination --from-
beginning
```

Wenn im Zielthema keine Datensätze angezeigt werden, lesen Sie den Abschnitt <u>Auf Ressourcen in</u> <u>einer VPC kann nicht zugegriffen werden</u> im Thema <u>Problembehandlung bei Managed Service für</u> Apache Flink.

Python-Beispiele

In den folgenden Beispielen wird die Erstellung von Anwendungen über Python mit der Apache Flink Tabellen-API gezeigt.

Themen

- Beispiel: Ein rollierendes Fenster in Python erstellen
- Beispiel: Ein gleitendes Fenster in Python erstellen
- Beispiel: Streaming-Daten in Python an Amazon S3 senden

Beispiel: Ein rollierendes Fenster in Python erstellen

Note

Aktuelle Beispiele finden Sie unter Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-Anwendungen.

In dieser Übung erstellen Sie eine Anwendung von Python Managed Service für Apache Flink, die Daten mithilfe eines rollierenden Fensters aggregiert.

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die Tutorial: Erste Schritte mit Python in Managed Service für Apache Flink-Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und überprüfen Sie ihn
- Komprimieren Sie den Apache Flink-Streaming-Python-Code und laden Sie ihn hoch
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Bereinigen von AWS -Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream)
- Einen Amazon S3-Bucket zum Speichern des Codes der Anwendung (ka-appcode-<username>)

Sie können die Kinesis Streams und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihre Data Streams ExampleInputStream und ExampleOutputStream.
- <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

Note

Das Python-Skript in diesem Abschnitt verwendet die AWS CLI. Sie müssen Ihren so konfigurieren AWS CLI, dass er Ihre Kontoanmeldeinformationen und Ihre Standardregion verwendet. Geben Sie AWS CLI zum Konfigurieren der Folgendes ein:

aws configure

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'ticker': round(random.random() * 100, 2)}
def generate(stream_name, kinesis_client):
    while True:
        data = get_data()
```

```
print(data)
kinesis_client.put_record(
StreamName=stream_name,
Data=json.dumps(data),
PartitionKey="partitionkey")

if __name__ == '__main__':
generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und überprüfen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/python/ TumblingWindow Verzeichnis.

Der Anwendungscode befindet sich in der tumbling-windows.py-Datei. Beachten Sie Folgendes zum Anwendungscode:

 Die Anwendung verwendet eine Kinesis-Tabellenquelle zum Lesen aus dem Quell-Stream. Der folgende Ausschnitt ruft die create_table-Funktion zum Erstellen der Kinesis-Tabellenquelle auf:

)

Die create_table-Funktion verwendet einen SQL-Befehl, um eine Tabelle zu erstellen, die von der Streaming-Quelle unterstützt wird:

```
def create_input_table(table_name, stream_name, region, stream_initpos):
    return """ CREATE TABLE {0} (
                ticker VARCHAR(6),
                price DOUBLE,
                event_time TIMESTAMP(3),
                WATERMARK FOR event_time AS event_time - INTERVAL '5' SECOND
              )
              PARTITIONED BY (ticker)
              WITH (
                'connector' = 'kinesis',
                'stream' = '{1}',
                'aws.region' = '{2}',
                'scan.stream.initpos' = '{3}',
                'format' = 'json',
                'json.timestamp-format.standard' = 'ISO-8601'
              ) """.format(table_name, stream_name, region, stream_initpos)
```

 Die Anwendung verwendet den Tumble-Operator, um Datensätze innerhalb eines bestimmten rollierenden Fensters zu aggregieren und die aggregierten Datensätze als Tabellenobjekt zurückzugeben:

```
tumbling_window_table = (
    input_table.window(
        Tumble.over("10.seconds").on("event_time").alias("ten_second_window")
    )
    .group_by("ticker, ten_second_window")
    .select("ticker, price.min as price, to_string(ten_second_window.end) as
    event_time")
```

Die Anwendung verwendet den Kinesis Flink-Konnektor aus <u>flink-sql-connector-kinesis-1.15.2.jar</u>.

Komprimieren Sie den Apache Flink-Streaming-Python-Code und laden Sie ihn hoch

In diesem Abschnitt laden Sie Ihren Anwendungscode in den Amazon S3-Bucket hoch, den Sie im Erstellen Sie abhängige Ressourcen-Abschnitt erstellt haben.

- Verwenden Sie Ihre bevorzugte Komprimierungsanwendung, um die Dateien tumblingwindows.py und flink-sql-connector-kinesis-1.15.2.jar zu komprimieren. Benennen Sie das Archiv myapp.zip.
- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 3. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der myapp.zipDatei, die Sie im vorherigen Schritt erstellt haben.
- 4. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.

1 Note

Managed Service für Apache Flink verwendet Apache Flink Version 1.15.2.

- Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **myapp.zip** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 5. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
<pre>consumer.config.0</pre>	<pre>input.stream.name</pre>	ExampleInputStream
consumer.config.0	aws.region	us-west-2
<pre>consumer.config.0</pre>	scan.stream.initpos	LATEST

Wählen Sie Speichern.

- 6. Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus.
- 7. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
producer.config.0	output.stream.name	ExampleOutputStream
producer.config.0	aws.region	us-west-2
producer.config.0	shard.count	1

- Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus. Geben Sie für Gruppen-ID kinesis.analytics.flink.run.options ein. Diese spezielle Eigenschaftsgruppe teilt Ihrer Anwendung mit, wo sich ihre Coderessourcen befinden. Weitere Informationen finden Sie unter <u>Geben Sie Ihre Codedateien an</u>.
- 9. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
kinesis.analytics. flink.run.options	python	<pre>tumbling-windows.py</pre>
kinesis.analytics. flink.run.options	jarfile	flink-sql-connecto r-kinesis-1.15.2.j ar

- 10. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 11. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 12. Wählen Sie Aktualisieren.

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "logs:DescribeLogGroups",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*",
                "arn:aws:s3:::ka-app-code-<username>/myapp.zip"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": "logs:DescribeLogStreams",
```

```
"Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:*"
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": "logs:PutLogEvents",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        ſ
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zur Bereinigung von AWS -Ressourcen, die im Rollierendes Fenster-Tutorial erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.

- 2. Wählen Sie den <username>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Ein gleitendes Fenster in Python erstellen

Note

Aktuelle Beispiele finden Sie unter<u>Beispiele für die Erstellung von und die Arbeit mit Managed</u> Service für Apache Flink-Anwendungen.

1 Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die Tutorial: Erste Schritte mit Python in Managed Service für Apache Flink-Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und überprüfen Sie ihn
- · Komprimieren Sie den Apache Flink-Streaming-Python-Code und laden Sie ihn hoch
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Bereinigen von AWS -Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream)
- Einen Amazon S3-Bucket zum Speichern des Codes der Anwendung (ka-appcode-<username>)

Sie können die Kinesis Streams und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihre Data Streams ExampleInputStream und ExampleOutputStream.
- <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

Das Python-Skript in diesem Abschnitt verwendet die AWS CLI. Sie müssen Ihren so konfigurieren AWS CLI, dass er Ihre Kontoanmeldeinformationen und Ihre Standardregion verwendet. Geben Sie AWS CLI zum Konfigurieren der Folgendes ein:

```
aws configure
```

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'price': round(random.random() * 100, 2)}
def generate(stream_name, kinesis_client):
    while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
            PartitionKey="partitionkey")
if ___name___ == '___main___':
    generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und überprüfen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

```
git clone https://github.com/aws-samples/>amazon-kinesis-data-analytics-java-
examples
```

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/python/ SlidingWindow Verzeichnis.

Der Anwendungscode befindet sich in der sliding-windows.py-Datei. Beachten Sie Folgendes zum Anwendungscode:

 Die Anwendung verwendet eine Kinesis-Tabellenquelle zum Lesen aus dem Quell-Stream. Der folgende Ausschnitt ruft die create_input_table-Funktion zum Erstellen der Kinesis-Tabellenquelle auf:

Die create_input_table-Funktion verwendet einen SQL-Befehl, um eine Tabelle zu erstellen, die von der Streaming-Quelle unterstützt wird:

```
def create_input_table(table_name, stream_name, region, stream_initpos):
    return """ CREATE TABLE {0} (
        ticker VARCHAR(6),
        price DOUBLE,
```

```
event_time TIMESTAMP(3),
WATERMARK FOR event_time AS event_time - INTERVAL '5' SECOND
)
PARTITIONED BY (ticker)
WITH (
    'connector' = 'kinesis',
    'stream' = '{1}',
    'aws.region' = '{2}',
    'scan.stream.initpos' = '{3}',
    'format' = 'json',
    'json.timestamp-format.standard' = 'ISO-8601'
) """.format(table_name, stream_name, region, stream_initpos)
}
```

 Die Anwendung verwendet den Slide-Operator, um Datensätze innerhalb eines bestimmten gleitenden Fensters zu aggregieren und die aggregierten Datensätze als Tabellenobjekt zurückzugeben:

```
sliding_window_table = (
    input_table
    .window(
        Slide.over("10.seconds")
        .every("5.seconds")
        .on("event_time")
        .alias("ten_second_window")
        )
        .group_by("ticker, ten_second_window")
        .select("ticker, price.min as price, to_string(ten_second_window.end) as
event_time")
    )
```

 Die Anwendung verwendet den Kinesis Flink-Konnektor aus der Datei <u>flink-sql-connector-</u> kinesis-1.15.2.jar.

Komprimieren Sie den Apache Flink-Streaming-Python-Code und laden Sie ihn hoch

In diesem Abschnitt laden Sie Ihren Anwendungscode in den Amazon S3-Bucket hoch, den Sie im Erstellen Sie abhängige Ressourcen-Abschnitt erstellt haben.

In diesem Abschnitt wird beschrieben, wie Sie Ihre Python-Anwendung verpacken.

- Verwenden Sie Ihre bevorzugte Komprimierungsanwendung, um die Dateien slidingwindows.py und flink-sql-connector-kinesis-1.15.2.jar zu komprimieren. Benennen Sie das Archiv myapp.zip.
- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 3. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der myapp.zipDatei, die Sie im vorherigen Schritt erstellt haben.
- 4. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.

1 Note

Managed Service für Apache Flink verwendet Apache Flink Version 1.15.2.

- Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **myapp.zip** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 5. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
<pre>consumer.config.0</pre>	<pre>input.stream.name</pre>	ExampleInputStream
<pre>consumer.config.0</pre>	aws.region	us-west-2
<pre>consumer.config.0</pre>	scan.stream.initpos	LATEST

Wählen Sie Speichern.

- 6. Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus.
- 7. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
producer.config.0	output.stream.name	ExampleOutputStream
producer.config.0	aws.region	us-west-2
producer.config.0	shard.count	1

- Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus. Geben Sie für Gruppen-ID kinesis.analytics.flink.run.options ein. Diese spezielle Eigenschaftsgruppe teilt Ihrer Anwendung mit, wo sich ihre Coderessourcen befinden. Weitere Informationen finden Sie unter <u>Geben Sie Ihre Codedateien an</u>.
- 9. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
kinesis.analytics. flink.run.options	python	<pre>sliding-windows.py</pre>
kinesis.analytics. flink.run.options	jarfile	flink-sql-connecto r-kinesis_1.15.2.j ar

- 10. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 11. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 12. Wählen Sie Aktualisieren.

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "logs:DescribeLogGroups",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*",
                "arn:aws:s3:::ka-app-code-<username>/myapp.zip"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": "logs:DescribeLogStreams",
```
```
"Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:*"
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": "logs:PutLogEvents",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        ſ
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Gleitendes Fenster erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.

- 2. Wählen Sie den <username>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Streaming-Daten in Python an Amazon S3 senden

Note

Aktuelle Beispiele finden Sie unter<u>Beispiele für die Erstellung von und die Arbeit mit Managed</u> Service für Apache Flink-Anwendungen.

In dieser Übung erstellen Sie eine Anwendung von Python Managed Service für Apache Flink, die Daten an eine Amazon Simple Storage Service-Senke streamt.

1 Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die Tutorial: Erste Schritte mit Python in Managed Service für Apache Flink-Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und überprüfen Sie ihn
- Komprimieren Sie den Apache Flink-Streaming-Python-Code und laden Sie ihn hoch
- Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus
- Bereinigen von AWS -Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Einen Kinesis Data Stream (ExampleInputStream)
- Einen Amazon S3-Bucket zum Speichern des Codes und der Ausgabe der Anwendung (ka-appcode-<username>)

Note

Managed Service für Apache Flink kann keine Daten auf Amazon S3 schreiben, wenn die serverseitige Verschlüsselung auf Managed Service für Apache Flink aktiviert ist.

Sie können den Kinesis-Stream und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

<u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihren Data Stream ExampleInputStream.

 <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

```
    Note
```

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

Note

Das Python-Skript in diesem Abschnitt verwendet die AWS CLI. Sie müssen Ihren so konfigurieren AWS CLI, dass er Ihre Kontoanmeldeinformationen und Ihre Standardregion verwendet. Geben Sie AWS CLI zum Konfigurieren der Folgendes ein:

aws configure

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
    return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'price': round(random.random() * 100, 2)}
```

```
def generate(stream_name, kinesis_client):
    while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
            PartitionKey="partitionkey")

if __name__ == '__main__':
    generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und überprüfen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/python/ S3Sink Verzeichnis.

Der Anwendungscode befindet sich in der streaming-file-sink.py-Datei. Beachten Sie Folgendes zum Anwendungscode: Die Anwendung verwendet eine Kinesis-Tabellenquelle zum Lesen aus dem Quell-Stream. Der folgende Ausschnitt ruft die create_source_table-Funktion zum Erstellen der Kinesis-Tabellenquelle auf:

Die create_source_table-Funktion verwendet einen SQL-Befehl, um eine Tabelle zu erstellen, die von der Streaming-Quelle unterstützt wird

```
import datetime
    import json
    import random
    import boto3
    STREAM_NAME = "ExampleInputStream"
    def get_data():
        return {
            'event_time': datetime.datetime.now().isoformat(),
            'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
            'price': round(random.random() * 100, 2)}
    def generate(stream_name, kinesis_client):
        while True:
            data = get_data()
            print(data)
            kinesis_client.put_record(
                StreamName=stream_name,
                Data=json.dumps(data),
                PartitionKey="partitionkey")
    if ___name___ == '___main___':
        generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

 Die Anwendung verwendet den filesystem-Konnektor zum Senden von Datensätzen an einen Amazon-S3-Bucket:

```
def create_sink_table(table_name, bucket_name):
    return """ CREATE TABLE {0} (
        ticker VARCHAR(6),
        price DOUBLE,
        event_time VARCHAR(64)
      )
      PARTITIONED BY (ticker)
      WITH (
            'connector'='filesystem',
            'path'='s3a://{1}/',
            'format'='json',
            'sink.partition-commit.policy.kind'='success-file',
            'sink.partition-commit.delay' = '1 min'
      ) """.format(table_name, bucket_name)
```

Die Anwendung verwendet den Kinesis Flink-Konnektor aus der Datei <u>flink-sql-connector-kinesis-1.15.2.jar</u>.

Komprimieren Sie den Apache Flink-Streaming-Python-Code und laden Sie ihn hoch

In diesem Abschnitt laden Sie Ihren Anwendungscode in den Amazon S3-Bucket hoch, den Sie im Erstellen Sie abhängige Ressourcen-Abschnitt erstellt haben.

- Verwenden Sie Ihre bevorzugte Komprimierungsanwendung, um die Dateien streamingfile-sink.py und <u>flink-sql-connector-kinesis-1.15.2.jar</u> zu komprimieren. Benennen Sie das Archiv myapp.zip.
- Wählen Sie in der Amazon S3 S3-Konsole den <username> Bucket ka-app-code- und wählen Sie Upload aus.
- 3. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der myapp.zipDatei, die Sie im vorherigen Schritt erstellt haben.
- 4. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und führen Sie die Anwendung Managed Service für Apache Flink aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.
 - Note

Managed Service für Apache Flink verwendet Apache Flink Version 1.15.2.

- Belassen Sie den Versions-Pulldown bei Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.
 - Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Konfigurieren der Anwendung

1. Wählen Sie auf der MyApplicationSeite Configure aus.

- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket **ka-app-code-**<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **myapp.zip** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 5. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
<pre>consumer.config.0</pre>	<pre>input.stream.name</pre>	ExampleInputStream
<pre>consumer.config.0</pre>	aws.region	us-west-2
<pre>consumer.config.0</pre>	scan.stream.initpos	LATEST

Wählen Sie Speichern.

- Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus. Geben Sie für Gruppen-ID kinesis.analytics.flink.run.options ein. Diese spezielle Eigenschaftsgruppe teilt Ihrer Anwendung mit, wo sich ihre Coderessourcen befinden. Weitere Informationen finden Sie unter <u>Geben Sie Ihre Codedateien an</u>.
- 7. Geben Sie die folgenden Eigenschaften und Werte der Anwendung ein:

Gruppen-ID	Schlüssel	Value (Wert)
kinesis.analytics. flink.run.options	python	streaming-file-sin k.py
kinesis.analytics. flink.run.options	jarfile	S3Sink/lib/flink-s ql-connector-kines is-1.15.2.jar

8. Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus. Geben Sie für Gruppen-ID **sink.config.0** ein. Diese spezielle Eigenschaftsgruppe teilt Ihrer Anwendung mit, wo sich ihre

Coderessourcen befinden. Weitere Informationen finden Sie unter <u>Geben Sie Ihre Codedateien</u> an.

9. Geben Sie die folgenden Anwendungseigenschaften und -Werte ein: (*bucket-name*Ersetzen Sie durch den tatsächlichen Namen Ihres Amazon S3 S3-Buckets.)

Gruppen-ID	Schlüssel	Value (Wert)
sink.config.0	output.bucket.name	bucket-name

- 10. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 11. Für die CloudWatch Protokollierung aktivieren Sie das Kontrollkästchen Aktivieren.
- 12. Wählen Sie Aktualisieren.

1 Note

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.

- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- 4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "logs:DescribeLogGroups",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*",
                "arn:aws:s3:::ka-app-code-<username>/myapp.zip"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": "logs:DescribeLogStreams",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:*"
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": "logs:PutLogEvents",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
```

```
]
        },
        ſ
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteObjects",
            "Effect": "Allow",
            "Action": [
                "s3:Abort*",
                "s3:DeleteObject*",
                "s3:GetObject*",
                "s3:GetBucket*",
                "s3:List*",
                "s3:ListBucket",
                "s3:PutObject"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-<username>",
                "arn:aws:s3:::ka-app-code-<username>/*"
            ]
        }
    ]
}
```

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Gleitendes Fenster erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- · Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- So löschen Sie den Kinesis Data Stream
- Löschen Ihrer Amazon-S3-Objekte und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

So löschen Sie den Kinesis Data Stream

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Amazon-S3-Objekte und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den <username>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.

- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Scala-Beispiele

In den folgenden Beispielen wird die Erstellung von Anwendungen über Scala mit Apache Flink gezeigt.

Themen

- Beispiel: Ein rollierendes Fenster in Scala erstellen
- Beispiel: Ein gleitendes Fenster in Scala erstellen
- Beispiel: Streaming-Daten in Scala an Amazon S3 senden

Beispiel: Ein rollierendes Fenster in Scala erstellen

1 Note

Aktuelle Beispiele finden Sie unter. Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-Anwendungen

1 Note

Ab Version 1.15 ist Flink Scala-frei. Anwendungen können jetzt die Java-API von jeder Scala-Version aus verwenden. Flink verwendet Scala intern immer noch in einigen

Schlüsselkomponenten, macht Scala jedoch nicht im Benutzercode-Classloader verfügbar. Aus diesem Grund müssen Benutzer Scala-Abhängigkeiten zu ihren Jar-Archiven hinzufügen. Weitere Informationen zu den Scala-Änderungen in Flink 1.15 finden Sie unter <u>Scalafrei in</u> <u>One Fifteen</u>.

In dieser Übung erstellen Sie eine einfache Streaming-Anwendung, die Scala 3.2.0 und die Java-API von Flink verwendet. DataStream Die Anwendung liest Daten aus dem Kinesis Stream, aggregiert sie mithilfe von gleitenden Fenstern und schreibt die Ergebnisse in den Kinesis-Ausgabestream.

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die Übung Erste Schritte (Scala) ab.

Dieses Thema enthält die folgenden Abschnitte:

- Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode und laden Sie ihn hoch
- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen und Ausführen der Anwendung (CLI)
- Den Anwendungscode aktualisieren
- Bereinigen von AWS -Ressourcen

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter <u>Git installieren</u>.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

3. Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/scala/ TumblingWindow Verzeichnis. Beachten Sie Folgendes zum Anwendungscode:

- Eine build.sbt-Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.
- Die BasicStreamingJob.scala-Datei enthält die Hauptmethode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

```
private def createSource: FlinkKinesisConsumer[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val inputProperties = applicationProperties.get("ConsumerConfigProperties")
  new FlinkKinesisConsumer[String](inputProperties.getProperty(streamNameKey,
  defaultInputStreamName),
    new SimpleStringSchema, inputProperties)
}
```

Die Anwendung verwendet auch eine Kinesis-Senke, um in den Ergebnisstream zu schreiben. Der folgende Codeausschnitt erstellt die Kinesis-Senke:

```
private def createSink: KinesisStreamsSink[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val outputProperties = applicationProperties.get("ProducerConfigProperties")
  KinesisStreamsSink.builder[String]
   .setKinesisClientProperties(outputProperties)
   .setSerializationSchema(new SimpleStringSchema)
   .setStreamName(outputProperties.getProperty(streamNameKey,
  defaultOutputStreamName))
   .setPartitionKeyGenerator((element: String) => String.valueOf(element.hashCode))
   .build
}
```

 Die Anwendung verwendet den Fensteroperator, um die Anzahl der Werte f
ür jedes Aktionssymbol über ein rollierendes Fenster von 5 Sekunden zu ermitteln. Der folgende Code erstellt den Operator und sendet die aggregierten Daten an eine neue Kinesis Data Streams Senke:

```
environment.addSource(createSource)
.map { value =>
```

```
val jsonNode = jsonParser.readValue(value, classOf[JsonNode])
new Tuple2[String, Int](jsonNode.get("ticker").toString, 1)
}
.returns(Types.TUPLE(Types.STRING, Types.INT))
.keyBy(v => v.f0) // Logically partition the stream for each ticker
.window(TumblingProcessingTimeWindows.of(Time.seconds(10)))
.sum(1) // Sum the number of tickers per partition
.map { value => value.f0 + "," + value.f1.toString + "\n" }
.sinkTo(createSink)
```

- Die Anwendung erstellt Quell- und Senkenkonnektoren für den Zugriff auf externe Ressourcen, indem ein StreamExecutionEnvironment Objekt verwendet wird.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit dynamischen Anwendungseigenschaften. Die Laufzeiteigenschaften der Anwendung werden gelesen, um die Konnektoren zu konfigurieren. Weitere Informationen zu Laufzeiteigenschaften finden Sie unter Laufzeiteigenschaften.

Kompilieren Sie den Anwendungscode und laden Sie ihn hoch

In diesem Abschnitt kompilieren Sie Ihren Anwendungscode und laden ihn in einen Amazon-S3-Bucket hoch.

Kompilieren des Anwendungscodes

Verwenden Sie das <u>SBT</u>-Build-Tool, um den Scala-Code für die Anwendung zu erstellen. Informationen zur Installation von SBT finden Sie unter <u>Installieren von SBT mit CS-Setup</u>. Sie müssen auch das Java Development Kits (JDK) installieren. Siehe <u>Voraussetzungen für das</u> <u>Fertigstellen der Übungen</u>.

1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code mit SBT kompilieren und verpacken:

sbt assembly

2. Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/scala-3.2.0/tumbling-window-scala-1.0.jar

Hochladen des Apache Flink-Streaming-Scala-Codes

In diesem Abschnitt erstellen Sie einen Amazon S3-Bucket und laden Ihren Anwendungscode hoch.

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Bucket erstellen aus
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- 7. Wählen Sie den Bucket ka-app-code-<username> und dann Hochladen aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der tumbling-window-scala-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 9. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- Geben Sie auf der Seite Managed Service f
 ür Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.

- Geben Sie für Beschreibung den Text My Scala test app ein.
- Wählen Sie als Laufzeit Apache Flink aus.
- Belassen Sie die Version als Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Konfigurieren der Anwendung

Verwenden Sie das folgende Verfahren, um die Anwendung zu konfigurieren.

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **tumbling-window-scala-1.0.jar** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 5. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ConsumerConfigProp erties	<pre>input.stream.name</pre>	ExampleInputStream
ConsumerConfigProp erties	aws.region	us-west-2
ConsumerConfigProp erties	flink.stream.initp os	LATEST

Wählen Sie Speichern.

- 6. Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus.
- 7. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	output.stream.name	ExampleOutputStream
ProducerConfigProp erties	aws.region	us-west-2

- 8. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 9. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 10. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

• Protokollgruppe: /aws/kinesis-analytics/MyApplication

Protokollstream: kinesis-analytics-log-stream

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Amazon S3-Bucket.

Um die IAM-Richtlinie zu bearbeiten, um S3-Bucket-Berechtigungen hinzuzufügen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- 4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-username/tumbling-window-scala-1.0.jar"
            ]
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
```

```
"arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            1
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ]
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Stoppt die Anwendung

Um die Anwendung zu beenden, wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Erstellen und Ausführen der Anwendung (CLI)

In diesem Abschnitt verwenden Sie, AWS Command Line Interface um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen. Verwenden Sie den AWS CLI -Befehl kinesisanalyticsv2, um Managed Service für Apache Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

1 Note

Sie müssen eine Berechtigungsrichtlinie und eine Rolle für Ihre Anwendung erstellen. Wenn Sie diese IAM-Ressourcen nicht erstellen, kann Ihre Anwendung nicht auf ihre Daten und Protokollstreams zugreifen.

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die Lese-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die Schreib-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie **username** durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) **(012345678901)** mit Ihrer Konto-ID. Die **MF-stream-rw-role**-Serviceausführungsrolle sollte auf die kundenspezifische Rolle zugeschnitten sein.

{

```
"ApplicationName": "tumbling_window",
    "ApplicationDescription": "Scala tumbling window application",
    "RuntimeEnvironment": "FLINK-1_15",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "tumbling-window-scala-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleInputStream",
                    "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleOutputStream"
               }
            }
         ]
      }
    },
    "CloudWatchLoggingOptions": [
      {
         "LogStreamARN": "arn:aws:logs:us-west-2:012345678901:log-
group:MyApplication:log-stream:kinesis-analytics-log-stream"
      }
   ]
```

}

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie im IAM-Benutzerhandbuch.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Rollen und dann Rolle erstellen.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus
- 4. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus.
- 5. Wählen Sie unter Wählen Sie Ihren Anwendungsfall aus die Option Managed Service für Apache Flink aus.
- 6. Wählen Sie Weiter: Berechtigungen aus.
- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 8. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle

9. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

1 Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt, Erstellen einer Berechtigungsrichtlinie, erstellt haben.

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.
- d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter <u>Erstellen einer IAM-Rolle</u> (Konsole) im IAM-Benutzerhandbuch.

Erstellen der Anwendung

Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (username) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (012345678901) in der Service-Ausführungsrolle mit Ihrer Konto-ID. Die ServiceExecutionRole sollte die IAM-Benutzerrolle enthalten, die Sie im vorherigen Abschnitt erstellt haben.

```
"ApplicationName": "tumbling_window",
    "ApplicationDescription": "Scala getting started application",
    "RuntimeEnvironment": "FLINK-1_15",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
```

```
"CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "tumbling-window-scala-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleInputStream",
                    "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleOutputStream"
               }
            }
         ]
      }
    },
    "CloudWatchLoggingOptions": [
      {
         "LogStreamARN": "arn:aws:logs:us-west-2:012345678901:log-
group:MyApplication:log-stream:kinesis-analytics-log-stream"
      }
   ]
```

Führen Sie den CreateApplicationmit der folgenden Anforderung aus, um die Anwendung zu erstellen:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

}

Starten der Anwendung

In diesem Abschnitt verwenden Sie die <u>StartApplication</u>-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{
    "ApplicationName": "tumbling_window",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
        }
}
```

2. Führen Sie die StartApplication-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die StopApplication-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "tumbling_window"
}
```

2. Führen Sie die StopApplication-Aktion mit der vorherigen Anforderung zum Stoppen der Anwendung aus:

aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

```
Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-
Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen
mit Ihrer Anwendung finden Sie unter Einrichten der Anwendungsprotokollierung.
```

Aktualisieren von Umgebungseigenschaften

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.

```
{"ApplicationName": "tumbling_window",
   "CurrentApplicationVersionId": 1,
   "ApplicationConfigurationUpdate": {
      "EnvironmentPropertyUpdates": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleInputStream",
                    "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleOutputStream"
               }
            }
```

```
]
}
}
```

2. Führen Sie die UpdateApplication-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die UpdateApplication-CLI-Aktion.

Note

Um eine neue Version des Anwendungscodes mit demselben Dateinamen zu laden, müssen Sie die neue Objektversion angeben. Weitere Informationen zur Verwendung von Amazon S3-Objektversionen finden Sie unter <u>Versionsverwaltung aktivieren oder deaktivieren</u>.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication dabei denselben Amazon S3 S3-Bucket und Objektnamen sowie die neue Objektversion an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (<username>) mit dem Suffix, das Sie im Abschnitt <u>Erstellen Sie abhängige</u> <u>Ressourcen</u> ausgewählt haben.

{

```
"ApplicationName": "tumbling_window",
```

```
"CurrentApplicationVersionId": 1,
```

```
"ApplicationConfigurationUpdate": {
```

```
"ApplicationCodeConfigurationUpdate": {
    "CodeContentUpdate": {
        "S3ContentLocationUpdate": {
            "BucketARNUpdate": "arn:aws:s3:::ka-app-code-username",
            "FileKeyUpdate": "tumbling-window-scala-1.0.jar",
            "ObjectVersionUpdate": "SAMPLEUehYngP87ex1nzYIGYgfhypvDU"
        }
    }
}
```

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zur Bereinigung von AWS -Ressourcen, die im Rollierendes Fenster-Tutorial erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- · Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.

- Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username*>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Ein gleitendes Fenster in Scala erstellen

Note

Aktuelle Beispiele finden Sie unter Beispiele für die Erstellung von und die Arbeit mit Managed Service für Apache Flink-Anwendungen.

1 Note

Ab Version 1.15 ist Flink Scala-frei. Anwendungen können jetzt die Java-API von jeder Scala-Version aus verwenden. Flink verwendet Scala intern immer noch in einigen Schlüsselkomponenten, macht Scala jedoch nicht im Benutzercode-Classloader verfügbar. Aus diesem Grund müssen Benutzer Scala-Abhängigkeiten zu ihren Jar-Archiven hinzufügen. Weitere Informationen zu den Scala-Änderungen in Flink 1.15 finden Sie unter <u>Scalafrei in</u> <u>One Fifteen.</u>

In dieser Übung erstellen Sie eine einfache Streaming-Anwendung, die Scala 3.2.0 und die Java-API von Flink verwendet. DataStream Die Anwendung liest Daten aus dem Kinesis Stream, aggregiert sie mithilfe von gleitenden Fenstern und schreibt die Ergebnisse in den Kinesis-Ausgabestream.

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die Übung Erste Schritte (Scala) ab.

Dieses Thema enthält die folgenden Abschnitte:

- Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode und laden Sie ihn hoch
- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen und Ausführen der Anwendung (CLI)
- Den Anwendungscode aktualisieren
- Bereinigen von AWS -Ressourcen

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/scala/ SlidingWindow Verzeichnis.

Beachten Sie Folgendes zum Anwendungscode:

- Eine build.sbt-Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.
- Die BasicStreamingJob.scala-Datei enthält die Hauptmethode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

```
private def createSource: FlinkKinesisConsumer[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val inputProperties = applicationProperties.get("ConsumerConfigProperties")
  new FlinkKinesisConsumer[String](inputProperties.getProperty(streamNameKey,
  defaultInputStreamName),
    new SimpleStringSchema, inputProperties)
}
```

Die Anwendung verwendet auch eine Kinesis-Senke, um in den Ergebnisstream zu schreiben. Der folgende Codeausschnitt erstellt die Kinesis-Senke:

```
private def createSink: KinesisStreamsSink[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val outputProperties = applicationProperties.get("ProducerConfigProperties")
```

```
KinesisStreamsSink.builder[String]
   .setKinesisClientProperties(outputProperties)
   .setSerializationSchema(new SimpleStringSchema)
   .setStreamName(outputProperties.getProperty(streamNameKey,
   defaultOutputStreamName))
   .setPartitionKeyGenerator((element: String) => String.valueOf(element.hashCode))
   .build
}
```

 Die Anwendung verwendet den Fensteroperator, um die Anzahl der Werte f
ür jedes Aktionssymbol über ein 10-Sekunden-Fenster, das um 5 Sekunden gleitet, zu ermitteln. Der folgende Code erstellt den Operator und sendet die aggregierten Daten an eine neue Kinesis Data Streams Senke:

```
environment.addSource(createSource)
.map { value =>
    val jsonNode = jsonParser.readValue(value, classOf[JsonNode])
    new Tuple2[String, Double](jsonNode.get("ticker").toString,
jsonNode.get("price").asDouble)
    }
    .returns(Types.TUPLE(Types.STRING, Types.DOUBLE))
    .keyBy(v => v.f0) // Logically partition the stream for each word
    .window(SlidingProcessingTimeWindows.of(Time.seconds(10), Time.seconds(5)))
    .min(1) // Calculate minimum price per ticker over the window
    .map { value => value.f0 + String.format(",%.2f", value.f1) + "\n" }
    .sinkTo(createSink)
```

- Die Anwendung erstellt Quell- und Senkenkonnektoren für den Zugriff auf externe Ressourcen, indem ein StreamExecutionEnvironment Objekt verwendet wird.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit dynamischen Anwendungseigenschaften. Die Laufzeiteigenschaften der Anwendung werden gelesen, um die Konnektoren zu konfigurieren. Weitere Informationen zu Laufzeiteigenschaften finden Sie unter Laufzeiteigenschaften.

Kompilieren Sie den Anwendungscode und laden Sie ihn hoch

In diesem Abschnitt kompilieren Sie Ihren Anwendungscode und laden ihn in einen Amazon-S3-Bucket hoch.
Kompilieren des Anwendungscodes

Verwenden Sie das <u>SBT</u>-Build-Tool, um den Scala-Code für die Anwendung zu erstellen. Informationen zur Installation von SBT finden Sie unter <u>Installieren von SBT mit CS-Setup</u>. Sie müssen auch das Java Development Kits (JDK) installieren. Siehe <u>Voraussetzungen für das</u> Fertigstellen der Übungen.

1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code mit SBT kompilieren und verpacken:

sbt assembly

2. Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/scala-3.2.0/sliding-window-scala-1.0.jar

Hochladen des Apache Flink-Streaming-Scala-Codes

In diesem Abschnitt erstellen Sie einen Amazon S3-Bucket und laden Ihren Anwendungscode hoch.

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Bucket erstellen aus
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- 7. Wählen Sie den Bucket ka-app-code-<username> und dann Hochladen aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der sliding-window-scala-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 9. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My Scala test app ein.
 - Wählen Sie als Laufzeit Apache Flink aus.
 - Belassen Sie die Version als Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-*MyApplication-us-west-2*

Konfigurieren der Anwendung

Verwenden Sie das folgende Verfahren, um die Anwendung zu konfigurieren.

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert sliding-window-scala-1.0.jar.
 ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 5. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ConsumerConfigProp erties	input.stream.name	ExampleInputStream
ConsumerConfigProp erties	aws.region	us-west-2
ConsumerConfigProp erties	flink.stream.initp os	LATEST

Wählen Sie Speichern.

- 6. Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus.
- 7. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	output.stream.name	ExampleOutputStream
ProducerConfigProp erties	aws.region	us-west-2

- 8. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 9. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 10. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Amazon S3-Bucket.

Um die IAM-Richtlinie zu bearbeiten, um S3-Bucket-Berechtigungen hinzuzufügen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.

4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-username/sliding-window-scala-1.0.jar"
            ]
       },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ]
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
```

```
],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ٦
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Stoppt die Anwendung

Um die Anwendung zu beenden, wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Erstellen und Ausführen der Anwendung (CLI)

In diesem Abschnitt verwenden Sie, AWS Command Line Interface um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen. Verwenden Sie den AWS CLI -Befehl kinesisanalyticsv2, um Managed Service für Apache Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

Note

Sie müssen eine Berechtigungsrichtlinie und eine Rolle für Ihre Anwendung erstellen. Wenn Sie diese IAM-Ressourcen nicht erstellen, kann Ihre Anwendung nicht auf ihre Daten und Protokollstreams zugreifen.

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die Lese-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die Schreib-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie **username** durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) **(012345678901)** mit Ihrer Konto-ID.

```
{
    "ApplicationName": "sliding_window",
    "ApplicationDescription": "Scala sliding window application",
    "RuntimeEnvironment": "FLINK-1_15",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "sliding-window-scala-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
```

```
"aws.region" : "us-west-2",
                     "stream.name" : "ExampleInputStream",
                     "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                     "aws.region" : "us-west-2",
                     "stream.name" : "ExampleOutputStream"
               }
            }
         ]
      }
    },
    "CloudWatchLoggingOptions": [
      {
         "LogStreamARN": "arn:aws:logs:us-west-2:012345678901:log-
group:MyApplication:log-stream:kinesis-analytics-log-stream"
      }
   ]
}
```

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: <u>Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie</u> im IAM-Benutzerhandbuch.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Rollen und dann Rolle erstellen.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus
- 4. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus.
- 5. Wählen Sie unter Wählen Sie Ihren Anwendungsfall aus die Option Managed Service für Apache Flink aus.
- 6. Wählen Sie Weiter: Berechtigungen aus.
- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 8. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle

9. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt, Erstellen einer Berechtigungsrichtlinie, erstellt haben.

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.
- d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter Erstellen einer IAM-Rolle (Konsole) im IAM-Benutzerhandbuch.

Erstellen der Anwendung

Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (username) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (012345678901) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
{
    "ApplicationName": "sliding_window",
    "ApplicationDescription": "Scala sliding_window application",
    "RuntimeEnvironment": "FLINK-1_15",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "sliding-window-scala-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleInputStream",
                    "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
```

Führen Sie den CreateApplicationmit der folgenden Anforderung aus, um die Anwendung zu erstellen:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

Starten der Anwendung

In diesem Abschnitt verwenden Sie die StartApplication-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{
    "ApplicationName": "sliding_window",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
        }
    }
}
```

2. Führen Sie die StartApplication-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die StopApplication-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "sliding_window"
}
```

2. Führen Sie die StopApplication-Aktion mit der vorherigen Anforderung zum Stoppen der Anwendung aus:

```
aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json
```

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter Einrichten der Anwendungsprotokollierung.

Aktualisieren von Umgebungseigenschaften

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.

```
{"ApplicationName": "sliding_window",
   "CurrentApplicationVersionId": 1,
   "ApplicationConfigurationUpdate": {
      "EnvironmentPropertyUpdates": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleInputStream",
                    "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleOutputStream"
               }
            }
         ]
     }
  }
}
```

2. Führen Sie die UpdateApplication-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die UpdateApplication-CLI-Aktion.

1 Note

Um eine neue Version des Anwendungscodes mit demselben Dateinamen zu laden, müssen Sie die neue Objektversion angeben. Weitere Informationen zur Verwendung von Amazon S3-Objektversionen finden Sie unter Versionsverwaltung aktivieren oder deaktivieren.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication dabei denselben Amazon S3 S3-Bucket und Objektnamen sowie die neue Objektversion an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (<username>) mit dem Suffix, das Sie im Abschnitt <u>Erstellen Sie abhängige</u> <u>Ressourcen</u> ausgewählt haben.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Gleitendes Fenster erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- CloudWatch Löschen Sie Ihre Ressourcen

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username*>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.

- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Beispiel: Streaming-Daten in Scala an Amazon S3 senden

1 Note

Aktuelle Beispiele finden Sie unter<u>Beispiele für die Erstellung von und die Arbeit mit Managed</u> Service für Apache Flink-Anwendungen.

Note

Ab Version 1.15 ist Flink Scala-frei. Anwendungen können jetzt die Java-API von jeder Scala-Version aus verwenden. Flink verwendet Scala intern immer noch in einigen Schlüsselkomponenten, macht Scala jedoch nicht im Benutzercode-Classloader verfügbar. Aus diesem Grund müssen Benutzer Scala-Abhängigkeiten zu ihren Jar-Archiven hinzufügen. Weitere Informationen zu den Scala-Änderungen in Flink 1.15 finden Sie unter <u>Scalafrei in</u> <u>One Fifteen.</u> In dieser Übung erstellen Sie eine einfache Streaming-Anwendung, die Scala 3.2.0 und die Java-API von Flink verwendet. DataStream Die Anwendung liest Daten aus dem Kinesis Stream, aggregiert sie mithilfe von gleitenden Fenstern und schreibt die Ergebnisse in S3.

Note

Um die erforderlichen Voraussetzungen für diese Übung einzurichten, schließen Sie zunächst die Übung Erste Schritte (Scala) ab. Sie müssen nur einen zusätzlichen Ordner **data/** im Amazon-S3-Bucket ka-app-code erstellen. <username>

Dieses Thema enthält die folgenden Abschnitte:

- · Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Kompilieren Sie den Anwendungscode und laden Sie ihn hoch
- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen und Ausführen der Anwendung (CLI)
- Den Anwendungscode aktualisieren
- Bereinigen von AWS Ressourcen

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/scala/S3Sink Verzeichnis.

Beachten Sie Folgendes zum Anwendungscode:

• Eine build.sbt-Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.

- Die BasicStreamingJob.scala-Datei enthält die Hauptmethode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

```
private def createSource: FlinkKinesisConsumer[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val inputProperties = applicationProperties.get("ConsumerConfigProperties")
  new FlinkKinesisConsumer[String](inputProperties.getProperty(streamNameKey,
  defaultInputStreamName),
    new SimpleStringSchema, inputProperties)
}
```

Die Anwendung verwendet auch eine StreamingFileSink , um in einen Amazon-S3-Bucket zu schreiben:

```
def createSink: StreamingFileSink[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val s3SinkPath =
  applicationProperties.get("ProducerConfigProperties").getProperty("s3.sink.path")
  StreamingFileSink
   .forRowFormat(new Path(s3SinkPath), new SimpleStringEncoder[String]("UTF-8"))
   .build()
}
```

- Die Anwendung erstellt Quell- und Senkenkonnektoren f
 ür den Zugriff auf externe Ressourcen, indem ein StreamExecutionEnvironment Objekt verwendet wird.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit dynamischen Anwendungseigenschaften. Die Laufzeiteigenschaften der Anwendung werden gelesen, um die Konnektoren zu konfigurieren. Weitere Informationen zu Laufzeiteigenschaften finden Sie unter Laufzeiteigenschaften.

Kompilieren Sie den Anwendungscode und laden Sie ihn hoch

In diesem Abschnitt kompilieren Sie Ihren Anwendungscode und laden ihn in einen Amazon-S3-Bucket hoch. Kompilieren des Anwendungscodes

Verwenden Sie das <u>SBT</u>-Build-Tool, um den Scala-Code für die Anwendung zu erstellen. Informationen zur Installation von SBT finden Sie unter <u>Installieren von SBT mit CS-Setup</u>. Sie müssen auch das Java Development Kits (JDK) installieren. Siehe <u>Voraussetzungen für das</u> Fertigstellen der Übungen.

1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code mit SBT kompilieren und verpacken:

sbt assembly

2. Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/scala-3.2.0/s3-sink-scala-1.0.jar

Hochladen des Apache Flink-Streaming-Scala-Codes

In diesem Abschnitt erstellen Sie einen Amazon S3-Bucket und laden Ihren Anwendungscode hoch.

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Bucket erstellen aus
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- 7. Wählen Sie den Bucket ka-app-code-<username> und dann Hochladen aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der s3-sink-scala-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 9. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My java test app ein.
 - Wählen Sie als Laufzeit Apache Flink aus.
 - Belassen Sie die Version als Apache Flink Version 1.15.2 (empfohlene Version).
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-*MyApplication-us-west-2*

Konfigurieren der Anwendung

Verwenden Sie das folgende Verfahren, um die Anwendung zu konfigurieren.

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **s3-sink-scala-1.0.jar** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 5. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ConsumerConfigProp erties	<pre>input.stream.name</pre>	ExampleInputStream
ConsumerConfigProp erties	aws.region	us-west-2
ConsumerConfigProp erties	flink.stream.initp os	LATEST

Wählen Sie Speichern.

- 6. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 7. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	s3.sink.path	s3a://ka-app-code- <user-name> /data</user-name>

- 8. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 9. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 10. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Amazon S3-Bucket.

Um die IAM-Richtlinie zu bearbeiten, um S3-Bucket-Berechtigungen hinzuzufügen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto IDs (012345678901) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
```

```
"s3:Abort*",
                "s3:DeleteObject*",
                "s3:GetObject*",
                "s3:GetBucket*",
                "s3:List*",
                "s3:ListBucket",
                "s3:PutObject"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-<username>",
                "arn:aws:s3:::ka-app-code-<username>/*"
            ]
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ]
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ]
```

```
},
{
    "Sid": "ReadInputStream",
    "Effect": "Allow",
    "Action": "kinesis:*",
    "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
    }
]
```

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Stoppt die Anwendung

Um die Anwendung zu beenden, wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Erstellen und Ausführen der Anwendung (CLI)

In diesem Abschnitt verwenden Sie, AWS Command Line Interface um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen. Verwenden Sie den AWS CLI -Befehl kinesisanalyticsv2, um Managed Service für Apache Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

Note

Sie müssen eine Berechtigungsrichtlinie und eine Rolle für Ihre Anwendung erstellen. Wenn Sie diese IAM-Ressourcen nicht erstellen, kann Ihre Anwendung nicht auf ihre Daten und Protokollstreams zugreifen.

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die Lese-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die Schreib-Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle Managed Service für Apache Flink

übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie **username** durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) **(012345678901)** mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3:::ka-app-code-username/getting-started-scala-1.0.jar"
            ]
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                 "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-analytics/
MyApplication:log-stream:*"
            ٦
        },
```

```
{
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ٦,
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-analytics/
MyApplication:log-stream:kinesis-analytics-log-stream"
            1
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: <u>Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie</u> im IAM-Benutzerhandbuch.

Erstellen einer IAM-Rolle

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Rollen und dann Rolle erstellen.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus
- 4. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus.
- 5. Wählen Sie unter Wählen Sie Ihren Anwendungsfall aus die Option Managed Service für Apache Flink aus.
- 6. Wählen Sie Weiter: Berechtigungen aus.
- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 8. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle

9. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

1 Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt, Erstellen einer Berechtigungsrichtlinie, erstellt haben.

- a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.
- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.

d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter <u>Erstellen einer IAM-Rolle</u> (Konsole) im IAM-Benutzerhandbuch.

Erstellen der Anwendung

Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (username) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (012345678901) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
{
```

```
"ApplicationName": "s3_sink",
"ApplicationDescription": "Scala tumbling window application",
"RuntimeEnvironment": "FLINK-1_15",
"ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
"ApplicationConfiguration": {
    "ApplicationCodeConfiguration": {
        "CodeContent": {
            "S3ContentLocation": {
                "BucketARN": "arn:aws:s3:::ka-app-code-username",
                "FileKey": "s3-sink-scala-1.0.jar"
            }
        },
        "CodeContentType": "ZIPFILE"
    },
    "EnvironmentProperties": {
     "PropertyGroups": [
        {
           "PropertyGroupId": "ConsumerConfigProperties",
           "PropertyMap" : {
                "aws.region" : "us-west-2",
                "stream.name" : "ExampleInputStream",
                "flink.stream.initpos" : "LATEST"
           }
        },
```

```
{
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                     "s3.sink.path" : "s3a://ka-app-code-<username>/data"
               }
            }
         ]
      }
    },
    "CloudWatchLoggingOptions": [
      {
         "LogStreamARN": "arn:aws:logs:us-west-2:012345678901:log-
group:MyApplication:log-stream:kinesis-analytics-log-stream"
      }
   ]
}
```

Führen Sie den <u>CreateApplication</u>mit der folgenden Anforderung aus, um die Anwendung zu erstellen:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

Starten der Anwendung

In diesem Abschnitt verwenden Sie die StartApplication-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
{{
    "ApplicationName": "s3_sink",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
            }
    }
}
```

2. Führen Sie die StartApplication-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

```
aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json
```

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die <u>StopApplication</u>-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "s3_sink"
}
```

2. Führen Sie die StopApplication-Aktion mit der vorherigen Anforderung zum Stoppen der Anwendung aus:

```
aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json
```

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter Einrichten der Anwendungsprotokollierung.

Aktualisieren von Umgebungseigenschaften

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.

```
{"ApplicationName": "s3_sink",
   "CurrentApplicationVersionId": 1,
   "ApplicationConfigurationUpdate": {
      "EnvironmentPropertyUpdates": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
                    "aws.region" : "us-west-2",
                    "stream.name" : "ExampleInputStream",
                    "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                    "s3.sink.path" : "s3a://ka-app-code-<username>/data"
               }
            }
         ]
      }
  }
}
```

2. Führen Sie die UpdateApplication-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die UpdateApplication-CLI-Aktion.

1 Note

Um eine neue Version des Anwendungscodes mit demselben Dateinamen zu laden, müssen Sie die neue Objektversion angeben. Weitere Informationen zur Verwendung von Amazon S3-Objektversionen finden Sie unter Versionsverwaltung aktivieren oder deaktivieren.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication dabei denselben Amazon S3 S3-Bucket und Objektnamen sowie die neue Objektversion an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (<username>) mit dem Suffix, das Sie im Abschnitt <u>Erstellen Sie abhängige</u> <u>Ressourcen</u> ausgewählt haben.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zur Bereinigung von AWS -Ressourcen, die im Rollierendes Fenster-Tutorial erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis Data Streams
- Löschen Ihres Amazon-S3-Objekten und Buckets
- So löschen Sie die IAM-Ressourcen
- <u>CloudWatch Löschen Sie Ihre Ressourcen</u>

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplicationManaged Service für Apache Flink.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter. https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Ihres Amazon-S3-Objekten und Buckets

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username*>Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.

- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-#- MyApplication -us-west-2.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Verwenden Sie ein Studio-Notebook mit Managed Service für Apache Flink

Studio-Notebooks für Managed Service für Apache Flink ermöglichen Ihnen die interaktive Abfrage von Datenströmen in Echtzeit und die einfache Erstellung und Ausführung von Stream-Verarbeitungsanwendungen mit Standard-SQL, Python und Scala. Mit ein paar Klicks in der AWS Management-Konsole können Sie ein serverloses Notebook starten, um Datenströme abzufragen und innerhalb von Sekunden Ergebnisse zu erhalten.

Ein Notebook ist eine webbasierte Entwicklungsumgebung. Notebooks bieten ein einfaches interaktives Entwicklungserlebnis in Kombination mit den fortschrittlichen Funktionen von Apache Flink. Studio-Notebooks verwenden Notebooks, die auf <u>Apache Zeppelin</u> basieren, und <u>Apache Flink</u> als Engine für die Streamverarbeitung. Studio-Notebooks kombinieren diese Technologien nahtlos, um Entwicklern aller Qualifikationsstufen erweiterte Analysen von Datenströmen zugänglich zu machen.

Apache Zeppelin bietet für Ihre Studio-Notebooks eine komplette Suite von Analysetools, darunter die folgenden:

- Datenvisualisierung
- Exportieren der Daten in Dateien
- Kontrolle über das Ausgabeformat zur Erleichterung von Analysen

Hinweise zu den ersten Schritten mit Managed Service für Apache Flink und Apache Zeppelin finden Sie unter <u>Tutorial: Erstellen Sie ein Studio-Notizbuch in Managed Service für Apache Flink</u>. Weitere Informationen zu Apache Zeppelin finden Sie in der Apache-Zeppelin-Dokumentation.

Mit einem Notizbuch modellieren Sie Abfragen mithilfe der Apache Flink <u>Table API und SQL</u> in SQL, Python oder Scala oder der <u>DataStream API</u> in Scala. Mit wenigen Klicks können Sie das Studio-Notebook dann zu einer kontinuierlich laufenden, nicht interaktiven Stream-Verarbeitungsanwendung, die Managed Service für Apache Flink nutzt, für Ihre Produktions-Workloads heraufstufen.

Dieses Thema enthält die folgenden Abschnitte:

- Verwenden Sie die richtige Runtime-Version des Studio-Notebooks
- Erstellen Sie ein Studio-Notizbuch
- · Führen Sie eine interaktive Analyse von Streaming-Daten durch

- Stellen Sie es als Anwendung mit dauerhaftem Zustand bereit
- Überprüfen Sie die IAM-Berechtigungen für Studio-Notebooks
- Verwenden Sie Konnektoren und Abhängigkeiten
- Implementieren Sie benutzerdefinierte Funktionen
- Checkpointing aktivieren
- Aktualisieren Sie Studio Runtime
- Arbeiten Sie mit AWS Glue
- Beispiele und Tutorials für Studio-Notebooks in Managed Service für Apache Flink
- Beheben Sie Probleme mit Studio-Notebooks für Managed Service für Apache Flink
- Erstellen Sie benutzerdefinierte IAM-Richtlinien für Managed Service für Apache Flink Studio-Notebooks

Verwenden Sie die richtige Runtime-Version des Studio-Notebooks

Mit Amazon Managed Service für Apache Flink Studio können Sie Datenströme in Echtzeit abfragen und Streamverarbeitungsanwendungen mit Standard-SQL, Python und Scala in einem interaktiven Notizbuch erstellen und ausführen. Studio-Notebooks werden von <u>Apache Zeppelin</u> unterstützt und verwenden Apache Flink als Stream-Verarbeitungs-Engine.

Note

Wir werden Studio Runtime mit Apache Flink Version 1.11 am 5. November 2024 als veraltet markieren. Ab diesem Datum können Sie mit dieser Version keine neuen Notebooks ausführen oder neue Anwendungen erstellen. Wir empfehlen, dass Sie vor diesem Zeitpunkt auf die neueste Runtime (Apache Flink 1.15 und Apache Zeppelin 0.10) aktualisieren. Hinweise zur Aktualisierung Ihres Notebooks finden Sie unter. <u>Aktualisieren Sie Studio</u> <u>Runtime</u>

Studio-Laufzeit

Apache Flink-Version	Apache Zeppelin- Ausführung	Python-Version	
1.15	0.1	3.8	Empfohlen
Apache Flink-Version	Apache Zeppelin- Ausführung	Python-Version	
----------------------	--------------------------------	----------------	---
1.13	0.9	3.8	Wird bis 16. Oktober 2024 unterstützt
1.11	0.9	3.7	Wird am 24. Februar 2025 nicht mehr unterstützt

Erstellen Sie ein Studio-Notizbuch

Ein Studio-Notebook enthält in SQL, Python oder Scala geschriebene Abfragen oder Programme, die auf Streaming-Daten ausgeführt werden und Analyseergebnisse zurückgeben. Sie erstellen Ihre Anwendung entweder mit der Konsole oder der CLI und stellen Abfragen zur Analyse der Daten aus Ihrer Datenquelle bereit.

Die Anwendung besteht aus folgenden Komponenten:

- Einer Datenquelle, z. B. einem Amazon-MSK-Cluster, einem Kinesis-Datenstrom oder einem Amazon-S3-Bucket.
- Eine AWS Glue Datenbank. Diese Datenbank enthält Tabellen, in denen Ihre Datenquellen- und Zielschemas und Endpunkte gespeichert sind. Weitere Informationen finden Sie unter <u>Arbeiten Sie</u> mit AWS Glue.
- Ihr Anwendungscode. Ihr Code implementiert Ihre Analyseabfrage oder Ihr Analyseprogramm.
- Ihre Anwendungseinstellungen und Laufzeiteigenschaften. Informationen zu Anwendungseinstellungen und Laufzeiteigenschaften finden Sie unter den folgenden Themen im Entwicklerhandbuch f
 ür Apache-Flink-Anwendungen:
 - Anwendungsparallelität und -skalierung: Sie verwenden die Parallelitätseinstellung Ihrer Anwendung, um die Anzahl der Abfragen zu steuern, die Ihre Anwendung gleichzeitig ausführen kann. Ihre Abfragen können auch von der erhöhten Parallelität profitieren, wenn sie mehrere Ausführungspfade haben, z. B. unter den folgenden Umständen:
 - Bei der Verarbeitung mehrerer Shards eines Kinesis-Datenstroms
 - Bei der Partitionierung von Daten mit dem KeyBy-Operator.
 - Bei Verwendung mehrerer Fensteroperatoren

Weitere Informationen zur Anwendungsskalierung finden Sie unter <u>Anwendungsskalierung in</u> Managed Service für Apache Flink.

- Protokollierung und Überwachung: Informationen zur Anwendungsprotokollierung und überwachung finden Sie unter <u>Protokollierung und Überwachung in Amazon Managed Service</u> für Apache Flink.
- Ihre Anwendung verwendet Checkpoints und Savepoints aus Gründen der Fehlertoleranz. Checkpoints und Savepoints sind für Studio-Notebooks standardmäßig nicht aktiviert.

Sie können Ihr Studio-Notizbuch entweder mit dem AWS Management Console oder dem erstellen AWS CLI.

Beim Erstellen der Anwendung über die Konsole stehen Ihnen die folgenden Optionen zur Verfügung:

- Wählen Sie in der Amazon-MSK-Konsole Ihren Cluster aus und wählen Sie dann Daten in Echtzeit verarbeiten.
- Wählen Sie in der Konsole von Kinesis Data Streams Ihren Datenstrom und dann auf der Registerkarte Anwendungen die Option Daten in Echtzeit verarbeiten aus.
- Wählen Sie in der Konsole von Managed Service für Apache Flink die Registerkarte Studio und dann Studio-Notebook erstellen aus.

Ein Tutorial finden Sie unter Ereigniserkennung mit Managed Service für Apache Flink.

Ein Beispiel für eine erweiterte Studio-Notebook-Lösung finden Sie unter <u>Apache Flink in Amazon</u> Managed Service für Apache Flink Studio.

Führen Sie eine interaktive Analyse von Streaming-Daten durch

Sie verwenden ein Serverless Notebook mit Apache Zeppelin, um mit Ihren Streaming-Daten zu interagieren. Ihr Notebook kann mehrere Notizen enthalten, und jede Notiz kann einen oder mehrere Absätze enthalten, in die Sie Ihren Code schreiben können.

Die folgende beispielhafte SQL-Abfrage zeigt, wie Daten aus einer Datenquelle abgerufen werden:

```
%flink.ssql(type=update)
select * from stock;
```

Weitere Beispiele für Flink Streaming SQL-Abfragen finden Sie im <u>Beispiele und Tutorials für Studio-</u> <u>Notebooks in Managed Service für Apache Flink</u> Folgenden und unter <u>Abfragen</u> in der Apache Flink-Dokumentation.

Sie können Flink-SQL-Abfragen im Studio-Notebook verwenden, um Streaming-Daten abzufragen. Sie können auch Python (Tabellen-API) und Scala (Table und Datastream APIs) verwenden, um Programme zu schreiben, mit denen Sie Ihre Streaming-Daten interaktiv abfragen können. Sie können die Ergebnisse Ihrer Abfragen oder Programme anzeigen, sie innerhalb von Sekunden aktualisieren und erneut ausführen, um aktualisierte Ergebnisse anzuzeigen.

Flink-Interpreter

Sie geben mithilfe eines Interpreters an, in welcher Sprache Managed Service für Apache Flink Ihre Anwendung ausführt. Sie können die folgenden Interpreter mit Managed Service für Apache Flink verwenden:

Name	Klasse	Beschreibung
%flink	FlinkInterpreter	Erzeugt ExecutionEnvironme nt/StreamExecutionEnvironme nt/BatchTableEnvironment/St reamTableEnvironmentund stellt eine Scala-Umgebung bereit
%flink.pyflink	PyFlinkInterpreter	Stellt eine Python-Umgebung bereit
%flink.ipyflink	IPyFlinkInterpreter	Stellt eine IPython-Umgebung bereit
%flink.ssql	FlinkStreamSqlInterpreter	Stellt eine Stream-SQL- Umgebung bereit
%flink.bsql	FlinkBatchSqlInterpreter	Stellt eine Batch-SQL- Umgebung bereit

Weitere Informationen zu Flink-Interpretern finden Sie unter Flink-Interpreter für Apache Zeppelin.

Wenn Sie %flink.pyflink oder %flink.ipyflink als Interpreter verwenden, müssen Sie den ZeppelinContext verwenden, um die Ergebnisse im Notebook zu visualisieren.

PyFlink Spezifischere Beispiele finden Sie unter Interaktive Abfrage Ihrer Datenströme mithilfe von Managed Service für Apache Flink Studio und Python.

Tabellenumgebungsvariablen von Apache Zeppelin

Apache Zeppelin bietet mithilfe von Umgebungsvariablen Zugriff auf Tabellenumgebungsressourcen.

Sie greifen mit den folgenden Variablen auf Ressourcen der Scala-Tabellenumgebung zu:

Variable	Ressource
senv	StreamExecutionEnvironment
stenv	StreamTableEnvironment for blink planner

Sie greifen mit den folgenden Variablen auf Ressourcen der Python-Tabellenumgebung zu:

Variable	Ressource
s_env	StreamExecutionEnvironment
st_env	StreamTableEnvironment for blink planner

Weitere Informationen zur Verwendung von Tabellenumgebungen finden Sie unter <u>Concepts and</u> <u>Common API</u> in der Apache Flink-Dokumentation.

Stellen Sie es als Anwendung mit dauerhaftem Zustand bereit

Sie können Ihren Code erstellen und zu Amazon S3 exportieren. Sie können den Code, den Sie in Ihrer Notiz geschrieben haben, in eine kontinuierlich laufende Stream-Verarbeitungsanwendung umwandeln. Es gibt zwei Arten, eine Apache-Flink-Anwendung auf Managed Service für Apache Flink auszuführen: Mit einem Studio-Notebook haben Sie die Möglichkeit, Ihren Code interaktiv zu entwickeln, die Ergebnisse Ihres Codes in Echtzeit anzuzeigen und ihn in Ihrer Notiz zu visualisieren.

Tabellenumgebungsvariablen von Apache Zeppelin

Nachdem Sie eine Notiz für die Ausführung im Streaming-Modus bereitgestellt haben, erstellt Managed Service für Apache Flink eine Anwendung für Sie, die kontinuierlich ausgeführt wird, Daten aus Ihren Quellen liest, in Ihre Ziele schreibt, den Status lang laufender Anwendungen beibehält und automatisch auf der Grundlage des Durchsatzes Ihrer Quellströme skaliert.

1 Note

Der S3-Bucket, in den Sie den Anwendungscode exportieren, muss sich in derselben Region wie Ihr Studio-Notebook befinden.

Sie können eine Notiz aus Ihrem Studio-Notebook nur bereitstellen, wenn sie die folgenden Kriterien erfüllt:

- Die Absätze müssen der Reihe nach angeordnet werden. Wenn Sie Ihre Anwendung bereitstellen, werden alle Absätze in einer Notiz nacheinander ausgeführt (left-to-right, top-to-bottom), so wie sie in Ihrer Notiz erscheinen. Sie können diese Reihenfolge überprüfen, indem Sie in Ihrer Notiz Alle Absätze ausführen wählen.
- Ihr Code ist eine Kombination aus Python und SQL oder Scala und SQL. Wir unterstützen Python und Scala derzeit nicht zusammen für deploy-as-application.
- Ihre Notiz darf nur die folgenden Interpreter enthalten: %flink, %flink.ssql, %flink.pyflink, %flink.ipyflink, %md.
- Die Verwendung des <u>Zeppelin-Kontext</u>-Objekts z wird nicht unterstützt. Methoden, die nichts zurückgeben, tun nichts, außer eine Warnung zu protokollieren. Andere Methoden lösen Python-Ausnahmen aus oder können nicht in Scala kompiliert werden.
- Eine Notiz muss zu einem einzigen Apache-Flink-Auftrag führen.
- Notizen mit <u>dynamischen Formularen</u> werden für die Bereitstellung als Anwendung nicht unterstützt.
- %md-Absätze (<u>Markdown</u>) werden bei der Bereitstellung als Anwendung übersprungen, da davon ausgegangen wird, dass sie menschenlesbare Dokumentation enthalten, die für die Ausführung als Teil der resultierenden Anwendung nicht geeignet ist.
- Absätze, die für die Ausführung in Zeppelin deaktiviert sind, werden bei der Bereitstellung als Anwendung übersprungen. Selbst wenn ein deaktivierter Absatz einen inkompatiblen Interpreter verwendet, z. B. %flink.ipyflink in einer Notiz mit %flink- and %flink.ssql-Interpretern, wird er bei der Bereitstellung der Notiz als Anwendung übersprungen und führt nicht zu einem Fehler.

- Damit die Anwendungsbereitstellung erfolgreich ist, muss mindestens ein Absatz mit Quellcode (Flink SQL PyFlink oder Flink Scala) vorhanden sein, der für die Ausführung aktiviert ist.
- Das Einstellen von Parallelität in der Interpreter-Direktive innerhalb eines Absatzes (z. B. %flink.ssql(parallelism=32)) wird in Anwendungen, die über eine Notiz bereitgestellt werden, ignoriert. Stattdessen können Sie die bereitgestellte Anwendung über die AWS Command Line Interface oder AWS API aktualisieren AWS Management Console, um die Parallelismusund/oder ParallelismPer KPU-Einstellungen entsprechend dem Grad der Parallelität zu ändern, den Ihre Anwendung benötigt, oder Sie können Autoscaling für Ihre bereitgestellte Anwendung aktivieren.
- Wenn Sie als Anwendung mit einem dauerhaften Zustand bereitstellen, muss Ihre VPC über Internetzugang verfügen. Wenn Ihre VPC keinen Internetzugang hat, finden Sie weitere Informationen unter <u>Als Anwendung mit dauerhaftem Zustand in einer VPC ohne Internetzugang</u> <u>bereitstellen</u>.

Scala/Python-Kriterien

- Verwenden Sie in Ihrem Scala- oder Python-Code den <u>Blink-Planer</u> (senv, stenv für Scala; s_env, st_env für Python) und nicht den älteren "Flink"-Planer (stenv_2 für Scala, st_env_2 für Python). Das Apache-Flink-Projekt empfiehlt die Verwendung des Blink-Planers für Produktionsanwendungen. Dies ist der Standardplaner in Zeppelin und Flink.
- Ihre Python-Absätze dürfen keine <u>Shell-Aufrufe/Zuweisungen verwenden ! oder IPython magische</u> <u>Befehle wie %timeit oder %conda in Notizen verwenden, die als Anwendungen</u> bereitgestellt werden sollen.
- Sie können Scala-Fallklassen nicht als Parameter von Funktionen verwenden, die an Datenflussoperatoren höherer Ordnung wie map und filter übergeben werden. Informationen zu Scala-Fallklassen finden Sie unter FALLKLASSEN in der Scala-Dokumentation.

SQL-Kriterien

- Einfache SELECT-Anweisungen sind nicht zulässig, da es kein Äquivalent zum Ausgabeabschnitt eines Absatzes gibt, in den die Daten übermittelt werden können.
- In jedem Absatz müssen DDL-Anweisungen (USE, CREATE, ALTER, DROP, SET, RESET) den DML-(INSERT)-Anweisungen vorangehen. Dies liegt daran, dass DML-Anweisungen in einem Absatz zusammen als ein einziger Flink-Auftrag eingereicht werden müssen.

 Es darf höchstens einen Absatz geben, der DML-Anweisungen enthält. Das liegt daran, dass wir für diese deploy-as-application Funktion nur das Senden eines einzelnen Jobs an Flink unterstützen.

Weitere Informationen und ein Beispiel finden Sie unter <u>Übersetzen, Redigieren und Analysieren</u> von Streaming-Daten mithilfe von SQL-Funktionen mit Amazon Managed Service für Apache Flink, Amazon Translate und Amazon Comprehend.

Überprüfen Sie die IAM-Berechtigungen für Studio-Notebooks

Managed Service für Apache Flink erstellt eine IAM-Rolle für Sie, wenn Sie ein Studio-Notebook über die AWS Management Console erstellen. Außerdem wird dieser Rolle eine Richtlinie zugeordnet, die den folgenden Zugriff ermöglicht:

Service	Zugriff
CloudWatch Logs	Auflisten
Amazon EC2	Auflisten
AWS Glue	Lesen, Schreiben
Managed Service für Apache Flink	Lesen
Managed Service für Apache Flink V2	Lesen
Amazon S3	Lesen, Schreiben

Verwenden Sie Konnektoren und Abhängigkeiten

Konnektoren ermöglichen es Ihnen, Daten über verschiedene Technologien hinweg zu lesen und zu schreiben. Managed Service für Apache Flink bündelt drei Standard-Konnektoren mit Ihrem Studio-Notebook. Sie können auch benutzerdefinierte Konnektoren verwenden. Weitere Informationen zu Konnektoren finden Sie unter <u>Tabellen- und SQL-Konnektoren</u> in der Apache-Flink-Dokumentation.

Standardkonnektoren

Wenn Sie das verwenden, AWS Management Console um Ihr Studio-Notizbuch zu erstellen, enthält Managed Service for Apache Flink standardmäßig die folgenden benutzerdefinierten Konnektoren:flink-sql-connector-kinesis, flink-connector-kafka_2.12 undawsmsk-iam-auth. Um über die Konsole ein Studio-Notebook ohne diese benutzerdefinierten Konnektoren zu erstellen, wählen Sie die Option Mit benutzerdefinierten Einstellungen erstellen. Wenn Sie dann zur Seite Konfigurationen gelangen, deaktivieren Sie die Kontrollkästchen neben den beiden Konnektoren.

Wenn Sie die <u>CreateApplication</u>API verwenden, um Ihr Studio-Notizbuch zu erstellen, sind die flink-connector-kafka Konnektoren flink-sql-connector-flink und -Konnektoren standardmäßig nicht enthalten. Um sie hinzuzufügen, geben Sie sie als eine MavenReference im CustomArtifactsConfiguration-Datentyp an, wie in den folgenden Beispielen gezeigt.

Der Konnektor aws-msk-iam-auth ist der Konnektor, der mit Amazon MSK verwendet werden soll und das Feature zur automatischen Authentifizierung bei IAM enthält.

Note

Die im folgenden Beispiel gezeigten Konnektor-Versionen sind die einzigen Versionen, die wir unterstützen.

```
For the Kinesis connector:
"CustomArtifactsConfiguration": [{
"ArtifactType": "DEPENDENCY_JAR",
    "MavenReference": {
"GroupId": "org.apache.flink",
    "ArtifactId": "flink-sql-connector-kinesis",
    "Version": "1.15.4"
    }
}]
For authenticating with AWS MSK through AWS IAM:
"CustomArtifactsConfiguration": [{
```

```
"ArtifactType": "DEPENDENCY_JAR",
   "MavenReference": {
"GroupId": "software.amazon.msk",
      "ArtifactId": "aws-msk-iam-auth",
      "Version": "1.1.6"
   }
}]
For the Apache Kafka connector:
"CustomArtifactsConfiguration": [{
"ArtifactType": "DEPENDENCY_JAR",
   "MavenReference": {
"GroupId": "org.apache.flink",
      "ArtifactId": "flink-connector-kafka",
      "Version": "1.15.4"
   }
}]
```

Um diese Konnektoren zu einem vorhandenen Notizbuch hinzuzufügen, verwenden Sie den <u>UpdateApplication</u>API-Vorgang und geben Sie sie als a MavenReference im CustomArtifactsConfigurationUpdate Datentyp an.

Note

Sie können failOnError für den Konnektor flink-sql-connector-kinesis in der Tabellen-API auf true setzen.

Fügen Sie Abhängigkeiten und benutzerdefinierte Konnektoren hinzu

Gehen Sie folgendermaßen vor AWS Management Console, um Ihrem Studio-Notizbuch eine Abhängigkeit oder einen benutzerdefinierten Connector hinzuzufügen:

- 1. Laden Sie die Datei Ihres benutzerdefinierten Konnektors in Amazon S3 hoch.
- Wählen Sie im die Option Benutzerdefiniert erstellen AWS Management Console, um Ihr Studio-Notizbuch zu erstellen.

- 3. Folgen Sie dem Workflow zur Erstellung eines Studio-Notebooks, bis Sie zum Schritt Konfigurationen gelangen.
- 4. Wählen Sie im Abschnitt Benutzerdefinierte Konnektoren die Option Benutzerdefinierten Konnektor hinzufügen aus.
- 5. Geben Sie den Amazon-S3-Speicherort der Abhängigkeit oder des benutzerdefinierten Konnektors an.
- 6. Wählen Sie Änderungen speichern.

Um eine Abhängigkeits-JAR oder einen benutzerdefinierten Connector hinzuzufügen, wenn Sie ein neues Studio-Notizbuch mithilfe der <u>CreateApplication</u>API erstellen, geben Sie den Amazon S3 S3-Speicherort der Abhängigkeits-JAR oder des benutzerdefinierten Connectors im CustomArtifactsConfiguration Datentyp an. Um einem vorhandenen Studio-Notizbuch eine Abhängigkeit oder einen benutzerdefinierten Connector hinzuzufügen, rufen Sie den <u>UpdateApplication</u>API-Vorgang auf und geben Sie den Amazon S3 S3-Speicherort der Abhängigkeits-JAR oder des benutzerdefinierten Connectors im CustomArtifactsConfigurationUpdate Datentyp an.

i Note

Wenn Sie eine Abhängigkeit oder einen benutzerdefinierten Konnektor einbeziehen, müssen Sie auch alle zugehörigen transitiven Abhängigkeiten einbeziehen, die nicht darin gebündelt sind.

Implementieren Sie benutzerdefinierte Funktionen

Benutzerdefinierte Funktionen (UDFs) sind Erweiterungspunkte, mit denen Sie häufig verwendete Logik oder benutzerdefinierte Logik aufrufen können, die in Abfragen nicht anders ausgedrückt werden kann. Sie können Python oder eine JVM-Sprache wie Java oder Scala verwenden, um Ihre In-Paragraphen UDFs in Ihrem Studio-Notizbuch zu implementieren. Sie können Ihrem Studio-Notizbuch auch externe JAR-Dateien hinzufügen, die in einer UDFs JVM-Sprache implementiert sind.

Verwenden Sie bei der Implementierung JARs dieses Registers abstrakter Klassen dieser Unterklasse UserDefinedFunction (oder Ihrer eigenen abstrakten Klassen) den bereitgestellten Bereich in Apache Maven, compileOnly Abhängigkeitsdeklarationen in Gradle, den bereitgestellten Bereich in SBT oder eine entsprechende Direktive in Ihrer UDF-Projekt-Build-Konfiguration. Dadurch kann der UDF-Quellcode gegen den Flink kompiliert werden APIs, aber die Flink-API-Klassen sind selbst nicht in den Build-Artefakten enthalten. Beziehen Sie sich auf dieses <u>POM</u> aus dem UDF-JAR-Beispiel, das diese Voraussetzung für ein Maven-Projekt erfüllt.

1 Note

Weitere Informationen und ein Beispiel finden Sie unter <u>Übersetzen, Redigieren und</u> Analysieren von Streaming-Daten mithilfe von SQL-Funktionen mit Amazon Managed Service für Apache Flink, Amazon Translate und Amazon Comprehend im AWS Machine Learning Blog.

Gehen Sie folgendermaßen vor, um die Konsole zum Hinzufügen von UDF-JAR-Dateien zu Ihrem Studio-Notebook zu verwenden:

- 1. Laden Sie Ihre UDF-JAR-Datei in Amazon S3 hoch.
- 2. Wählen Sie im die Option Benutzerdefiniert erstellen AWS Management Console, um Ihr Studio-Notizbuch zu erstellen.
- 3. Folgen Sie dem Workflow zur Erstellung eines Studio-Notebooks, bis Sie zum Schritt Konfigurationen gelangen.
- 4. Wählen Sie im Abschnitt Benutzerdefinierte Funktionen die Option Benutzerdefinierte Funktion hinzufügen aus.
- 5. Geben Sie den Amazon-S3-Speicherort der JAR- oder ZIP-Datei an, in der Ihre UDF implementiert ist.
- 6. Wählen Sie Änderungen speichern.

Um beim Erstellen eines neuen Studio-Notebooks mithilfe der <u>CreateApplication</u>API eine UDF-JAR hinzuzufügen, geben Sie den JAR-Speicherort im CustomArtifactConfiguration Datentyp an. Um einem vorhandenen Studio-Notizbuch eine UDF-JAR hinzuzufügen, rufen Sie den <u>UpdateApplication</u>API-Vorgang auf und geben Sie den JAR-Speicherort im CustomArtifactsConfigurationUpdate Datentyp an. Alternativ können Sie das verwenden, AWS Management Console um UDF-JAR-Dateien zu Ihrem Studio-Notebook hinzuzufügen.

Überlegungen zu benutzerdefinierten Funktionen

 Managed Service f
ür Apache Flink Studio verwendet die <u>Apache-Zeppelin-Terminologie</u>, wobei ein Notebook eine Zeppelin-Instance ist, die mehrere Notizen enthalten kann. Jede Notiz kann dann wiederum mehrere Absätze enthalten. Mit Managed Service f
ür Apache Flink Studio wird der Interpreter-Prozess von allen Notizen im Notebook gemeinsam genutzt. Wenn Sie also eine explizite Funktionsregistrierung mithilfe von <u>createTemporarySystemFunction</u> in einer Notiz durchführen, kann dieselbe so referenziert werden, wie sie in einer anderen Notiz desselben Notizbuchs ist.

Der Vorgang Als Anwendung bereitstellen bezieht sich jedoch auf eine einzelne Notiz und nicht auf alle Notizen im Notebook. Wenn Sie Als Anwendung bereitstellen ausführen, werden nur die Inhalte der aktiven Notiz zur Generierung der Anwendung verwendet. Jede explizite Funktionsregistrierung, die in anderen Notebooks durchgeführt wird, ist nicht Teil der generierten Anwendungsabhängigkeiten. Darüber hinaus erfolgt bei der Option "Als Anwendung bereitstellen" eine implizite Funktionsregistrierung, indem der Hauptklassenname von JAR in eine Zeichenfolge in Kleinbuchstaben umgewandelt wird.

Wenn TextAnalyticsUDF beispielsweise die Hauptklasse für UDF-JAR ist, führt eine implizite Registrierung zum Funktionsnamen textanalyticsudf. Wenn also eine explizite Funktionsregistrierung in Notiz 1 von Studio wie folgt erfolgt, dann können alle anderen Notizen in diesem Notebook (z. B. Notiz 2) aufgrund des gemeinsamen Interpreters mit dem Namen myNewFuncNameForClass auf die Funktion verweisen:

stenv.createTemporarySystemFunction("myNewFuncNameForClass", new TextAnalyticsUDF())

Bei der Bereitstellung als Anwendung in Notiz 2 ist diese explizite Registrierung jedoch nicht in den Abhängigkeiten enthalten, sodass die bereitgestellte Anwendung nicht wie erwartet funktioniert. Aufgrund der impliziten Registrierung wird standardmäßig erwartet, dass alle Verweise auf diese Funktion mit textanalyticsudf und nicht myNewFuncNameForClass erfolgen.

Falls eine Registrierung von benutzerdefinierten Funktionsnamen erforderlich ist, wird davon ausgegangen, dass Notiz 2 selbst einen weiteren Absatz enthält, in dem eine weitere explizite Registrierung wie folgt durchgeführt wird:

```
%flink(parallelism=1)
import com.amazonaws.kinesis.udf.textanalytics.TextAnalyticsUDF
# re-register the JAR for UDF with custom name
stenv.createTemporarySystemFunction("myNewFuncNameForClass", new TextAnalyticsUDF())
```

```
%flink. ssql(type=update, parallelism=1)
INSERT INTO
    table2
```

Überlegungen zu benutzerdefinierten Funktionen

```
SELECT
  myNewFuncNameForClass(column_name)
FROM
  table1
;
```

 Wenn Ihr UDF-JAR Flink enthält SDKs, konfigurieren Sie Ihr Java-Projekt so, dass der UDF-Quellcode mit dem Flink kompiliert werden kann SDKs, die Flink-SDK-Klassen selbst jedoch nicht im Build-Artefakt enthalten sind, z. B. in der JAR.

Sie können den provided-Scope in Apache Maven, compileOnly-Abhängigkeitsdeklarationen in Gradle, provided-Scope in SBT oder eine gleichwertige Direktive in der Build-Konfiguration ihres UDF-Projekts verwenden. Beziehen Sie sich auf dieses <u>POM</u> aus dem UDF-JAR-Beispiel, das diese Voraussetzung für ein Maven-Projekt erfüllt. Ein vollständiges step-by-step Tutorial finden Sie unter <u>Übersetzen</u>, <u>Redigieren und Analysieren von Streaming-Daten mithilfe von SQL-</u> <u>Funktionen mit Amazon Managed Service für Apache Flink, Amazon Translate und Amazon</u> Comprehend.

Checkpointing aktivieren

Sie aktivieren Checkpointing mithilfe der Umgebungseinstellungen. Informationen zum Checkpointing finden Sie unter Fehlertoleranz im Managed Service für Apache Flink Entwicklerhandbuch.

Stellen Sie das Checkpoint-Intervall ein

Im folgenden Scala-Codebeispiel wird das Checkpointing-Intervall Ihrer Anwendung auf eine Minute festgelegt:

```
// start a checkpoint every 1 minute
stenv.enableCheckpointing(60000)
```

Im folgenden Python-Codebeispiel wird das Checkpointing-Intervall Ihrer Anwendung auf eine Minute festgelegt:

```
st_env.get_config().get_configuration().set_string(
     "execution.checkpointing.interval", "1min"
)
```

Stellen Sie den Checkpoint-Typ ein

Das folgende Scala-Codebeispiel setzt den Checkpoint-Modus Ihrer Anwendung auf EXACTLY_0NCE (Standard):

```
// set mode to exactly-once (this is the default)
stenv.getCheckpointConfig.setCheckpointingMode(CheckpointingMode.EXACTLY_ONCE)
```

Das folgende Python-Codebeispiel setzt den Checkpoint-Modus Ihrer Anwendung auf EXACTLY_ONCE (Standard):

```
st_env.get_config().get_configuration().set_string(
        "execution.checkpointing.mode", "EXACTLY_ONCE"
)
```

Aktualisieren Sie Studio Runtime

Dieser Abschnitt enthält Informationen zum Upgrade Ihrer Studio-Notebook-Runtime. Wir empfehlen, dass Sie immer auf die neueste unterstützte Studio Runtime aktualisieren.

Führen Sie ein Upgrade Ihres Notebooks auf eine neue Studio Runtime durch

Je nachdem, wie Sie Studio verwenden, unterscheiden sich die Schritte zum Upgrade Ihrer Runtime. Wählen Sie die Option, die zu Ihrem Anwendungsfall passt.

SQL-Abfragen oder Python-Code ohne externe Abhängigkeiten

Wenn Sie SQL oder Python ohne externe Abhängigkeiten verwenden, verwenden Sie den folgenden Runtime-Upgrade-Prozess. Wir empfehlen Ihnen, auf die neueste Runtime-Version zu aktualisieren. Der Upgrade-Vorgang ist derselbe, unabhängig von der Runtime-Version, von der aus Sie das Upgrade durchführen.

- 1. Erstellen Sie ein neues Studio-Notizbuch mit der neuesten Runtime.
- 2. Kopieren Sie den Code jeder Notiz aus dem alten Notizbuch und fügen Sie ihn in das neue Notizbuch ein.
- 3. Passen Sie den Code im neuen Notizbuch so an, dass er mit allen Apache Flink-Funktionen kompatibel ist, die sich gegenüber der vorherigen Version geändert haben.

- Führen Sie das neue Notizbuch aus. Öffnen Sie das Notizbuch und führen Sie es Note für Note nacheinander aus und testen Sie, ob es funktioniert.
- Nehmen Sie alle erforderlichen Änderungen am Code vor.
- Stoppen Sie das neue Notizbuch.
- 4. Wenn Sie das alte Notizbuch als Anwendung bereitgestellt hätten:
 - Stellen Sie das neue Notebook als separate, neue Anwendung bereit.
 - Stoppen Sie die alte Anwendung.
 - Führen Sie die neue Anwendung ohne Snapshot aus.
- 5. Stoppen Sie das alte Notebook, falls es läuft. Starten Sie das neue Notizbuch nach Bedarf für die interaktive Nutzung.

Prozessablauf für Upgrades ohne externe Abhängigkeiten



Deploy the new notebook as separate, new application

431

SQL-Abfragen oder Python-Code mit externen Abhängigkeiten

Gehen Sie wie folgt vor, wenn Sie SQL oder Python verwenden und externe Abhängigkeiten wie Konnektoren oder benutzerdefinierte Artefakte verwenden, z. B. benutzerdefinierte Funktionen, die in Python oder Java implementiert sind. Wir empfehlen Ihnen, auf die neueste Runtime zu aktualisieren. Der Vorgang ist derselbe, unabhängig von der Runtime-Version, von der aus Sie das Upgrade durchführen.

- 1. Erstellen Sie ein neues Studio-Notizbuch mit der neuesten Runtime.
- 2. Kopieren Sie den Code jeder Notiz aus dem alten Notizbuch und fügen Sie ihn in das neue Notizbuch ein.
- 3. Aktualisieren Sie die externen Abhängigkeiten und benutzerdefinierten Artefakte.
 - Suchen Sie nach neuen Konnektoren, die mit der Apache Flink-Version der neuen Runtime kompatibel sind. Die richtigen <u>Konnektoren f
 ür die Flink-Version finden Sie in der Apache Flink-</u> Dokumentation unter Table & SQL Connectors.
 - Aktualisieren Sie den Code der benutzerdefinierten Funktionen, sodass er den Änderungen in der Apache Flink-API und allen Python- oder JAR-Abhängigkeiten entspricht, die von den benutzerdefinierten Funktionen verwendet werden. Verpacken Sie Ihr aktualisiertes benutzerdefiniertes Artefakt erneut.
 - Fügen Sie diese neuen Anschlüsse und Artefakte dem neuen Notizbuch hinzu.
- 4. Passen Sie den Code im neuen Notizbuch so an, dass er mit allen Apache Flink-Funktionen kompatibel ist, die sich gegenüber der vorherigen Version geändert haben.
 - Führen Sie das neue Notizbuch aus. Öffnen Sie das Notizbuch und führen Sie es Note für Note nacheinander aus und testen Sie, ob es funktioniert.
 - Nehmen Sie alle erforderlichen Änderungen am Code vor.
 - Stoppen Sie das neue Notizbuch.
- 5. Wenn Sie das alte Notizbuch als Anwendung bereitgestellt hätten:
 - Stellen Sie das neue Notebook als separate, neue Anwendung bereit.
 - Stoppen Sie die alte Anwendung.
 - Führen Sie die neue Anwendung ohne Snapshot aus.
- 6. Stoppen Sie das alte Notebook, falls es läuft. Starten Sie das neue Notizbuch nach Bedarf für die interaktive Nutzung.

Prozessablauf für das Upgrade mit externen Abhängigkeiten



Führen Sie ein Upgrade Ihres Notebooks auf eine neue Studio Runtime durch

Adjust the new notebook for new Runtime, if required

Arbeiten Sie mit AWS Glue

Ihr Studio-Notizbuch speichert und ruft Informationen über seine Datenquellen und Datenquellen ab AWS Glue. Wenn Sie Ihr Studio-Notizbuch erstellen, geben Sie die AWS Glue Datenbank an, die Ihre Verbindungsinformationen enthält. Wenn Sie auf Ihre Datenquellen und Datensenken zugreifen, geben Sie die in der Datenbank enthaltenen AWS Glue Tabellen an. Ihre AWS Glue Tabellen bieten Zugriff auf die AWS Glue Verbindungen, die die Speicherorte, Schemas und Parameter Ihrer Datenquellen und Ziele definieren.

Studio-Notebooks verwenden Tabelleneigenschaften, um anwendungsspezifische Daten zu speichern. Weitere Informationen finden Sie unter Tabelleneigenschaften.

Ein Beispiel für die Einrichtung einer AWS Glue Verbindung, einer Datenbank und einer Tabelle für die Verwendung mit Studio-Notebooks finden Sie <u>Erstellen Sie eine Datenbank AWS Glue</u> im Tutorial: Erstellen Sie ein Studio-Notizbuch in Managed Service für Apache Flink Tutorial.

Tabelleneigenschaften

Zusätzlich zu den Datenfeldern stellen Ihre AWS Glue Tabellen mithilfe von Tabelleneigenschaften weitere Informationen für Ihr Studio-Notizbuch bereit. Managed Service für Apache Flink verwendet die folgenden AWS Glue Tabelleneigenschaften:

- <u>Definieren Sie Apache Flink-Zeitwerte</u>: Diese Eigenschaften definieren, wie Managed Service f
 ür Apache Flink interne Datenverarbeitungszeitwerte von Apache Flink ausgibt.
- Verwenden Sie den Flink-Anschluss und die Formateigenschaften: Diese Eigenschaften liefern Informationen über Ihre Datenströme.

Gehen Sie wie folgt vor, um einer AWS Glue Tabelle eine Eigenschaft hinzuzufügen:

- 1. Melden Sie sich bei der an AWS Management Console und öffnen Sie die AWS Glue Konsole unter https://console.aws.amazon.com/glue/.
- 2. Wählen Sie aus der Tabellenliste die Tabelle aus, die Ihre Anwendung zum Speichern von Datenverbindungsinformationen verwendet. Wählen Sie Aktion, Tabellendetails bearbeiten aus.
- 3. Geben Sie unter Tabelleneigenschaften den Wert **managed-flink.proctime** für Schlüssel und **user_action_time** für Wert ein.

Definieren Sie Apache Flink-Zeitwerte

Apache Flink stellt Zeitwerte bereit, die beschreiben, wann Ereignisse bei der Stream-Verarbeitung aufgetreten sind, z. B. <u>Verarbeitungszeit</u> und <u>Ereigniszeit</u>. Um diese Werte in Ihre Anwendungsausgabe aufzunehmen, definieren Sie Eigenschaften in Ihrer AWS Glue Tabelle, die die Laufzeit von Managed Service for Apache Flink anweisen, diese Werte in die angegebenen Felder auszugeben.

Die Schlüssel und Werte, die Sie in Ihren Tabelleneigenschaften verwenden, lauten wie folgt:

Zeitstempeltyp	Schlüssel	Value (Wert)
Dauer der Verarbeitung	managed-flink.proctime	Der Spaltenname, der verwendet AWS Glue wird, um den Wert verfügbar zu machen. Dieser Spaltenname entspricht keiner vorhandenen Tabellenspalte.
<u>Zeit des Ereignisses</u>	managed-flink.rowtime	Der Spaltenname, der verwendet AWS Glue wird, um den Wert verfügbar zu machen. Dieser Spaltenname entspricht einer vorhandenen Tabellenspalte.
	managed-flink.watermark. <i>co1umn_name</i> . Milliseku nden	Das Wasserzeichenintervall in Millisekunden

Verwenden Sie den Flink-Anschluss und die Formateigenschaften

Mithilfe von AWS Glue -Tabelleneigenschaften stellen Sie den Flink-Konnektoren Ihrer Anwendung Informationen über Ihre Datenquellen zur Verfügung. Im Folgenden einige Beispiele für die Eigenschaften, die Managed Service für Apache Flink für Konnektoren verwendet:

Konnektortyp	Schlüssel	Value (Wert)
<u>Kafka</u>	format	Das Format, das zur Deseriali sierung und Serialisierung von Kafka-Nachrichten verwendet wird, z. B. oder. json csv
	scan.startup.mode	Der Startmodus für den Kafka-Verbraucher, z.B. oder.earliest-offset timestamp
<u>Kinesis</u>	format	Das Format, das zum Deserialisieren und Serialisi eren von Kinesis-Datenstrea m-Datensätzen verwendet wird, z. B. oder. json csv
	aws.region	Die AWS Region, in der der Stream definiert ist.
<u>S3 (Dateisystem)</u>	Format	Das Format, das zum Deserialisieren und Serialisi eren von Dateien verwendet wird, z. B. oder. json csv
	path	Der Amazon S3 S3-Pfad, s3://mybucket/ z.

Weitere Informationen zu anderen Konnektoren neben Kinesis und Apache Kafka finden Sie in der Dokumentation Ihres Konnektors.

Beispiele und Tutorials für Studio-Notebooks in Managed Service für Apache Flink

Themen

- Tutorial: Erstellen Sie ein Studio-Notizbuch in Managed Service für Apache Flink
- <u>Tutorial: Stellen Sie ein Studio-Notebook als Managed Service für Apache Flink-Anwendung mit</u> dauerhaftem Zustand bereit
- Sehen Sie sich Beispielabfragen zur Analyse von Daten in einem Studio-Notizbuch an

Tutorial: Erstellen Sie ein Studio-Notizbuch in Managed Service für Apache Flink

Das folgende Tutorial zeigt, wie Sie ein Studio-Notebook erstellen, das Daten aus einem Kinesis-Datenstream oder einem Amazon MSK-Cluster liest.

Dieses Tutorial enthält die folgenden Abschnitte:

- Erfüllen der Voraussetzungen
- Erstellen Sie eine Datenbank AWS Glue
- Nächste Schritte: Erstellen Sie ein Studio-Notizbuch mit Kinesis Data Streams oder Amazon MSK
- Erstellen Sie ein Studio-Notebook mit Kinesis Data Streams
- Erstellen Sie ein Studio-Notebook mit Amazon MSK
- Bereinigen Sie Ihre Anwendung und die abhängigen Ressourcen

Erfüllen der Voraussetzungen

Stellen Sie sicher, dass Sie AWS CLI Version 2 oder höher haben. Informationen zur Installation der neuesten AWS CLI Version finden Sie unter <u>Installation, Aktualisierung und Deinstallation der AWS</u> <u>CLI Version 2.</u>

Erstellen Sie eine Datenbank AWS Glue

Ihr Studio-Notebook verwendet eine <u>AWS Glue</u>-Datenbank für Metadaten zu Ihrer Amazon MSK-Datenquelle.

Erstellen Sie eine AWS Glue Datenbank

- 1. Öffnen Sie die AWS Glue Konsole unter https://console.aws.amazon.com/glue/.
- 2. Wählen Sie Add database (Datenbank hinzufügen). Geben Sie im Fenster Datenbank hinzufügen **default** als Namen der Datenbank ein. Wählen Sie Create (Erstellen) aus.

Nächste Schritte: Erstellen Sie ein Studio-Notizbuch mit Kinesis Data Streams oder Amazon MSK

Mit diesem Tutorial können Sie ein Studio-Notebook erstellen, das entweder Kinesis Data Streams oder Amazon MSK verwendet:

- Erstellen Sie ein Studio-Notebook mit Kinesis Data Streams: Mit Kinesis Data Streams können Sie schnell eine Anwendung erstellen, die einen Kinesis Data Stream als Quelle verwendet. Sie müssen nur einen Kinesis Data Stream als abhängige Ressource erstellen.
- Erstellen Sie ein Studio-Notebook mit Amazon MSK: Mit Amazon MSK erstellen Sie eine Anwendung, die einen Amazon MSK-Cluster als Quelle verwendet. Sie müssen eine Amazon VPC, eine EC2 Amazon-Client-Instance und einen Amazon MSK-Cluster als abhängige Ressourcen erstellen.

Erstellen Sie ein Studio-Notebook mit Kinesis Data Streams

In diesem Tutorial wird beschrieben, wie Sie ein Studio-Notebook erstellen, das einen Kinesis Data Stream als Quelle verwendet.

Dieses Tutorial enthält die folgenden Abschnitte:

- Erfüllen der Voraussetzungen
- Erstellen Sie eine Tabelle AWS Glue
- Erstellen Sie ein Studio-Notebook mit Kinesis Data Streams
- Senden von Daten an den Kinesis Data Stream
- Testen Sie Ihr Studio-Notebook

Erfüllen der Voraussetzungen

Bevor Sie ein Studio-Notebook erstellen, erstellen Sie einen Kinesis Data Stream (ExampleInputStream). Ihre Anwendung verwendet diesen Stream als Anwendungsquelle.

Sie können diesen Stream mithilfe der Amazon Kinesis-Konsole oder des folgenden AWS CLI -Befehls erstellen. Anweisungen für die Konsole finden Sie unter <u>Erstellen und Aktualisieren von</u> <u>Datenströmen</u> im Amazon Kinesis Data Streams Entwicklerhandbuch. Benennen Sie den Stream **ExampleInputStream** und legen Sie die Anzahl der offenen Shards auf **1** fest. Verwenden Sie den folgenden Amazon Kinesis create-stream AWS CLI Kinesis-Befehl AWS CLI, um den Stream (ExampleInputStream) mit dem zu erstellen.

```
$ aws kinesis create-stream \
--stream-name ExampleInputStream \
--shard-count 1 \
--region us-east-1 \
--profile adminuser
```

Erstellen Sie eine Tabelle AWS Glue

Ihr Studio-Notebook verwendet eine <u>AWS Glue</u>-Datenbank für Metadaten zu Ihrer Kinesis Data Streams-Datenquelle.

Note

Sie können die Datenbank entweder zuerst manuell erstellen oder sie beim Erstellen des Notebooks von Managed Service für Apache Flink für Sie erstellen lassen. Ebenso können Sie die Tabelle entweder manuell erstellen, wie im folgenden Abschnitt beschrieben, oder Sie können den Konnektorcode zum Erstellen einer Tabelle für Managed Service für Apache Flink in Ihrem Notebook innerhalb von Apache Zeppelin verwenden, um Ihre Tabelle über eine DDL-Anweisung zu erstellen. Sie können dann einchecken AWS Glue, um sicherzustellen, dass die Tabelle korrekt erstellt wurde.

Erstellen einer Tabelle

- 1. Melden Sie sich bei der an AWS Management Console und öffnen Sie die AWS Glue Konsole unter https://console.aws.amazon.com/glue/.
- Wenn Sie noch keine AWS Glue Datenbank haben, wählen Sie in der linken Navigationsleiste Datenbanken aus. Wählen Sie Datenbank hinzufügen. Geben Sie im Fenster Datenbank hinzufügen default als Namen der Datenbank ein. Wählen Sie Create (Erstellen) aus.
- Wählen Sie in der linken Navigationsleiste die Option Tabellen. Wählen Sie auf der Seite Tabellen die Optionen Tabellen hinzufügen, Tabelle manuell hinzufügen aus.
- Geben Sie auf der Seite Eigenschaften Ihrer Tabelle einrichten stock als Tabellennamen ein. Stellen Sie sicher, dass Sie die Datenbank auswählen, die Sie zuvor erstellt haben. Wählen Sie Weiter.

- 5. Wählen Sie auf der Seite Datenstore hinzufügen die Option Kinesis aus. Geben Sie als Streamnamen ExampleInputStream ein. Wählen Sie für Kinesis-Quell-URL die Eingabetaste https://kinesis.us-east-1.amazonaws.com. Wenn Sie die Kinesis-Quell-URL kopieren und einfügen, achten Sie darauf, alle führenden oder nachfolgenden Leerzeichen zu löschen. Wählen Sie Weiter.
- 6. Wählen Sie auf der Seite Klassifikation die Option JSON aus. Wählen Sie Weiter.
- 7. Wählen Sie auf der Seite Schema definieren die Option "Spalte hinzufügen", um eine Spalte hinzuzufügen. Fügen Sie Spalten mit den folgenden Eigenschaften hinzu:

Spaltenname	Datentyp
ticker	string
price	double

Wählen Sie Weiter.

- 8. Überprüfen Sie auf der nächsten Seite Ihre Einstellungen und wählen Sie Fertigstellen.
- 9. Wählen Sie die neu erstellte Tabelle aus der Liste der Tabellen aus.
- 10. Wählen Sie Tabelle bearbeiten und fügen Sie eine Eigenschaft mit dem Schlüssel managedflink.proctime und dem Wert proctime hinzu.
- 11. Wählen Sie Anwenden aus.

Erstellen Sie ein Studio-Notebook mit Kinesis Data Streams

Nachdem Sie die Ressourcen erstellt haben, die Ihre Anwendung verwendet, erstellen Sie Ihr Studio-Notebook.

Um Ihre Anwendung zu erstellen, können Sie entweder den AWS Management Console oder den verwenden AWS CLI.

- Erstellen Sie ein Studio-Notizbuch mit dem AWS Management Console
- Erstellen Sie ein Studio-Notizbuch mit dem AWS CLI

Erstellen Sie ein Studio-Notizbuch mit dem AWS Management Console

- 1. Die Managed Service for Apache Flink-Konsole zu <u>https://console.aws.amazon.com/managed-</u> flink/Hause öffnen? region=us-east-1#/applications/dashboard.
- 2. Wählen Sie auf der Seite Managed Service für Apache Flink-Anwendungen die Registerkarte Studio aus. Wählen Sie Studio-Notebook erstellen.

Note

Sie können ein Studio-Notebook auch über die Amazon MSK- oder Kinesis Data Streams-Konsolen erstellen, indem Sie Ihren Amazon MSK-Eingabe-Cluster oder Kinesis Data Stream auswählen und dann Daten in Echtzeit verarbeiten auswählen.

- 3. Geben Sie auf der Seite Notebook-Instance erstellen folgende Informationen ein:
 - Geben Sie MyNotebook als Namen des Notebooks ein.
 - Wählen Sie Standard für die AWS -Glue-Datenbank.

Wählen Sie Studio-Notebook erstellen.

4. Wählen Sie auf der Seite "Ausführen" aus. MyNotebook Warten Sie, bis der Status Wird ausgeführt angezeigt wird. Es fallen Gebühren an, wenn das Notebook läuft.

Erstellen Sie ein Studio-Notizbuch mit dem AWS CLI

Gehen Sie wie folgt vor AWS CLI, um Ihr Studio-Notizbuch mit dem zu erstellen:

- 1. Überprüfen Sie die Konto-ID. Sie benötigen diesen Wert, um die Anwendung zu erstellen.
- 2. Erstellen Sie die Rolle arn: aws: iam: :*AccountID*:role/ZeppelinRole und fügen Sie der automatisch erstellten Rolle über die Konsole die folgenden Berechtigungen hinzu.

"kinesis:GetShardIterator",

"kinesis:GetRecords",

"kinesis:ListShards"

3. Erstellen Sie eine Datei mit dem Namen create.json und den folgenden Inhalten. Ersetzen Sie die Platzhalterwerte durch Ihre Informationen.

```
{
    "ApplicationName": "MyNotebook",
    "RuntimeEnvironment": "ZEPPELIN-FLINK-3_0",
    "ApplicationMode": "INTERACTIVE",
    "ServiceExecutionRole": "arn:aws:iam::AccountID:role/ZeppelinRole",
    "ApplicationConfiguration": {
        "ApplicationSnapshotConfiguration": {
            "SnapshotsEnabled": false
        },
        "ZeppelinApplicationConfiguration": {
            "CatalogConfiguration": {
                "GlueDataCatalogConfiguration": {
                    "DatabaseARN": "arn:aws:glue:us-east-1:AccountID:database/
default"
                }
            }
       }
    }
}
```

4. Um Ihre Anwendung zu erstellen, führen Sie den folgenden Befehl aus.

```
aws kinesisanalyticsv2 create-application --cli-input-json file://create.json
```

5. Wenn der Befehl abgeschlossen ist, sehen Sie eine Ausgabe, die die Details für Ihr neues Studio-Notebook enthält. Es folgt ein Beispiel für die Ausgabe.

```
{
    "ApplicationDetail": {
        "ApplicationARN": "arn:aws:kinesisanalyticsus-
east-1:012345678901:application/MyNotebook",
        "ApplicationName": "MyNotebook",
        "RuntimeEnvironment": "ZEPPELIN-FLINK-3_0",
        "ApplicationMode": "INTERACTIVE",
        "ServiceExecutionRole": "arn:aws:iam::012345678901:role/ZeppelinRole",
        ...
```

6. Um Ihre Anwendung zu starten, führen Sie den folgenden Befehl aus. Ersetzen Sie die Beispielwerte durch Ihre Konto-ID.

aws kinesisanalyticsv2 start-application --application-arn
arn:aws:kinesisanalyticsus-east-1:012345678901:application/MyNotebook\

Senden von Daten an den Kinesis Data Stream

Gehen Sie wie folgt vor, um Testdaten an Ihren Kinesis Data Stream zu senden:

- 1. Öffnen Sie den Kinesis Data Generator.
- 2. Wählen Sie "Cognito-Benutzer erstellen mit CloudFormation".
- Die AWS CloudFormation Konsole wird mit der Kinesis Data Generator-Vorlage geöffnet. Wählen Sie Weiter.
- 4. Auf der Seite Festlegen von Komponentendetails geben Sie den Benutzernamen und das Passwort für Ihren Cognito-Benutzer ein. Wählen Sie Weiter.
- 5. Wählen Sie auf der Seite Stack-Optionen konfigurieren Weiter aus.
- Wählen Sie auf der Seite "Kinesis-Data-Generator-CognitoBenutzer überprüfen" die Option Ich bestätige, dass AWS CloudFormation möglicherweise IAM-Ressourcen erstellt werden. Kontrollkästchen. Wählen Sie Stapel erstellen aus.
- 7. Warten Sie, bis der AWS CloudFormation Stapel fertig erstellt ist. Nachdem der Stack abgeschlossen ist, öffnen Sie den Kinesis-Data-Generator-Cognito-User-Stack in der Konsole und wählen Sie die Registerkarte Outputs aus. AWS CloudFormation KinesisDataGeneratorUrlÖffnen Sie die URL, die für den Ausgabewert aufgeführt ist.
- 8. Melden Sie sich auf der Amazon Kinesis Data Generator-Seite mit den Anmeldeinformationen an, die Sie in Schritt 4 erstellt haben.
- 9. Geben Sie auf der nächsten Seite die folgenden Werte an:

Region	us-east-1
Bach/Firehose-Stream	ExampleInputStream
Aufzeichnungen pro Sekunde	1

Fügen Sie für Datensatzvorlage den folgenden Code ein:

{

Tutorial: Erstellen Sie ein Studio-Notizbuch in Managed Service für Apache Flink

```
"ticker": "{{random.arrayElement(
        ["AMZN","MSFT","GOOG"]
)}}",
"price": {{random.number(
        {
        "min":10,
        "max":150
      }
)}}
```

10. Wählen Sie Daten senden aus.

11. Der Generator sendet Daten an den Kinesis Data Stream.

Lassen Sie den Generator laufen, während Sie den nächsten Abschnitt abschließen.

Testen Sie Ihr Studio-Notebook

In diesem Abschnitt verwenden Sie Ihr Studio-Notebook, um Daten aus Ihrem Kinesis Data Stream abzufragen.

- 1. Die Managed Service for Apache Flink-Konsole zu <u>https://console.aws.amazon.com/managed-</u> flink/Hause öffnen? region=us-east-1#/applications/dashboard.
- 2. Wählen Sie auf der Seite Managed Service für Apache Flink-Anwendungen die Registerkarte Studio-Notebook aus. Wählen Sie MyNotebook.
- 3. Wählen Sie auf der Seite "In Apache Zeppelin öffnen". MyNotebook

Die Oberfläche von Apache Zeppelin wird in einer neuen Registerkarte geöffnet.

- 4. Auf der Seite Willkommen bei Zeppelin! wählen Sie Zeppelin Notiz aus.
- 5. Geben Sie auf der Seite Zeppelin Notiz die folgende Abfrage in eine neue Notiz ein:

```
%flink.ssql(type=update)
select * from stock
```

Wählen Sie das Ausführungssymbol.

Nach kurzer Zeit werden in der Notiz Daten aus dem Kinesis Data Stream angezeigt.

Um das Apache Flink-Dashboard für Ihre Anwendung zu öffnen und betriebliche Aspekte zu sehen, wählen Sie FLINK JOB. Weitere Informationen zum Flink-Dashboard finden Sie unter <u>Apache Flink-Dashboard im Managed Service für Apache Flink Entwicklerhandbuch</u>.

Weitere Beispiele für Flink-Streaming-SQL-Abfragen finden Sie unter <u>Abfragen</u> in der <u>Apache Flink-</u> Dokumentation.

Erstellen Sie ein Studio-Notebook mit Amazon MSK

In diesem Tutorial wird beschrieben, wie Sie ein Studio-Notebook erstellen, das einen Amazon-MSK-Cluster als Quelle verwendet.

Dieses Tutorial enthält die folgenden Abschnitte:

- Einen Amazon MSK-Cluster einrichten
- Fügen Sie Ihrer VPC ein NAT-Gateway hinzu
- Erstellen Sie eine AWS Glue Verbindung und eine Tabelle
- Erstellen Sie ein Studio-Notebook mit Amazon MSK
- Senden Sie Daten an Ihren Amazon MSK-Cluster
- Testen Sie Ihr Studio-Notebook

Einen Amazon MSK-Cluster einrichten

Für dieses Tutorial benötigen Sie einen Amazon-MSK-Cluster, der Klartextzugriff ermöglicht. Wenn Sie noch keinen Amazon MSK-Cluster eingerichtet haben, folgen Sie dem Tutorial <u>Erste Schritte mit</u> <u>Amazon MSK, um eine Amazon</u> VPC, einen Amazon MSK-Cluster, ein Thema und eine Amazon-Client-Instance zu erstellen. EC2

Gehen Sie beim Befolgen des Tutorials wie folgt vor:

• Ändern Sie in <u>Schritt 3: Amazon MSK-Cluster erstellen</u> bei Schritt 4 den ClientBroker-Wert von TLS auf **PLAINTEXT**.

Fügen Sie Ihrer VPC ein NAT-Gateway hinzu

Wenn Sie einen Amazon MSK-Cluster erstellt haben, indem Sie dem Tutorial Erste Schritte mit Amazon MSK gefolgt sind, oder wenn Ihre bestehende Amazon VPC noch kein NAT-Gateway für ihre privaten Subnetze hat, müssen Sie Ihrer Amazon VPC ein NAT-Gateway hinzufügen. Das folgende Diagramm zeigt die Architektur.



Gehen Sie wie folgt vor, um ein NAT-Gateway für Ihre Amazon VPC zu erstellen:

- 1. Öffnen Sie die Amazon-VPC-Konsole unter https://console.aws.amazon.com/vpc/.
- 2. Wählen Sie in der linken Navigationsleiste NAT-Gateway aus.
- 3. Wählen Sie auf der Seite NAT-Gateways die Option NAT-Gateway erstellen aus.

4. Geben Sie auf der Seite NAT-Gateway erstellen die folgenden Werte an:

Name — optional	ZeppelinGateway
Subnetz	AWS KafkaTutorialSubnet1
Elastische IP-Zuweisungs-ID	Wählen Sie eine verfügbare Elastic IP aus. Wenn kein Elastic IPs verfügbar ist, wählen Sie Allocate Elastic IP und dann die Elastic IP aus, die die Konsole erstellt.

Wählen Sie NAT-Gateway erstellen aus.

- 5. Wählen Sie in der linken Navigationsleiste Routing-Tabellen aus.
- 6. Klicken Sie auf Create Route Table (Routing-Tabelle erstellen).
- 7. Geben Sie auf der Seite Routing-Tabelle erstellen folgende Informationen ein:
 - Name-Tag: ZeppelinRouteTable
 - VPC: Wählen Sie Ihre VPC (z. B. AWS KafkaTutorialVPC).

Wählen Sie Create (Erstellen) aus.

- 8. Wählen Sie in der Liste der Routentabellen. ZeppelinRouteTable Klicken Sie auf der Registerkarte Routen auf Routen bearbeiten.
- 9. Wählen Sie auf der Seite Routen bearbeiten die Option Route hinzufügen aus.
- 10. Geben Sie im Für-Ziel **0.0.0/0** ein. Wählen Sie für Target die Option NAT Gateway, ZeppelinGateway. Wählen Sie Routen speichern aus. Klicken Sie auf Close (Schließen).
- 11. Wählen Sie auf der Seite Routing-Tabellen die ZeppelinRouteTableOption "Subnetzzuordnungen" aus. Wählen Sie Subnetzzuordnungen bearbeiten aus.
- Wählen Sie auf der Seite Subnetzzuordnungen bearbeiten die Optionen AWS KafkaTutorialSubnet2 und AWS KafkaTutorialSubnet 3 aus. Wählen Sie Save (Speichern) aus.

Erstellen Sie eine AWS Glue Verbindung und eine Tabelle

Ihr Studio-Notebook verwendet eine <u>AWS Glue</u>-Datenbank für Metadaten zu Ihrer Amazon MSK-Datenquelle. In diesem Abschnitt erstellen Sie eine AWS Glue Verbindung, die beschreibt, wie Sie auf Ihren Amazon MSK-Cluster zugreifen können, und eine AWS Glue Tabelle, die beschreibt, wie Sie die Daten in Ihrer Datenquelle für Clients wie Ihr Studio-Notebook präsentieren.

Eine Verbindung erstellen

- 1. Melden Sie sich bei der an AWS Management Console und öffnen Sie die AWS Glue Konsole unter https://console.aws.amazon.com/glue/.
- 2. Wenn Sie noch keine AWS Glue Datenbank haben, wählen Sie in der linken Navigationsleiste Datenbanken aus. Wählen Sie Datenbank hinzufügen. Geben Sie im Fenster Datenbank hinzufügen **default** als Namen der Datenbank ein. Wählen Sie Create (Erstellen) aus.
- 3. Wählen Sie in der linken Navigationsleiste Verbindungen aus. Wählen Sie Verbindung hinzufügen aus.
- 4. Geben Sie im Fenster Verbindung hinzufügen die folgenden Werte ein:
 - Geben Sie für Verbindungsname ZeppelinConnection ein.
 - Wählen Sie für Verbindungstyp den Eintrag Kafka.
 - Geben Sie f
 ür den Kafka-Bootstrap-Server URLs die Bootstrap-Broker-String f
 ür Ihren Cluster an. Sie k
 önnen die Bootstrap-Broker entweder
 über die MSK-Konsole oder durch Eingabe des folgenden CLI-Befehls abrufen:

aws kafka get-bootstrap-brokers --region us-east-1 --cluster-arn ClusterArn

• Deaktivieren Sie das Kontrollkästchen SSL-Verbindung erforderlich.

Wählen Sie Weiter.

- 5. Geben Sie auf der VPC-Seite die folgenden Werte an:
 - Wählen Sie für VPC den Namen Ihrer VPC (z. B. AWS KafkaTutorialVPC).
 - Wählen Sie für Subnetz 2 aus.AWS KafkaTutorialSubnet
 - Wählen Sie für Sicherheitsgruppen alle verfügbaren Gruppen aus.

Wählen Sie Weiter.

6. Wählen Sie auf der Seite Verbindungseigenschaften / Verbindungszugriff die Option Fertigstellen aus.

Erstellen einer Tabelle

1 Note

Sie können die Tabelle entweder manuell erstellen, wie in den folgenden Schritten beschrieben, oder Sie können den Konnektorcode zum Erstellen einer Tabelle für Managed Service für Apache Flink in Ihrem Notebook innerhalb von Apache Zeppelin verwenden, um Ihre Tabelle über eine DDL-Anweisung zu erstellen. Sie können dann einchecken AWS Glue, um sicherzustellen, dass die Tabelle korrekt erstellt wurde.

- Wählen Sie in der linken Navigationsleiste die Option Tabellen. Wählen Sie auf der Seite Tabellen die Optionen Tabellen hinzufügen, Tabelle manuell hinzufügen aus.
- Geben Sie auf der Seite Eigenschaften Ihrer Tabelle einrichten stock als Tabellennamen ein. Stellen Sie sicher, dass Sie die Datenbank auswählen, die Sie zuvor erstellt haben. Wählen Sie Weiter.
- Wählen Sie auf der Seite Datenspeicher hinzufügen die Option Kafka aus. Geben Sie als Themennamen Ihren Themennamen ein (z. B. AWS KafkaTutorialTopic). Wählen Sie für Verbindung ZeppelinConnection.
- 4. Wählen Sie auf der Seite Klassifikation die Option JSON aus. Wählen Sie Weiter.
- 5. Wählen Sie auf der Seite Schema definieren die Option "Spalte hinzufügen", um eine Spalte hinzuzufügen. Fügen Sie Spalten mit den folgenden Eigenschaften hinzu:

Spaltenname	Datentyp
ticker	string
price	double

Wählen Sie Weiter.

- 6. Überprüfen Sie auf der nächsten Seite Ihre Einstellungen und wählen Sie Fertigstellen.
- 7. Wählen Sie die neu erstellte Tabelle aus der Liste der Tabellen aus.
- 8. Wählen Sie Tabelle bearbeiten und fügen Sie die folgenden Eigenschaften hinzu:
 - Schlüssel:managed-flink.proctime, Wert: proctime

- Schlüssel:flink.properties.group.id, Wert: test-consumer-group
- Schlüssel:flink.properties.auto.offset.reset, Wert: latest
- Schlüssel:classification, Wert: json

Ohne diese Schlüssel/Wert-Paare tritt im Flink-Notebook ein Fehler auf.

9. Wählen Sie Anwenden aus.

Erstellen Sie ein Studio-Notebook mit Amazon MSK

Nachdem Sie die Ressourcen erstellt haben, die Ihre Anwendung verwendet, erstellen Sie Ihr Studio-Notebook.

Sie können Ihre Anwendung entweder mit dem oder dem AWS Management Console erstellen. AWS CLI

- Erstellen Sie ein Studio-Notizbuch mit dem AWS Management Console
- Erstellen Sie ein Studio-Notizbuch mit dem AWS CLI
 - Note

Sie können ein Studio-Notebook auch von der Amazon MSK-Konsole aus erstellen, indem Sie einen vorhandenen Cluster auswählen und dann Daten in Echtzeit verarbeiten wählen.

Erstellen Sie ein Studio-Notizbuch mit dem AWS Management Console

- 1. Die Managed Service for Apache Flink-Konsole zu <u>https://console.aws.amazon.com/managed-</u> flink/Hause öffnen? region=us-east-1#/applications/dashboard.
- 2. Wählen Sie auf der Seite Managed Service für Apache Flink-Anwendungen die Registerkarte Studio aus. Wählen Sie Studio-Notebook erstellen.

Note

Um ein Studio-Notebook über die Amazon MSK- oder Kinesis Data Streams-Konsolen zu erstellen, wählen Sie Ihren Amazon MSK-Eingabe-Cluster oder Kinesis Data Stream aus und wählen Sie dann Daten in Echtzeit verarbeiten aus.

- 3. Geben Sie auf der Seite Notebook-Instance erstellen folgende Informationen ein:
 - Geben Sie MyNotebook als Studio-Notebookname.
 - Wählen Sie Standard für die AWS -Glue-Datenbank.

Wählen Sie Studio-Notebook erstellen.

- 4. Wählen Sie auf der Seite die Registerkarte Konfiguration aus. MyNotebook Wählen Sie im Abschnitt Netzwerk die Option Bearbeiten.
- Wählen Sie auf der MyNotebook Seite Netzwerk bearbeiten für die VPC-Konfiguration basierend auf dem Amazon MSK-Cluster aus. Wählen Sie Ihren Amazon MSK-Cluster für den Amazon MSK-Cluster aus. Wählen Sie Änderungen speichern.
- 6. Wählen Sie auf der MyNotebookSeite die Option Ausführen aus. Warten Sie, bis der Status Wird ausgeführt angezeigt wird.

Erstellen Sie ein Studio-Notizbuch mit dem AWS CLI

Gehen Sie wie folgt vor AWS CLI, um Ihr Studio-Notizbuch mit dem zu erstellen:

- 1. Stellen Sie sicher, dass Sie über die folgenden Informationen verfügen: Sie benötigen diese Werte, um Ihre Anwendung zu erstellen.
 - Ihre Konto-ID.
 - Das Subnetz IDs und die Sicherheitsgruppen-ID f
 ür die Amazon VPC, die Ihren Amazon MSK-Cluster enth
 ält.
- 2. Erstellen Sie eine Datei mit dem Namen create.json und den folgenden Inhalten. Ersetzen Sie die Platzhalterwerte durch Ihre Informationen.
```
"SubnetIds": [
                     "SubnetID 1",
                     "SubnetID 2",
                     "SubnetID 3"
                ],
                "SecurityGroupIds": [
                     "VPC Security Group ID"
                ]
            }
        ],
        "ZeppelinApplicationConfiguration": {
            "CatalogConfiguration": {
                "GlueDataCatalogConfiguration": {
                     "DatabaseARN": "arn:aws:glue:us-east-1:AccountID:database/
default"
                }
            }
        }
    }
}
```

3. Um Ihre Anwendung zu erstellen, führen Sie den folgenden Befehl aus.

```
aws kinesisanalyticsv2 create-application --cli-input-json file://create.json
```

4. Wenn der Befehl abgeschlossen ist, sollte eine Ausgabe wie die folgende angezeigt werden, die die Details für Ihr neues Studio-Notebook enthält:

```
{
    "ApplicationDetail": {
        "ApplicationARN": "arn:aws:kinesisanalyticsus-
east-1:012345678901:application/MyNotebook",
        "ApplicationName": "MyNotebook",
        "RuntimeEnvironment": "ZEPPELIN-FLINK-3_0",
        "ApplicationMode": "INTERACTIVE",
        "ServiceExecutionRole": "arn:aws:iam::012345678901:role/ZeppelinRole",
        ...
```

5. Um Ihre Anwendung zu starten, führen Sie den folgenden Befehl aus. Ersetzen Sie die Beispielwerte durch Ihre Konto-ID.

```
aws kinesisanalyticsv2 start-application --application-arn
arn:aws:kinesisanalyticsus-east-1:012345678901:application/MyNotebook\
```

Senden Sie Daten an Ihren Amazon MSK-Cluster

In diesem Abschnitt führen Sie ein Python-Skript in Ihrem EC2 Amazon-Client aus, um Daten an Ihre Amazon MSK-Datenquelle zu senden.

- 1. Connect zu Ihrem EC2 Amazon-Client her.
- 2. Führen Sie die folgenden Befehle aus, um Python Version 3, Pip und das Kafka für Python-Paket zu installieren, und bestätigen Sie die Aktionen:

```
sudo yum install python37
curl -0 https://bootstrap.pypa.io/get-pip.py
python3 get-pip.py --user
pip install kafka-python
```

 Konfigurieren Sie das AWS CLI auf Ihrem Client-Computer, indem Sie den folgenden Befehl eingeben:

```
aws configure
```

Geben Sie Ihre Kontoanmeldeinformationen ein, und **us-east-1** für die region.

4. Erstellen Sie eine Datei mit dem Namen stock.py und den folgenden Inhalten. Ersetzen Sie den Beispielwert durch die Bootstrap Brokers-Zeichenfolge Ihres Amazon MSK-Clusters und aktualisieren Sie den Themennamen, falls Ihr Thema nicht: AWS KafkaTutorialTopic

```
from kafka import KafkaProducer
import json
import random
from datetime import datetime
BROKERS = "<<Bootstrap Broker List>>"
producer = KafkaProducer(
    bootstrap_servers=BROKERS,
    value_serializer=lambda v: json.dumps(v).encode('utf-8'),
    retry_backoff_ms=500,
    request_timeout_ms=20000,
```

security_protocol='PLAINTEXT')

```
def getStock():
   data = \{\}
   now = datetime.now()
    str_now = now.strftime("%Y-%m-%d %H:%M:%S")
   data['event_time'] = str_now
   data['ticker'] = random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV'])
    price = random.random() * 100
   data['price'] = round(price, 2)
   return data
while True:
    data =getStock()
   # print(data)
    try:
        future = producer.send("AWSKafkaTutorialTopic", value=data)
        producer.flush()
        record_metadata = future.get(timeout=10)
        print("sent event to Kafka! topic {} partition {} offset
 {}".format(record_metadata.topic, record_metadata.partition,
 record_metadata.offset))
    except Exception as e:
        print(e.with_traceback())
```

5. Führen Sie das Skript mit dem folgenden Befehl aus:

\$ python3 stock.py

6. Lassen Sie das Skript laufen, während Sie den folgenden Abschnitt abschließen.

Testen Sie Ihr Studio-Notebook

In diesem Abschnitt verwenden Sie Ihr Studio-Notebook, um Daten aus Ihrem Amazon MSK-Cluster abzufragen.

- 1. <u>Die Managed Service for Apache Flink-Konsole zu Hause öffnen? https://</u> console.aws.amazon.com/managed-flink/ region=us-east-1#/applications/dashboard.
- 2. Wählen Sie auf der Seite Managed Service für Apache Flink-Anwendungen die Registerkarte Studio-Notebook aus. Wählen Sie MyNotebook.

3. Wählen Sie auf der Seite "In Apache Zeppelin öffnen". MyNotebook

Die Oberfläche von Apache Zeppelin wird in einer neuen Registerkarte geöffnet.

- 4. Auf der Seite Willkommen bei Zeppelin! wählen Sie Zeppelin neue Notiz aus.
- 5. Geben Sie auf der Seite Zeppelin Notiz die folgende Abfrage in eine neue Notiz ein:

```
%flink.ssql(type=update)
select * from stock
```

Wählen Sie das Ausführungssymbol.

Die Anwendung zeigt Daten aus dem Amazon MSK-Cluster an.

Um das Apache Flink-Dashboard für Ihre Anwendung zu öffnen und betriebliche Aspekte zu sehen, wählen Sie FLINK JOB. Weitere Informationen zum Flink-Dashboard finden Sie unter <u>Apache Flink-Dashboard</u> im <u>Managed Service für Apache Flink Entwicklerhandbuch</u>.

Weitere Beispiele für Flink-Streaming-SQL-Abfragen finden Sie unter <u>Abfragen</u> in der <u>Apache Flink-</u> <u>Dokumentation</u>.

Bereinigen Sie Ihre Anwendung und die abhängigen Ressourcen

Löschen Sie Ihr Studio-Notebook

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole.
- 2. Wählen Sie MyNotebook.
- 3. Wählen Sie Aktionen und dann Löschen aus.

Löschen Sie Ihre AWS Glue Datenbank und Verbindung

- 1. Öffnen Sie die AWS Glue Konsole unter https://console.aws.amazon.com/glue/.
- 2. Wählen Sie in der linken Navigationsleiste Datenbanken aus. Markieren Sie das Kontrollkästchen neben Standard, um es auszuwählen. Wählen Sie Aktion, Datenbank löschen. Bestätigen Sie Ihre Auswahl.
- Wählen Sie in der linken Navigationsleiste Verbindungen aus. Markieren Sie das Kontrollkästchen neben, ZeppelinConnectionum es auszuwählen. Wählen Sie Aktion, Verbindung löschen. Bestätigen Sie Ihre Auswahl.

So löschen Sie die IAM-Rolle und -Richtlinie

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Klicken Sie in der linken Navigationsleiste auf Rollen.
- 3. Verwenden Sie die Suchleiste, um nach der ZeppelinRoleRolle zu suchen.
- 4. Wählen Sie die ZeppelinRoleRolle aus. Wählen Sie Rolle löschen aus. Bestätigen Sie das Löschen.

Löschen Sie Ihre CloudWatch Protokollgruppe

Die Konsole erstellt eine CloudWatch Logs-Gruppe und einen Log-Stream für Sie, wenn Sie Ihre Anwendung mit der Konsole erstellen. Sie haben keine Protokollgruppe und keinen Stream, wenn Sie Ihre Anwendung mit der AWS CLI erstellt haben.

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der linken Navigationsleiste Protokollgruppen aus.
- 3. Wählen Sie die Gruppe/AWS/KinesisAnalytics/MyNotebooklog aus.
- 4. Wählen Sie Actions (Aktionen), Delete log group(s) (Protokollgruppe(n) löschen) aus. Bestätigen Sie das Löschen.

Kinesis Data Streams Streams-Ressourcen bereinigen

Um Ihren Kinesis Stream zu löschen, öffnen Sie die Kinesis Data Streams-Konsole, wählen Sie Ihren Kinesis Stream aus und wählen Sie Aktionen, Löschen.

Bereinigen von MSK-Ressourcen

Führen Sie die Schritte in diesem Abschnitt aus, wenn Sie für dieses Tutorial einen Amazon MSK-Cluster erstellt haben. In diesem Abschnitt finden Sie Anweisungen zur Bereinigung Ihrer EC2 Amazon-Client-Instance, Ihrer Amazon VPC und Ihres Amazon MSK-Clusters.

Löschen Sie Ihren Amazon MSK-Cluster

Gehen Sie wie folgt vor, wenn Sie für dieses Tutorial einen Amazon MSK-Cluster erstellt haben.

 Die Amazon MSK-Konsole zu <u>https://console.aws.amazon.com/msk/Hause öffnen? region=us-</u> east-1#/home/.

Tutorial: Erstellen Sie ein Studio-Notizbuch in Managed Service für Apache Flink

2. Wählen Sie AWS KafkaTutorialCluster. Wählen Sie Löschen. Geben Sie **delete** in das angezeigte Fenster ein und bestätigen Sie Ihre Auswahl.

Beenden Ihrer Client-Instance

Gehen Sie wie folgt vor, wenn Sie für dieses Tutorial eine EC2 Amazon-Client-Instance erstellt haben.

- 1. Öffnen Sie die EC2 Amazon-Konsole unter https://console.aws.amazon.com/ec2/.
- 2. Wählen Sie in der linken Navigationsleiste Instances aus.
- 3. Klicken Sie auf das Kontrollkästchen neben ZeppelinClient, um es auszuwählen.
- 4. Wählen Sie Instance-Status, Instance beenden.

Löschen Ihrer Amazon VPC

Gehen Sie wie folgt vor, wenn Sie für dieses Tutorial eine Amazon VPC erstellt haben.

- 1. Öffnen Sie die EC2 Amazon-Konsole unter https://console.aws.amazon.com/ec2/.
- 2. Wählen Sie in der linken Navigationsleiste Netzwerkschnittstellen aus.
- 3. Geben Sie Ihre VPC-ID in das Suchfeld ein und drücken Sie die Eingabetaste.
- 4. Aktivieren Sie das Kontrollkästchen in der Kopfzeile der Tabelle, um alle angezeigten Netzwerkschnittstellen auszuwählen.
- 5. Wählen Sie Actions (Aktionen), Loslösen (Detach). Wählen Sie in dem daraufhin angezeigten Fenster unter Trennung erzwingen die Option Aktivieren aus. Wählen Sie Trennen und warten Sie, bis alle Netzwerkschnittstellen den Status Verfügbar erreichen.
- 6. Aktivieren Sie das Kontrollkästchen in der Kopfzeile der Tabelle, um alle angezeigten Netzwerkschnittstellen erneut auszuwählen.
- 7. Wählen Sie Aktionen, Löschen aus. Bestätigen Sie die Aktion.
- 8. Öffnen Sie die Amazon-VPC-Konsole unter https://console.aws.amazon.com/vpc/.
- Wählen Sie AWS KafkaTutorialVPC aus. Wählen Sie Aktionen, VPC löschen aus. Geben Sie delete ein und bestätigen Sie den Löschvorgang.

Tutorial: Stellen Sie ein Studio-Notebook als Managed Service für Apache Flink-Anwendung mit dauerhaftem Zustand bereit

Das folgende Tutorial zeigt, wie Sie ein Studio-Notebook als Managed-Service für Apache Flink-Anwendung mit einem dauerhaften Status bereitstellen.

Dieses Tutorial enthält die folgenden Abschnitte:

- Erfüllen der Voraussetzungen
- <u>Stellen Sie eine Anwendung mit einem dauerhaften Zustand bereit, indem Sie AWS Management</u> Console
- Stellen Sie eine Anwendung mit einem dauerhaften Zustand bereit, indem Sie AWS CLI

Erfüllen der Voraussetzungen

Erstellen Sie ein neues Studio-Notizbuch, indem Sie den Anweisungen folgen<u>Tutorial: Erstellen Sie</u> <u>ein Studio-Notizbuch in Managed Service für Apache Flink</u> und entweder Kinesis Datenstrom oder Amazon MSK verwenden. Name des Studio-Notizbuchs ExampleTestDeploy.

Stellen Sie eine Anwendung mit einem dauerhaften Zustand bereit, indem Sie AWS Management Console

- 1. Fügen Sie einen S3-Bucket-Speicherort hinzu, an dem der gepackte Code unter Speicherort des Anwendungscodes gespeichert werden soll - optional in der Konsole. Dies ermöglicht die Schritte zum Bereitstellen und Ausführen Ihrer Anwendung direkt vom Notebook aus.
- Fügen Sie der Anwendungsrolle die erforderlichen Berechtigungen hinzu, um die von Ihnen verwendete Rolle zum Lesen und Schreiben in einen Amazon S3-Bucket zu aktivieren und um eine Managed Service for Apache Flink-Anwendung zu starten:
 - Amazon S3 FullAccess
 - Amazon hat es geschafft- flinkFullAccess
 - Zugriff auf Ihre Quellen, Ziele und VPCs gegebenenfalls Weitere Informationen finden Sie unter Überprüfen Sie die IAM-Berechtigungen für Studio-Notebooks.
- 3. Verwenden Sie den folgenden Beispielcode:

```
%flink.ssql(type=update)
CREATE TABLE exampleoutput (
```

```
'ticket' VARCHAR,
'price' DOUBLE
)
WITH (
  'connector' = 'kinesis',
  'stream' = 'ExampleOutputStream',
  'aws.region' = 'us-east-1',
  'scan.stream.initpos' = 'LATEST',
  'format' = 'json'
);
INSERT INTO exampleoutput SELECT ticker, price FROM exampleinputstream
```

- 4. Mit der Einführung dieses Feature sehen Sie in der rechten oberen Ecke jeder Notiz in Ihrem Notizbuch ein neues Dropdown-Menü mit dem Namen des Notizbuchs. Sie haben die folgenden Möglichkeiten:
 - Sehen Sie sich die Studio-Notizbucheinstellungen in der AWS Management Console an.
 - Erstellen Sie Ihren Zeppelin Note und exportieren Sie ihn zu Amazon S3. Geben Sie an dieser Stelle einen Namen f
 ür Ihre Anwendung ein und w
 ählen Sie Erstellen und Exportieren. Sie erhalten eine Benachrichtigung, wenn der Export abgeschlossen ist.
 - Bei Bedarf können Sie alle zusätzlichen Tests der ausführbaren Datei in Amazon S3 anzeigen und ausführen.
 - Sobald der Build abgeschlossen ist, können Sie Ihren Code als Kinesis-Streaming-Anwendung mit dauerhaftem Zustand und automatischer Skalierung bereitstellen.
 - Verwenden Sie das Drop-down-Menü und wählen Sie Zeppelin Note als Kinesis-Streaming-Anwendung bereitstellen. Überprüfen Sie den Namen der Anwendung und wählen Sie Über AWS Konsole bereitstellen aus.
 - Dadurch gelangen Sie zu der AWS Management Console Seite, auf der Sie eine Managed Service for Apache Flink-Anwendung erstellen können. Beachten Sie, dass Anwendungsname, Parallelität, Codespeicherort, Standard-Glue-DB, VPC (falls zutreffend) und IAM-Rollen vorab ausgefüllt wurden. Stellen Sie sicher, dass die IAM-Rollen über die erforderlichen Berechtigungen für Ihre Quellen und Ziele verfügen. Snapshots sind standardmäßig aktiviert, um eine dauerhafte Verwaltung des Anwendungsstatus zu gewährleisten.
 - Wählen Sie Erstellen der Anwendung.
 - Sie können alle Einstellungen konfigurieren und ändern und anschließend Ausführen wählen, um Ihre Streaming-Anwendung zu starten.

Stellen Sie eine Anwendung mit einem dauerhaften Zustand bereit, indem Sie AWS CLI

Um eine Anwendung mithilfe von bereitzustellen AWS CLI, müssen Sie Ihre Version aktualisieren, AWS CLI um das mit Ihren Beta 2-Informationen bereitgestellte Servicemodell verwenden zu können. Weitere Informationen zur Verwendung des aktualisierten Servicemodells finden Sie unter Erfüllen der Voraussetzungen.

Der folgende Beispielcode erstellt ein neues Studio-Notizbuch:

```
aws kinesisanalyticsv2 create-application \
     --application-name <app-name> \
     --runtime-environment ZEPPELIN-FLINK-3_0 \
     --application-mode INTERACTIVE \
     --service-execution-role <iam-role>
     --application-configuration '{
       "ZeppelinApplicationConfiguration": {
         "CatalogConfiguration": {
           "GlueDataCatalogConfiguration": {
             "DatabaseARN": "arn:aws:glue:us-east-1:<account>:database/<glue-database-
name>"
           }
         }
       },
       "FlinkApplicationConfiguration": {
         "ParallelismConfiguration": {
           "ConfigurationType": "CUSTOM",
           "Parallelism": 4,
           "ParallelismPerKPU": 4
         }
       },
       "DeployAsApplicationConfiguration": {
            "S3ContentLocation": {
               "BucketARN": "arn:aws:s3:::<s3bucket>",
               "BasePath": "/something/"
            }
        },
       "VpcConfigurations": [
         {
           "SecurityGroupIds": [
             "<security-group>"
           ],
           "SubnetIds": [
```

```
"<subnet-1>",
    "<subnet-2>"
    ]
    }
}' \
    --region us-east-1
```

Das folgende Codebeispiel startet ein Studio-Notebook:

```
aws kinesisanalyticsv2 start-application \
    --application-name <app-name> \
    --region us-east-1 \
    --no-verify-ssl
```

Der folgende Code gibt die URL für die Apache Zeppelin-Notizbuch-Seite einer Anwendung zurück:

```
aws kinesisanalyticsv2 create-application-presigned-url \
    --application-name <app-name> \
    --url-type ZEPPELIN_UI_URL \
    --region us-east-1 \
    --no-verify-ssl
```

Sehen Sie sich Beispielabfragen zur Analyse von Daten in einem Studio-Notizbuch an

Die folgenden Beispielabfragen zeigen, wie Daten mithilfe von Fensterabfragen in einem Studio-Notebook analysiert werden.

- Erstellen Sie Tabellen mit Amazon MSK/Apache Kafka
- Erstellen Sie Tabellen mit Kinesis
- Fragen Sie ein taumelndes Fenster ab
- Fragen Sie ein Schiebefenster ab
- Verwenden Sie interaktives SQL
- Verwenden Sie den BlackHole SQL-Konnektor
- Verwenden Sie Scala, um Beispieldaten zu generieren
- Verwenden Sie interaktives Scala

- Interaktives Python verwenden
- Verwenden Sie eine Kombination aus interaktivem Python, SQL und Scala
- Verwenden Sie einen kontoübergreifenden Kinesis-Datenstream

Informationen zu den SQL-Abfrageeinstellungen von Apache Flink finden Sie unter <u>Flink auf</u> Zeppelin-Notebooks für interaktive Datenanalyse.

Um Ihre Anwendung im Apache-Flink-Dashboard anzuzeigen, wählen Sie FLINK-AUFTRAG auf der Seite Zeppelin Notiz Ihrer Anwendung.

Weitere Informationen zu Fensterabfragen finden Sie unter <u>Windows</u> in der <u>Apache-Flink-</u> Dokumentation.

Weitere Beispiele für Streaming-SQL-Abfragen in Apache Flink finden Sie unter <u>Abfragen</u> in der Apache-Flink-Dokumentation.

Erstellen Sie Tabellen mit Amazon MSK/Apache Kafka

Sie können den Amazon-MSK-Flink-Konnektor mit Managed Service für Apache Flink Studio verwenden, um Ihre Verbindung mit Klartext-, SSL- oder IAM-Authentifizierung zu authentifizieren. Erstellen Sie Ihre Tabellen mit den spezifischen Eigenschaften gemäß Ihren Anforderungen.

```
-- Plaintext connection
CREATE TABLE your_table (
  `column1` STRING,
  `column2` BIGINT
) WITH (
  'connector' = 'kafka',
  'topic' = 'your_topic',
  'properties.bootstrap.servers' = '<bootstrap servers>',
  'scan.startup.mode' = 'earliest-offset',
  'format' = 'json'
);
-- SSL connection
CREATE TABLE your_table (
  `column1` STRING,
  `column2` BIGINT
) WITH (
```

```
'connector' = 'kafka',
   'topic' = 'your_topic',
  'properties.bootstrap.servers' = '<bootstrap servers>',
  'properties.security.protocol' = 'SSL',
  'properties.ssl.truststore.location' = '/usr/lib/jvm/java-11-amazon-corretto/lib/
security/cacerts',
  'properties.ssl.truststore.password' = 'changeit',
  'properties.group.id' = 'myGroup',
  'scan.startup.mode' = 'earliest-offset',
  'format' = 'json'
);
-- IAM connection (or for MSK Serverless)
CREATE TABLE your_table (
  `column1` STRING,
  `column2` BIGINT
) WITH (
  'connector' = 'kafka',
  'topic' = 'your_topic',
  'properties.bootstrap.servers' = '<bootstrap servers>',
  'properties.security.protocol' = 'SASL_SSL',
  'properties.sasl.mechanism' = 'AWS_MSK_IAM',
  'properties.sasl.jaas.config' = 'software.amazon.msk.auth.iam.IAMLoginModule
 required;',
  'properties.sasl.client.callback.handler.class' =
 'software.amazon.msk.auth.iam.IAMClientCallbackHandler',
  'properties.group.id' = 'myGroup',
  'scan.startup.mode' = 'earliest-offset',
  'format' = 'json'
);
```

Sie können diese mit anderen Eigenschaften im Apache-Kafka-SQL-Konnektor kombinieren.

Erstellen Sie Tabellen mit Kinesis

Im folgenden Beispiel erstellen Sie eine Tabelle mit Kinesis:

```
CREATE TABLE KinesisTable (
  `column1` BIGINT,
  `column2` BIGINT,
  `column3` BIGINT,
  `column4` STRING,
```

```
`ts` TIMESTAMP(3)
)
PARTITIONED BY (column1, column2)
WITH (
    'connector' = 'kinesis',
    'stream' = 'test_stream',
    'aws.region' = '<region>',
    'scan.stream.initpos' = 'LATEST',
    'format' = 'csv'
);
```

Weitere Informationen zu anderen Eigenschaften, die Sie verwenden können, finden Sie unter Amazon Kinesis Data Streams SQL-Konnektor.

Fragen Sie ein taumelndes Fenster ab

Die folgende Flink-Streaming-SQL-Abfrage wählt den höchsten Preis in jedem fünfsekündigen rollierenden Fenster aus der ZeppelinTopic-Tabelle aus:

```
%flink.ssql(type=update)
SELECT TUMBLE_END(event_time, INTERVAL '5' SECOND) as winend, MAX(price) as
five_second_high, ticker
FROM ZeppelinTopic
GROUP BY ticker, TUMBLE(event_time, INTERVAL '5' SECOND)
```

Fragen Sie ein Schiebefenster ab

Die folgende Flink-Streaming-SQL-Abfrage wählt den höchsten Preis in jedem fünfsekündigen rollierenden Fenster aus der ZeppelinTopic-Tabelle aus:

```
%flink.ssql(type=update)
SELECT HOP_END(event_time, INTERVAL '3' SECOND, INTERVAL '5' SECOND) AS winend,
MAX(price) AS sliding_five_second_max
FROM ZeppelinTopic//or your table name in AWS Glue
GROUP BY HOP(event_time, INTERVAL '3' SECOND, INTERVAL '5' SECOND)
```

Verwenden Sie interaktives SQL

In diesem Beispiel wird der Höchstwert der Ereignis- und Verarbeitungszeit sowie die Summe der Werte aus der Schlüssel-Wert-Tabelle ausgegeben. Stellen Sie sicher, dass Sie das Beispielskript

zur Datengenerierung aus dem laufenden <u>the section called "Verwenden Sie Scala, um Beispieldaten</u> <u>zu generieren</u>" haben. Informationen zum Ausprobieren anderer SQL-Abfragen wie Filtern und Joins in Ihrem Studio-Notebook finden Sie in der Apache-Flink-Dokumentation: <u>Abfragen</u> in der Apache-Flink-Dokumentation.

```
%flink.ssql(type=single, parallelism=4, refreshInterval=1000, template=<h1>{2}</h1>
records seen until <h1>Processing Time: {1}</h1> and <h1>Event Time: {0}</h1>)
-- An interactive query prints how many records from the `key-value-stream` we have
seen so far, along with the current processing and event time.
SELECT
MAX(`et`) as `et`,
MAX(`et`) as `pt`,
SUM(`value`) as `sum`
FROM
`key-values`
```

```
%flink.ssql(type=update, parallelism=4, refreshInterval=1000)
-- An interactive tumbling window query that displays the number of records observed
per (event time) second.
-- Browse through the chart views to see different visualizations of the streaming
result.
SELECT
TUMBLE_START(`et`, INTERVAL '1' SECONDS) as `window`,
    `key`,
SUM(`value`) as `sum`
FROM
    `key-values`
GROUP BY
```

```
TUMBLE(`et`, INTERVAL '1' SECONDS),
`key`;
```

Verwenden Sie den BlackHole SQL-Konnektor

Der BlackHole SQL-Connector erfordert nicht, dass Sie einen Kinesis-Datenstream oder einen Amazon MSK-Cluster erstellen, um Ihre Abfragen zu testen. Informationen zum SQL-Konnektor finden Sie unter BlackHole <u>BlackHole SQL Connector</u> in der Apache Flink-Dokumentation. In diesem Beispiel ist der Standardkatalog ein speicherinterner Katalog.

%flink.ssql

```
CREATE TABLE default_catalog.default_database.blackhole_table (
    `key` BIGINT,
    `value` BIGINT,
    `et` TIMESTAMP(3)
) WITH (
    'connector' = 'blackhole'
)
```

```
%flink.ssql(parallelism=1)
INSERT INTO `test-target`
SELECT
   `key`,
   `value`,
   `et`
FROM
   `test-source`
WHERE
   `key` > 3
```

```
%flink.ssql(parallelism=2)
```

```
INSERT INTO `default_catalog`.`default_database`.`blackhole_table`
SELECT
   `key`,
   `value`,
   `et`
FROM
   `test-target`
WHERE
   `key` > 7
```

Verwenden Sie Scala, um Beispieldaten zu generieren

In diesem Beispiel wird Scala verwendet, um Beispieldaten zu generieren. Sie können diese Beispieldaten verwenden, um verschiedene Abfragen zu testen. Verwenden Sie die Anweisung create table, um die Schlüssel-Wert-Tabelle zu erstellen.

import org.apache.flink.streaming.api.functions.source.datagen.DataGeneratorSource import org.apache.flink.streaming.api.functions.source.datagen.RandomGenerator

```
import org.apache.flink.streaming.api.scala.DataStream
import java.sql.Timestamp
// ad-hoc convenience methods to be defined on Table
implicit class TableOps[T](table: DataStream[T]) {
    def asView(name: String): DataStream[T] = {
        if (stenv.listTemporaryViews.contains(name)) {
            stenv.dropTemporaryView("`" + name + "`")
        }
        stenv.createTemporaryView("`" + name + "`", table)
        return table;
    }
}
```

```
%flink(parallelism=4)
val stream = senv
.addSource(new DataGeneratorSource(RandomGenerator.intGenerator(1, 10), 1000))
.map(key => (key, 1, new Timestamp(System.currentTimeMillis)))
.asView("key-values-data-generator")
```

```
%flink.ssql(parallelism=4)
-- no need to define the paragraph type with explicit parallelism (such as
    "%flink.ssql(parallelism=2)")
-- in this case the INSERT query will inherit the parallelism of the of the above
    paragraph
INSERT INTO `key-values`
SELECT
    `_1` as `key`,
    `_2` as `value`,
    `_3` as `et`
FROM
    `key-values-data-generator`
```

Verwenden Sie interaktives Scala

Dies ist die Scala-Übersetzung von <u>the section called "Verwenden Sie interaktives SQL"</u>. Weitere Scala-Beispiele finden Sie unter Tabellen-API in der Apache-Flink-Dokumentation.

```
%flink
import org.apache.flink.api.scala._
import org.apache.flink.table.api._
```

```
import org.apache.flink.table.api.bridge.scala._
// ad-hoc convenience methods to be defined on Table
implicit class TableOps(table: Table) {
    def asView(name: String): Table = {
        if (stenv.listTemporaryViews.contains(name)) {
            stenv.dropTemporaryView(name)
        }
        stenv.createTemporaryView(name, table)
        return table;
    }
}
```

```
%flink(parallelism=4)
```

```
// A view that computes many records from the `key-values` we have seen so far, along
with the current processing and event time.
val query01 = stenv
.from("`key-values`")
.select(
    $"et".max().as("et"),
    $"pt".max().as("pt"),
    $"value".sum().as("sum")
).asView("query01")
```

```
%flink.ssql(type=single, parallelism=16, refreshInterval=1000, template=<h1>{2}</h1>
records seen until <h1>Processing Time: {1}</h1> and <h1>Event Time: {0}</h1>)
```

```
-- An interactive query prints the query01 output.
SELECT * FROM query01
```

```
%flink(parallelism=4)
```

```
// An tumbling window view that displays the number of records observed per (event
time) second.
val query02 = stenv
.from("`key-values`")
.window(Tumble over 1.seconds on $"et" as $"w")
.groupBy($"w", $"key")
.select(
    $"w".start.as("window"),
    $"key",
```

```
$"value".sum().as("sum")
).asView("query02")
%flink.ssql(type=update, parallelism=4, refreshInterval=1000)
-- An interactive query prints the query02 output.
-- Browse through the chart views to see different visualizations of the streaming
result.
SELECT * FROM `query02`
```

Interaktives Python verwenden

Dies ist die Python-Übersetzung von <u>the section called "Verwenden Sie interaktives SQL"</u>. Weitere Python-Beispiele finden Sie unter Tabellen-API in der Apache-Flink-Dokumentation.

```
%flink.pyflink
from pyflink.table.table import Table

def as_view(table, name):
    if (name in st_env.list_temporary_views()):
        st_env.drop_temporary_view(name)
        st_env.create_temporary_view(name, table)
        return table
```

```
Table.as_view = as_view
```

```
%flink.pyflink(parallelism=16)
```

```
# A view that computes many records from the `key-values` we have seen so far, along
with the current processing and event time
st_env \
   .from_path("`keyvalues`") \
   .select(", ".join([
        "max(et) as et",
        "max(pt) as pt",
        "sum(value) as sum"
])) \
   .as_view("query01")
```

%flink.ssql(type=single, parallelism=16, refreshInterval=1000, template=<h1>{2}</h1>
records seen until <h1>Processing Time: {1}</h1> and <h1>Event Time: {0}</h1>)

```
-- An interactive query prints the query01 output.
SELECT * FROM query01
```

```
%flink.pyflink(parallelism=16)
```

```
# A view that computes many records from the `key-values` we have seen so far, along
with the current processing and event time
st_env \
   .from_path("`key-values`") \
   .window(Tumble.over("1.seconds").on("et").alias("w")) \
   .group_by("w, key") \
   .select(", ".join([
    "w.start as window",
    "key",
    "sum(value) as sum"
])) \
   .as_view("query02")
```

```
%flink.ssql(type=update, parallelism=16, refreshInterval=1000)
-- An interactive query prints the query02 output.
-- Browse through the chart views to see different visualizations of the streaming
result.
SELECT * FROM `query02`
```

Verwenden Sie eine Kombination aus interaktivem Python, SQL und Scala

Sie können eine beliebige Kombination aus SQL, Python und Scala in Ihrem Notebook für interaktive Analysen verwenden. In einem Studio-Notebook, das Sie als dauerhafte Anwendung bereitstellen möchten, können Sie eine Kombination aus SQL und Scala verwenden. Dieses Beispiel zeigt Ihnen die Abschnitte, die ignoriert werden, und diejenigen, die in der Anwendung mit dem dauerhaften Zustand bereitgestellt werden.

```
%flink.ssql
CREATE TABLE `default_catalog`.`default_database`.`my-test-source` (
    `key` BIGINT NOT NULL,
    `value` BIGINT NOT NULL,
    `et` TIMESTAMP(3) NOT NULL,
    `pt` AS PROCTIME(),
    WATERMARK FOR `et` AS `et` - INTERVAL '5' SECOND
```

```
)
WITH (
    'connector' = 'kinesis',
    'stream' = 'kda-notebook-example-test-source-stream',
    'aws.region' = 'eu-west-1',
    'scan.stream.initpos' = 'LATEST',
    'format' = 'json',
    'json.timestamp-format.standard' = 'ISO-8601'
)
```

```
%flink.ssql
CREATE TABLE `default_catalog`.`default_database`.`my-test-target` (
  `key` BIGINT NOT NULL,
  `value` BIGINT NOT NULL,
  `et` TIMESTAMP(3) NOT NULL,
  `pt` AS PROCTIME(),
  WATERMARK FOR `et` AS `et` - INTERVAL '5' SECOND
)
WITH (
  'connector' = 'kinesis',
  'stream' = 'kda-notebook-example-test-target-stream',
  'aws.region' = 'eu-west-1',
  'scan.stream.initpos' = 'LATEST',
  'format' = 'json',
  'json.timestamp-format.standard' = 'ISO-8601'
)
```

%flink()

```
// ad-hoc convenience methods to be defined on Table
implicit class TableOps(table: Table) {
   def asView(name: String): Table = {
     if (stenv.listTemporaryViews.contains(name)) {
        stenv.dropTemporaryView(name)
     }
     stenv.createTemporaryView(name, table)
     return table;
   }
}
```

```
%flink(parallelism=1)
val table = stenv
```

```
.from("`default_catalog`.`default_database`.`my-test-source`")
.select($"key", $"value", $"et")
.filter($"key" > 10)
.asView("query01")
```

%flink.ssql(parallelism=1)

```
-- forward data
INSERT INTO `default_catalog`.`default_database`.`my-test-target`
SELECT * FROM `query01`
```

%flink.ssql(type=update, parallelism=1, refreshInterval=1000)

```
-- forward data to local stream (ignored when deployed as application) SELECT * FROM `query01`
```

%flink

```
// tell me the meaning of life (ignored when deployed as application!)
print("42!")
```

Verwenden Sie einen kontoübergreifenden Kinesis-Datenstream

Um einen Kinesis-Datenstrom zu verwenden, der sich in einem anderen Konto als dem Konto befindet, das Ihr Studio-Notebook enthält, erstellen Sie eine Serviceausführungsrolle in dem Konto, in dem Ihr Studio-Notebook ausgeführt wird, und eine Rollenvertrauensrichtlinie für das Konto, das den Datenstrom enthält. Verwenden Sie aws.credentials.provider, aws.credentials.role.arn und aws.credentials.role.sessionName im Kinesis-Konnektor in Ihrer DDL-Anweisung create table, um eine Tabelle anhand des Datenstroms zu erstellen.

Verwenden Sie die folgende Serviceausführungsrolle für das Studio-Notebook-Konto.

```
{
   "Sid": "AllowNotebookToAssumeRole",
   "Effect": "Allow",
   "Action": "sts:AssumeRole"
   "Resource": "*"
}
```

Verwenden Sie die AmazonKinesisFullAccess-Richtlinie und die folgende Rollenvertrauensrichtlinie für das Datenstrom-Konto.

```
{
    "Version": "2012-10-17",
    "Statement": [
    {
        "Effect": "Allow",
        "Principal": {
        "AWS": "arn:aws:iam::<accountID>:root"
        },
        "Action": "sts:AssumeRole",
        "Condition": {}
    }
    ]
}
```

Verwenden Sie den folgenden Absatz für die create-table-Anweisung.

```
%flink.ssql
CREATE TABLE test1 (
name VARCHAR,
age BIGINT
) WITH (
 'connector' = 'kinesis',
 'stream' = 'stream-assume-role-test',
 'aws.region' = 'us-east-1',
 'aws.credentials.provider' = 'ASSUME_ROLE',
 'aws.credentials.provider' = 'arn:aws:iam::<accountID>:role/stream-assume-role-test-
role',
 'aws.credentials.role.arn' = 'arn:aws:iam::<accountID>:role/stream-assume-role-test-
role',
 'aws.credentials.role.sessionName' = 'stream-assume-role-test-session',
 'scan.stream.initpos' = 'TRIM_HORIZON',
 'format' = 'json'
)
```

Beheben Sie Probleme mit Studio-Notebooks für Managed Service für Apache Flink

Dieser Abschnitt enthält Informationen zur Fehlerbehebung für Studio-Notebooks.

Stoppen Sie eine blockierte Anwendung

Um eine Anwendung zu beenden, die in einem vorübergehenden Zustand feststeckt, rufen Sie die <u>StopApplication</u>Aktion auf, wobei der Force Parameter auf true gesetzt ist. Weitere Informationen finden Sie unter <u>Ausführen von Anwendungen</u> im <u>Managed Service für Apache Flink</u> Entwicklerhandbuch.

Als Anwendung mit dauerhaftem Zustand in einer VPC ohne Internetzugang bereitstellen

Die deploy-as-application Funktion Managed Service for Apache Flink Studio unterstützt keine VPC-Anwendungen ohne Internetzugang. Wir empfehlen, dass Sie Ihre Anwendung in Studio erstellen und dann Managed Service für Apache Flink verwenden, um manuell eine Flink-Anwendung zu erstellen und die ZIP-Datei auszuwählen, die Sie in Ihrem Notebook erstellt haben.

Die folgenden Schritte beschreiben, wie Sie dies tun:

- 1. Erstellen und exportieren Sie Ihre Studio-Anwendung in Amazon S3. Dies sollte eine ZIP-Datei sein.
- Erstellen Sie manuell eine Anwendung, die Managed Service f
 ür Apache Flink nutzt, mit einem Codepfad, der auf den Speicherort der ZIP-Datei in Amazon S3 verweist. Dar
 über hinaus m
 üssen Sie die Anwendung mit den folgenden env-Variablen (2 groupID, 3 var insgesamt) konfigurieren:
- 3. kinesis.analytics.flink.run.options
 - a. python: source/note.py
 - b. jarfile: lib/ .jar PythonApplicationDependencies
- 4. managed.deploy_as_app.options
 - DatabaseARN: <glue database ARN (Amazon Resource Name)>
- 5. Möglicherweise müssen Sie Managed Service für Apache Flink Studio und Managed Service für Apache Flink IAM-Rollen für die Services, die Ihre Anwendung verwendet, Berechtigungen erteilen. Sie können dieselbe IAM-Rolle für beide Apps verwenden.

Deploy-as-app Reduzierung von Größe und Bauzeit

Studio deploy-as-app für Python-Anwendungen packt alles, was in der Python-Umgebung verfügbar ist, da wir nicht ermitteln können, welche Bibliotheken Sie benötigen. Dies kann zu einer Größe führen, die größer als nötig ist deploy-as-app. Das folgende Verfahren zeigt, wie Sie die Größe der deploy-as-app Python-Anwendung reduzieren können, indem Sie Abhängigkeiten deinstallieren.

Wenn Sie eine Python-Anwendung mit deploy-as-app Funktionen von Studio erstellen, sollten Sie erwägen, vorinstallierte Python-Pakete aus dem System zu entfernen, wenn Ihre Anwendungen nicht davon abhängig sind. Dies trägt nicht nur dazu bei, die endgültige Artefaktgröße zu reduzieren, um zu verhindern, dass das Servicelimit für die Anwendungsgröße überschritten wird, sondern verbessert auch die Erstellungszeit von Anwendungen, die diese Funktion verwenden. deploy-as-app

Sie können den folgenden Befehl ausführen, um alle installierten Python-Pakete mit ihrer jeweiligen installierten Größe aufzulisten und Pakete mit signifikanter Größe selektiv zu entfernen.

%flink.pyflink

```
!pip list --format freeze | awk -F = {'print $1'} | xargs pip show | grep -E
'Location:|Name:' | cut -d ' ' -f 2 | paste -d ' ' - - | awk '{gsub("-","_",$1); print
$2 "/" tolower($1)}' | xargs du -sh 2> /dev/null | sort -hr
```

Note

apache-beam wird von Flink Python zum Betrieb benötigt. Sie sollten dieses Paket und seine Abhängigkeiten niemals entfernen.

Im Folgenden finden Sie eine Liste der vorinstallierten Python-Pakete in Studio V2, deren Entfernung in Betracht gezogen werden kann:

scipy	
statsmodels	
plotnine	
seaborn	
llvmlite	
bokeh	
pandas	
matplotlib	
botocore	

boto3 numba

So entfernen Sie ein Python-Paket aus dem Zeppelin-Notebook:

- Prüfen Sie, ob Ihre Anwendung von dem Paket oder einem seiner konsumierenden Pakete abhängt, bevor Sie es entfernen. Mit <u>pipdeptree</u> können Sie die Abhängigkeiten eines Pakets identifizieren.
- 2. Führen Sie den folgenden Befehl aus, um ein Paket zu entfernen:

```
%flink.pyflink
!pip uninstall -y <package-to-remove>
```

3. Wenn Sie ein Paket abrufen müssen, das Sie versehentlich entfernt haben, führen Sie den folgenden Befehl aus:

```
%flink.pyflink
!pip install <package-to-install>
```

Example Beispiel: Entfernen Sie **scipy** das Paket, bevor Sie Ihre Python-Anwendung mit deploy-asapp Funktion bereitstellen.

- Verwenden Sie pipdeptree, um alle scipy-Verbraucher zu ermitteln und zu überprüfen, ob Sie scipy sicher entfernen können.
 - · Installieren Sie das Tool über das Notebook:

```
%flink.pyflink
!pip install pipdeptree
```

 Rufen Sie den umgekehrten Abhängigkeitsbaum von scipy ab, indem Sie Folgendes ausführen:

```
%flink.pyflink
!pip -r -p scipy
```

Sie sollten eine ähnliche Ausgabe wie die folgende sehen (aus Platzgründen gekürzt):

••

```
scipy==1.8.0
### plotnine==0.5.1 [requires: scipy>=1.0.0]
### seaborn==0.9.0 [requires: scipy>=0.14.0]
### statsmodels==0.12.2 [requires: scipy>=1.1]
    ### plotnine==0.5.1 [requires: statsmodels>=0.8.0]
```

- Prüfen Sie sorgfältig die Verwendung von seaborn, statsmodels und plotnine in Ihren Anwendungen. Wenn Ihre Anwendungen nicht von scipy, seaborn, statemodels oder plotnine abhängig sind, können Sie alle diese Pakete oder nur diejenigen entfernen, die Ihre Anwendungen nicht benötigen.
- 3. Entfernen Sie das Paket, indem Sie Folgendes ausführen:

!pip uninstall -y scipy plotnine seaborn statemodels

Jobs stornieren

In diesem Abschnitt erfahren Sie, wie Sie Apache-Flink-Aufträge abbrechen, auf die Sie von Apache Zeppelin aus nicht zugreifen können. Wenn Sie einen solchen Auftrag abbrechen möchten, rufen Sie das Apache-Flink-Dashboard auf, kopieren Sie die Auftrags-ID und verwenden Sie sie dann in einem der folgenden Beispiele.

Um einen einzelnen Auftrag abzubrechen:

```
%flink.pyflink
import requests
requests.patch("https://zeppelin-flink:8082/jobs/[job_id]", verify=False)
```

Um alle laufenden Aufträge abzubrechen:

```
%flink.pyflink
import requests
r = requests.get("https://zeppelin-flink:8082/jobs", verify=False)
jobs = r.json()['jobs']
for job in jobs:
    if (job["status"] == "RUNNING"):
```

```
print(requests.patch("https://zeppelin-flink:8082/jobs/{}".format(job["id"]),
verify=False))
```

Um alle Aufträge abzubrechen:

```
%flink.pyflink
import requests
r = requests.get("https://zeppelin-flink:8082/jobs", verify=False)
jobs = r.json()['jobs']
for job in jobs:
    requests.patch("https://zeppelin-flink:8082/jobs/{}".format(job["id"]),
    verify=False)
```

Starten Sie den Apache Flink-Interpreter neu

Um den Apache-Flink-Interpreter in Ihrem Studio-Notebook neu zu starten

- 1. Wählen Sie Konfiguration in der oberen rechten Ecke des Bildschirms.
- 2. Wählen Sie Interpreter.
- 3. Wählen Sie Neustart und dann OK.

Erstellen Sie benutzerdefinierte IAM-Richtlinien für Managed Service für Apache Flink Studio-Notebooks

Normalerweise verwenden Sie verwaltete IAM-Richtlinien, um Ihrer Anwendung den Zugriff auf abhängige Ressourcen zu ermöglichen. Wenn Sie eine genauere Kontrolle über die Berechtigungen Ihrer Anwendung benötigen, können Sie eine benutzerdefinierte IAM-Richtlinie verwenden. Dieser Abschnitt enthält Beispiele für benutzerdefinierte IAM-Richtlinien.

Ersetzen Sie in den folgenden Richtlinienbeispielen den Platzhaltertext durch die Werte Ihrer Anwendung.

Dieses Thema enthält die folgenden Abschnitte:

Note

- AWS Glue
- CloudWatch Logs
- Kinesis-Streams
- Amazon-MSK-Cluster

AWS Glue

Die folgende Beispielrichtlinie gewährt Berechtigungen für den Zugriff auf eine AWS Glue Datenbank.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "GlueTable",
            "Effect": "Allow",
            "Action": [
                "glue:GetConnection",
                "glue:GetTable",
                "glue:GetTables",
                "glue:GetDatabase",
                "glue:CreateTable",
                "glue:UpdateTable"
            ],
            "Resource": [
                "arn:aws:glue:<region>:<accountId>:connection/*",
                "arn:aws:glue:<region>:<accountId>:table/<database-name>/*",
                "arn:aws:glue:<region>:<accountId>:database/<database-name>",
                "arn:aws:glue:<region>:<accountId>:database/hive",
                "arn:aws:glue:<region>:<accountId>:catalog"
            ]
        },
        {
            "Sid": "GlueDatabase",
            "Effect": "Allow",
            "Action": "glue:GetDatabases",
            "Resource": "*"
        }
    ]
}
```

CloudWatch Logs

Die folgende Richtlinie gewährt Berechtigungen für den Zugriff auf CloudWatch Protokolle:

```
{
      "Sid": "ListCloudwatchLogGroups",
      "Effect": "Allow",
      "Action": [
        "logs:DescribeLogGroups"
      ],
      "Resource": [
        "arn:aws:logs:<region>:<accountId>:log-group:*"
      ]
    },
    {
      "Sid": "ListCloudwatchLogStreams",
      "Effect": "Allow",
      "Action": [
        "logs:DescribeLogStreams"
      ],
      "Resource": [
        "<logGroupArn>:log-stream:*"
      ]
    },
    {
      "Sid": "PutCloudwatchLogs",
      "Effect": "Allow",
      "Action": [
        "logs:PutLogEvents"
      ],
      "Resource": [
        "<logStreamArn>"
      ]
    }
```

Note

Wenn Sie Ihre Anwendung mithilfe der Konsole erstellen, fügt die Konsole Ihrer Anwendungsrolle die erforderlichen Richtlinien für den Zugriff auf CloudWatch Protokolle hinzu.

Kinesis-Streams

Ihre Anwendung kann einen Kinesis-Stream für eine Quelle oder ein Ziel verwenden. Ihre Anwendung benötigt Leseberechtigungen, um aus einem Quell-Stream zu lesen, und Schreibberechtigungen, um in einen Ziel-Stream zu schreiben.

Die folgende Richtlinie gewährt Berechtigungen zum Lesen aus einem Kinesis-Stream, der als Quelle verwendet wird:

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "KinesisShardDiscovery",
      "Effect": "Allow",
      "Action": "kinesis:ListShards",
      "Resource": "*"
    },
    {
      "Sid": "KinesisShardConsumption",
      "Effect": "Allow",
      "Action": [
        "kinesis:GetShardIterator",
        "kinesis:GetRecords",
        "kinesis:DescribeStream",
        "kinesis:DescribeStreamSummary",
        "kinesis:RegisterStreamConsumer",
        "kinesis:DeregisterStreamConsumer"
      ],
      "Resource": "arn:aws:kinesis:<region>:<accountId>:stream/<stream-name>"
    },
    {
      "Sid": "KinesisEfoConsumer",
      "Effect": "Allow",
      "Action": [
        "kinesis:DescribeStreamConsumer",
        "kinesis:SubscribeToShard"
      ],
      "Resource": "arn:aws:kinesis:<region>:<account>:stream/<stream-name>/consumer/*"
    }
  ]
}
```

Die folgende Richtlinie gewährt Berechtigungen zum Schreiben in einen Kinesis-Stream, der als Ziel verwendet wird:

```
{
    "Version": "2012-10-17",
    "Statement": [
         {
            "Sid": "KinesisStreamSink",
            "Effect": "Allow",
            "Action": [
                "kinesis:PutRecord",
                "kinesis:PutRecords",
                "kinesis:DescribeStreamSummary",
                "kinesis:DescribeStream"
            ],
            "Resource": "arn:aws:kinesis:<region>:<accountId>:stream/<stream-name>"
        }
    ]
}
```

Wenn Ihre Anwendung auf einen verschlüsselten Kinesis-Stream zugreift, müssen Sie zusätzliche Berechtigungen für den Zugriff auf den Stream und den Verschlüsselungsschlüssel des Streams gewähren.

Die folgende Richtlinie gewährt Berechtigungen für den Zugriff auf einen verschlüsselten Quell-Stream und den Verschlüsselungsschlüssel des Streams:

```
{
    "Sid": "ReadEncryptedKinesisStreamSource",
    "Effect": "Allow",
    "Action": [
        "kms:Decrypt"
    ],
    "Resource": [
        "<inputStreamKeyArn>"
    ]
    }
    ,
```

Die folgende Richtlinie gewährt Berechtigungen für den Zugriff auf einen verschlüsselten Ziel-Stream und den Verschlüsselungsschlüssel des Streams:

```
{
    "Sid": "WriteEncryptedKinesisStreamSink",
    "Effect": "Allow",
    "Action": [
        "kms:GenerateDataKey"
    ],
    "Resource": [
        "<outputStreamKeyArn>"
    ]
    }
}
```

Amazon-MSK-Cluster

Um Zugriff auf einen Amazon-MSK-Cluster zu gewähren, gewähren Sie Zugriff auf die VPC des Clusters. Richtlinienbeispiele für den Zugriff auf eine Amazon VPC finden Sie unter <u>VPC-Anwendungsberechtigungen</u>.

Erste Schritte mit Amazon Managed Service für Apache Flink (DataStream API)

In diesem Abschnitt werden Ihnen die grundlegenden Konzepte von Managed Service für Apache Flink und die Implementierung einer Anwendung in Java mithilfe der DataStream API vorgestellt. Es werden die verfügbaren Optionen für die Erstellung und das Testen von Anwendungen beschrieben. Er enthält auch Anweisungen zur Installation der Tools, die Sie benötigen, um die Tutorials in diesem Handbuch abzuschließen und Ihre erste Anwendung zu erstellen.

Themen

- Sehen Sie sich die Komponenten der Anwendung Managed Service für Apache Flink an
- Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen
- Richten Sie ein AWS Konto ein und erstellen Sie einen Administratorbenutzer
- Richten Sie das AWS Command Line Interface ()AWS CLI ein
- Erstellen Sie eine Managed Service for Apache Flink-Anwendung und führen Sie sie aus
- Ressourcen bereinigen AWS
- Erkunden Sie zusätzliche Ressourcen

Sehen Sie sich die Komponenten der Anwendung Managed Service für Apache Flink an

Note

Amazon Managed Service für Apache Flink unterstützt alle Apache Flink APIs - und potenziell alle JVM-Sprachen. <u>Weitere Informationen finden Sie unter Flink's. APIs</u> Je nachdem, für welche API Sie sich entscheiden, unterscheiden sich die Struktur der Anwendung und die Implementierung geringfügig. Dieses Tutorial "Erste Schritte" behandelt die Implementierung der Anwendungen mithilfe der DataStream API in Java.

Zur Verarbeitung von Daten verwendet Ihre Managed Service for Apache Flink-Anwendung eine Java-Anwendung, die mithilfe der Apache Flink-Laufzeit Eingaben verarbeitet und Ausgaben erzeugt.

Eine typische Managed Service for Apache Flink-Anwendung besteht aus den folgenden Komponenten:

- Laufzeiteigenschaften: Sie können Laufzeiteigenschaften verwenden, um Konfigurationsparameter an Ihre Anwendung zu übergeben, um sie zu ändern, ohne den Code zu ändern und erneut zu veröffentlichen.
- Quellen: Die Anwendung verwendet Daten aus einer oder mehreren Quellen. Eine Quelle verwendet einen <u>Konnektor</u>, um Daten aus einem externen System zu lesen, z. B. einem Kinesis-Datenstream oder einem Kafka-Bucket. Weitere Informationen finden Sie unter <u>Fügen Sie</u> <u>Streaming-Datenquellen hinzu</u>.
- Operatoren: Die Anwendung verarbeitet Daten mithilfe eines oder mehrerer Operatoren. Ein Operator kann Daten transformieren, anreichern oder aggregieren. Weitere Informationen finden Sie unter <u>Operatoren</u>.
- Senken: Die Anwendung sendet Daten über Senken an externe Quellen. Eine Senke verwendet einen Konnektor v, um Daten an einen Kinesis-Datenstrom, ein Kafka-Thema, Amazon S3 oder eine relationale Datenbank zu senden. Sie können auch einen speziellen Anschluss verwenden, um die Ausgabe nur zu Entwicklungszwecken zu drucken. Weitere Informationen finden Sie unter Schreiben Sie Daten mithilfe von Senken.

Ihre Anwendung erfordert einige externe Abhängigkeiten, z. B. die Flink-Konnektoren, die Ihre Anwendung verwendet, oder möglicherweise eine Java-Bibliothek. Um in Amazon Managed Service für Apache Flink ausgeführt zu werden, muss die Anwendung zusammen mit den Abhängigkeiten in ein Fat-Jar gepackt und in einen Amazon S3 S3-Bucket hochgeladen werden. Anschließend erstellen Sie eine Managed Service für Apache Flink-Anwendung. Sie übergeben den Speicherort des Codepakets zusammen mit allen anderen Laufzeitkonfigurationsparametern.

Dieses Tutorial zeigt, wie Sie Apache Maven verwenden, um die Anwendung zu verpacken, und wie Sie die Anwendung lokal in der IDE Ihrer Wahl ausführen.

Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen

Zur Durchführung der Schritte in dieser Anleitung benötigen Sie Folgendes:

- Git-Client. Installiere den Git-Client, falls du es noch nicht getan hast.
- Java Development Kit (JDK) Version 11. Installieren Sie ein Java JDK 11 und legen Sie die JAVA_HOME Umgebungsvariable so fest, dass sie auf Ihren JDK-Installationsort verweist. Wenn

Sie kein JDK 11 haben, können Sie <u>Amazon Coretto 11</u> oder ein anderes Standard-JDK Ihrer Wahl verwenden.

 Führen Sie den folgenden Befehl aus, um zu überprüfen, ob das JDK korrekt installiert ist. Die Ausgabe ist anders, wenn Sie ein anderes JDK als Amazon Corretto verwenden. Stellen Sie sicher, dass die Version 11.x ist.

```
$ java --version
openjdk 11.0.23 2024-04-16 LTS
OpenJDK Runtime Environment Corretto-11.0.23.9.1 (build 11.0.23+9-LTS)
OpenJDK 64-Bit Server VM Corretto-11.0.23.9.1 (build 11.0.23+9-LTS, mixed mode)
```

- <u>Apache Maven</u>. Installieren Sie Apache Maven, falls Sie dies noch nicht getan haben. Informationen zur Installation finden Sie unter <u>Apache Maven installieren</u>.
 - Zum Testen Ihrer Apache Maven-Installation geben Sie Folgendes ein:

```
$ mvn -version
```

- IDE f
 ür lokale Entwicklung. Wir empfehlen Ihnen, eine Entwicklungsumgebung wie <u>Eclipse, Java</u> Neon oder IntelliJ IDEA zu verwenden, um Ihre Anwendung zu entwickeln und zu kompilieren.
 - Zum Testen Ihrer Apache Maven-Installation geben Sie Folgendes ein:

```
$ mvn -version
```

Um zu beginnen, gehen Sie zu <u>Richten Sie ein AWS Konto ein und erstellen Sie einen</u> Administratorbenutzer.

Richten Sie ein AWS Konto ein und erstellen Sie einen Administratorbenutzer

Führen Sie die folgenden Aufgaben aus, bevor Sie Managed Service für Apache Flink zum ersten Mal verwenden:

Melde dich an für ein AWS-Konto

Wenn Sie noch keine haben AWS-Konto, führen Sie die folgenden Schritte aus, um eine zu erstellen.

Um sich für eine anzumelden AWS-Konto

- 1. Öffnen Sie https://portal.aws.amazon.com/billing/die Anmeldung.
- 2. Folgen Sie den Online-Anweisungen.

Bei der Anmeldung müssen Sie auch einen Telefonanruf entgegennehmen und einen Verifizierungscode über die Telefontasten eingeben.

Wenn Sie sich für eine anmelden AWS-Konto, Root-Benutzer des AWS-Kontoswird eine erstellt. Der Root-Benutzer hat Zugriff auf alle AWS-Services und Ressourcen des Kontos. Als bewährte Sicherheitsmethode weisen Sie einem Administratorbenutzer Administratorzugriff zu und verwenden Sie nur den Root-Benutzer, um Aufgaben auszuführen, die Root-Benutzerzugriff erfordern.

AWS sendet Ihnen nach Abschluss des Anmeldevorgangs eine Bestätigungs-E-Mail. Du kannst jederzeit deine aktuellen Kontoaktivitäten einsehen und dein Konto verwalten, indem du zu <u>https://aws.amazon.com/gehst und Mein Konto auswählst.</u>

Erstellen eines Benutzers mit Administratorzugriff

Nachdem Sie sich für einen angemeldet haben AWS-Konto, sichern Sie Ihren Root-Benutzer des AWS-Kontos AWS IAM Identity Center, aktivieren und erstellen Sie einen Administratorbenutzer, sodass Sie den Root-Benutzer nicht für alltägliche Aufgaben verwenden.

Sichern Sie Ihre Root-Benutzer des AWS-Kontos

 Melden Sie sich <u>AWS Management Console</u>als Kontoinhaber an, indem Sie Root-Benutzer auswählen und Ihre AWS-Konto E-Mail-Adresse eingeben. Geben Sie auf der nächsten Seite Ihr Passwort ein.

Hilfe bei der Anmeldung mit dem Root-Benutzer finden Sie unter <u>Anmelden als Root-Benutzer</u> im AWS-Anmeldung Benutzerhandbuch zu.

2. Aktivieren Sie die Multi-Faktor-Authentifizierung (MFA) für den Root-Benutzer.

Anweisungen finden Sie unter <u>Aktivieren eines virtuellen MFA-Geräts für Ihren AWS-Konto Root-</u> <u>Benutzer (Konsole)</u> im IAM-Benutzerhandbuch.
Erstellen eines Benutzers mit Administratorzugriff

1. Aktivieren Sie das IAM Identity Center.

Anweisungen finden Sie unter <u>Aktivieren AWS IAM Identity Center</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Gewähren Sie einem Administratorbenutzer im IAM Identity Center Benutzerzugriff.

Ein Tutorial zur Verwendung von IAM-Identity-Center-Verzeichnis als Identitätsquelle finden Sie IAM-Identity-Center-Verzeichnis im Benutzerhandbuch unter <u>Benutzerzugriff mit der</u> <u>Standardeinstellung konfigurieren</u>.AWS IAM Identity Center

Anmelden als Administratorbenutzer

 Um sich mit Ihrem IAM-Identity-Center-Benutzer anzumelden, verwenden Sie die Anmelde-URL, die an Ihre E-Mail-Adresse gesendet wurde, als Sie den IAM-Identity-Center-Benutzer erstellt haben.

Hilfe bei der Anmeldung mit einem IAM Identity Center-Benutzer finden Sie <u>im AWS-Anmeldung</u> Benutzerhandbuch unter Anmeldung beim AWS Access-Portal.

Weiteren Benutzern Zugriff zuweisen

1. Erstellen Sie im IAM-Identity-Center einen Berechtigungssatz, der den bewährten Vorgehensweisen für die Anwendung von geringsten Berechtigungen folgt.

Anweisungen hierzu finden Sie unter <u>Berechtigungssatz erstellen</u> im AWS IAM Identity Center Benutzerhandbuch.

2. Weisen Sie Benutzer einer Gruppe zu und weisen Sie der Gruppe dann Single Sign-On-Zugriff zu.

Eine genaue Anleitung finden Sie unter <u>Gruppen hinzufügen</u> im AWS IAM Identity Center Benutzerhandbuch.

Erteilen programmgesteuerten Zugriffs

Benutzer benötigen programmatischen Zugriff, wenn sie mit AWS außerhalb des interagieren möchten. AWS Management Console Die Art und Weise, wie programmatischer Zugriff gewährt wird, hängt vom Benutzertyp ab, der zugreift. AWS

Um Benutzern programmgesteuerten Zugriff zu gewähren, wählen Sie eine der folgenden Optionen.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
Mitarbeiteridentität (Benutzer, die in IAM Identity Center verwaltet werden)	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen zu den AWS CLI finden Sie <u>unter</u> Konfiguration der AWS CLI zur Verwendung AWS IAM Identity Center im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs Tools und AWS APIs finden Sie unter IAM Identity Center-Authentifizierung im Referenzhandbuch AWS SDKs und im Tools-Ref erenzhandbuch.
IAM	Verwenden Sie temporäre Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	Folgen Sie den Anweisungen unter <u>Verwenden temporäre</u> <u>r Anmeldeinformationen mit</u> <u>AWS Ressourcen</u> im IAM- Benutzerhandbuch.

Welcher Benutzer benötigt programmgesteuerten Zugriff?	Bis	Von
	(Nicht empfohlen) Verwenden Sie langfristige Anmeldeinformationen, um programmatische Anfragen an das AWS CLI AWS SDKs, oder zu signieren. AWS APIs	 Befolgen Sie die Anweisung en für die Schnittstelle, die Sie verwenden möchten. Informationen dazu AWS CLI finden Sie unter <u>Authentifizierung mithilfe</u> von IAM-Benutzeranmeld einformationen im AWS Command Line Interface Benutzerhandbuch. Informationen zu AWS SDKs und Tools finden Sie unter <u>Authentifizieren mit</u> langfristigen Anmeldein formationen im Referenzh andbuch AWS SDKs und im Tools-Referenzhandbuch. Weitere Informationen finden Sie unter <u>Verwaltun</u> g von Zugriffsschlüsseln für IAM-Benutzer im IAM-Benut zerhandbuch. AWS APIs

Nächster Schritt

Richten Sie das AWS Command Line Interface ()AWS CLI ein

Richten Sie das AWS Command Line Interface ()AWS CLI ein

In diesem Schritt laden Sie den herunter und konfigurieren ihn für AWS CLI die Verwendung mit Managed Service für Apache Flink.

Note

Bei allen Erste-Schritte-Übungen in diesem Handbuch wird davon ausgegangen, dass Sie in Ihrem Konto Administrator-Anmeldeinformationen (adminuser) verwenden, um die Operationen auszuführen.

1 Note

Wenn Sie das bereits AWS CLI installiert haben, müssen Sie möglicherweise ein Upgrade durchführen, um die neuesten Funktionen zu erhalten. Weitere Informationen finden Sie unter <u>Installieren der AWS Command Line Interface</u> im AWS Command Line Interface - Benutzerhandbuch. Führen Sie den folgenden Befehl aus AWS CLI, um die Version von zu überprüfen:

aws --version

Für die Übungen in diesem Tutorial ist die folgende AWS CLI Version oder höher erforderlich:

aws-cli/1.16.63

Um das einzurichten AWS CLI

- 1. Herunterladen und Konfigurieren von AWS CLI. Eine Anleitung finden Sie unter den folgenden Themen im AWS Command Line Interface -Benutzerhandbuch:
 - Installieren des AWS Command Line Interface
 - Konfigurieren von AWS CLI
- Fügen Sie der Datei ein benanntes Profil f
 ür den Administratorbenutzer AWS CLI config hinzu. Verwenden Sie dieses Profil beim Ausf
 ühren von AWS CLI -Befehlen. Weitere Informationen zu benannten Profilen finden Sie unter <u>Benannte Profile</u> im AWS Command Line Interface Benutzerhandbuch.

```
[profile adminuser]
aws_access_key_id = adminuser access key ID
aws_secret_access_key = adminuser secret access key
```

region = aws-region

Eine Liste der verfügbaren AWS Regionen finden Sie unter <u>Regionen und Endpunkte</u> in der Allgemeine Amazon Web Services-Referenz.

Note

Der Beispielcode und die Befehle in diesem Tutorial verwenden die Region us-east-1 US East (Nord-Virginia). Um eine andere Region zu verwenden, ändern Sie die Region im Code und in den Befehlen für dieses Tutorial in die Region, die Sie verwenden möchten.

3. Überprüfen Sie die Einrichtung, indem Sie die folgenden Hilfebefehle in die Befehlszeile eingeben:

aws help

Nachdem Sie ein AWS Konto eingerichtet haben AWS CLI, können Sie die nächste Übung ausprobieren, in der Sie eine Beispielanwendung konfigurieren und das end-to-end Setup testen.

Nächster Schritt

Erstellen Sie eine Managed Service for Apache Flink-Anwendung und führen Sie sie aus

Erstellen Sie eine Managed Service for Apache Flink-Anwendung und führen Sie sie aus

In diesem Schritt erstellen Sie eine Managed Service für Apache Flink-Anwendung mit Kinesis-Datenströmen als Quelle und Senke.

Dieser Abschnitt enthält die folgenden Schritte:

- Erstellen Sie abhängige Ressourcen
- Einrichten der lokalen Entwicklungsumgebung
- Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Führen Sie Ihre Anwendung lokal aus
- Beobachten Sie Eingabe- und Ausgabedaten in Kinesis-Streams

- Stoppen Sie, dass Ihre Anwendung lokal ausgeführt wird
- Kompilieren und verpacken Sie Ihren Anwendungscode
- Laden Sie die JAR-Datei mit dem Anwendungscode hoch
- Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink
- <u>Nächster Schritt</u>

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis-Datenströme für Eingabe und Ausgabe
- Ein Amazon S3 S3-Bucket zum Speichern des Anwendungscodes

1 Note

In diesem Tutorial wird davon ausgegangen, dass Sie Ihre Anwendung in der Region useast-1 US East (Nord-Virginia) bereitstellen. Wenn Sie eine andere Region verwenden, passen Sie alle Schritte entsprechend an.

Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream). Ihre Anwendung verwendet diese Streams für die Quell- und Ziel-Streams der Anwendung.

Sie können diese Streams entweder mit der Amazon Kinesis Kinesis-Konsole oder mit dem folgenden AWS CLI Befehl erstellen. Anweisungen für die Konsole finden Sie unter <u>Erstellen und</u> <u>Aktualisieren von Datenströmen</u> im Amazon Kinesis Data Streams Entwicklerhandbuch. Um die Streams mit dem zu erstellen AWS CLI, verwenden Sie die folgenden Befehle und passen Sie sie an die Region an, die Sie für Ihre Anwendung verwenden.

So erstellen Sie die Daten-Streams (AWS CLI)

 Verwenden Sie den folgenden Amazon Kinesis create-stream AWS CLI Kinesis-Befehl, um den ersten Stream (ExampleInputStream) zu erstellen:

```
$ aws kinesis create-stream \
--stream-name ExampleInputStream \
--shard-count 1 \
--region us-east-1 \
```

 Um den zweiten Stream zu erstellen, den die Anwendung zum Schreiben der Ausgabe verwendet, führen Sie denselben Befehl aus und ändern Sie den Stream-Namen inExampleOutputStream:

```
$ aws kinesis create-stream \
--stream-name ExampleOutputStream \
--shard-count 1 \
--region us-east-1 \
```

Erstellen Sie einen Amazon S3 S3-Bucket für den Anwendungscode

Sie können ein Amazon-S3-Bucket mithilfe der Konsole erstellen. Informationen zum Erstellen eines Amazon S3 S3-Buckets mithilfe der Konsole finden Sie unter <u>Erstellen eines Buckets</u> im <u>Amazon S3</u> <u>S3-Benutzerhandbuch</u>. Benennen Sie den Amazon S3 S3-Bucket mit einem weltweit eindeutigen Namen, indem Sie beispielsweise Ihren Anmeldenamen anhängen.

Note

Stellen Sie sicher, dass Sie den Bucket in der Region erstellen, die Sie für dieses Tutorial verwenden (us-east-1).

Sonstige Ressourcen

Wenn Sie Ihre Anwendung erstellen, erstellt Managed Service for Apache Flink automatisch die folgenden CloudWatch Amazon-Ressourcen, sofern sie noch nicht vorhanden sind:

- Eine Protokollgruppe mit dem Namen /AWS/KinesisAnalytics-java/<my-application>
- Einen Protokollstream mit dem Namen kinesis-analytics-log-stream

Einrichten der lokalen Entwicklungsumgebung

Für die Entwicklung und das Debuggen können Sie die Apache Flink-Anwendung auf Ihrem Computer direkt von der IDE Ihrer Wahl aus ausführen. Alle Apache Flink-Abhängigkeiten werden wie normale Java-Abhängigkeiten mit Apache Maven behandelt.

Note

Auf Ihrem Entwicklungscomputer müssen Sie Java JDK 11, Maven und Git installiert haben. Wir empfehlen Ihnen, eine Entwicklungsumgebung wie <u>Eclipse</u>, Java Neon oder <u>IntelliJ</u> IDEA zu verwenden. Informationen darüber, ob Sie alle Voraussetzungen erfüllen, finden Sie unter. <u>Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen</u> Sie müssen keinen Apache Flink-Cluster auf Ihrem Computer installieren.

Authentifizieren Sie Ihre Sitzung AWS

Die Anwendung verwendet Kinesis-Datenströme, um Daten zu veröffentlichen. Bei der lokalen Ausführung benötigen Sie eine gültige AWS authentifizierte Sitzung mit Schreibberechtigungen in den Kinesis-Datenstrom. Verwenden Sie die folgenden Schritte, um Ihre Sitzung zu authentifizieren:

- 1. Wenn Sie das Profil AWS CLI und ein benanntes Profil mit gültigen Anmeldeinformationen nicht konfiguriert haben, finden Sie weitere Informationen unter. <u>Richten Sie das AWS Command Line</u> Interface ()AWS CLI ein
- 2. Vergewissern Sie sich, dass Ihre korrekt konfiguriert AWS CLI ist und dass Ihre Benutzer über Schreibberechtigungen in den Kinesis-Datenstrom verfügen, indem Sie den folgenden Testdatensatz veröffentlichen:

```
$ aws kinesis put-record --stream-name ExampleOutputStream --data TEST --partition-
key TEST
```

 Wenn Ihre IDE über ein Plug-in zur Integration verfügt AWS, können Sie dieses verwenden, um die Anmeldeinformationen an die Anwendung zu übergeben, die in der IDE ausgeführt wird.
 Weitere Informationen finden Sie unter <u>AWS Toolkit für Intellij IDEA</u> und <u>AWS Toolkit</u> for Eclipse.

Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

1. Klonen Sie das Remote-Repository, indem Sie den folgenden Befehl verwenden:

```
git clone https://github.com/aws-samples/amazon-managed-service-for-apache-flink-
examples.git
```

 Navigieren Sie zum amazon-managed-service-for-apache-flink-examples/tree/ main/java/GettingStarted Verzeichnis.

Überprüfen Sie die Anwendungskomponenten

Die Anwendung ist vollständig in der com.amazonaws.services.msf.BasicStreamingJob Klasse implementiert. Die main() Methode definiert den Datenfluss, um die Streaming-Daten zu verarbeiten und auszuführen.

1 Note

Für ein optimiertes Entwicklererlebnis ist die Anwendung so konzipiert, dass sie ohne Codeänderungen sowohl auf Amazon Managed Service für Apache Flink als auch lokal für die Entwicklung in Ihrer IDE ausgeführt werden kann.

- Um die Laufzeitkonfiguration zu lesen, damit sie funktioniert, wenn sie in Amazon Managed Service for Apache Flink und in Ihrer IDE ausgeführt wird, erkennt die Anwendung automatisch, ob sie lokal in der IDE eigenständig ausgeführt wird. In diesem Fall lädt die Anwendung die Laufzeitkonfiguration anders:
 - 1. Wenn die Anwendung feststellt, dass sie in Ihrer IDE im Standalone-Modus ausgeführt wird, erstellen Sie die application_properties.json Datei, die im Ressourcenordner des Projekts enthalten ist. Der Inhalt der Datei folgt.
 - 2. Wenn die Anwendung in Amazon Managed Service für Apache Flink ausgeführt wird, lädt das Standardverhalten die Anwendungskonfiguration aus den Laufzeiteigenschaften, die Sie in

der Anwendung Amazon Managed Service für Apache Flink definieren. Siehe <u>Erstellen und</u> konfigurieren Sie die Anwendung Managed Service für Apache Flink.

```
private static Map<String, Properties>
loadApplicationProperties(StreamExecutionEnvironment env) throws IOException {
    if (env instanceof LocalStreamEnvironment) {
        LOGGER.info("Loading application properties from '{}'",
LOCAL_APPLICATION_PROPERTIES_RESOURCE);
        return KinesisAnalyticsRuntime.getApplicationProperties(
            BasicStreamingJob.class.getClassLoader()

.getResource(LOCAL_APPLICATION_PROPERTIES_RESOURCE).getPath());
    } else {
       LOGGER.info("Loading application properties from Amazon Managed Service for
Apache Flink");
        return KinesisAnalyticsRuntime.getApplicationProperties();
    }
}
```

- Die main() Methode definiert den Anwendungsdatenfluss und führt ihn aus.
 - Initialisiert die Standard-Streaming-Umgebungen. In diesem Beispiel zeigen wir, wie Sie sowohl die API für StreamExecutionEnvironment die Verwendung mit der DataSteam API als auch die API für StreamTableEnvironment die Verwendung mit SQL und der Tabelle erstellen. Die beiden Umgebungsobjekte sind zwei separate Verweise auf dieselbe Laufzeitumgebung, die unterschiedlich verwendet werden soll APIs.

```
StreamExecutionEnvironment env =
  StreamExecutionEnvironment.getExecutionEnvironment();
```

• Laden Sie die Konfigurationsparameter der Anwendung. Dadurch werden sie automatisch von der richtigen Stelle geladen, je nachdem, wo die Anwendung ausgeführt wird:

```
Map<String, Properties> applicationParameters = loadApplicationProperties(env);
```

 Die Anwendung definiert mithilfe des <u>Kinesis Consumer-Connectors</u> eine Quelle, um Daten aus dem Eingabestream zu lesen. Die Konfiguration des Eingabestreams ist im PropertyGroupId = InputStream0 definiert. Der Name und die Region des Streams sind in den jeweiligen Eigenschaften aws.region benanntstream.name. Der Einfachheit halber liest diese Quelle die Datensätze als Zeichenfolge.

```
private static FlinkKinesisConsumer<String> createSource(Properties
    inputProperties) {
        String inputStreamName = inputProperties.getProperty("stream.name");
        return new FlinkKinesisConsumer<>(inputStreamName, new SimpleStringSchema(),
        inputProperties);
    }
    ...
public static void main(String[] args) throws Exception {
            ...
        SourceFunction<String> source =
            createSource(applicationParameters.get("InputStream0"));
        DataStream<String> input = env.addSource(source, "Kinesis Source");
        ...
}
```

 Die Anwendung definiert dann mithilfe des <u>Kinesis Streams Sink</u> Connectors eine Senke, um Daten an den Ausgabestrom zu senden. Name und Region des Ausgabestreams sind im PropertyGroupId = definiertOutputStream0, ähnlich wie beim Eingabestream. Die Senke ist direkt mit der internen Senke verbundenDataStream, die Daten von der Quelle bezieht. In einer echten Anwendung gibt es eine gewisse Transformation zwischen Quelle und Senke.

```
private static KinesisStreamsSink<String> createSink(Properties outputProperties) {
    String outputStreamName = outputProperties.getProperty("stream.name");
    return KinesisStreamsSink.<String>builder()
            .setKinesisClientProperties(outputProperties)
            .setSerializationSchema(new SimpleStringSchema())
            .setStreamName(outputStreamName)
            .setPartitionKeyGenerator(element ->
String.valueOf(element.hashCode()))
            .build();
}
. .
public static void main(String[] args) throws Exception {
   . . .
   Sink<String> sink = createSink(applicationParameters.get("OutputStream0"));
   input.sinkTo(sink);
   . . .
}
```

env.execute("Flink streaming Java API skeleton");

Verwenden Sie die Datei pom.xml

Die Datei pom.xml definiert alle Abhängigkeiten, die von der Anwendung benötigt werden, und richtet das Maven Shade-Plugin ein, um das Fat-Jar zu erstellen, das alle von Flink benötigten Abhängigkeiten enthält.

 Einige Abhängigkeiten haben einen Geltungsbereich. provided Diese Abhängigkeiten sind automatisch verfügbar, wenn die Anwendung in Amazon Managed Service for Apache Flink ausgeführt wird. Sie sind erforderlich, um die Anwendung zu kompilieren oder die Anwendung lokal in Ihrer IDE auszuführen. Weitere Informationen finden Sie unter <u>Führen Sie Ihre Anwendung lokal</u> <u>aus</u>. Stellen Sie sicher, dass Sie dieselbe Flink-Version wie die Runtime verwenden, die Sie in Amazon Managed Service for Apache Flink verwenden werden.

```
<dependency>
<groupId>org.apache.flink</groupId>
<artifactId>flink-clients</artifactId>
<version>${flink.version}</version>
<scope>provided</scope>
</dependency>
<groupId>org.apache.flink</groupId>
<artifactId>flink.streaming-java</artifactId>
<version>${flink.version}</version>
<scope>provided</scope>
</dependency>
```

 Sie müssen dem POM zusätzliche Apache Flink-Abhängigkeiten mit dem Standardbereich hinzufügen, z. B. den von dieser Anwendung verwendeten <u>Kinesis-Connector</u>. Weitere Informationen finden Sie unter <u>Verwenden Sie Apache Flink-Konnektoren</u>. Sie können auch alle zusätzlichen Java-Abhängigkeiten hinzufügen, die für Ihre Anwendung erforderlich sind.

```
<dependency>
```

```
<groupId>org.apache.flink</groupId>
    <artifactId>flink-connector-kinesis</artifactId>
    <version>${aws.connector.version}</version>
</dependency>
```

- Das Maven Java Compiler-Plugin stellt sicher, dass der Code mit Java 11 kompiliert wird, der JDK-Version, die derzeit von Apache Flink unterstützt wird.
- Das Maven Shade-Plugin packt das Fat-Jar, mit Ausnahme einiger Bibliotheken, die von der Runtime bereitgestellt werden. Es spezifiziert auch zwei Transformatoren: und. ServicesResourceTransformer ManifestResourceTransformer Letzteres konfiguriert die Klasse, die die main Methode zum Starten der Anwendung enthält. Wenn Sie die Hauptklasse umbenennen, vergessen Sie nicht, diesen Transformator zu aktualisieren.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt senden Sie Beispieldatensätze an den Stream, damit die Anwendung sie verarbeiten kann. Sie haben zwei Möglichkeiten, Beispieldaten zu generieren, entweder mit einem Python-Skript oder mit dem Kinesis Data Generator.

Generieren Sie Beispieldaten mit einem Python-Skript

Sie können ein Python-Skript verwenden, um Beispieldatensätze an den Stream zu senden.

Note

Um dieses Python-Skript auszuführen, müssen Sie Python 3.x verwenden und die <u>AWS SDK</u> for Python (Boto) -Bibliothek installiert haben.

Um mit dem Senden von Testdaten an den Kinesis-Eingabestream zu beginnen:

- 1. Laden Sie das stock.py Python-Skript für den Datengenerator aus dem <u>GitHub Datengenerator-</u> Repository herunter.
- 2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen. Sie können jetzt Ihre Apache Flink-Anwendung ausführen.

Generieren Sie Beispieldaten mit Kinesis Data Generator

Alternativ zur Verwendung des Python-Skripts können Sie <u>Kinesis Data Generator</u> verwenden, der auch in einer <u>gehosteten Version</u> verfügbar ist, um Zufallsstichprobendaten an den Stream zu senden. Kinesis Data Generator läuft in Ihrem Browser und Sie müssen nichts auf Ihrem Computer installieren.

So richten Sie Kinesis Data Generator ein und führen ihn aus:

- Folgen Sie den Anweisungen in der <u>Kinesis Data Generator-Dokumentation</u>, um den Zugriff auf das Tool einzurichten. Sie werden eine AWS CloudFormation Vorlage ausführen, die einen Benutzer und ein Passwort einrichtet.
- Greifen Sie über die von der CloudFormation Vorlage generierte URL auf Kinesis Data Generator zu. Sie finden die URL auf der Registerkarte "Ausgabe", nachdem die CloudFormation Vorlage fertiggestellt wurde.
- 3. Konfigurieren Sie den Datengenerator:
 - Region: Wählen Sie die Region aus, die Sie für dieses Tutorial verwenden: us-east-1
 - Stream/Delivery-Stream: W\u00e4hlen Sie den Eingabestream aus, den die Anwendung verwenden soll: ExampleInputStream
 - Datensätze pro Sekunde: 100
 - Datensatzvorlage: Kopieren Sie die folgende Vorlage und fügen Sie sie ein:

```
{
    "event_time" : "{{date.now("YYYY-MM-DDTkk:mm:ss.SSSSS")}},
    "ticker" : "{{random.arrayElement(
            ["AAPL", "AMZN", "MSFT", "INTC", "TBV"]
```

```
)}}",
"price" : {{random.number(100)}}
}
```

4. Testen Sie die Vorlage: Wählen Sie Testvorlage und stellen Sie sicher, dass der generierte Datensatz dem folgenden ähnelt:

{ "event_time" : "2024-06-12T15:08:32.04800, "ticker" : "INTC", "price" : 7 }

5. Starten Sie den Datengenerator: Wählen Sie Select Send Data.

Kinesis Data Generator sendet jetzt Daten an denExampleInputStream.

Führen Sie Ihre Anwendung lokal aus

Sie können Ihre Flink-Anwendung lokal in Ihrer IDE ausführen und debuggen.

Note

Bevor Sie fortfahren, stellen Sie sicher, dass die Eingabe- und Ausgabestreams verfügbar sind. Siehe <u>Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams</u>. Stellen Sie außerdem sicher, dass Sie über Lese- und Schreibberechtigungen für beide Streams verfügen. Siehe <u>Authentifizieren Sie Ihre Sitzung AWS</u>.

Für die Einrichtung der lokalen Entwicklungsumgebung sind Java 11 JDK, Apache Maven und eine IDE für die Java-Entwicklung erforderlich. Stellen Sie sicher, dass Sie die erforderlichen Voraussetzungen erfüllen. Siehe Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen.

Importieren Sie das Java-Projekt in Ihre IDE

Um mit der Arbeit an der Anwendung in Ihrer IDE zu beginnen, müssen Sie sie als Java-Projekt importieren.

Das von Ihnen geklonte Repository enthält mehrere Beispiele. Jedes Beispiel ist ein separates Projekt. Importieren Sie für dieses Tutorial den Inhalt im ./java/GettingStarted Unterverzeichnis in Ihre IDE.

Fügen Sie den Code mithilfe von Maven als vorhandenes Java-Projekt ein.

Note

Der genaue Vorgang zum Importieren eines neuen Java-Projekts hängt von der verwendeten IDE ab.

Überprüfen Sie die lokale Anwendungskonfiguration

Bei der lokalen Ausführung verwendet die Anwendung die Konfiguration in der application_properties.json Datei im Ressourcenordner des Projekts unter./src/main/ resources. Sie können diese Datei bearbeiten, um verschiedene Kinesis-Stream-Namen oder -Regionen zu verwenden.

```
Ε
  {
    "PropertyGroupId": "InputStream0",
    "PropertyMap": {
      "stream.name": "ExampleInputStream",
      "flink.stream.initpos": "LATEST",
      "aws.region": "us-east-1"
    }
  },
  {
    "PropertyGroupId": "OutputStream0",
    "PropertyMap": {
      "stream.name": "ExampleOutputStream",
      "aws.region": "us-east-1"
    }
  }
]
```

Richten Sie Ihre IDE-Run-Konfiguration ein

Sie können die Flink-Anwendung direkt von Ihrer IDE aus ausführen und debuggen, indem Sie die Hauptklasse ausführencom.amazonaws.services.msf.BasicStreamingJob, wie Sie jede Java-Anwendung ausführen würden. Bevor Sie die Anwendung ausführen, müssen Sie die Run-Konfiguration einrichten. Das Setup hängt von der IDE ab, die Sie verwenden. Weitere Informationen finden Sie beispielsweise unter Konfigurationen ausführen/debuggen in der IntelliJ IDEA-Dokumentation. Insbesondere müssen Sie Folgendes einrichten:

- Fügen Sie die provided Abhängigkeiten zum Klassenpfad hinzu. Dies ist erforderlich, um sicherzustellen, dass die Abhängigkeiten mit provided Gültigkeitsbereich an die Anwendung übergeben werden, wenn sie lokal ausgeführt wird. Ohne diese Einrichtung zeigt die Anwendung sofort einen class not found Fehler an.
- 2. Übergeben Sie die AWS Anmeldeinformationen f
 ür den Zugriff auf die Kinesis-Streams an die Anwendung. Am schnellsten ist es, das <u>AWS Toolkit f
 ür IntelliJ</u> IDEA zu verwenden. Mit diesem IDE-Plugin in der Run-Konfiguration k
 önnen Sie ein bestimmtes Profil ausw
 ählen. AWS AWS Die Authentifizierung erfolgt mit diesem Profil. Sie m
 üssen die AWS Anmeldeinformationen nicht direkt weitergeben.
- 3. Stellen Sie sicher, dass die IDE die Anwendung mit JDK 11 ausführt.

Führen Sie die Anwendung in Ihrer IDE aus

Nachdem Sie die Run-Konfiguration für eingerichtet habenBasicStreamingJob, können Sie sie wie eine normale Java-Anwendung ausführen oder debuggen.

1 Note

Sie können das von Maven generierte Fat-Jar nicht direkt über die java -jar ... Befehlszeile ausführen. Dieses JAR enthält nicht die Kernabhängigkeiten von Flink, die für die eigenständige Ausführung der Anwendung erforderlich sind.

Wenn die Anwendung erfolgreich gestartet wird, protokolliert sie einige Informationen über den eigenständigen Minicluster und die Initialisierung der Konnektoren. Darauf folgen eine Reihe von INFO- und einige WARN-Logs, die Flink normalerweise beim Start der Anwendung ausgibt.

```
13:43:31,405 INFO com.amazonaws.services.msf.BasicStreamingJob [] -
Loading application properties from 'flink-application-properties-dev.json'
13:43:31,549 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer
[] - Flink Kinesis Consumer is going to read the following streams:
ExampleInputStream,
13:43:31,676 INFO org.apache.flink.runtime.taskexecutor.TaskExecutorResourceUtils []
- The configuration option taskmanager.cpu.cores required for local execution is not
set, setting it to the maximal possible value.
13:43:31,676 INFO org.apache.flink.runtime.taskexecutor.TaskExecutorResourceUtils
[] - The configuration option taskmanager.memory.task.heap.size required for local
execution is not set, setting it to the maximal possible value.
```

13:43:31,676 INFO org.apache.flink.runtime.taskexecutor.TaskExecutorResourceUtils [] - The configuration option taskmanager.memory.task.off-heap.size required for local execution is not set, setting it to the maximal possible value. 13:43:31,676 INFO org.apache.flink.runtime.taskexecutor.TaskExecutorResourceUtils [] - The configuration option taskmanager.memory.network.min required for local execution is not set, setting it to its default value 64 mb. 13:43:31,676 INFO org.apache.flink.runtime.taskexecutor.TaskExecutorResourceUtils [] - The configuration option taskmanager.memory.network.max required for local execution is not set, setting it to its default value 64 mb. 13:43:31,676 INFO org.apache.flink.runtime.taskexecutor.TaskExecutorResourceUtils [] -The configuration option taskmanager.memory.managed.size required for local execution is not set, setting it to its default value 128 mb. 13:43:31,677 INFO org.apache.flink.runtime.minicluster.MiniCluster [] -Starting Flink Mini Cluster

Nach Abschluss der Initialisierung gibt die Anwendung keine weiteren Protokolleinträge aus. Während des Datenflusses wird kein Protokoll ausgegeben.

Um zu überprüfen, ob die Anwendung Daten korrekt verarbeitet, können Sie die Eingabe- und Ausgabe-Kinesis-Streams überprüfen, wie im folgenden Abschnitt beschrieben.

Note

Es ist das normale Verhalten einer Flink-Anwendung, keine Protokolle über fließende Daten auszugeben. Das Ausgeben von Protokollen für jeden Datensatz mag für das Debuggen praktisch sein, kann aber bei der Ausführung in der Produktion zu erheblichem Mehraufwand führen.

Beobachten Sie Eingabe- und Ausgabedaten in Kinesis-Streams

Sie können Datensätze beobachten, die vom (generierenden Beispiel-Python) oder dem Kinesis Data Generator (Link) an den Eingabestream gesendet wurden, indem Sie den Data Viewer in der Amazon Kinesis Kinesis-Konsole verwenden.

Um Aufzeichnungen zu beobachten

1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.

- Stellen Sie sicher, dass die Region mit der Region übereinstimmt, in der Sie dieses Tutorial ausführen, und zwar standardmäßig us-east-1 US East (Nord-Virginia). Ändern Sie die Region, falls sie nicht übereinstimmt.
- 3. Wählen Sie Datenströme.
- 4. Wählen Sie den Stream aus, den Sie beobachten möchten, entweder ExampleInputStream oder ExampleOutputStream.
- 5. Wählen Sie die Registerkarte "Datenanzeige".
- 6. Wählen Sie einen beliebigen Shard aus, behalten Sie "Letzte" als Startposition bei und wählen Sie dann "Datensätze abrufen". Möglicherweise wird die Fehlermeldung "Für diese Anfrage wurde kein Datensatz gefunden" angezeigt. Wenn ja, wählen Sie "Erneut versuchen, Datensätze abzurufen". Die neuesten Datensätze, die im Stream veröffentlicht wurden, werden angezeigt.
- 7. Wählen Sie den Wert in der Datenspalte aus, um den Inhalt des Datensatzes im JSON-Format zu überprüfen.

Stoppen Sie, dass Ihre Anwendung lokal ausgeführt wird

Stoppen Sie die Anwendung, die in Ihrer IDE ausgeführt wird. Die IDE bietet normalerweise eine "Stopp" -Option. Der genaue Standort und die Methode hängen von der IDE ab, die Sie verwenden.

Kompilieren und verpacken Sie Ihren Anwendungscode

In diesem Abschnitt verwenden Sie Apache Maven, um den Java-Code zu kompilieren und in eine JAR-Datei zu packen. Sie können Ihren Code mit dem Maven-Befehlszeilentool oder Ihrer IDE kompilieren und verpacken.

Um mit der Maven-Befehlszeile zu kompilieren und zu paketieren:

Gehen Sie in das Verzeichnis, das das GettingStarted Java-Projekt enthält, und führen Sie den folgenden Befehl aus:

\$ mvn package

Um mit Ihrer IDE zu kompilieren und zu paketieren:

Führen Sie es mvn package von Ihrer IDE-Maven-Integration aus.

In beiden Fällen wird die folgende JAR-Datei erstellt:target/amazon-msf-java-streamapp-1.0.jar.

Note

Wenn Sie ein "Build-Projekt" von Ihrer IDE aus ausführen, wird die JAR-Datei möglicherweise nicht erstellt.

Laden Sie die JAR-Datei mit dem Anwendungscode hoch

In diesem Abschnitt laden Sie die JAR-Datei, die Sie im vorherigen Abschnitt erstellt haben, in den Amazon Simple Storage Service (Amazon S3) -Bucket hoch, den Sie zu Beginn dieses Tutorials erstellt haben. Wenn Sie diesen Schritt noch nicht abgeschlossen haben, finden Sie weitere Informationen unter (Link).

Um die JAR-Datei mit dem Anwendungscode hochzuladen

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den Bucket aus, den Sie zuvor für den Anwendungscode erstellt haben.
- 3. Klicken Sie auf Upload.
- 4. Klicken Sie auf Add files.
- 5. Navigieren Sie zu der im vorherigen Schritt generierten JAR-Datei:target/amazon-msfjava-stream-app-1.0.jar.
- 6. Wählen Sie Hochladen, ohne andere Einstellungen zu ändern.

🛕 Warning

Stellen Sie sicher, dass Sie die richtige JAR-Datei in auswählen<repo-dir>/java/ GettingStarted/target/amazon-msf-java-stream-app-1.0.jar. Das target Verzeichnis enthält auch andere JAR-Dateien, die Sie nicht hochladen müssen.

Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder AWS CLI erstellen und ausführen. Für dieses Tutorial verwenden Sie die Konsole.

1 Note

Wenn Sie die Anwendung mithilfe der Konsole erstellen, werden Ihre AWS Identity and Access Management (IAM) und Amazon CloudWatch Logs-Ressourcen für Sie erstellt. Wenn Sie die Anwendung mithilfe von erstellen AWS CLI, erstellen Sie diese Ressourcen separat.

Themen

- Erstellen der Anwendung
- Bearbeiten Sie die IAM-Richtlinie
- Konfigurieren Sie die Anwendung
- Führen Sie die Anwendung aus.
- Beobachten Sie die Metriken der laufenden Anwendung
- Beobachten Sie die Ausgabedaten in Kinesis-Streams
- Beenden Sie die Anwendung

Erstellen der Anwendung

So erstellen Sie die Anwendung

- 1. Öffnen Sie die Managed Service for Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Stellen Sie sicher, dass die richtige Region ausgewählt ist: us-east-1 US East (Nord-Virginia)
- Öffnen Sie das Menü auf der rechten Seite und wählen Sie Apache Flink-Anwendungen und dann Streaming-Anwendung erstellen. Wählen Sie alternativ im Container Erste Schritte auf der Startseite die Option Streaming-Anwendung erstellen aus.
- 4. Gehen Sie auf der Seite Streaming-Anwendung erstellen wie folgt vor:
 - Wählen Sie eine Methode, um die Stream-Verarbeitungsanwendung einzurichten: Wählen Sie Von Grund auf neu erstellen.
 - Apache Flink-Konfiguration, Flink-Version der Anwendung: Wählen Sie Apache Flink 1.20.
- 5. Konfigurieren Sie Ihre Anwendung
 - Name der Anwendung: Geben Sie einMyApplication.

- Beschreibung: eingebenMy java test app.
- Zugriff auf Anwendungsressourcen: Wählen Sie "IAM-Rolle kinesis-analytics-MyApplication-us-east-1 mit den erforderlichen Richtlinien erstellen/aktualisieren".
- 6. Konfigurieren Sie Ihre Vorlage für Anwendungseinstellungen
 - Vorlagen: Wählen Sie Entwicklung.
- 7. Wählen Sie unten auf der Seite die Option Streaming-Anwendung erstellen aus.
 - Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-east-1
- Rolle: kinesisanalytics-MyApplication-us-east-1

Amazon Managed Service für Apache Flink war früher als Kinesis Data Analytics bekannt. Dem Namen der Ressourcen, die automatisch erstellt werden, wird aus Gründen der Abwärtskompatibilität ein Präfix kinesis-analytics- vorangestellt.

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

Um die Richtlinie zu bearbeiten

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-east-1-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie Bearbeiten und dann die Registerkarte JSON.

4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie das Beispielkonto IDs (*012345678901*) durch Ihre Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3:::my-bucket/kinesis-analytics-placeholder-s3-object"
            ]
       },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "ListCloudwatchLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ]
        },
        {
            "Sid": "PutCloudwatchLogs",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
```

```
],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-east-1:012345678901:stream/
ExampleInputStream"
        },
        ſ
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-east-1:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

5. Wählen Sie unten auf der Seite Weiter und dann Änderungen speichern aus.

Konfigurieren Sie die Anwendung

Bearbeiten Sie die Anwendungskonfiguration, um das Anwendungscode-Artefakt festzulegen.

Um die Konfiguration zu bearbeiten

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Gehen Sie im Abschnitt Speicherort des Anwendungscodes wie folgt vor:
 - Wählen Sie für Amazon S3 S3-Bucket den Bucket aus, den Sie zuvor für den Anwendungscode erstellt haben. Wählen Sie Durchsuchen und wählen Sie den richtigen Bucket aus. Wählen Sie dann Auswählen aus. Klicken Sie nicht auf den Bucket-Namen.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert amazon-msf-java-streamapp-1.0.jar ein.
- Wählen Sie für Zugriffsberechtigungen die Option IAM-Rolle kinesis-analytics-MyApplication-us-east-1 mit den erforderlichen Richtlinien erstellen/aktualisieren aus.

- 4. Fügen Sie im Abschnitt Runtime-Eigenschaften die folgenden Eigenschaften hinzu.
- 5. Wählen Sie Neues Element hinzufügen und fügen Sie jeden der folgenden Parameter hinzu:

Gruppen-ID	Schlüssel	Value (Wert)
InputStream0	stream.name	ExampleInputStream
InputStream0	aws.region	us-east-1
OutputStream0	stream.name	ExampleOutputStream
OutputStream0	aws.region	us-east-1

- 6. Ändern Sie keinen der anderen Abschnitte.
- 7. Wählen Sie Änderungen speichern.

Note

Wenn Sie sich dafür entscheiden, die CloudWatch Amazon-Protokollierung zu aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

Die Anwendung ist jetzt konfiguriert und kann ausgeführt werden.

Ausführen der Anwendung

- 1. Wählen Sie auf der Konsole für Amazon Managed Service für Apache Flink My Application und anschließend Run aus.
- Wählen Sie auf der nächsten Seite, der Konfigurationsseite für die Anwendungswiederherstellung, die Option Mit neuestem Snapshot ausführen und anschließend Ausführen aus.

Der Status in den Anwendungsdetails wechselt von Ready zu Starting und dann zu dem Running Zeitpunkt, an dem die Anwendung gestartet wurde.

Wenn sich die Anwendung im Running Status befindet, können Sie jetzt das Flink-Dashboard öffnen.

So öffnen Sie das -Dashboard

- 1. Wählen Sie Apache Flink-Dashboard öffnen. Das Dashboard wird auf einer neuen Seite geöffnet.
- 2. Wählen Sie in der Liste "Laufende Jobs" den einzelnen Job aus, den Sie sehen können.

1 Note

Wenn Sie die Runtime-Eigenschaften festgelegt oder die IAM-Richtlinien falsch bearbeitet haben, ändert sich der Anwendungsstatus möglicherweise inRunning, aber das Flink-Dashboard zeigt an, dass der Job kontinuierlich neu gestartet wird. Dies ist ein häufiges Fehlerszenario, wenn die Anwendung falsch konfiguriert ist oder keine Zugriffsberechtigungen für die externen Ressourcen hat. In diesem Fall überprüfen Sie im Flink-Dashboard auf der Registerkarte Ausnahmen die Ursache des Problems.

Beobachten Sie die Metriken der laufenden Anwendung

Auf der MyApplicationSeite, im Abschnitt CloudWatch Amazon-Metriken, können Sie einige der grundlegenden Metriken der laufenden Anwendung sehen.

Um die Metriken einzusehen

- 1. Wählen Sie neben der Schaltfläche "Aktualisieren" in der Dropdownliste die Option 10 Sekunden aus.
- 2. Wenn die Anwendung läuft und fehlerfrei ist, können Sie sehen, dass die Uptime-Metrik kontinuierlich zunimmt.
- Die Metrik f
 ür vollst
 ändige Neustarts sollte Null sein. Wenn sie zunimmt, kann es bei der Konfiguration zu Problemen kommen. Um das Problem zu untersuchen,
 überpr
 üfen Sie den Tab Ausnahmen im Flink-Dashboard.

4. Die Metrik "Anzahl fehlgeschlagener Checkpoints" sollte in einer fehlerfreien Anwendung Null sein.

1 Note

Dieses Dashboard zeigt einen festen Satz von Metriken mit einer Granularität von 5 Minuten. Sie können ein benutzerdefiniertes Anwendungs-Dashboard mit beliebigen Metriken im CloudWatch Dashboard erstellen.

Beobachten Sie die Ausgabedaten in Kinesis-Streams

Vergewissern Sie sich, dass Sie weiterhin Daten in der Eingabe veröffentlichen, entweder mit dem Python-Skript oder dem Kinesis Data Generator.

Sie können jetzt die Ausgabe der Anwendung beobachten, die auf Managed Service for Apache Flink ausgeführt wird, indem Sie den Datenviewer in der verwenden <u>https://console.aws.amazon.com/</u> <u>kinesis/</u>, ähnlich wie Sie es bereits zuvor getan haben.

Um die Ausgabe anzusehen

- 1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.
- 3. Wählen Sie Data Streams aus.
- 4. Wählen Sie den Stream aus, den Sie beobachten möchten. Verwenden Sie für dieses Tutorial ExampleOutputStream.
- 5. Wählen Sie die Registerkarte Datenanzeige.
- 6. Wählen Sie einen beliebigen Shard aus, behalten Sie "Letzte" als Startposition bei und wählen Sie dann "Datensätze abrufen". Möglicherweise wird die Fehlermeldung "Für diese Anfrage wurde kein Datensatz gefunden" angezeigt. Wenn ja, wählen Sie "Erneut versuchen, Datensätze abzurufen". Die neuesten Datensätze, die im Stream veröffentlicht wurden, werden angezeigt.
- 7. Wählen Sie den Wert in der Datenspalte aus, um den Inhalt des Datensatzes im JSON-Format zu überprüfen.

Beenden Sie die Anwendung

Um die Anwendung zu beenden, rufen Sie die Konsolenseite der Anwendung Managed Service for Apache Flink mit dem Namen auf. MyApplication

So stoppen Sie die Anwendung

- 1. Wählen Sie in der Dropdownliste Aktion die Option Stopp aus.
- 2. Der Status in den Anwendungsdetails wechselt von Running zu und dann zu dem Ready ZeitpunktStopping, an dem die Anwendung vollständig gestoppt wurde.

1 Note

Vergessen Sie nicht, auch das Senden von Daten aus dem Python-Skript oder dem Kinesis Data Generator an den Eingabestream zu beenden.

Nächster Schritt

Ressourcen bereinigen AWS

Ressourcen bereinigen AWS

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS Ressourcen, die in diesem Tutorial "Erste Schritte" (DataStream API) erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie Ihre Managed Service for Apache Flink-Anwendung
- Löschen Sie Ihre Kinesis-Datenstreams
- Löschen Sie Ihre Amazon S3 S3-Objekte und Ihren Bucket
- Löschen Sie Ihre IAM-Ressourcen
- <u>CloudWatch Löschen Sie Ihre Ressourcen</u>
- Erkunden Sie zusätzliche Ressourcen für Apache Flink

Löschen Sie Ihre Managed Service for Apache Flink-Anwendung

Gehen Sie wie folgt vor, um die Anwendung zu löschen.

- 1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Managed Service for Apache Flink die Option. MyApplication
- 3. Wählen Sie in der Dropdownliste Aktionen die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Sie Ihre Kinesis-Datenstreams

- 1. Öffnen Sie die Managed Service for Apache Flink-Konsole unter /flink. https:// console.aws.amazon.com
- 2. Wählen Sie Datenströme.
- 3. Wählen Sie die beiden Streams aus, die Sie erstellt haben, ExampleInputStream undExampleOutputStream.
- 4. Wählen Sie in der Dropdownliste Aktionen die Option Löschen aus, und bestätigen Sie dann den Löschvorgang.

Löschen Sie Ihre Amazon S3 S3-Objekte und Ihren Bucket

Gehen Sie wie folgt vor, um Ihre Amazon S3-Objekte und Ihren Amazon S3-Bucket zu löschen.

Um das Objekt aus dem S3-Bucket zu löschen

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den S3-Bucket aus, den Sie für das Anwendungsartefakt erstellt haben.
- 3. Wählen Sie das Anwendungsartefakt, das Sie hochgeladen haben, mit dem Namen aus. amazon-msf-java-stream-app-1.0.jar
- 4. Wählen Sie Löschen und bestätigen Sie den Löschvorgang.

So löschen Sie den S3-Bucket:

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den Bucket aus, den Sie für die Artefakte erstellt haben.
- 3. Wählen Sie Löschen und bestätigen Sie den Löschvorgang.

Note

Der S3-Bucket muss leer sein, um ihn zu löschen.

Löschen Sie Ihre IAM-Ressourcen

Um Ihre IAM-Ressourcen zu löschen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-east-1.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics- MyApplication -us-east-1.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Erkunden Sie zusätzliche Ressourcen für Apache Flink

Erkunden Sie zusätzliche Ressourcen

Erkunden Sie zusätzliche Ressourcen

Nachdem Sie nun eine grundlegende Managed Service für Apache Flink-Anwendung erstellt und ausgeführt haben, finden Sie in den folgenden Ressourcen erweiterte Managed Service für Apache Flink-Lösungen.

- <u>Amazon Managed Service for Apache Flink Workshop</u>: In diesem Workshop entwickeln Sie eine end-to-end Streaming-Architektur, um Streaming-Daten nahezu in Echtzeit aufzunehmen, zu analysieren und zu visualisieren. Sie haben sich vorgenommen, den Betrieb eines Taxiunternehmens in New York City zu verbessern. Sie analysieren die Telemetriedaten einer Taxiflotte in New York City nahezu in Echtzeit, um deren Flottenbetrieb zu optimieren.
- <u>Beispiele f
 ür die Erstellung und Arbeit mit Managed Service f
 ür Apache Flink-Anwendungen</u>: Dieser Abschnitt dieses Entwicklerhandbuchs enth
 ält Beispiele f
 ür die Erstellung von und die Arbeit mit Anwendungen in Managed Service f
 ür Apache Flink. Sie enthalten Beispielcode und step-by-step Anweisungen, die Ihnen helfen, Managed Service f
 ür Apache Flink-Anwendungen zu erstellen und Ihre Ergebnisse zu testen.
- <u>Lernen Sie Flink kennen: Praktisches Training</u>: Offizielle Apache Flink-Einführungsschulung, die Ihnen den Einstieg in die Entwicklung skalierbarer Streaming-ETL-, Analyse- und ereignisgesteuerter Anwendungen ermöglicht.

Erste Schritte mit Amazon Managed Service für Apache Flink (Tabellen-API)

In diesem Abschnitt werden Sie mit den grundlegenden Konzepten von Managed Service für Apache Flink und der Implementierung von Anwendungen in Java unter Verwendung der Tabellen-API und SQL vertraut gemacht. Es werden die verfügbaren Optionen für die Erstellung und das Testen von Anwendungen beschrieben. APIs Er enthält auch Anweisungen zur Installation der Tools, die Sie benötigen, um die Tutorials in diesem Handbuch abzuschließen und Ihre erste Anwendung zu erstellen.

Themen

- Sehen Sie sich die Komponenten der Anwendung Managed Service für Apache Flink an
- Sorgen Sie dafür, dass die Voraussetzungen erfüllt sind
- Erstellen Sie einen Managed Service für Apache Flink-Anwendung und führen Sie ihn aus
- <u>Nächster Schritt</u>
- Bereinigen von AWS -Ressourcen
- Erkunden Sie weitere Ressourcen

Sehen Sie sich die Komponenten der Anwendung Managed Service für Apache Flink an

Note

Managed Service für Apache Flink unterstützt alle <u>Apache Flink APIs</u> - und möglicherweise alle JVM-Sprachen. Je nachdem, für welche API Sie sich entscheiden, unterscheiden sich die Struktur der Anwendung und die Implementierung geringfügig. Dieses Tutorial behandelt die Implementierung von Anwendungen mithilfe der Tabellen-API und SQL sowie die Integration mit der in Java implementierten DataStream API.

Zur Verarbeitung von Daten verwendet Ihre Managed Service für Apache Flink-Anwendung eine Java-Anwendung, die mithilfe der Apache Flink-Laufzeit Eingaben verarbeitet und Ausgaben erzeugt.

Eine typische Apache Flink-Anwendung besteht aus folgenden Komponenten:

- Runtime-Eigenschaften: Sie können Runtime-Eigenschaften verwenden, um Konfigurationsparameter an Ihre Anwendung zu übergeben, ohne den Code zu ändern und erneut zu veröffentlichen.
- Quellen: Die Anwendung verwendet Daten aus einer oder mehreren Quellen. Eine Quelle verwendet einen <u>Konnektor</u>, um Daten aus einem externen System zu lesen, z. B. einem Kinesis-Datenstream oder einem Amazon MSK-Thema. Für Entwicklungs- oder Testzwecke können Sie auch Testdaten von Quellen nach dem Zufallsprinzip generieren lassen. Weitere Informationen finden Sie unter <u>Fügen Sie Streaming-Datenquellen zu Managed Service für Apache Flink hinzu</u>. Mit SQL oder der Tabellen-API werden Quellen als Quelltabellen definiert.
- Transformationen: Die Anwendung verarbeitet Daten durch eine oder mehrere Transformationen, mit denen Daten gefiltert, angereichert oder aggregiert werden können. Bei Verwendung von SQL oder Tabellen-API werden Transformationen als Abfragen über Tabellen oder Ansichten definiert.
- Senken: Die Anwendung sendet Daten über Senken an externe Systeme. Eine Senken verwendet einen <u>Konnektor</u>, um Daten an ein externes System zu senden, z. B. einen Kinesis Data Stream, ein Amazon MSK-Thema, einen Amazon S3 S3-Bucket oder eine relationale Datenbank. Sie können auch einen speziellen Anschluss verwenden, um die Ausgabe ausschließlich zu Entwicklungszwecken zu drucken. Wenn Sie SQL oder die Tabellen-API verwenden, werden Senken als Senkentabellen definiert, in die Sie Ergebnisse einfügen. Weitere Informationen finden Sie unter Schreiben Sie Daten mithilfe von Senken in Managed Service für Apache Flink.

Ihre Anwendung erfordert einige externe Abhängigkeiten, z. B. Flink-Konnektoren, die Ihre Anwendung verwendet, oder möglicherweise eine Java-Bibliothek. Um in Amazon Managed Service für Apache Flink ausgeführt zu werden, müssen Sie die Anwendung zusammen mit den Abhängigkeiten in ein FAT-JAR packen und in einen Amazon S3 S3-Bucket hochladen. Anschließend erstellen Sie eine Managed Service für Apache Flink-Anwendung. Sie übergeben den Speicherort des Codepakets zusammen mit anderen Laufzeitkonfigurationsparametern. Dieses Tutorial zeigt, wie Sie Apache Maven zum Verpacken der Anwendung verwenden und wie Sie die Anwendung lokal in der IDE Ihrer Wahl ausführen.

Sorgen Sie dafür, dass die Voraussetzungen erfüllt sind

Bevor Sie dieses Tutorial starten, führen Sie die ersten zwei Schritte von Erste Schritte mit Amazon Managed Service für Apache Flink (DataStream API) aus.

- Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen
- Richten Sie das AWS Command Line Interface ()AWS CLI ein

Um zu beginnen, sehen Sie sich Erstellen einer Anwendung an.

Erstellen Sie einen Managed Service für Apache Flink-Anwendung und führen Sie ihn aus

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink mit Kinesis Datenströmen als Quelle und Senke.

Dieser Abschnitt enthält die folgenden Schritte.

- Erstellen Sie abhängige Ressourcen
- Einrichten der lokalen Entwicklungsumgebung
- Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn
- Führen Sie Ihre Anwendung lokal aus
- Beobachten Sie, wie die Anwendung Daten in einen S3-Bucket schreibt
- Stoppen Sie die lokale Ausführung Ihrer Anwendung
- Kompilieren und verpacken Sie Ihren Anwendungscode
- Laden Sie die Anwendungscode-JAR-Datei hoch
- Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung einen Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

• Ein Amazon-S3-Bucket zum Speichern des Codes der Anwendung und zum Schreiben der Anwendungsausgabe.

Note

In diesem Tutorial wird davon ausgegangen, dass Sie Ihre Anwendung in der Region "useast-1" bereitstellen. Wenn Sie eine andere Region verwenden, müssen Sie alle Schritte entsprechend anpassen.

Erstellen eines Amazon-S3-Buckets

Sie können ein Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressource finden Sie in den folgenden Themen:

 <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service-Benutzerhandbuch. Geben Sie dem Amazon S3 S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen.

Note

Stellen Sie sicher, dass Sie den Bucket in der Region erstellen, die Sie für dieses Tutorial verwenden. Die Standardregion für das Tutorial ist us-east-1.

Sonstige Ressourcen

Wenn Sie Ihre Anwendung erstellen, erstellt Managed Service für Apache Flink die folgenden CloudWatch Amazon-Ressourcen, falls sie noch nicht vorhanden sind:

- Eine Protokollgruppe namens /AWS/KinesisAnalytics-java/<my-application>.
- Einen Protokollstream mit dem Namen kinesis-analytics-log-stream.

Einrichten der lokalen Entwicklungsumgebung

Für die Entwicklung und das Debuggen können Sie die Apache Flink-Anwendung auf Ihrem Computer direkt von der IDE Ihrer Wahl aus ausführen. Alle Apache Flink-Abhängigkeiten werden mit Maven als normale Java-Abhängigkeiten behandelt.

Note

Auf Ihrem Entwicklungscomputer müssen Sie Java JDK 11, Maven und Git installiert haben. Wir empfehlen Ihnen, eine Entwicklungsumgebung wie <u>Eclipse, Java Neon</u> oder <u>IntelliJ</u> IDEA zu verwenden. Um zu überprüfen, ob Sie alle Voraussetzungen erfüllen, finden Sie unter. <u>Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen</u> Sie müssen keinen Apache Flink-Cluster auf Ihrem Computer installieren.

Authentifizieren Sie Ihre Sitzung AWS

Die Anwendung verwendet Kinesis-Datenströme, um Daten zu veröffentlichen. Bei der lokalen Ausführung benötigen Sie eine gültige AWS authentifizierte Sitzung mit Schreibberechtigungen in den Kinesis-Datenstrom. Führen Sie die folgenden Schritte aus, um Ihre Sitzung zu authentifizieren:

- Wenn Sie das AWS CLI und ein benanntes Profil mit g
 ültigen Anmeldeinformationen nicht konfiguriert haben, finden Sie weitere Informationen unter. <u>Richten Sie das AWS Command Line</u> <u>Interface ()AWS CLI ein</u>
- Wenn Ihre IDE über ein Plug-in zur Integration verfügt AWS, können Sie dieses verwenden, um die Anmeldeinformationen an die Anwendung zu übergeben, die in der IDE ausgeführt wird. Weitere Informationen finden Sie unter <u>AWS Toolkit für IntelliJ IDEA</u> und <u>AWS Toolkit zum</u> Kompilieren der Anwendung oder zum Ausführen von Eclipse.

Laden Sie den Apache Flink-Streaming-Java-Code herunter und untersuchen Sie ihn

Der Anwendungscode für dieses Beispiel ist verfügbar unter GitHub.

So laden Sie den Java-Anwendungscode herunter

1. Klonen Sie das Remote-Repository, indem Sie den folgenden Befehl verwenden:

```
git clone https://github.com/aws-samples/amazon-managed-service-for-apache-flink-
examples.git
```

2. Navigieren Sie zum ./java/GettingStartedTable Verzeichnis.

Überprüfen Sie die Anwendungskomponenten

Die Anwendung ist vollständig in der com.amazonaws.services.msf.BasicTableJob Klasse implementiert. Die main() Methode definiert Quellen, Transformationen und Senken. Die Ausführung wird durch eine Ausführungsanweisung am Ende dieser Methode eingeleitet.
Note

Für ein optimales Entwicklererlebnis ist die Anwendung so konzipiert, dass sie ohne Codeänderungen sowohl auf Amazon Managed Service für Apache Flink als auch lokal für die Entwicklung in Ihrer IDE ausgeführt werden kann.

- Um die Laufzeitkonfiguration so zu lesen, dass sie funktioniert, wenn sie in Amazon Managed Service for Apache Flink und in Ihrer IDE ausgeführt wird, erkennt die Anwendung automatisch, ob sie lokal in der IDE eigenständig ausgeführt wird. In diesem Fall lädt die Anwendung die Laufzeitkonfiguration anders:
 - Wenn die Anwendung feststellt, dass sie in Ihrer IDE im Standalone-Modus ausgeführt wird, erstellen Sie die application_properties.json Datei, die im Ressourcenordner des Projekts enthalten ist. Der Inhalt der Datei folgt.

```
private static Map<String, Properties>
loadApplicationProperties(StreamExecutionEnvironment env) throws IOException {
    if (env instanceof LocalStreamEnvironment) {
        LOGGER.info("Loading application properties from '{}'",
LOCAL_APPLICATION_PROPERTIES_RESOURCE);
        return KinesisAnalyticsRuntime.getApplicationProperties(
            BasicStreamingJob.class.getClassLoader()

.getResource(LOCAL_APPLICATION_PROPERTIES_RESOURCE).getPath());
    } else {
        LOGGER.info("Loading application properties from Amazon Managed Service for
Apache Flink");
        return KinesisAnalyticsRuntime.getApplicationProperties();
    }
}
```

- Die main() Methode definiert den Anwendungsdatenfluss und führt ihn aus.
 - Initialisiert die Standard-Streaming-Umgebungen. In diesem Beispiel zeigen wir, wie sowohl die StreamExecutionEnvironment zur Verwendung mit der DataStream API als auch die

StreamTableEnvironment zur Verwendung mit SQL und der Tabellen-API erstellt werden. Die beiden Umgebungsobjekte sind zwei separate Verweise auf dieselbe Laufzeitumgebung, die unterschiedlich verwendet werden soll APIs.

```
StreamExecutionEnvironment env =
   StreamExecutionEnvironment.getExecutionEnvironment();
StreamTableEnvironment tableEnv = StreamTableEnvironment.create(env,
   EnvironmentSettings.newInstance().build());
```

• Laden Sie die Konfigurationsparameter der Anwendung. Dadurch werden sie automatisch von der richtigen Stelle geladen, je nachdem, wo die Anwendung ausgeführt wird:

Map<String, Properties> applicationParameters = loadApplicationProperties(env);

 Der <u>FileSystem Sink-Connector</u>, den die Anwendung verwendet, um Ergebnisse in Amazon S3 S3-Ausgabedateien zu schreiben, wenn Flink einen <u>Checkpoint</u> abschließt. Sie müssen Checkpoints aktivieren, um Dateien in das Ziel zu schreiben. Wenn die Anwendung in Amazon Managed Service für Apache Flink ausgeführt wird, steuert die Anwendungskonfiguration den Checkpoint und aktiviert ihn standardmäßig. Umgekehrt sind Checkpoints standardmäßig deaktiviert, wenn sie lokal ausgeführt werden. Die Anwendung erkennt, dass sie lokal ausgeführt wird, und konfiguriert Checkpoints alle 5.000 ms.

```
if (env instanceof LocalStreamEnvironment) {
    env.enableCheckpointing(5000);
}
```

 Diese Anwendung empfängt keine Daten von einer tatsächlichen externen Quelle. Sie generiert zufällige Daten, die über den <u>DataGen Konnektor</u> verarbeitet werden. Dieser Konnektor ist für DataStream API, SQL und Tabellen-API verfügbar. Um die Integration zwischen beiden zu demonstrieren APIs, verwendet die Anwendung die DataStram API-Version, da sie mehr Flexibilität bietet. Jeder Datensatz wird durch eine Generatorfunktion generiert, die StockPriceGeneratorFunction in diesem Fall aufgerufen wird und in der Sie benutzerdefinierte Logik einfügen können.

```
DataGeneratorSource<StockPrice> source = new DataGeneratorSource<>(
    new StockPriceGeneratorFunction(),
    Long.MAX_VALUE,
    RateLimiterStrategy.perSecond(recordPerSecond),
    TypeInformation.of(StockPrice.class));
```

- In der DataStream API können Datensätze benutzerdefinierte Klassen haben. Klassen müssen bestimmten Regeln folgen, damit Flink sie als Datensatz verwenden kann. Weitere Informationen finden Sie unter <u>Unterstützte Datentypen</u>. In diesem Beispiel ist die StockPrice Klasse ein <u>POJO</u>.
- Die Quelle wird dann an die Ausführungsumgebung angehängt, wodurch ein DataStream of StockPrice generiert wird. Diese Anwendung verwendet keine <u>Semantik zur Ereigniszeit</u> und generiert kein Wasserzeichen. Führen Sie die DataGenerator Quelle unabhängig von der Parallelität der restlichen Anwendung mit einer Parallelität von 1 aus.

 Was im Datenverarbeitungsablauf folgt, wird mithilfe der Tabellen-API und SQL definiert. Dazu konvertieren wir den Wert DataStream von StockPrices in eine Tabelle. Das Schema der Tabelle wird automatisch aus der StockPrice Klasse abgeleitet.

Table stockPricesTable = tableEnv.fromDataStream(stockPrices);

 Der folgende Codeausschnitt zeigt, wie eine Ansicht und eine Abfrage mithilfe der programmatischen Tabellen-API definiert werden:

tableEnv.createTemporaryView("filtered_stock_prices", filteredStockPricesTable);

 Eine Senkentabelle ist so definiert, dass die Ergebnisse als JSON-Dateien in einen Amazon-S3-Bucket geschrieben werden. Um den Unterschied bei der programmgesteuerten Definition einer Ansicht zu verdeutlichen, wird die Sink-Tabelle mit der Tabellen-API mithilfe von SQL definiert.

```
tableEnv.executeSql("CREATE TABLE s3_sink (" +
```

```
"eventTime TIMESTAMP(3)," +
  "ticker STRING," +
  "price DOUBLE," +
  "dt STRING," +
  "hr STRING" +
") PARTITIONED BY ( dt, hr ) WITH (" +
 "'connector' = 'filesystem'," +
 "'fmat' = 'json'," +
 "'path' = 's3a://" + s3Path + "'" +
")");
```

 Der letzte Schritt von besteht darinexecuteInsert(), die gefilterte Aktienkursansicht in die Sink-Tabelle einzufügen. Diese Methode initiiert die Ausführung des Datenflusses, den wir bisher definiert haben.

```
filteredStockPricesTable.executeInsert("s3_sink");
```

Verwenden Sie die Datei pom.xml

Die Datei pom.xml definiert alle Abhängigkeiten, die von der Anwendung benötigt werden, und richtet das Maven Shade-Plugin ein, um das Fat-Jar zu erstellen, das alle von Flink benötigten Abhängigkeiten enthält.

 Einige Abhängigkeiten haben einen Gültigkeitsbereich. provided Diese Abhängigkeiten sind automatisch verfügbar, wenn die Anwendung in Amazon Managed Service für Apache Flink ausgeführt wird. Sie sind für die Anwendung oder für die Anwendung lokal in Ihrer IDE erforderlich. Weitere Informationen finden Sie unter (Update auf TableAPI)<u>Führen Sie Ihre Anwendung lokal</u> <u>aus</u>. Stellen Sie sicher, dass Sie dieselbe Flink-Version wie die Runtime verwenden, die Sie in Amazon Managed Service für Apache Flink verwenden werden. Um die TableAPI und SQL zu verwenden, müssen Sie das flink-table-planner-loader und angebenflink-tableruntime-dependencies, beide mit Gültigkeitsbereich. provided

```
<dependency>
<groupId>org.apache.flink</groupId>
<artifactId>flink-streaming-java</artifactId>
<version>${flink.version}</version>
<scope>provided</scope>
</dependency>
<dependency>
<groupId>org.apache.flink</groupId>
```

<artifactid>flink-clients</artifactid>		
<version>\${flink.version}</version>		
<scope>provided</scope>		
<dependency></dependency>		
<groupid>org.apache.flink</groupid>		
<artifactid>flink-table-planner-loader</artifactid>		
<version>\${flink.version}</version>		
<scope>provided</scope>		
<dependency></dependency>		
<groupid>org.apache.flink</groupid>		
<artifactid>flink-table-runtime</artifactid>		
<version>\${flink.version}</version>		
<scope>provided</scope>		

 Sie müssen dem POM mit dem Standardbereich zusätzliche Apache Flink-Abhängigkeiten hinzufügen. Zum Beispiel der <u>DataGen Konnektor</u>, der <u>FileSystem SQL-Konnektor</u> und das <u>JSON-</u> <u>Format</u>.

```
<dependency>
<groupId>org.apache.flink</groupId>
<artifactId>flink-connector-datagen</artifactId>
<version>${flink.version}</version>
</dependency>
<groupId>org.apache.flink</groupId>
<artifactId>flink-connector-files</artifactId>
<version>${flink.version}</version>
</dependency>
<dependency>
<groupId>org.apache.flink</groupId>
<artifactId>flink-json</artifactId>
<version>${flink.version}
```

• Um in Amazon S3 zu schreiben, wenn es lokal ausgeführt wird, ist das S3 Hadoop File System ebenfalls in provided Scope enthalten.

<dependency>
 <groupId>org.apache.flink</groupId>
 <artifactId>flink-s3-fs-hadoop</artifactId>
 <version>\${flink.version}</version>
 <scope>provided</scope>
</dependency>

- Das Maven Java Compiler-Plugin stellt sicher, dass der Code mit Java 11 kompiliert wird, der JDK-Version, die derzeit von Apache Flink unterstützt wird.
- Das Maven Shade-Plugin packt das Fat-Jar, mit Ausnahme einiger Bibliotheken, die von der Runtime bereitgestellt werden. Es spezifiziert auch zwei Transformatoren: und. ServicesResourceTransformer ManifestResourceTransformer Letzteres konfiguriert die Klasse, die die main Methode zum Starten der Anwendung enthält. Wenn Sie die Hauptklasse umbenennen, vergessen Sie nicht, diesen Transformator zu aktualisieren.

Führen Sie Ihre Anwendung lokal aus

Sie können Ihre Flink-Anwendung lokal in Ihrer IDE ausführen und debuggen.

Note

Vergewissern Sie sich, bevor Sie fortfahren, dass die Eingabe- und Ausgabestreams verfügbar sind. Siehe <u>Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams</u>. Stellen Sie außerdem sicher, dass Sie über Lese- und Schreibberechtigungen für beide Streams verfügen. Siehe <u>Authentifizieren Sie Ihre Sitzung AWS</u>.

Für die Einrichtung der lokalen Entwicklungsumgebung sind Java 11 JDK, Apache Maven und eine IDE für die Java-Entwicklung erforderlich. Stellen Sie sicher, dass Sie die

erforderlichen Voraussetzungen erfüllen. Siehe Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen.

Importieren Sie das Java-Projekt in Ihre IDE

Um mit der Arbeit an der Anwendung in Ihrer IDE zu beginnen, müssen Sie sie als Java-Projekt importieren.

Das von Ihnen geklonte Repository enthält mehrere Beispiele. Jedes Beispiel ist ein separates Projekt. Importieren Sie für dieses Tutorial den Inhalt im ./jave/GettingStartedTable Unterverzeichnis in Ihre IDE.

Fügen Sie den Code mithilfe von Maven als vorhandenes Java-Projekt ein.

Note

Der genaue Vorgang zum Importieren eines neuen Java-Projekts hängt von der verwendeten IDE ab.

Ändern Sie die lokale Anwendungskonfiguration

Bei der lokalen Ausführung verwendet die Anwendung die Konfiguration in der application_properties.json Datei im Ressourcenordner des Projekts unter./src/main/ resources. Für diese Tutorial-Anwendung sind die Konfigurationsparameter der Name des Buckets und der Pfad, in den die Daten geschrieben werden.

Bearbeiten Sie die Konfiguration und den Namen des Amazon S3 S3-Buckets so, dass er mit dem Bucket übereinstimmt, den Sie zu Beginn dieses Tutorials erstellt haben.

]

Note

Die Konfigurationseigenschaft name darf beispielsweise nur den Bucket-Namen enthaltenmybucket-name. Geben Sie kein Präfix wie s3:// oder einen abschließenden Schrägstrich ein.

Wenn Sie den Pfad ändern, lassen Sie alle führenden oder nachfolgenden Schrägstriche weg.

Einrichten der IDE-Run-Konfiguration

Sie können die Flink-Anwendung direkt von Ihrer IDE aus ausführen und debuggen, indem Sie die Hauptklasse ausführencom.amazonaws.services.msf.BasicTableJob, wie Sie jede Java-Anwendung ausführen würden. Bevor Sie die Anwendung ausführen, müssen Sie die Run-Konfiguration einrichten. Die Einrichtung hängt von der IDE ab, die Sie verwenden. Weitere Informationen finden Sie beispielsweise unter Konfigurationen ausführen/debuggen in der IntelliJ IDEA-Dokumentation. Sie müssen insbesondere die folgenden Einstellungen vornehmen:

- Fügen Sie die provided Abhängigkeiten zum Klassenpfad hinzu. Dies ist erforderlich, um sicherzustellen, dass die Abhängigkeiten mit provided Gültigkeitsbereich an die Anwendung übergeben werden, wenn sie lokal ausgeführt wird. Ohne diese Einrichtung zeigt die Anwendung sofort einen class not found Fehler an.
- 2. Übergeben Sie die AWS Anmeldeinformationen f
 ür den Zugriff auf die Kinesis-Streams an die Anwendung. Am schnellsten ist es, das <u>AWS Toolkit f
 ür IntelliJ</u> IDEA zu verwenden. Mit diesem IDE-Plugin in der Run-Konfiguration k
 önnen Sie ein bestimmtes Profil ausw
 ählen. AWS AWS Die Authentifizierung erfolgt mit diesem Profil. Sie m
 üssen die AWS Anmeldeinformationen nicht direkt weitergeben.
- 3. Stellen Sie sicher, dass die IDE die Anwendung mit JDK 11 ausführt.

Führen Sie die Anwendung in Ihrer IDE aus

Nachdem Sie die Run-Konfiguration für eingerichtet habenBasicTableJob, können Sie sie wie eine normale Java-Anwendung ausführen oder debuggen.

Note

Sie können das von Maven generierte Fat-Jar nicht direkt über die java -jar ... Befehlszeile ausführen. Dieses JAR enthält nicht die Kernabhängigkeiten von Flink, die für die eigenständige Ausführung der Anwendung erforderlich sind.

Wenn die Anwendung erfolgreich gestartet wird, protokolliert sie einige Informationen über den eigenständigen Minicluster und die Initialisierung der Konnektoren. Darauf folgen eine Reihe von INFO- und einige WARN-Logs, die Flink normalerweise beim Start der Anwendung ausgibt.

```
21:28:34,982 INF0 com.amazonaws.services.msf.BasicTableJob
        [] - Loading application properties from 'flink-application-properties-
dev.json'
21:28:35,149 INF0 com.amazonaws.services.msf.BasicTableJob
[] - s3Path is ExampleBucket/my-output-bucket
...
```

Nach Abschluss der Initialisierung gibt die Anwendung keine weiteren Protokolleinträge aus. Während des Datenflusses wird kein Protokoll ausgegeben.

Um zu überprüfen, ob die Anwendung Daten korrekt verarbeitet, können Sie den Inhalt des Ausgabe-Buckets überprüfen, wie im folgenden Abschnitt beschrieben.

Note

Es ist das normale Verhalten einer Flink-Anwendung, keine Protokolle über fließende Daten auszugeben. Das Ausgeben von Protokollen für jeden Datensatz mag für das Debuggen praktisch sein, kann aber bei der Ausführung in der Produktion zu erheblichem Mehraufwand führen.

Beobachten Sie, wie die Anwendung Daten in einen S3-Bucket schreibt

Diese Beispielanwendung generiert intern zufällige Daten und schreibt diese Daten in den von Ihnen konfigurierten Ziel-S3-Bucket. Sofern Sie den Standardkonfigurationspfad nicht geändert haben, werden die Daten im folgenden Format ./output/<yyyy-MM-dd>/<HH> in den output Pfad geschrieben, gefolgt von der Daten- und Stundenpartitionierung.

Der <u>FileSystem Sink-Connector</u> erstellt neue Dateien auf dem Flink-Checkpoint. Bei der lokalen Ausführung führt die Anwendung alle 5 Sekunden (5.000 Millisekunden) einen Checkpoint aus, wie im Code angegeben.

```
if (env instanceof LocalStreamEnvironment) {
    env.enableCheckpointing(5000);
}
```

Um den S3-Bucket zu durchsuchen und die von der Anwendung geschriebene Datei zu beobachten

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den Bucket aus, den Sie zuvor erstellt haben.
- 3. Navigieren Sie zum output Pfad und dann zu den Datums- und Stundenordnern, die der aktuellen Uhrzeit in der UTC-Zeitzone entsprechen.
- 4. Aktualisieren Sie regelmäßig, um zu beobachten, dass alle 5 Sekunden neue Dateien angezeigt werden.
- 5. Wählen Sie eine Datei aus und laden Sie sie herunter, um den Inhalt zu beobachten.

Note

Standardmäßig haben die Dateien keine Erweiterungen. Der Inhalt ist als JSON formatiert. Sie können die Dateien mit einem beliebigen Texteditor öffnen, um den Inhalt zu überprüfen.

Stoppen Sie die lokale Ausführung Ihrer Anwendung

Stoppen Sie die Anwendung, die in Ihrer IDE ausgeführt wird. Die IDE bietet normalerweise eine "Stopp" -Option. Der genaue Standort und die Methode hängen von der IDE ab.

Kompilieren und verpacken Sie Ihren Anwendungscode

In diesem Abschnitt verwenden Sie Apache Maven, um den Java-Code zu kompilieren und in eine JAR-Datei zu packen. Sie können Ihren Code mit dem Maven-Befehlszeilentool oder Ihrer IDE kompilieren und verpacken.

Um mit der Maven-Befehlszeile zu kompilieren und zu paketieren

Gehen Sie in das Verzeichnis, das das GettingStarted Jave-Projekt enthält, und führen Sie den folgenden Befehl aus:

\$ mvn package

Um mit Ihrer IDE zu kompilieren und zu paketieren

Führen Sie es mvn package von Ihrer IDE-Maven-Integration aus aus.

In beiden Fällen target/amazon-msf-java-table-app-1.0.jar wird die JAR-Datei erstellt.

1 Note

Wenn Sie ein Build-Projekt von Ihrer IDE aus ausführen, wird die JAR-Datei möglicherweise nicht erstellt.

Laden Sie die Anwendungscode-JAR-Datei hoch

In diesem Abschnitt laden Sie die im vorherigen Abschnitt erstellte JAR-Datei in den Amazon S3 S3-Bucket hoch, den Sie zu Beginn dieses Tutorials erstellt haben. Wenn Sie es schon getan haben, schließen Sie es abErstellen eines Amazon-S3-Buckets.

So laden Sie den Anwendungscode hoch

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den Bucket aus, den Sie zuvor für den Anwendungscode erstellt haben.
- 3. Wählen Sie Feld hochladen.
- 4. Klicken Sie auf Add files.
- 5. Navigieren Sie zu der im vorherigen Abschnitt generierten JAR-Datei:target/amazon-msfjava-table-app-1.0.jar.
- 6. Wählen Sie Hochladen, ohne andere Einstellungen zu ändern.

🛕 Warning

Stellen Sie sicher, dass Sie die richtige JAR-Datei in auswählen<repo-dir>/java/ GettingStarted/target/**amazon/msf-java-table-app-1.0.jar**. Das Zielverzeichnis enthält auch andere JAR-Dateien, die Sie nicht hochladen müssen.

Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder erstellen und konfigurieren. AWS CLI Für dieses Tutorial wird die Konsole verwendet.

Note

Wenn Sie die Anwendung mithilfe der Konsole erstellen, werden die Ressourcen AWS Identity and Access Management (IAM) und Amazon CloudWatch Logs für Sie erstellt. Wenn Sie die Anwendung mithilfe von erstellen AWS CLI, müssen Sie diese Ressourcen separat erstellen.

Erstellen der Anwendung

- 1. Öffnen Sie die Konsole Managed Service für Apache Flink unter https:// console.aws.amazon.com /flink
- 2. Vergewissern Sie sich, dass die richtige Region ausgewählt ist: USA Ost (Nord-Virginia) useast-1.
- 3. Wählen Sie im rechten Menü Apache Flink-Anwendungen und dann Streaming-Anwendung erstellen. Wählen Sie alternativ im Bereich Erste Schritte auf der Startseite die Option Streaming-Anwendung erstellen aus.
- 4. Gehen Sie auf der Seite Streaming-Anwendung erstellen wie folgt vor:
 - Wählen Sie für Wählen Sie eine Methode zum Einrichten der Streamverarbeitungsanwendung die Option Von Grund auf neu erstellen aus.
 - Wählen Sie für die Apache Flink-Konfiguration und die Version von Application Flink die Option Apache Flink 1.19.
 - Gehen Sie im Abschnitt Anwendungskonfiguration wie folgt vor:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My Java Table API test app ein.
 - Wählen Sie für Zugriff auf Anwendungsressourcen die Option Create/update IAM role kinesis-analytics-MyApplication-us -east-1 with required policies aus.
 - Gehen Sie unter Vorlage für Anwendungseinstellungen wie folgt vor:

- Wählen Sie für Vorlagen die Option Entwicklung aus.
- 5. Wählen Sie Streaming-Anwendung erstellen aus.

1 Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-east-1
- Rolle: kinesisanalytics-MyApplication-us-east-1

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Amazon S3-Bucket.

Um die IAM-Richtlinie zu bearbeiten, um S3-Bucket-Berechtigungen hinzuzufügen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-east-1-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie Bearbeiten und dann die Registerkarte JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie die Beispielkonto-ID (012345678901) durch Ihre Konto-ID und <bucket-name> den Namen des S3-Buckets, den Sie erstellt haben.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
```

```
"Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3::::my-bucket/kinesis-analytics-placeholder-s3-object"
            ]
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "ListCloudwatchLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            1
        },
        {
            "Sid": "PutCloudwatchLogs",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            ]
        },
        {
            "Sid": "WriteOutputBucket",
            "Effect": "Allow",
            "Action": "s3:*",
```

```
Resource": [
"arn:aws:s3:::my-bucket"
]
}
]
}
```

5. Wählen Sie Weiter und dann Änderungen speichern aus.

Konfigurieren der Anwendung

Bearbeiten Sie die Anwendung, um das Anwendungscode-Artefakt festzulegen.

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Wählen Sie im Abschnitt Speicherort des Anwendungscodes die Option Konfigurieren aus.
 - Wählen Sie für Amazon S3 S3-Bucket den Bucket aus, den Sie zuvor für den Anwendungscode erstellt haben. Wählen Sie Durchsuchen und wählen Sie den richtigen Bucket aus. Wählen Sie dann Wählen aus. Klicken Sie nicht auf den Bucket-Namen.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert amazon-msf-java-tableapp-1.0.jar ein.
- 3. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-east-1 aus.
- 4. Fügen Sie im Abschnitt Runtime-Eigenschaften die folgenden Eigenschaften hinzu.
- 5. Wählen Sie Neues Element hinzufügen und fügen Sie jeden der folgenden Parameter hinzu:

Gruppen-ID	Schlüssel	Value (Wert)
bucket	name	your-bucket-name
bucket	path	output

- 6. Ändern Sie keine weiteren Einstellungen.
- 7. Wählen Sie Änderungen speichern aus.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

Die Anwendung ist nun konfiguriert und einsatzbereit.

Ausführen der Anwendung

- 1. Kehren Sie zur Konsolenseite in Amazon Managed Service für Apache Flink zurück und wählen Sie MyApplication.
- 2. Wählen Sie Ausführen, um die Anwendung zu starten.
- 3. Wählen Sie in der Konfiguration zur Anwendungswiederherstellung die Option Mit neuestem Snapshot ausführen aus.
- 4. Wählen Sie Ausführen aus.
- 5. Der Status in den Anwendungsdetails wechselt von Ready zu Starting und dann zu "RunningNach dem Start der Anwendung".

Wenn sich die Anwendung im Running Status befindet, können Sie das Flink-Dashboard öffnen.

Um das Dashboard zu öffnen und den Job anzusehen

- 1. Wählen Sie Apache Flink-Dashboard öffnen. Das Dashboard wird auf einer neuen Seite geöffnet.
- 2. Wählen Sie in der Liste "Laufende Jobs" den einzelnen Job aus, den Sie sehen können.

Note

Wenn Sie die Laufzeiteigenschaften festgelegt oder die IAM-Richtlinien falsch bearbeitet haben, ändert sich der Anwendungsstatus möglicherweise auf, aber das Flink-Dashboard zeigt anRunning, dass der Job kontinuierlich neu gestartet wird. Dies ist ein häufiges Fehlerszenario, wenn die Anwendung falsch konfiguriert ist oder nicht über die erforderlichen Berechtigungen für den Zugriff auf die externen Ressourcen verfügt. Überprüfen Sie in diesem Fall die Registerkarte Ausnahmen im Flink-Dashboard, um die Ursache des Problems zu untersuchen.

Beobachten Sie die Metriken der laufenden Anwendung

Auf der MyApplicationSeite, im Abschnitt CloudWatch Amazon-Metriken, können Sie einige der grundlegenden Metriken der laufenden Anwendung sehen.

So zeigen Sie die Metriken an

- 1. Wählen Sie neben der Schaltfläche "Aktualisieren" in der Dropdownliste die Option 10 Sekunden aus.
- 2. Wenn die Anwendung läuft und fehlerfrei ist, können Sie sehen, dass die Uptime-Metrik kontinuierlich zunimmt.
- Die Metrik f
 ür vollst
 ändige Neustarts sollte Null sein. Wenn sie zunimmt, kann es bei der Konfiguration zu Problemen kommen.
 Überpr
 üfen Sie die Registerkarte Ausnahmen im Flink-Dashboard, um das Problem zu untersuchen.
- 4. Die Metrik "Anzahl fehlgeschlagener Checkpoints" sollte in einer fehlerfreien Anwendung Null sein.

1 Note

Dieses Dashboard zeigt einen festen Satz von Metriken mit einer Granularität von 5 Minuten. Sie können ein benutzerdefiniertes Anwendungs-Dashboard mit beliebigen Metriken im CloudWatch Dashboard erstellen.

Beobachten Sie, wie die Anwendung Daten in den ZielBucket schreibt

Sie können nun beobachten, wie die Anwendung in Amazon Managed Service für Apache Flink Dateien in Amazon S3 schreibt.

Um die Dateien zu beobachten, gehen Sie genauso vor, wie Sie die Dateien überprüft haben, die geschrieben wurden, als die Anwendung lokal ausgeführt wurde. Siehe <u>Beobachten Sie, wie die</u> Anwendung Daten in einen S3-Bucket schreibt.

Denken Sie daran, dass die Anwendung neue Dateien auf den Flink-Checkpoint schreibt. Bei der Ausführung auf Amazon Managed Service für Apache Flink sind Checkpoints standardmäßig aktiviert und werden alle 60 Sekunden ausgeführt. Die Anwendung erstellt ungefähr alle 1 Minute neue Dateien.

Stoppen Sie die Anwendung

Um die Anwendung zu beenden, rufen Sie die Konsolenseite der Anwendung Managed Service for Apache Flink mit dem Namen auf. MyApplication

So stoppen Sie die Anwendung

- 1. Wählen Sie in der Dropdownliste Aktion die Option Stopp aus.
- 2. Der Status in den Anwendungsdetails wechselt von Running zu und dann zu dem Ready ZeitpunktStopping, an dem die Anwendung vollständig gestoppt wurde.

Note

Vergessen Sie nicht, auch das Senden von Daten aus dem Python-Skript oder dem Kinesis Data Generator an den Eingabestream zu beenden.

Nächster Schritt

Bereinigen von AWS -Ressourcen

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Erste Schritte (Tabellen-API) erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte.

- Löschen Sie die Anwendung Managed Service für Apache Flink
- Löschen Sie Ihre Amazon-S3-Objekte und Buckets
- Löschen Ihrer IAM-Ressourcen
- <u>CloudWatch Löschen Sie Ihre Ressourcen</u>
- <u>Nächster Schritt</u>

Löschen Sie die Anwendung Managed Service für Apache Flink

Gehen Sie wie folgt vor, um die Anwendung zu löschen.

So löschen Sie die Anwendung:

- 1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplication.
- Wählen Sie in der Dropdownliste Aktionen die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Sie Ihre Amazon-S3-Objekte und Buckets

Gehen Sie wie folgt vor, um die S3-Objekte und den Bucket zu löschen.

Um das Anwendungsobjekt aus dem S3-Bucket zu löschen

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den S3-Bucket aus, den Sie erstellt haben.
- 3. Wählen Sie das hochgeladene Anwendungsartefakt mit dem Namen ausamazon-msf-javatable-app-1.0.jar, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Um alle von der Anwendung geschriebenen Ausgabedateien zu löschen

- 1. Wählen Sie den Ordner output aus.
- 2. Wählen Sie Löschen aus.
- 3. Bestätigen Sie, dass Sie den Inhalt dauerhaft löschen möchten.

So löschen Sie den S3-Bucket:

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den S3-Bucket aus, den Sie erstellt haben.
- 3. Wählen Sie Delete (Löschen) und bestätigen Sie das Löschen.

Löschen Ihrer IAM-Ressourcen

Führen Sie die folgenden Schritte aus, um Ihre IAM-Ressourcen zu löschen.

Um Ihre IAM-Ressourcen zu löschen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-east-1.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics- MyApplication -us-east-1.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

Führen Sie die folgenden Schritte aus, um Ihre CloudWatch Ressourcen zu löschen.

Um Ihre CloudWatch Ressourcen zu löschen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Nächster Schritt

Erkunden Sie weitere Ressourcen

Erkunden Sie weitere Ressourcen

Nachdem Sie nun eine Managed Service für Apache Flink-Anwendung erstellt und ausgeführt haben, die die Tabellen-API verwendet, finden Sie <u>Erkunden Sie zusätzliche Ressourcen</u> in <u>Erste Schritte mit</u> Amazon Managed Service für Apache Flink (DataStream API).

Erste Schritte mit Amazon Managed Service für Apache Flink für Python

In diesem Abschnitt werden Sie mit den grundlegenden Konzepten eines Managed Service für Apache Flink unter Verwendung von Python und der Tabellen-API vertraut gemacht. Es werden die verfügbaren Optionen für die Erstellung und das Testen von Anwendungen beschrieben. Er enthält auch Anweisungen zur Installation der Tools, die Sie benötigen, um die Tutorials in diesem Handbuch abzuschließen und Ihre erste Anwendung zu erstellen.

Themen

- Sehen Sie sich die Komponenten der Anwendung Managed Service für Apache Flink an
- Erfüllen Sie die Voraussetzungen
- Erstellen und Ausführen einer Anwendung von Managed Service für Apache Flink für Python-Anwendung
- Bereinigen von AWS Ressourcen

Sehen Sie sich die Komponenten der Anwendung Managed Service für Apache Flink an

1 Note

Amazon Managed Service für Apache Flink unterstützt alle <u>Apache APIs Flink</u>. Je nachdem, welche API Sie wählen, unterscheidet sich die Struktur der Anwendung geringfügig. Ein beliebter Ansatz bei der Entwicklung einer Apache Flink-Anwendung in Python besteht darin, den Anwendungsablauf mithilfe von in Python-Code eingebettetem SQL zu definieren. Diesem Ansatz folgen wir im folgenden Tutorial "Erste Schritte".

Zur Verarbeitung von Daten verwendet Ihre Managed Service für Apache Flink-Anwendung ein Python-Skript zum Definieren des Datenflusses, der mithilfe der Apache Flink-Laufzeit Eingaben verarbeitet und Ausgaben erzeugt.

Eine typische Anwendung von Managed Service für Apache Flink besteht aus den folgenden Komponenten:

- Runtime-Eigenschaften: Sie können Runtime-Eigenschaften verwenden, um Ihre Anwendung zu konfigurieren, ohne Ihren Anwendungscode neu kompilieren zu müssen.
- Quellen: Die Anwendung verwendet Daten aus einer oder mehreren Quellen. Eine Quelle verwendet einen <u>Konnektor</u> zum Lesen von Daten aus einem externen System, z. B. einem Kinesis-Datenstrom oder einem Amazon-MSK-Thema. Sie können auch spezielle Konnektoren verwenden, um Daten aus der Anwendung heraus zu generieren. Wenn Sie SQL verwenden, definiert die Anwendung Quellen als Quelltabellen.
- Transformationen: Die Anwendung verarbeitet Daten mithilfe einer oder mehrerer Transformationen, mit denen Daten gefiltert, angereichert oder aggregiert werden können. Wenn Sie SQL verwenden, definiert die Anwendung Transformationen als SQL-Abfragen.
- Senken: Die Anwendung sendet Daten über Senken an externe Quellen. Eine Senke verwendet einen Konnektor zum Senden von Daten an ein externes System wie einen Kinesis-Datenstrom, ein Amazon MSK-Thema, einen Amazon S3 S3-Bucket oder eine relationale Datenbank. Sie können auch einen speziellen Anschluss verwenden, um die Ausgabe zu Entwicklungszwecken zu drucken. Wenn Sie SQL verwenden, definiert die Anwendung Senken als Senkentabellen, in die Sie Ergebnisse einfügen. Weitere Informationen finden Sie unter <u>Schreiben Sie Daten mithilfe von</u> <u>Senken in Managed Service für Apache Flink</u>.

Ihre Python-Anwendung benötigt möglicherweise auch externe Abhängigkeiten, z. B. zusätzliche Python-Bibliotheken oder einen beliebigen Flink-Connector, den Ihre Anwendung verwendet. Wenn Sie Ihre Anwendung paketieren, müssen Sie alle Abhängigkeiten einbeziehen, die Ihre Anwendung benötigt. Dieses Tutorial zeigt, wie Sie Connector-Abhängigkeiten einbeziehen und wie Sie die Anwendung für die Bereitstellung auf Amazon Managed Service für Apache Flink verpacken.

Erfüllen Sie die Voraussetzungen

Für dieses Tutorial benötigen Sie Folgendes:

- Python 3.11, vorzugsweise mit einer eigenständigen Umgebung wie VirtualEnv (venv), Conda oder Miniconda.
- <u>Git-Client</u> installieren Sie den Git-Client, falls Sie ihn noch nicht installiert haben.
- Java Development Kit (JDK) Version 11 installieren Sie ein Java JDK 11 und stellen Sie die JAVA_HOME Umgebungsvariable so ein, dass sie auf Ihren Installationsort verweist. Wenn Sie kein JDK 11 haben, können Sie <u>Amazon Corretto</u>oder ein beliebiges Standard-JDK unserer Wahl verwenden.

 Führen Sie den folgenden Befehl aus, um zu überprüfen, dass das JDK korrekt installiert ist. Die Ausgabe ist anders, wenn Sie ein anderes JDK als Amazon Corretto 11 verwenden. Stellen Sie sicher, dass die Version 11.x ist.

```
$ java --version
openjdk 11.0.23 2024-04-16 LTS
OpenJDK Runtime Environment Corretto-11.0.23.9.1 (build 11.0.23+9-LTS)
OpenJDK 64-Bit Server VM Corretto-11.0.23.9.1 (build 11.0.23+9-LTS, mixed mode)
```

- <u>Apache Maven</u> installieren Sie Apache Maven Maven, falls Sie dies noch nicht getan haben.
 Weitere Informationen finden Sie unter <u>Installation von Apache Maven</u>.
 - Mit dem folgenden Befehl können Sie Ihre Apache-Maven-Installation testen:

\$ mvn -version

1 Note

Obwohl Ihre Anwendung in Python geschrieben ist, läuft Apache Flink in der Java Virtual Machine (JVM). Es verteilt die meisten Abhängigkeiten, wie z. B. den Kinesis-Konnektor, als JAR-Dateien. Verwenden Sie <u>Apache</u> Maven, um diese Abhängigkeiten zu verwalten und die Anwendung in einer ZIP-Datei zu verpacken. In diesem Tutorial wird erklärt, wie das geht.

🛕 Warning

Wir empfehlen, dass Sie Python 3.11 für die lokale Entwicklung verwenden. Dies ist dieselbe Python-Version, die von Amazon Managed Service für Apache Flink mit der Flink-Laufzeit 1.19 verwendet wird.

Die Installation der Python-Flink-Bibliothek 1.19 auf Python 3.12 schlägt möglicherweise fehl. Wenn Sie standardmäßig eine andere Python-Version auf Ihrem Computer installiert haben, empfehlen wir Ihnen, eine eigenständige Umgebung zu erstellen, z. B. VirtualEnv mit Python 3.11.

IDE für lokale Entwicklung

Wir empfehlen, dass Sie eine Entwicklungsumgebung wie <u>PyCharmVisual Studio Code</u> verwenden, um Ihre Anwendung zu entwickeln und zu kompilieren.

Führen Sie dann die ersten zwei Schritte von aus Erste Schritte mit Amazon Managed Service für Apache Flink (DataStream API).

- Richten Sie ein AWS Konto ein und erstellen Sie einen Administratorbenutzer
- Richten Sie das AWS Command Line Interface ()AWS CLI ein

Informationen zum Einstieg finden Sie unter Erstellen einer Anwendung.

Erstellen und Ausführen einer Anwendung von Managed Service für Apache Flink für Python-Anwendung

In diesem Abschnitt erstellen Sie eine Anwendung von Managed Service für Apache Flink für Python-Anwendung mit einem Kinesis Stream als Quelle und Senke.

Dieser Abschnitt enthält die folgenden Schritte.

- Erstellen Sie abhängige Ressourcen
- Einrichten der lokalen Entwicklungsumgebung
- Laden Sie den Apache Flink-Streaming-Python-Code herunter und untersuchen Sie ihn
- JAR-Abhängigkeiten
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Führen Sie Ihre Anwendung lokal aus
- Beobachten Sie Eingabe- und Ausgabedaten in Kinesis-Streams
- Stoppen Sie die lokale Ausführung Ihrer Anwendung
- Package Sie Ihren Anwendungscode
- Hochladen des Anwendungspakets in einen Amazon S3 Bucket
- Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink
- <u>Nächster Schritt</u>

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung einen Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis Streams für Eingaben und Ausgaben.
- Einen Amazon S3 S3-Bucket zum Speichern des Anwendungscodes.

1 Note

In diesem Tutorial wird davon ausgegangen, dass Sie Ihre Anwendung in der Region useast-1 bereitstellen. Wenn Sie eine andere Region verwenden, müssen Sie alle Schritte entsprechend anpassen.

Erstellen Sie zwei Kinesis-Streams

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie zwei Kinesis-Datenströme (ExampleInputStreamundExampleOutputStream) in derselben Region, die Sie für die Bereitstellung Ihrer Anwendung verwenden werden (us-east-1 in diesem Beispiel). Ihre Anwendung verwendet diese Streams für die Quell- und Ziel-Streams der Anwendung.

Sie können diese Streams mithilfe der Amazon-Kinesis-Konsole oder des folgenden AWS CLI -Befehls erstellen. Anweisungen für die Konsole finden Sie unter <u>Erstellen und Aktualisieren von</u> Datenströmen im Amazon Kinesis Data Streams Entwicklerhandbuch.

So erstellen Sie die Daten-Streams (AWS CLI)

1. Verwenden Sie den folgenden Amazon Kinesis create-stream AWS CLI Befehl, um den ersten Stream (ExampleInputStream) zu erstellen.

```
$ aws kinesis create-stream \
--stream-name ExampleInputStream \
--shard-count 1 \
--region us-east-1
```

 Um den zweiten Stream zu erstellen, den die Anwendung zum Schreiben der Ausgabe verwendet, führen Sie denselben Befehl aus und ändern den Stream-Namen in ExampleOutputStream.

```
$ aws kinesis create-stream \
--stream-name ExampleOutputStream \
--shard-count 1 \
--region us-east-1
```

Erstellen eines Amazon-S3-Buckets

Sie können ein Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressource finden Sie in den folgenden Themen:

 <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service-Benutzerhandbuch.
 Geben Sie dem Amazon S3 S3-Bucket einen global eindeutigen Namen, z. B. indem Sie Ihren Anmeldenamen anhängen.

```
Note
```

Stellen Sie sicher, dass Sie den S3-Bucket in der Region erstellen, die Sie für dieses Tutorial verwenden (us-east-1).

Sonstige Ressourcen

Wenn Sie Ihre Anwendung erstellen, erstellt Managed Service für Apache Flink die folgenden CloudWatch Amazon-Ressourcen, falls sie noch nicht vorhanden sind:

- Eine Protokollgruppe namens /AWS/KinesisAnalytics-java/<my-application>.
- Einen Protokollstream mit dem Namen kinesis-analytics-log-stream.

Einrichten der lokalen Entwicklungsumgebung

Für die Entwicklung und das Debuggen können Sie die Python Flink-Anwendung auf Ihrem Computer ausführen. Sie können die Anwendung von der Befehlszeile aus mit python main.py oder in einer Python-IDE Ihrer Wahl starten.

Note

Auf Ihrem Entwicklungscomputer müssen Python 3.10 oder 3.11, Java 11, Apache Maven und Git installiert sein. Wir empfehlen, dass Sie eine IDE wie <u>PyCharmVisual</u> Studio Code verwenden. <u>Erfüllen Sie die Voraussetzungen für das Abschließen der Übungen</u>Bevor Sie fortfahren, können Sie überprüfen, ob Sie alle Voraussetzungen erfüllen.

Installieren Sie die PyFlink Bibliothek

Um Ihre Anwendung zu entwickeln und lokal auszuführen, müssen Sie die Flink-Python-Bibliothek installieren.

- 1. Erstellen Sie eine eigenständige Python-Umgebung mit VirtualEnv Conda oder einem ähnlichen Python-Tool.
- Installieren Sie die PyFlink Bibliothek in dieser Umgebung. Verwenden Sie dieselbe Apache Flink-Laufzeit, die Sie in Amazon Managed Service f
 ür Apache Flink verwenden. Derzeit ist die empfohlene Laufzeit 1.19.1.

\$ pip install apache-flink==1.19.1

3. Stellen Sie sicher, dass die Umgebung aktiv ist, wenn Sie Ihre Anwendung ausführen. Wenn Sie die Anwendung in der IDE ausführen, stellen Sie sicher, dass die IDE die Umgebung als Laufzeit verwendet. Der Vorgang hängt von der IDE ab, die Sie verwenden.

1 Note

Sie müssen nur die PyFlink Bibliothek installieren. Sie müssen keinen Apache Flink-Cluster auf Ihrem Computer installieren.

Authentifizieren Sie Ihre Sitzung AWS

Die Anwendung verwendet Kinesis-Datenströme, um Daten zu veröffentlichen. Bei der lokalen Ausführung benötigen Sie eine gültige AWS authentifizierte Sitzung mit Schreibberechtigungen in den Kinesis-Datenstrom. Führen Sie die folgenden Schritte aus, um Ihre Sitzung zu authentifizieren:

- Wenn Sie das Profil AWS CLI und ein benanntes Profil mit g
 ültigen Anmeldeinformationen nicht konfiguriert haben, finden Sie weitere Informationen unter. <u>Richten Sie das AWS Command Line</u> Interface ()AWS CLI ein
- 2. Vergewissern Sie sich, dass Ihre korrekt konfiguriert AWS CLI ist und dass Ihre Benutzer über Schreibberechtigungen in den Kinesis-Datenstrom verfügen, indem Sie den folgenden Testdatensatz veröffentlichen:

```
$ aws kinesis put-record --stream-name ExampleOutputStream --data TEST --partition-
key TEST
```

 Wenn Ihre IDE über ein Plug-in zur Integration verfügt AWS, können Sie dieses verwenden, um die Anmeldeinformationen an die Anwendung zu übergeben, die in der IDE ausgeführt wird. Weitere Informationen finden Sie unter <u>AWS Toolkit für PyCharm,AWS Toolkit for Visual Studio</u> Code und AWS Toolkit für IntelliJ IDEA.

Laden Sie den Apache Flink-Streaming-Python-Code herunter und untersuchen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

1. Klonen Sie das Remote-Repository, indem Sie den folgenden Befehl verwenden:

```
git clone https://github.com/aws-samples/amazon-managed-service-for-apache-flink-
examples.git
```

2. Navigieren Sie zum ./python/GettingStarted Verzeichnis.

Überprüfen Sie die Anwendungskomponenten

Der Anwendungscode befindet sich inmain.py. Wir verwenden in Python eingebettetes SQL, um den Ablauf der Anwendung zu definieren.

Note

Für ein optimiertes Entwicklererlebnis ist die Anwendung so konzipiert, dass sie ohne Codeänderungen sowohl auf Amazon Managed Service für Apache Flink als auch lokal für die Entwicklung auf Ihrem Computer ausgeführt werden kann. Die Anwendung verwendet die

- UmgebungsvariableIS_LOCAL = true, um zu erkennen, wann sie lokal ausgeführt wird. Sie müssen die Umgebungsvariable IS_LOCAL = true entweder in Ihrer Shell oder in der Run-Konfiguration Ihrer IDE festlegen.
- Die Anwendung richtet die Ausführungsumgebung ein und liest die Laufzeitkonfiguration. Um sowohl auf Amazon Managed Service for Apache Flink als auch lokal zu funktionieren, überprüft die Anwendung die IS_LOCAL Variable.
 - Folgendes ist das Standardverhalten, wenn die Anwendung in Amazon Managed Service f
 ür Apache Flink ausgef
 ührt wird:
 - 1. Lädt die in der Anwendung enthaltenen Abhängigkeiten. Weitere Informationen finden Sie unter (Link)
 - Laden Sie die Konfiguration aus den Runtime-Eigenschaften, die Sie in der Anwendung Amazon Managed Service f
 ür Apache Flink definieren. Weitere Informationen finden Sie unter (Link)
 - Wenn die Anwendung erkenntIS_LOCAL = true, dass Sie Ihre Anwendung lokal ausführen:
 - 1. Lädt externe Abhängigkeiten aus dem Projekt.
 - 2. Lädt die Konfiguration aus der im Projekt enthaltenen application_properties.json Datei.

```
...
APPLICATION_PROPERTIES_FILE_PATH = "/etc/flink/application_properties.json"
...
is_local = (
    True if os.environ.get("IS_LOCAL") else False
)
...
if is_local:
    APPLICATION_PROPERTIES_FILE_PATH = "application_properties.json"
    CURRENT_DIR = os.path.dirname(os.path.realpath(__file__))
    table_env.get_config().get_configuration().set_string(
        "pipeline.jars",
        "file:///" + CURRENT_DIR + "/target/pyflink-dependencies.jar",
    )
```

 Die Anwendung definiert mithilfe des <u>Kinesis Connectors</u> eine Quelltabelle mit einer CREATE TABLE Anweisung. Diese Tabelle liest Daten aus dem Kinesis-Eingabestream. Die Anwendung verwendet den Namen des Streams, die Region und die Anfangsposition aus der Laufzeitkonfiguration.

```
table_env.execute_sql(f"""
    CREATE TABLE prices (
        ticker VARCHAR(6),
        price DOUBLE,
        event_time TIMESTAMP(3),
        WATERMARK FOR event_time AS event_time - INTERVAL '5' SECOND
    )
    PARTITIONED BY (ticker)
    WITH (
        'connector' = 'kinesis',
        'stream' = '{input_stream_name}',
        'aws.region' = '{input_stream_region}',
        'format' = 'json',
        'json.timestamp-format.standard' = 'ISO-8601'
    ) """)
```

Die Anwendung definiert in diesem Beispiel auch eine Sinktabelle mithilfe des <u>Kinesis Connectors</u>.
 Diese Geschichte sendet Daten an den Kinesis-Ausgabestream.

```
table_env.execute_sql(f"""
            CREATE TABLE output (
                ticker VARCHAR(6),
                price DOUBLE,
                event_time TIMESTAMP(3)
              )
              PARTITIONED BY (ticker)
              WITH (
                'connector' = 'kinesis',
                'stream' = '{output_stream_name}',
                'aws.region' = '{output_stream_region}',
                 'sink.partitioner-field-delimiter' = ';',
                 'sink.batch.max-size' = '100',
                 'format' = 'json',
                 'json.timestamp-format.standard' = 'ISO-8601'
              )""")
```

 Schließlich führt die Anwendung eine SQL-Anweisung aus, die die Tabelle aus INSERT INTO... der Quelltabelle ableitet. In einer komplexeren Anwendung müssen Sie wahrscheinlich zusätzliche Schritte ausführen, um Daten zu transformieren, bevor Sie in die Datensenke schreiben.

• Sie müssen am Ende der main() Funktion einen weiteren Schritt hinzufügen, um die Anwendung lokal auszuführen:

```
if is_local:
    table_result.wait()
```

Ohne diese Anweisung wird die Anwendung sofort beendet, wenn Sie sie lokal ausführen. Sie dürfen diese Anweisung nicht ausführen, wenn Sie Ihre Anwendung in Amazon Managed Service für Apache Flink ausführen.

JAR-Abhängigkeiten

Eine PyFlink Anwendung benötigt normalerweise einen oder mehrere Konnektoren. Die Anwendung in diesem Tutorial verwendet den <u>Kinesis Connector</u>. Da Apache Flink in der Java-JVM ausgeführt wird, werden Konnektoren als JAR-Dateien verteilt, unabhängig davon, ob Sie Ihre Anwendung in Python implementieren. Sie müssen diese Abhängigkeiten mit der Anwendung verpacken, wenn Sie sie auf Amazon Managed Service für Apache Flink bereitstellen.

In diesem Beispiel zeigen wir, wie Sie Apache Maven verwenden, um die Abhängigkeiten abzurufen und die Anwendung so zu verpacken, dass sie auf Managed Service für Apache Flink ausgeführt wird.

Note

Es gibt alternative Möglichkeiten, Abhängigkeiten abzurufen und zu paketieren. Dieses Beispiel zeigt eine Methode, die mit einem oder mehreren Konnektoren korrekt funktioniert. Außerdem können Sie die Anwendung lokal, zu Entwicklungszwecken und auf Managed Service für Apache Flink ohne Codeänderungen ausführen.

Verwenden Sie die Datei pom.xml

Apache Maven verwendet die pom.xml Datei, um Abhängigkeiten und das Paketieren von Anwendungen zu kontrollieren.

Alle JAR-Abhängigkeiten sind in der pom.xml Datei im <dependencies>...</dependencies> Block angegeben.

Informationen zum richtigen Artefakt und zur richtigen Version des zu verwendenden Konnektors finden Sie unter<u>Verwenden Sie Apache Flink-Konnektoren mit Managed Service für Apache Flink</u>. Vergewissern Sie sich, dass Sie sich auf die Version von Apache Flink beziehen, die Sie verwenden. In diesem Beispiel wird der Kinesis-Connector verwendet. Für Apache Flink 1.19 lautet die Connector-Version. 4.3.0-1.19

Note

Wenn Sie Apache Flink 1.19 verwenden, gibt es keine Connector-Version, die speziell für diese Version veröffentlicht wurde. Verwenden Sie die für 1.18 veröffentlichten Konnektoren.

Abhängigkeiten herunterladen und verpacken

Verwenden Sie Maven, um die in der pom. xml Datei definierten Abhängigkeiten herunterzuladen und sie für die Python-Flink-Anwendung zu verpacken.

- 1. Navigieren Sie zu dem Verzeichnis, in dem sich das Python-Projekt Getting Started befindetpython/GettingStarted.
- 2. Führen Sie den folgenden Befehl aus:

\$ mvn package

Maven erstellt eine neue Datei namens./target/pyflink-dependencies.jar. Wenn Sie lokal auf Ihrem Computer entwickeln, sucht die Python-Anwendung nach dieser Datei.

1 Note

Wenn Sie vergessen, diesen Befehl auszuführen, schlägt er bei dem Versuch, Ihre Anwendung auszuführen, mit der folgenden Fehlermeldung fehl: Es konnte keine Factory für den Bezeichner "kinesis" gefunden werden.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt senden Sie Beispielwerte an den Stream für die zu verarbeitende Anwendung. Sie haben zwei Möglichkeiten, Beispieldaten zu generieren, entweder mit einem Python-Skript oder mit dem Kinesis Data Generator.

Generieren Sie Beispieldaten mit einem Python-Skript

Sie können ein Python-Skript verwenden, um Beispieldatensätze an den Stream zu senden.

Note

Um dieses Python-Skript auszuführen, müssen Sie Python 3.x verwenden und die <u>AWS SDK</u> for Python (Boto) -Bibliothek installiert haben.

Um mit dem Senden von Testdaten an den Kinesis-Eingabestream zu beginnen:

- 1. Laden Sie das stock.py Python-Skript für den Datengenerator aus dem <u>GitHub Datengenerator-</u> <u>Repository</u> herunter.
- 2. Führen Sie das stock.pySkript aus:

\$ python stock.py

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen. Sie können jetzt Ihre Apache-Flink-Anwendung ausführen.

Generieren Sie Beispieldaten mit Kinesis Data Generator

Alternativ zur Verwendung des Python-Skripts können Sie <u>Kinesis Data Generator</u> verwenden, der auch in einer <u>gehosteten Version</u> verfügbar ist, um Zufallsstichprobendaten an den Stream zu senden. Kinesis Data Generator wird in Ihrem Browser ausgeführt und Sie müssen nichts auf Ihrem Computer installieren.

So richten Sie Kinesis Data Generator ein und führen ihn aus:

- Folgen Sie den Anweisungen in der <u>Kinesis Data Generator-Dokumentation</u>, um den Zugriff auf das Tool einzurichten. Sie werden eine AWS CloudFormation Vorlage ausführen, die einen Benutzer und ein Passwort einrichtet.
- Greifen Sie über die von der CloudFormation Vorlage generierte URL auf Kinesis Data Generator zu. Sie finden die URL auf der Registerkarte "Ausgabe", nachdem die CloudFormation Vorlage fertiggestellt wurde.
- 3. Konfigurieren Sie den Datengenerator:
 - Region: Wählen Sie die Region aus, die Sie für dieses Tutorial verwenden: us-east-1
 - Stream/Delivery-Stream: W\u00e4hlen Sie den Eingabestream aus, den die Anwendung verwenden soll: ExampleInputStream
 - Datensätze pro Sekunde: 100
 - Datensatzvorlage: Kopieren Sie die folgende Vorlage und fügen Sie ihn ein:

```
{
    "event_time" : "{{date.now("YYYY-MM-DDTkk:mm:ss.SSSSS")}},
    "ticker" : "{{random.arrayElement(
            ["AAPL", "AMZN", "MSFT", "INTC", "TBV"]
        )}}",
    "price" : {{random.number(100)}}
}
```

4. Testen Sie die Vorlage: Wählen Sie Testvorlage und stellen Sie sicher, dass der generierte Datensatz dem folgenden ähnelt:

```
{ "event_time" : "2024-06-12T15:08:32.04800, "ticker" : "INTC", "price" : 7 }
```

5. Starten Sie den Datengenerator: Wählen Sie Select Send Data.

Kinesis Data Generator sendet jetzt Daten an denExampleInputStream.

Führen Sie Ihre Anwendung lokal aus

Sie können die Anwendung lokal testen, indem Sie sie über die Befehlszeile mit python main.py oder über Ihre IDE ausführen.

Um Ihre Anwendung lokal ausführen zu können, muss die richtige Version der PyFlink Bibliothek installiert sein, wie im vorherigen Abschnitt beschrieben. Weitere Informationen finden Sie unter (Link)

Note

Vergewissern Sie sich, bevor Sie fortfahren, dass die Eingabe- und Ausgabeströme verfügbar sind. Siehe <u>Erstellen Sie zwei Amazon Kinesis Kinesis-Datenstreams</u>. Stellen Sie außerdem sicher, dass Sie über Lese- und Schreibberechtigungen für beide Streams verfügen. Siehe <u>Authentifizieren Sie Ihre Sitzung AWS</u>.

Importiere das Python-Projekt in deine IDE

Um mit der Arbeit an der Anwendung in Ihrer IDE zu beginnen, müssen Sie sie als Python-Projekt importieren.

Das von Ihnen geklonte Repository enthält mehrere Beispiele. Jedes Beispiel ist ein separates Projekt. Importieren Sie für dieses Tutorial den Inhalt im ./python/GettingStarted Unterverzeichnis in Ihre IDE.

Importieren Sie den Code als vorhandenes Python-Projekt.

1 Note

Der genaue Vorgang zum Importieren eines neuen Python-Projekts hängt von der verwendeten IDE ab.

Überprüfen Sie die lokale Anwendungskonfiguration

Bei der lokalen Ausführung verwendet die Anwendung die Konfiguration in der application_properties.json Datei im Ressourcenordner des Projekts unter./src/main/ resources. Sie können diese Datei bearbeiten, um verschiedene Kinesis-Stream-Namen oder Regionen zu verwenden.

```
Ε
  {
    "PropertyGroupId": "InputStream0",
    "PropertyMap": {
      "stream.name": "ExampleInputStream",
      "flink.stream.initpos": "LATEST",
      "aws.region": "us-east-1"
    }
  },
  {
    "PropertyGroupId": "OutputStream0",
    "PropertyMap": {
      "stream.name": "ExampleOutputStream",
      "aws.region": "us-east-1"
    }
  }
]
```

Führen Sie Ihre Python-Anwendung lokal aus

Sie können Ihre Anwendung lokal ausführen, entweder über die Befehlszeile als normales Python-Skript oder über die IDE.

So führen Sie Ihre Anwendung über die Befehlszeile aus

- Stellen Sie sicher, dass die eigenständige Python-Umgebung wie Conda oder VirtualEnv in der Sie die Python-Flink-Bibliothek installiert haben, derzeit aktiv ist.
- 2. Stellen Sie sicher, dass Sie mvn package mindestens einmal gelaufen sind.
- 3. Legen Sie die IS_LOCAL = true-Umgebungsvariable fest:

```
$ export IS_LOCAL=true
```

4. Führen Sie die Anwendung als normales Python-Skript aus.

```
$python main.py
```

So führen Sie die Anwendung aus der IDE aus

1. Konfigurieren Sie Ihre IDE so, dass das main.py Skript mit der folgenden Konfiguration ausgeführt wird:
- 1. Verwenden Sie die eigenständige Python-Umgebung wie Conda oder den VirtualEnv Ort, an dem Sie die PyFlink Bibliothek installiert haben.
- 2. Verwenden Sie die AWS Anmeldeinformationen, um auf die Eingabe- und Ausgabe-Kinesis-Datenstreams zuzugreifen.
- 3. Set IS_LOCAL = true.
- 2. Das genaue Verfahren zum Einstellen der Run-Konfiguration hängt von Ihrer IDE ab und ist unterschiedlich.
- 3. Wenn Sie Ihre IDE eingerichtet haben, führen Sie das Python-Skript aus und verwenden Sie die von Ihrer IDE bereitgestellten Tools, während die Anwendung ausgeführt wird.

Lokales Prüfen der Anwendungsprotokolle

Wenn die Anwendung lokal ausgeführt wird, zeigt sie kein Protokoll in der Konsole an, mit Ausnahme einiger Zeilen, die beim Start der Anwendung gedruckt und angezeigt werden. PyFlink schreibt Protokolle in eine Datei in dem Verzeichnis, in dem die Python-Flink-Bibliothek installiert ist. Die Anwendung gibt beim Start den Speicherort der Protokolle aus. Sie können auch den folgenden Befehl ausführen, um die Protokolle zu finden:

```
$ python -c "import pyflink;import
os;print(os.path.dirname(os.path.abspath(pyflink.__file__))+'/log')"
```

- 1. Listet die Dateien im Logging-Verzeichnis auf. Normalerweise finden Sie eine einzelne .log Datei.
- Speichern Sie die Datei, w\u00e4hrend die Anwendung l\u00e4uft:tail -f <log-path>/<logfile>.log.

Beobachten Sie Eingabe- und Ausgabedaten in Kinesis-Streams

Sie können Datensätze beobachten, die vom (generierenden Beispiel-Python) oder dem Kinesis Data Generator (Link) an den Eingabestream gesendet wurden, indem Sie den Data Viewer in der Amazon Kinesis Kinesis-Konsole verwenden.

Um Aufzeichnungen zu beobachten:

Stoppen Sie die lokale Ausführung Ihrer Anwendung

Stoppen Sie die Anwendung, die in Ihrer IDE ausgeführt wird. Die IDE bietet normalerweise eine "Stopp" -Option. Der genaue Standort und die Methode hängen von der IDE ab.

Package Sie Ihren Anwendungscode

In diesem Abschnitt verwenden Sie Apache Maven, um den Anwendungscode und alle erforderlichen Abhängigkeiten in einer ZIP-Datei zu verpacken.

Führen Sie den Maven-Paketbefehl erneut aus:

\$ mvn package

Dieser Befehl generiert die Dateitarget/managed-flink-pyflink-gettingstarted-1.0.0.zip.

Hochladen des Anwendungspakets in einen Amazon S3 Bucket

In diesem Abschnitt laden Sie die ZIP-Datei, die Sie im vorherigen Abschnitt erstellt haben, in den Amazon Simple Storage Service (Amazon S3) -Bucket hoch, den Sie zu Beginn dieses Tutorials erstellt haben. Wenn Sie diesen Schritt nicht abgeschlossen haben, finden Sie weitere Informationen unter (Link).

Hochladen der JAR-Datei mit Anwendungscode

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den Bucket aus, den Sie zuvor für den Anwendungscode erstellt haben.
- 3. Klicken Sie auf Upload.
- 4. Klicken Sie auf Add files.
- 5. Navigieren Sie zu der im vorherigen Schritt generierten ZIP-Datei:target/managed-flinkpyflink-getting-started-1.0.0.zip.
- 6. Wählen Sie Hochladen, ohne andere Einstellungen zu ändern.

Erstellen und konfigurieren Sie die Anwendung Managed Service für Apache Flink

Sie können eine Anwendung von Managed Service für Apache Flink entweder über die Konsole oder erstellen und konfigurieren. AWS CLI In diesem Tutorial werden wir die Konsole verwenden.

Erstellen der Anwendung

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Stellen Sie sicher, dass die richtige Region ausgewählt ist: USA Ost (Nord-Virginia) us-east-1.
- Öffnen Sie das Menü auf der rechten Seite und wählen Sie Apache Flink-Anwendungen und dann Streaming-Anwendung erstellen. Wählen Sie alternativ im Bereich Erste Schritte auf der Startseite die Option Streaming-Anwendung erstellen aus.
- 4. Gehen Sie auf der Seite Streaming-Anwendungen erstellen wie folgt vor:
 - Wählen Sie unter Methode zum Einrichten der Streamverarbeitungsanwendung die Option Von Grund auf neu erstellen aus.
 - Wählen Sie für Apache Flink-Konfiguration, Application Flink-Version, Apache Flink 1.19.
 - Für die Anwendungskonfiguration:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My Python test app ein.
 - Wählen Sie unter Zugriff auf Anwendungsressourcen die Option Create/update IAM role kinesis-analytics-MyApplication-us -east-1 with required policies aus.
 - Gehen Sie für die Einstellungen für Vorlagen für Anwendungen wie folgt vor:
 - Wählen Sie für Vorlagen die Option Entwicklung aus.
 - Wählen Sie Streaming-Anwendung erstellen aus.
 - Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Amazon Managed Service für Apache Flink war früher als Kinesis Data Analytics bekannt. Dem Namen der Ressourcen, die automatisch generiert werden, wird aus kinesisanalytics Gründen der Abwärtskompatibilität ein Präfix vorangestellt.

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Amazon S3-Bucket.

Um die IAM-Richtlinie zu bearbeiten, um S3-Bucket-Berechtigungen hinzuzufügen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-east-1-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie Bearbeiten und dann die Registerkarte JSON.
- Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie das Beispielkonto IDs (012345678901) durch Ihre Konto-ID.

```
"Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "ListCloudwatchLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            1
        },
        {
            "Sid": "PutCloudwatchLogs",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            1
        },
        ſ
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-east-1:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-east-1:012345678901:stream/
ExampleOutputStream"
```

}

]

5. Wählen Sie Weiter und dann Änderungen speichern aus.

Konfigurieren der Anwendung

Bearbeiten Sie die Anwendungskonfiguration, um das Anwendungscode-Artefakt festzulegen.

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Gehen Sie im Abschnitt Speicherort des Anwendungscodes wie folgt vor:
 - Wählen Sie für Amazon S3 S3-Bucket den Bucket aus, den Sie zuvor für den Anwendungscode erstellt haben. Wählen Sie Durchsuchen und wählen Sie den richtigen Bucket aus. Wählen Sie dann Auswählen. Wählen Sie nicht den Bucket-Namen aus.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert managed-flink-pyflinkgetting-started-1.0.0.zip ein.
- 3. Wählen Sie für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-east-1** mit den erforderlichen Richtlinien erstellen/aktualisieren aus.
- 4. Wechseln Sie zu den Runtime-Eigenschaften und behalten Sie die Standardwerte für alle anderen Einstellungen bei.
- 5. Wählen Sie Neues Element hinzufügen und fügen Sie jeden der folgenden Parameter hinzu:

Gruppen-ID	Schlüssel	Value (Wert)
InputStream0	stream.name	ExampleInputStream
InputStream0	flink.stream.initp os	LATEST
InputStream0	aws.region	us-east-1
OutputStream0	stream.name	ExampleOutputStream
OutputStream0	aws.region	us-east-1

Gruppen-ID	Schlüssel	Value (Wert)
kinesis.analytics. flink.run.options	python	main.py
kinesis.analytics. flink.run.options	jarfile	lib/pyflink-depend encies.jar

6. Ändern Sie keinen der anderen Abschnitte und wählen Sie Änderungen speichern.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Führen Sie die Anwendung aus.

Die Anwendung ist nun konfiguriert und einsatzbereit.

Ausführen der Anwendung

- 1. Wählen Sie auf der Konsole für Amazon Managed Service für Apache Flink My Application und anschließend Run aus.
- Wählen Sie auf der nächsten Seite, der Konfigurationsseite für die Anwendungswiederherstellung, die Option Mit neuestem Snapshot ausführen und anschließend Ausführen aus.

Der Status in den Anwendungsdetails wechselt von Ready zu Starting und dann zu dem Running Zeitpunkt, an dem die Anwendung gestartet wurde.

Wenn sich die Anwendung im Running Status befindet, können Sie jetzt das Flink-Dashboard öffnen.

So öffnen Sie das -Dashboard

- 1. Wählen Sie Apache Flink-Dashboard öffnen. Das Dashboard wird auf einer neuen Seite geöffnet.
- 2. Wählen Sie in der Liste "Laufende Jobs" den einzelnen Job aus, den Sie sehen können.

Note

Wenn Sie die Runtime-Eigenschaften festgelegt oder die IAM-Richtlinien falsch bearbeitet haben, ändert sich der Anwendungsstatus möglicherweise inRunning, aber das Flink-Dashboard zeigt an, dass der Job kontinuierlich neu gestartet wird. Dies ist ein häufiges Fehlerszenario, wenn die Anwendung falsch konfiguriert ist oder keine Zugriffsberechtigungen für die externen Ressourcen hat. In diesem Fall überprüfen Sie im Flink-Dashboard auf der Registerkarte Ausnahmen die Ursache des Problems.

Beobachten Sie die Metriken der laufenden Anwendung

Auf der MyApplicationSeite, im Abschnitt CloudWatch Amazon-Metriken, können Sie einige der grundlegenden Metriken der laufenden Anwendung sehen.

Anzeigen der -Metriken

- 1. Wählen Sie neben der Schaltfläche "Aktualisieren" in der Dropdownliste die Option 10 Sekunden aus.
- 2. Wenn die Anwendung läuft und fehlerfrei ist, können Sie sehen, dass die Uptime-Metrik kontinuierlich zunimmt.
- Die Metrik f
 ür vollst
 ändige Neustarts sollte Null sein. Wenn sie zunimmt, kann es bei der Konfiguration zu Problemen kommen. Um das Problem zu untersuchen,
 überpr
 üfen Sie den Tab Ausnahmen im Flink-Dashboard.
- 4. Die Metrik "Anzahl fehlgeschlagener Checkpoints" sollte in einer fehlerfreien Anwendung Null sein.

Note

Dieses Dashboard zeigt einen festen Satz von Metriken mit einer Granularität von 5 Minuten. Sie können ein benutzerdefiniertes Anwendungs-Dashboard mit beliebigen Metriken im CloudWatch Dashboard erstellen.

Beobachten Sie die Ausgabedaten in Kinesis-Streams

Vergewissern Sie sich, dass Sie weiterhin Daten in der Eingabe veröffentlichen, entweder mit dem Python-Skript oder dem Kinesis Data Generator.

Sie können jetzt die Ausgabe der Anwendung beobachten, die auf Managed Service for Apache Flink ausgeführt wird, indem Sie den Datenviewer in der verwenden <u>https://console.aws.amazon.com/</u>kinesis/, ähnlich wie Sie es bereits zuvor getan haben.

Anzeigen der Ausgabe

- 1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.
- Stellen Sie sicher, dass die Region mit der Region übereinstimmt, die Sie f
 ür die Ausf
 ührung dieses Tutorials verwenden. Standardm
 äßig ist es US-east-1 US East (N. Virginia).
 Ändern Sie die Region bei Bedarf.
- 3. Wählen Sie Data Streams.
- 4. Wählen Sie den Stream aus, den Sie beobachten möchten. Verwenden Sie für dieses Tutorial ExampleOutputStream.
- 5. Wählen Sie die Registerkarte Datenanzeige.
- 6. Wählen Sie einen beliebigen Shard aus, behalten Sie "Letzte" als Startposition bei und wählen Sie dann "Datensätze abrufen". Möglicherweise wird die Fehlermeldung "Für diese Anfrage wurde kein Datensatz gefunden" angezeigt. Wenn ja, wählen Sie "Erneut versuchen, Datensätze abzurufen". Die neuesten im Stream veröffentlichten Datensätze werden angezeigt.
- 7. Wählen Sie den Wert in der Datenspalte aus, um den Inhalt des Datensatzes im JSON-Format zu überprüfen.

Stoppen Sie die Anwendung

Um die Anwendung zu beenden, rufen Sie die Konsolenseite der Anwendung Managed Service for Apache Flink mit dem Namen auf. MyApplication

So stoppen Sie die Anwendung

- 1. Wählen Sie in der Dropdownliste Aktion die Option Stopp aus.
- 2. Der Status in den Anwendungsdetails wechselt von Running zu und dann zu dem Ready ZeitpunktStopping, an dem die Anwendung vollständig gestoppt wurde.

Note

Vergessen Sie nicht, auch das Senden von Daten aus dem Python-Skript oder dem Kinesis Data Generator an den Eingabestream zu beenden.

Nächster Schritt

Bereinigen von AWS -Ressourcen

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Tutorial Erste Schritte (Python) erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte.

- Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt
- Löschen Ihrer Kinesis-Datenstreams
- Löschen Sie Ihre Amazon-S3-Objekte und Buckets
- Löschen Ihrer IAM-Ressourcen
- <u>CloudWatch Löschen Sie Ihre Ressourcen</u>

Löschen Sie Ihre Anwendung, die Managed Service für Apache Flink nutzt

Gehen Sie wie folgt vor, um die Anwendung zu löschen.

So löschen Sie die Anwendung:

- 1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplication.
- 3. Wählen Sie in der Dropdownliste Aktionen die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

Löschen Ihrer Kinesis-Datenstreams

- 1. Öffnen Sie die Managed Service für Apache Flink-Konsole unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie Datenströme.
- 3. Wählen Sie die beiden Streams aus, die Sie erstellt haben, ExampleInputStream undExampleOutputStream.
- 4. Wählen Sie in der Dropdownliste Aktionen die Option Löschen aus, und bestätigen Sie dann den Löschvorgang.

Löschen Sie Ihre Amazon-S3-Objekte und Buckets

Gehen Sie wie folgt vor, um die S3-Objekte und den Bucket zu löschen.

Um das Objekt aus dem S3-Bucket zu löschen

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den S3-Bucket aus, den Sie für das Anwendungsartefakt erstellt haben.
- 3. Wählen Sie das Anwendungsartefakt, das Sie hochgeladen haben, mit dem Namen aus. amazon-msf-java-stream-app-1.0.jar
- 4. Wählen Sie Delete (Löschen) und bestätigen Sie das Löschen.

So löschen Sie den S3-Bucket:

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den Bucket aus, den Sie für die Artefakte erstellt haben.
- 3. Wählen Sie Delete (Löschen) und bestätigen Sie das Löschen.

Note

Der S3-Bucket muss leer sein, um ihn zu löschen.

Löschen Ihrer IAM-Ressourcen

Führen Sie die folgenden Schritte aus, um Ihre IAM-Ressourcen zu löschen.

Um Ihre IAM-Ressourcen zu löschen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-east-1.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics- MyApplication -us-east-1.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

Gehen Sie wie folgt vor, um Ihre CloudWatch Ressourcen zu löschen.

Um Ihre CloudWatch Ressourcen zu löschen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Erste Schritte (Scala)

1 Note

Ab Version 1.15 ist Flink Scala-frei. Anwendungen können jetzt die Java-API von jeder Scala-Version aus verwenden. Flink verwendet Scala intern immer noch in einigen Schlüsselkomponenten, macht Scala jedoch nicht im Benutzercode-Classloader verfügbar. Aus diesem Grund müssen Sie Scala-Abhängigkeiten zu Ihren Jar-Archiven hinzufügen. Weitere Informationen zu den Scala-Änderungen in Flink 1.15 finden Sie unter <u>Scalafrei in</u> <u>One Fifteen.</u>

In dieser Übung erstellen Sie eine Anwendung von Managed Service für Apache Flink für Scala mit einem Kinesis Stream als Quelle und Senke.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und überprüfen Sie ihn
- Kompilieren Sie den Anwendungscode und laden Sie ihn hoch
- Erstellen und Ausführen der Anwendung (Konsole)
- Erstellen und Ausführen der Anwendung (CLI)
- Bereinigen von AWS -Ressourcen

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis Streams für Eingaben und Ausgaben.
- Einen Amazon S3-Bucket zum Speichern des Anwendungscodes (ka-app-code-<username>)

Sie können die Kinesis Streams und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen: <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihre Data Streams ExampleInputStream und ExampleOutputStream.

So erstellen Sie die Daten-Streams (AWS CLI)

• Verwenden Sie den folgenden Amazon Kinesis create-stream -Befehl, um den ersten Stream (ExampleInputStream) zu erstellen AWS CLI.

```
aws kinesis create-stream \
    --stream-name ExampleInputStream \
    --shard-count 1 \
    --region us-west-2 \
    --profile adminuser
```

 Um den zweiten Stream zu erstellen, den die Anwendung zum Schreiben der Ausgabe verwendet, führen Sie denselben Befehl aus und ändern den Stream-Namen in ExampleOutputStream.

```
aws kinesis create-stream \
    --stream-name ExampleOutputStream \
    --shard-count 1 \
    --region us-west-2 \
    --profile adminuser
```

 <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Sonstige Ressourcen

Wenn Sie Ihre Anwendung erstellen, erstellt Managed Service für Apache Flink die folgenden CloudWatch Amazon-Ressourcen, falls sie noch nicht vorhanden sind:

- Eine Protokollgruppe mit dem Namen /AWS/KinesisAnalytics-java/MyApplication
- Einen Protokollstream mit dem Namen kinesis-analytics-log-stream

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.

Note

Dieser Abschnitt erfordert AWS SDK for Python (Boto).

1 Note

Das Python-Skript in diesem Abschnitt verwendet die AWS CLI. Sie müssen Ihren so konfigurieren AWS CLI, dass er Ihre Kontoanmeldeinformationen und Ihre Standardregion verwendet. Geben Sie AWS CLI zum Konfigurieren der Folgendes ein:

aws configure

1. Erstellen Sie eine Datei stock.py mit dem folgenden Inhalt:

```
import datetime
import json
import random
import boto3
STREAM_NAME = "ExampleInputStream"
def get_data():
   return {
        'event_time': datetime.datetime.now().isoformat(),
        'ticker': random.choice(['AAPL', 'AMZN', 'MSFT', 'INTC', 'TBV']),
        'price': round(random.random() * 100, 2)}
def generate(stream_name, kinesis_client):
   while True:
        data = get_data()
        print(data)
        kinesis_client.put_record(
            StreamName=stream_name,
            Data=json.dumps(data),
            PartitionKey="partitionkey")
```

```
if __name__ == '__main__':
    generate(STREAM_NAME, boto3.client('kinesis', region_name='us-west-2'))
```

2. Führen Sie das stock.pySkript aus:

```
$ python stock.py
```

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und überprüfen Sie ihn

Der Python-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/scala/ GettingStarted Verzeichnis.

Beachten Sie Folgendes zum Anwendungscode:

- Eine build.sbt-Datei enthält Informationen über die Konfiguration und Abhängigkeiten der Anwendung, einschließlich der Bibliotheken des Managed Service für Apache Flink.
- Die BasicStreamingJob.scala-Datei enthält die Hauptmethode, die die Funktionalität der Anwendung definiert.
- Die Anwendung verwendet eine Kinesis-Quelle zum Lesen aus dem Quell-Stream. Der folgende Codeausschnitt erstellt die Kinesis-Quelle:

```
private def createSource: FlinkKinesisConsumer[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val inputProperties = applicationProperties.get("ConsumerConfigProperties")
  new FlinkKinesisConsumer[String](inputProperties.getProperty(streamNameKey,
  defaultInputStreamName),
```

}

```
new SimpleStringSchema, inputProperties)
```

Die Anwendung verwendet auch eine Kinesis-Senke, um in den Ergebnisstream zu schreiben. Der folgende Codeausschnitt erstellt die Kinesis-Senke:

```
private def createSink: KinesisStreamsSink[String] = {
  val applicationProperties = KinesisAnalyticsRuntime.getApplicationProperties
  val outputProperties = applicationProperties.get("ProducerConfigProperties")
  KinesisStreamsSink.builder[String]
   .setKinesisClientProperties(outputProperties)
   .setSerializationSchema(new SimpleStringSchema)
   .setStreamName(outputProperties.getProperty(streamNameKey,
   defaultOutputStreamName))
   .setPartitionKeyGenerator((element: String) => String.valueOf(element.hashCode))
   .build
}
```

- Die Anwendung erstellt Quell- und Senkenkonnektoren, um mithilfe eines StreamExecutionEnvironment Objekts auf externe Ressourcen zuzugreifen.
- Die Anwendung erstellt Quell- und Senkenkonnektoren mit dynamischen Anwendungseigenschaften. Die Laufzeiteigenschaften der Anwendung werden gelesen, um die Konnektoren zu konfigurieren. Weitere Informationen zu Laufzeiteigenschaften finden Sie unter Laufzeiteigenschaften.

Kompilieren Sie den Anwendungscode und laden Sie ihn hoch

In diesem Abschnitt kompilieren Sie Ihren Anwendungscode und laden ihn in den Amazon-S3-Bucket hoch, den Sie im Abschnitt Erstellen Sie abhängige Ressourcen erstellt haben.

Kompilieren des Anwendungscodes

In diesem Abschnitt verwenden Sie das <u>SBT</u>-Build-Tool, um den Scala-Code für die Anwendung zu erstellen. Informationen zur Installation von SBT finden Sie unter <u>Installieren von SBT mit CS-Setup</u>. Sie müssen auch das Java Development Kits (JDK) installieren. Siehe <u>Voraussetzungen für das</u> Fertigstellen der Übungen.

1. Zum Verwenden Ihres Anwendungscodes kompilieren und packen Sie ihn in eine JAR-Datei. Sie können Ihren Code mit SBT kompilieren und verpacken:

sbt assembly

2. Wenn die Anwendung erfolgreich kompiliert wurde, wird die folgende Datei erstellt:

target/scala-3.2.0/getting-started-scala-1.0.jar

Hochladen des Apache Flink-Streaming-Scala-Codes

In diesem Abschnitt erstellen Sie einen Amazon S3-Bucket und laden Ihren Anwendungscode hoch.

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie Bucket erstellen aus
- Geben Sie ka-app-code-<username> im Feld Bucket-Name ein. Fügen Sie dem Bucket-Namen ein Suffix hinzu, wie z. B. Ihren Benutzernamen, damit er global eindeutig ist. Wählen Sie Weiter aus.
- 4. Lassen Sie im Schritt Optionen konfigurieren die Einstellungen unverändert und klicken Sie auf Weiter.
- 5. Lassen Sie im Schritt Berechtigungen festlegen die Einstellungen unverändert und klicken Sie auf Weiter.
- 6. Wählen Sie Create Bucket (Bucket erstellen) aus.
- 7. Wählen Sie den Bucket ka-app-code-<username> und dann Hochladen aus.
- 8. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der getting-started-scala-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 9. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen und Ausführen der Anwendung (Konsole)

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen Sie die Anwendung

- 1. Öffnen Sie die Konsole von Managed Service für Apache unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Dashboard Managed Service für Apache Flink die Option Analyseanwendung erstellen aus.
- Geben Sie auf der Seite Managed Service f
 ür Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Geben Sie für Beschreibung den Text My scala test app ein.
 - Wählen Sie als Laufzeit Apache Flink aus.
 - Behalten Sie die Version Apache Flink Version 1.19.1 bei.
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesisanalytics-MyApplication-us-west-2

Konfigurieren der Anwendung

Verwenden Sie das folgende Verfahren, um die Anwendung zu konfigurieren.

Konfigurieren der Anwendung

1. Wählen Sie auf der MyApplicationSeite Configure aus.

- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert getting-startedscala-1.0.jar. ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Wählen Sie unter Eigenschaften die Option Gruppe hinzufügen aus.
- 5. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ConsumerConfigProp erties	<pre>input.stream.name</pre>	ExampleInputStream
ConsumerConfigProp erties	aws.region	us-west-2
ConsumerConfigProp erties	flink.stream.initp os	LATEST

Wählen Sie Speichern.

- 6. Wählen Sie unter Eigenschaften erneut Gruppe hinzufügen aus.
- 7. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
ProducerConfigProp erties	output.stream.name	ExampleOutputStream
ProducerConfigProp erties	aws.region	us-west-2

8. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.

- 9. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 10. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Amazon-Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf den Amazon S3-Bucket.

Um die IAM-Richtlinie zu bearbeiten, um S3-Bucket-Berechtigungen hinzuzufügen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- 3. Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- 4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie das beispielhafte Konto IDs (*012345678901*) mit Ihrer Konto-ID.

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

```
],
            "Resource": [
                "arn:aws:s3:::ka-app-code-username/getting-started-scala-1.0.jar"
            ]
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:*"
            ٦
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-
analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
            1
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
```

```
{
    "Sid": "WriteOutputStream",
    "Effect": "Allow",
    "Action": "kinesis:*",
    "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
    }
]
```

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Stoppt die Anwendung

Um die Anwendung zu beenden, wählen Sie auf der MyApplicationSeite Stopp aus. Bestätigen Sie die Aktion.

Erstellen und Ausführen der Anwendung (CLI)

In diesem Abschnitt verwenden Sie, AWS Command Line Interface um die Anwendung Managed Service für Apache Flink zu erstellen und auszuführen. Verwenden Sie den AWS CLI -Befehl kinesisanalyticsv2, um Managed Service für Apache Flink-Anwendungen zu erstellen und mit diesen zu interagieren.

Erstellen einer Berechtigungsrichtlinie

1 Note

Sie müssen eine Berechtigungsrichtlinie und eine Rolle für Ihre Anwendung erstellen. Wenn Sie diese IAM-Ressourcen nicht erstellen, kann Ihre Anwendung nicht auf ihre Daten und Protokollstreams zugreifen.

Zuerst erstellen Sie eine Berechtigungsrichtlinie mit zwei Anweisungen: eine, die Berechtigungen für die Lese-Aktion auf den Quell-Stream zulässt, und eine andere, die Berechtigungen für die Schreib-

Managed Service für Apache Flink

Aktionen auf den Senken-Stream zulässt. Anschließend fügen Sie die Richtlinie an eine IAM-Rolle (die Sie im nächsten Abschnitt erstellen) an. Wenn Managed Service für Apache Flink also die Rolle übernimmt, verfügt der Service über die erforderlichen Berechtigungen zum Lesen aus dem Quell-Stream und zum Schreiben in den Senken-Stream.

Verwenden Sie den folgenden Code zum Erstellen der AKReadSourceStreamWriteSinkStream-Berechtigungsrichtlinie. Ersetzen Sie **username** durch den Benutzernamen, den Sie verwendet haben, um den Amazon-S3-Bucket zum Speichern des Anwendungscodes zu erstellen. Ersetzen Sie die Konto-ID in den Amazon-Ressourcennamen (ARNs) **(012345678901)** mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:s3::::ka-app-code-username/getting-started-scala-1.0.jar"
            ]
        },
        {
            "Sid": "DescribeLogGroups",
            "Effect": "Allow",
            "Action": [
                "logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": [
                 "logs:DescribeLogStreams"
            ],
            "Resource": [
                 "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-analytics/
MyApplication:log-stream:*"
```

```
]
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:/aws/kinesis-analytics/
MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

step-by-stepAnweisungen zum Erstellen einer Berechtigungsrichtlinie finden Sie unter <u>Tutorial</u>: <u>Erstellen und Anhängen Ihrer ersten vom Kunden verwalteten Richtlinie</u> im IAM-Benutzerhandbuch.

Eine IAM-Richtlinie erstellen

In diesem Abschnitt erstellen Sie eine IAM-Rolle, die die Anwendung von Managed Service für Apache Flink annehmen kann, um einen Quell-Stream zu lesen und in den Senken-Stream zu schreiben.

Managed Service für Apache Flink kann ohne Berechtigungen nicht auf Ihren Stream zugreifen. Sie erteilen diese Berechtigungen über eine IAM-Rolle. Jeder IAM-Rolle sind zwei Richtlinien angefügt. Die Vertrauensrichtlinie erteilt Managed Service für Apache Flink die Berechtigung zum Übernehmen

der Rolle und die Berechtigungsrichtlinie bestimmt, was Managed Service für Apache Flink nach Annahme der Rolle tun kann.

Sie können die Berechtigungsrichtlinie, die Sie im vorherigen Abschnitt erstellt haben, dieser Rolle anfügen.

So erstellen Sie eine IAM-Rolle

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie im Navigationsbereich Rollen und dann Rolle erstellen.
- 3. Wählen Sie unter Typ der vertrauenswürdigen Entität auswählen die Option AWS -Service aus
- 4. Wählen Sie unter Choose the service that will use this role (Wählen Sie den Service aus, der diese Rolle verwendet) die Option Kinesis aus.
- 5. Wählen Sie unter Wählen Sie Ihren Anwendungsfall aus die Option Managed Service für Apache Flink aus.
- 6. Wählen Sie Weiter: Berechtigungen aus.
- Wählen Sie auf der Seite Attach permissions policies (Berechtigungsrichtlinien hinzufügen) Next: Review (Weiter: Überprüfen) aus. Sie fügen Berechtigungsrichtlinien an, nachdem Sie die Rolle erstellt haben.
- 8. Geben Sie auf der Seite Create role (Rolle erstellen) den Text **MF-stream-rw-role** für Role name (Rollenname) ein. Wählen Sie Rolle erstellen aus.

Jetzt haben Sie eine neue IAM-Rolle mit dem Namen MF-stream-rw-role erstellt. Im nächsten Schritt aktualisieren Sie die Vertrauens- und Berechtigungsrichtlinien für die Rolle

9. Fügen Sie die Berechtigungsrichtlinie der Rolle an.

Note

Für diese Übung übernimmt Managed Service für Apache Flink diese Rolle sowohl für das Lesen von Daten aus einem Kinesis-Datenstrom (Quelle) als auch zum Schreiben der Ausgabedaten in einen anderen Kinesis-Datenstrom. Daher fügen Sie die Richtlinie an, die Sie im vorherigen Schritt, Erstellen einer Berechtigungsrichtlinie, erstellt haben.

a. Wählen Sie auf der Seite Summary (Übersicht) die Registerkarte Permissions (Berechtigungen) aus.

- b. Wählen Sie Attach Policies (Richtlinien anfügen) aus.
- c. Geben Sie im Suchfeld **AKReadSourceStreamWriteSinkStream** (die Richtlinie, die Sie im vorhergehenden Abschnitt erstellt haben) ein.
- d. Wählen Sie die AKReadSourceStreamWriteSinkStream-Richtlinie und wählen Sie Richtlinie anhängen aus.

Sie haben nun die Service-Ausführungsrolle erstellt, die Ihre Anwendung für den Zugriff auf Ressourcen verwendet. Notieren Sie sich den ARN der neuen Rolle.

step-by-stepAnweisungen zum Erstellen einer Rolle finden Sie unter Erstellen einer IAM-Rolle (Konsole) im IAM-Benutzerhandbuch.

Erstellen der Anwendung

Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen create_request.json. Ersetzen Sie den Beispiel-Rollen-ARN durch den ARN für die Rolle, die Sie zuvor erstellt haben. Ersetzen Sie das Bucket-ARN-Suffix (username) mit dem Suffix, das Sie im vorherigen Abschnitt gewählt haben. Ersetzen Sie die beispielhafte Konto-ID (012345678901) in der Service-Ausführungsrolle mit Ihrer Konto-ID.

```
{
    "ApplicationName": "getting_started",
    "ApplicationDescription": "Scala getting started application",
    "RuntimeEnvironment": "FLINK-1_19",
    "ServiceExecutionRole": "arn:aws:iam::012345678901:role/MF-stream-rw-role",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation": {
                    "BucketARN": "arn:aws:s3:::ka-app-code-username",
                    "FileKey": "getting-started-scala-1.0.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        },
        "EnvironmentProperties": {
         "PropertyGroups": [
            {
               "PropertyGroupId": "ConsumerConfigProperties",
               "PropertyMap" : {
```

```
"aws.region" : "us-west-2",
                     "stream.name" : "ExampleInputStream",
                     "flink.stream.initpos" : "LATEST"
               }
            },
            {
               "PropertyGroupId": "ProducerConfigProperties",
               "PropertyMap" : {
                     "aws.region" : "us-west-2",
                     "stream.name" : "ExampleOutputStream"
               }
            }
         ]
      }
    },
    "CloudWatchLoggingOptions": [
      {
         "LogStreamARN": "arn:aws:logs:us-west-2:012345678901:log-
group:MyApplication:log-stream:kinesis-analytics-log-stream"
      }
   ]
}
```

Führen Sie den <u>CreateApplication</u>mit der folgenden Anforderung aus, um die Anwendung zu erstellen:

```
aws kinesisanalyticsv2 create-application --cli-input-json file://create_request.json
```

Die Anwendung wird nun erstellt. Sie starten die Anwendung im nächsten Schritt.

Starten der Anwendung

In diesem Abschnitt verwenden Sie die StartApplication-Aktion, um die Anwendung zu starten.

So starten Sie die Anwendung

 Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen start_request.json.

```
"ApplicationName": "getting_started",
"RunConfiguration": {
```

{

}

```
"ApplicationRestoreConfiguration": {
    "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
    }
}
```

2. Führen Sie die StartApplication-Aktion mit der vorherigen Anforderung zum Starten der Anwendung aus:

```
aws kinesisanalyticsv2 start-application --cli-input-json file://start_request.json
```

Die Anwendung wird jetzt ausgeführt. Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Amazon-Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Stoppt die Anwendung

In diesem Abschnitt verwenden Sie die StopApplication-Aktion, um die Anwendung zu stoppen.

So stoppen Sie die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen stop_request.json.

```
{
    "ApplicationName": "s3_sink"
}
```

2. Führen Sie die StopApplication-Aktion mit der vorherigen Anforderung zum Stoppen der Anwendung aus:

aws kinesisanalyticsv2 stop-application --cli-input-json file://stop_request.json

Die Anwendung wird nun gestoppt.

Fügen Sie eine CloudWatch Protokollierungsoption hinzu

Sie können die verwenden AWS CLI, um Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzuzufügen. Weitere Informationen zur Verwendung von CloudWatch Protokollen mit Ihrer Anwendung finden Sie unter Einrichten der Anwendungsprotokollierung.

Aktualisieren von Umgebungseigenschaften

In diesem Abschnitt verwenden Sie die <u>UpdateApplication</u>-Aktion, um die Umgebungseigenschaften für die Anwendung zu ändern, ohne den Anwendungscode neu kompilieren zu müssen. In diesem Beispiel ändern Sie die Region der Quell- und Ziel-Streams.

So aktualisieren Sie die Umgebungseigenschaften für die Anwendung

1. Speichern Sie den folgenden JSON-Code in eine Datei mit dem Namen update_properties_request.json.



2. Führen Sie die UpdateApplication-Aktion mit der vorherigen Anforderung aus, um die Umgebungseigenschaften zu aktualisieren:

```
aws kinesisanalyticsv2 update-application --cli-input-json file://
update_properties_request.json
```

Den Anwendungscode aktualisieren

Wenn Sie Ihren Anwendungscode mit einer neuen Version Ihres Codepakets aktualisieren müssen, verwenden Sie die UpdateApplicationCLI-Aktion.

Note

Um eine neue Version des Anwendungscodes mit demselben Dateinamen zu laden, müssen Sie die neue Objektversion angeben. Weitere Informationen zur Verwendung von Amazon S3-Objektversionen finden Sie unter Versionsverwaltung aktivieren oder deaktivieren.

Um die zu verwenden AWS CLI, löschen Sie Ihr vorheriges Codepaket aus Ihrem Amazon S3 S3-Bucket, laden Sie die neue Version hoch und rufen Sie UpdateApplication auf. Geben Sie dabei denselben Amazon S3 S3-Bucket und Objektnamen sowie die neue Objektversion an. Die Anwendung wird mit dem neuen Codepaket neu gestartet.

Die folgende Beispielanforderung für die UpdateApplication-Aktion lädt den Anwendungscode neu und startet die Anwendung neu. Aktualisieren Sie die CurrentApplicationVersionId auf die aktuelle Anwendungsversion. Sie können die aktuelle Anwendungsversion mithilfe der Aktionen ListApplications oder DescribeApplication überprüfen. Aktualisieren Sie das Bucket-Namenssuffix (<username>) mit dem Suffix, das Sie im Abschnitt <u>Erstellen Sie abhängige</u> <u>Ressourcen</u> ausgewählt haben.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zum Bereinigen von AWS -Ressourcen, die im Rollierendes Fenster-Tutorial erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- So löschen Sie die Anwendung Managed Service für Apache Flink
- So löschen Sie die Kinesis Data Streams
- Löschen Sie Ihr Amazon S3 S3-Objekt und Ihren Bucket
- So löschen Sie die IAM-Ressourcen
- <u>CloudWatch Löschen Sie Ihre Ressourcen</u>

So löschen Sie die Anwendung Managed Service für Apache Flink

- 1. Öffnen Sie die Konsole von Managed Service für Apache unter https:// console.aws.amazon.com /flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplication.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

So löschen Sie die Kinesis Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Sie Ihr Amazon S3 S3-Objekt und Ihren Bucket

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username*>Bucket ka-app-code -.

3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

- 1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.
- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-us-west-2 MyApplication aus.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Verwenden Sie Apache Beam mit Managed Service für Apache Flink-Anwendungen

Note

Es gibt keinen kompatiblen Apache Flink Runner für Flink 1.20. Weitere Informationen finden Sie unter Flink-Versionskompatibilität in der Apache Beam-Dokumentation. >

Sie können das <u>Apache Beam</u>-Framework mit Ihrer Managed Service for Apache Flink-Anwendung verwenden, um Streaming-Daten zu verarbeiten. Managed Service für Apache Flink-Anwendungen, die Apache Beam verwenden, verwendet <u>Apache Flink Runner</u> zur Ausführung von Beam-Pipelines.

Ein Tutorial zur Verwendung von Apache Beam in einer Managed Service for Apache Flink-Anwendung finden Sie unter<u>Verwenden CloudFormation</u>.

Dieses Thema enthält die folgenden Abschnitte:

- Einschränkungen des Apache Flink Runners mit Managed Service für Apache Flink
- Funktionen von Apache Beam mit Managed Service für Apache Flink
- Erstellen Sie eine Anwendung mit Apache Beam

Einschränkungen des Apache Flink Runners mit Managed Service für Apache Flink

Beachten Sie Folgendes zur Verwendung des Apache Flink Runners mit Managed Service für Apache Flink:

- Apache Beam-Metriken sind in der Managed Service for Apache Flink-Konsole nicht sichtbar.
- Apache Beam wird nur mit Managed Service f
 ür Apache Flink-Anwendungen unterst
 ützt, die Apache Flink Version 1.8 und h
 öher verwenden. Apache Beam wird mit Managed Service f
 ür Apache Flink-Anwendungen, die Apache Flink Version 1.6 verwenden, nicht unterst
 ützt.

Funktionen von Apache Beam mit Managed Service für Apache Flink

Managed Service für Apache Flink unterstützt dieselben Apache Beam-Funktionen wie der Apache Flink Runner. Informationen darüber, welche Feature vom Apache Flink Runner unterstützt werden, finden Sie in der Beam-Kompatibilitätsmatrix.

Wir empfehlen Ihnen, Ihre Apache Flink-Anwendung im Managed Service for Apache Flink-Dienst zu testen, um sicherzustellen, dass wir alle Feature unterstützen, die Ihre Anwendung benötigt.

Erstellen Sie eine Anwendung mit Apache Beam

In dieser Übung erstellen Sie eine Managed Service for Apache Flink-Anwendung, die Daten mithilfe von <u>Apache Beam</u> transformiert. Apache Beam ist ein Programmiermodell für die Verarbeitung von Streaming-Daten. Informationen zur Verwendung von Apache Beam mit Managed Service für Apache Flink finden Sie unter<u>Verwenden Sie Apache Beam mit Managed Service für Apache Flink-Anwendungen</u>.

Note

Um die erforderlichen Voraussetzungen für diese Übung festzulegen, schließen Sie zunächst die <u>Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink</u> Übung ab.

Dieses Thema enthält die folgenden Abschnitte:

- Erstellen Sie abhängige Ressourcen
- Schreiben Sie Beispieldatensätze in den Eingabestream
- Laden Sie den Anwendungscode herunter und untersuchen Sie ihn
- Kompilieren des Anwendungscodes
- Hochladen des Apache Flink-Streaming-Java-Codes
- Erstellen Sie die Anwendung Managed Service für Apache Flink und führen Sie sie aus
- Bereinigen von AWS -Ressourcen
- Nächste Schritte

Funktionen von Apache Beam mit Managed Service für Apache Flink

Erstellen Sie abhängige Ressourcen

Bevor Sie für diese Übung eine Anwendung von Managed Service für Apache Flink erstellen, erstellen Sie die folgenden abhängigen Ressourcen:

- Zwei Kinesis Data Streams (ExampleInputStream und ExampleOutputStream)
- Einen Amazon S3-Bucket zum Speichern des Codes der Anwendung (ka-appcode-<username>)

Sie können die Kinesis Streams und den Amazon-S3-Bucket mithilfe der Konsole erstellen. Anweisungen zum Erstellen dieser Ressourcen finden Sie in den folgenden Themen:

- <u>Data Streams erstellen und aktualisieren</u> im Amazon Kinesis Data Streams Entwicklerleitfaden.
 Benennen Sie Ihre Data Streams ExampleInputStream und ExampleOutputStream.
- <u>Wie erstelle ich einen S3-Bucket?</u> im Amazon Simple Storage Service Benutzerhandbuch. Geben Sie dem Amazon S3-Bucket einen global eindeutigen Namen, indem Sie Ihren Anmeldenamen anhängen, z. B. ka-app-code-<username>.

Schreiben Sie Beispieldatensätze in den Eingabestream

In diesem Abschnitt verwenden Sie ein Python-Skript zum Schreiben von Datensätzen in den Stream für die zu verarbeitende Anwendung.



1. Erstellen Sie eine Datei ping.py mit dem folgenden Inhalt:
```
print(data)
kinesis.put_record(
    StreamName="ExampleInputStream",
    Data=data,
    PartitionKey="partitionkey")
```

2. Führen Sie das ping.pySkript aus:

```
$ python ping.py
```

Lassen Sie das Skript laufen, während Sie den Rest des Tutorials abschließen.

Laden Sie den Anwendungscode herunter und untersuchen Sie ihn

Der Java-Anwendungscode für dieses Beispiel ist verfügbar unter GitHub. Zum Herunterladen des Anwendungscodes gehen Sie wie folgt vor:

- 1. Installieren Sie den Git-Client, wenn Sie dies noch nicht getan haben. Weitere Informationen finden Sie unter Git installieren.
- 2. Klonen Sie das Remote-Repository mit dem folgenden Befehl:

git clone https://github.com/aws-samples/amazon-kinesis-data-analytics-examples.git

 Navigieren Sie zum amazon-kinesis-data-analytics-java-examples/Beam Verzeichnis.

Der Anwendungscode befindet sich in der BasicBeamStreamingJob.java-Datei. Beachten Sie Folgendes zum Anwendungscode:

• Die Anwendung verwendet Apache Beam <u>ParDo</u>, um eingehende Datensätze zu verarbeiten, indem sie eine benutzerdefinierte Transformationsfunktion namens PingPongFn aufruft.

Der Code zum Aufrufen der PingPongFn Funktion lautet wie folgt:

```
.apply("Pong transform",
      ParDo.of(new PingPongFn())
```

 Managed Service f
ür Apache Flink-Anwendungen, die Apache Beam verwenden, erfordert die folgenden Komponenten. Wenn Sie diese Komponenten und Versionen nicht in Ihre pom.xml aufnehmen, lädt Ihre Anwendung die falschen Versionen aus den Umgebungsabhängigkeiten, und da die Versionen nicht übereinstimmen, stürzt Ihre Anwendung zur Laufzeit ab.

```
<jackson.version>2.10.2</jackson.version>
...
<dependency>
        <groupId>com.fasterxml.jackson.module</groupId>
        <artifactId>jackson-module-jaxb-annotations</artifactId>
        <version>2.10.2</version>
</dependency>
```

 Die PingPongFn Transformationsfunktion übergibt die Eingabedaten an den Ausgabestrom, sofern es sich bei den Eingabedaten nicht um einen Ping-Wert handelt. In diesem Fall gibt sie die Zeichenfolge pong\nan den Ausgabestrom aus.

Der Code der Transformationsfunktion lautet wie folgt:

```
private static class PingPongFn extends DoFn<KinesisRecord, byte[]> {
    private static final Logger LOG = LoggerFactory.getLogger(PingPongFn.class);
    @ProcessElement
    public void processElement(ProcessContext c) {
        String content = new String(c.element().getDataAsBytes(),
        StandardCharsets.UTF_8);
        if (content.trim().equalsIgnoreCase("ping")) {
            LOG.info("Ponged!");
            c.output("pong\n".getBytes(StandardCharsets.UTF_8));
        } else {
            LOG.info("No action for: " + content);
            c.output(c.element().getDataAsBytes());
        }
    }
}
```

Kompilieren des Anwendungscodes

Zum Kompilieren der Anwendung gehen Sie wie folgt vor:

 Installieren Sie Java und Maven, wenn das noch nicht geschehen ist. Weitere Informationen finden Sie unter <u>Erfüllen Sie die erforderlichen Voraussetzungen</u> im <u>Tutorial: Erste Schritte mit</u> der DataStream API in Managed Service f
ür Apache Flink Tutorial. 2. Kompilieren Sie die Anwendung mit dem folgenden Befehl:

mvn package -Dflink.version=1.15.2 -Dflink.version.minor=1.8

Note

Der bereitgestellte Quellcode basiert auf Bibliotheken von Java 11.

Beim Kompilieren der Anwendung wird die JAR-Datei der Anwendung (target/basic-beamapp-1.0.jar) erstellt.

Hochladen des Apache Flink-Streaming-Java-Codes

In diesem Abschnitt laden Sie Ihren Anwendungscode in das Amazon S3-Bucket hoch, das Sie im Erstellen Sie abhängige Ressourcen Abschnitt erstellt haben.

- Wählen Sie in der Amazon S3 S3-Konsole den *<username>* Bucket ka-app-code- und wählen Sie Upload aus.
- 2. Klicken Sie im Schritt Auswählen von Dateien auf Hinzufügen von Dateien. Navigieren Sie zu der basic-beam-app-1.0.jarDatei, die Sie im vorherigen Schritt erstellt haben.
- 3. Sie müssen keine der Einstellungen für das Objekt ändern. Wählen Sie daher Hochladen.

Ihr Anwendungscode ist jetzt in einem Amazon-S3-Bucket gespeichert, in dem Ihre Anwendung darauf zugreifen kann.

Erstellen Sie die Anwendung Managed Service für Apache Flink und führen Sie sie aus

Befolgen Sie diese Schritte, um die Anwendung über die Konsole zu erstellen, zu konfigurieren, zu aktualisieren und auszuführen.

Erstellen Sie die Anwendung

 Öffnen Sie die Konsole Managed Service f
ür Apache unter https://console.aws.amazon.com / flink

- Wählen Sie im Dashboard Managed Service f
 ür Apache Flink die Option Analyseanwendung erstellen aus.
- 3. Geben Sie auf der Seite Managed Service für Apache Flink Anwendung erstellen die Anwendungsdetails wie folgt ein:
 - Geben Sie als Anwendungsname ein MyApplication.
 - Wählen Sie für Laufzeit die Option Apache Flink aus.

Note

Apache Beam ist derzeit nicht mit Apache Flink Version 1.19 oder höher kompatibel.

- Wählen Sie Apache Flink Version 1.15 aus dem Pulldown-Menü Version.
- 4. Wählen Sie für Zugriffsberechtigungen die Option Erstellen / Aktualisieren Sie IAM-Rolle kinesis-analytics-MyApplication-us-west-2 aus.
- 5. Wählen Sie Create application aus.

Note

Beim Erstellen einer Anwendung von Managed Service für Apache Flink mit der Konsole haben Sie die Möglichkeit, eine IAM-Rolle und -Richtlinie für Ihre Anwendung erstellen zu lassen. Ihre Anwendung verwendet diese Rolle und Richtlinie für den Zugriff auf ihre abhängigen Ressourcen. Diese IAM-Ressourcen werden unter Verwendung Ihres Anwendungsnamens und der Region wie folgt benannt:

- Richtlinie: kinesis-analytics-service-MyApplication-us-west-2
- Rolle: kinesis-analytics-MyApplication-us-west-2

Bearbeiten Sie die IAM-Richtlinie

Bearbeiten Sie die IAM-Richtlinie zum Hinzufügen von Berechtigungen für den Zugriff auf die Kinesis-Datenströme.

1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.

Managed Service für Apache Flink

- Wählen Sie Policies (Richtlinien). Wählen Sie die kinesis-analytics-service-MyApplication-us-west-2-Richtlinie aus, die die Konsole im vorherigen Abschnitt für Sie erstellt hat.
- Wählen Sie auf der Seite Summary (Übersicht) die Option Edit policy (Richtlinie bearbeiten) aus. Wählen Sie den Tab JSON.
- 4. Fügen Sie den markierten Abschnitt der folgenden Beispielrichtlinie der Richtlinie hinzu. Ersetzen Sie das beispielhafte Konto IDs (*012345678901*) mit Ihrer Konto-ID.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "ReadCode",
            "Effect": "Allow",
            "Action": [
                "s3:GetObject",
                "logs:DescribeLogGroups",
                "s3:GetObjectVersion"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*",
                "arn:aws:s3:::ka-app-code-<username>/basic-beam-app-1.0.jar"
            ]
        },
        {
            "Sid": "DescribeLogStreams",
            "Effect": "Allow",
            "Action": "logs:DescribeLogStreams",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:*"
        },
        {
            "Sid": "PutLogEvents",
            "Effect": "Allow",
            "Action": "logs:PutLogEvents",
            "Resource": "arn:aws:logs:us-west-2:012345678901:log-group:/aws/
kinesis-analytics/MyApplication:log-stream:kinesis-analytics-log-stream"
        },
        {
            "Sid": "ListCloudwatchLogGroups",
            "Effect": "Allow",
            "Action": [
```

```
"logs:DescribeLogGroups"
            ],
            "Resource": [
                "arn:aws:logs:us-west-2:012345678901:log-group:*"
            ]
        },
        {
            "Sid": "ReadInputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleInputStream"
        },
        {
            "Sid": "WriteOutputStream",
            "Effect": "Allow",
            "Action": "kinesis:*",
            "Resource": "arn:aws:kinesis:us-west-2:012345678901:stream/
ExampleOutputStream"
        }
    ]
}
```

Konfigurieren der Anwendung

- 1. Wählen Sie auf der MyApplicationSeite Configure aus.
- 2. Klicken Sie auf der Seite Configure application (Anwendung konfigurieren) auf die Option Code location (Codespeicherort):
 - Geben Sie für Amazon-S3-Bucket ka-app-code-<username> ein.
 - Geben Sie als Pfad zum Amazon-S3-Objekt den Wert **basic-beam-app-1.0.jar** ein.
- 3. Wählen Sie unter Zugriff auf Anwendungsressourcen für Zugriffsberechtigungen die Option IAM-Rolle **kinesis-analytics-MyApplication-us-west-2** erstellen/aktualisieren aus.
- 4. Geben Sie Folgendes ein:

Gruppen-ID	Schlüssel	Value (Wert)
BeamApplicationPro perties	InputStreamName	ExampleInputStream

Gruppen-ID	Schlüssel	Value (Wert)
BeamApplicationPro perties	OutputStreamName	ExampleOutputStream
BeamApplicationPro perties	AwsRegion	us-west-2

- 5. Stellen Sie unter Überwachung sicher, dass die Ebene der Überwachungsmetriken auf Anwendung eingestellt ist.
- 6. Wählen Sie für die CloudWatch Protokollierung das Kontrollkästchen Aktivieren aus.
- 7. Wählen Sie Aktualisieren.

Note

Wenn Sie die CloudWatch Protokollierung aktivieren, erstellt Managed Service für Apache Flink eine Protokollgruppe und einen Protokollstream für Sie. Die Namen dieser Ressourcen lauten wie folgt:

- Protokollgruppe: /aws/kinesis-analytics/MyApplication
- Protokollstream: kinesis-analytics-log-stream

Dieser Protokollstream wird zur Überwachung der Anwendung verwendet. Dies ist nicht derselbe Protokollstream, den die Anwendung zum Senden von Ergebnissen verwendet.

Führen Sie die Anwendung aus.

Das Flink-Jobdiagramm kann angezeigt werden, indem Sie die Anwendung ausführen, das Apache Flink-Dashboard öffnen und den gewünschten Flink-Job auswählen.

Sie können die Metriken des Managed Service für Apache Flink in der CloudWatch Konsole überprüfen, um zu sehen, ob die Anwendung funktioniert.

Bereinigen von AWS -Ressourcen

Dieser Abschnitt enthält Verfahren zur Bereinigung von AWS -Ressourcen, die im Rollierendes Fenster-Tutorial erstellt wurden.

Dieses Thema enthält die folgenden Abschnitte:

- Löschen Sie die Anwendung Managed Service für Apache Flink
- So löschen Sie die Kinesis-Data Streams
- Löschen Sie Ihr Amazon-S3-Objekt und -Bucket
- So löschen Sie die IAM-Ressourcen
- <u>CloudWatch Löschen Sie Ihre Ressourcen</u>

Löschen Sie die Anwendung Managed Service für Apache Flink

- Öffnen Sie die Konsole Managed Service f
 ür Apache unter https://console.aws.amazon.com / flink
- 2. Wählen Sie im Bereich Managed Service für Apache Flink die Option MyApplication.
- 3. Wählen Sie auf der Seite der Anwendung die Option Löschen aus und bestätigen Sie dann den Löschvorgang.

So löschen Sie die Kinesis-Data Streams

- 1. Öffnen Sie die Kinesis-Konsole unter https://console.aws.amazon.com/kinesis.
- 2. Wählen Sie im Bereich Kinesis Data Streams die Option ExampleInputStream.
- 3. Wählen Sie auf der ExampleInputStreamSeite Delete Kinesis Stream aus und bestätigen Sie dann den Löschvorgang.
- 4. Wählen Sie auf der Kinesis-Streams-Seite die ExampleOutputStream, wählen Sie Aktionen, wählen Sie Löschen und bestätigen Sie dann den Löschvorgang.

Löschen Sie Ihr Amazon-S3-Objekt und -Bucket

- 1. Öffnen Sie die Amazon S3 S3-Konsole unter https://console.aws.amazon.com/s3/.
- 2. Wählen Sie den *<username>*Bucket ka-app-code -.
- 3. Wählen Sie Löschen und geben Sie dann den Bucketnamen ein, um das Löschen zu bestätigen.

So löschen Sie die IAM-Ressourcen

1. Öffnen Sie unter https://console.aws.amazon.com/iam/ die IAM-Konsole.

- 2. Wählen Sie in der Navigationsleiste Policies aus.
- 3. Geben Sie in der Filtersteuerung Kinesis ein.
- 4. Wählen Sie die Richtlinie kinesis-analytics-service- MyApplication -us-west-2.
- 5. Klicken Sie auf Richtlinienaktionen und anschließend auf Löschen.
- 6. Wählen Sie in der Navigationsleiste Roles (Rollen) aus.
- 7. Wählen Sie die Rolle kinesis-analytics-us-west-2 MyApplication aus.
- 8. Wählen Sie dann Rolle löschen und bestätigen Sie das Löschen.

CloudWatch Löschen Sie Ihre Ressourcen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie in der Navigationsleiste Protokolle aus.
- 3. Wählen Sie die Gruppe/aws/kinesis-analytics/MyApplicationlog aus.
- 4. Wählen Sie dann Protokollgruppe löschen und bestätigen Sie das Löschen.

Nächste Schritte

Nachdem Sie nun eine grundlegende Managed Service for Apache Flink-Anwendung erstellt und ausgeführt haben, die Daten mithilfe von Apache Beam transformiert, finden Sie in der folgenden Anwendung ein Beispiel für eine erweiterte Managed Service für Apache Flink-Lösung.

• <u>Workshop "Beam on Managed Service for Apache Flink Streaming</u>": In diesem Workshop untersuchen wir ein durchgängiges Beispiel, das Batch- und Streaming-Aspekte in einer einheitlichen Apache Beam-Pipeline kombiniert.

Schulungsworkshops, Labore und Lösungsimplementierungen

Die folgenden end-to-end Beispiele zeigen fortschrittliche Managed Service für Apache Flink-Lösungen.

Themen

- <u>Bereitstellen, Betreiben und Skalieren von Anwendungen mit Amazon Managed Service für Apache</u> <u>Flink</u>
- <u>Entwickeln Sie Apache Flink-Anwendungen lokal, bevor Sie sie auf Managed Service für Apache</u> <u>Flink bereitstellen</u>
- Verwenden Sie die Ereigniserkennung mit Managed Service für Apache Flink Studio
- Verwenden Sie die AWS Streaming-Datenlösung für Amazon Kinesis
- Üben Sie die Nutzung eines Clickstream-Labors mit Apache Flink und Apache Kafka
- Richten Sie benutzerdefinierte Skalierung mit Application Auto Scaling ein
- Sehen Sie sich ein Beispiel für ein CloudWatch Amazon-Dashboard an
- Verwenden Sie Vorlagen für die AWS Streaming-Datenlösung für Amazon MSK
- Weitere Managed Service für Apache Flink-Lösungen finden Sie unter GitHub

Bereitstellen, Betreiben und Skalieren von Anwendungen mit Amazon Managed Service für Apache Flink

Dieser Workshop behandelt die Entwicklung einer Apache Flink-Anwendung in Java, die Ausführung und das Debuggen in Ihrer IDE sowie das Paketieren, Bereitstellen und Ausführen auf Amazon Managed Service für Apache Flink. Außerdem erfahren Sie, wie Sie Ihre Anwendung skalieren, überwachen und Fehler beheben können.

Workshop zu Amazon Managed Service für Apache Flink.

Entwickeln Sie Apache Flink-Anwendungen lokal, bevor Sie sie auf Managed Service für Apache Flink bereitstellen

In diesem Workshop werden die Grundlagen der lokalen Entwicklung von Apache Flink-Anwendungen vermittelt, mit dem langfristigen Ziel, Apache Flink auf Managed Service for Apache Flink zu implementieren.

Leitfaden für Einsteiger zur lokalen Entwicklung mit Apache Flink

Verwenden Sie die Ereigniserkennung mit Managed Service für Apache Flink Studio

Dieser Workshop beschreibt die Ereigniserkennung mit Managed Service für Apache Flink Studio und die Bereitstellung als Anwendung, die Managed Service für Apache Flink nutzt

Ereigniserkennung mit Managed Service für Apache Flink für Apache Flink

Verwenden Sie die AWS Streaming-Datenlösung für Amazon Kinesis

Die AWS Streaming-Datenlösung für Amazon Kinesis konfiguriert automatisch die AWS Dienste, die für die Erfassung, Speicherung, Verarbeitung und Bereitstellung von Streaming-Daten erforderlich sind. Die Lösung bietet mehrere Optionen zur Lösung von Anwendungsfällen mit Streaming-Daten. Die Option Managed Service for Apache Flink bietet ein end-to-end Streaming-ETL-Beispiel, das eine reale Anwendung demonstriert, die analytische Operationen mit simulierten Taxidaten aus New York ausführt.

Jede Lösung enthält die folgenden Komponenten:

- Ein AWS CloudFormation Paket zur Bereitstellung des vollständigen Beispiels.
- Ein CloudWatch Dashboard zur Anzeige von Anwendungsmetriken.
- CloudWatch Alarme zu den relevantesten Anwendungsmetriken.
- Alle erforderlichen IAM-Rollen und -Richtlinien.

Streaming-Datenlösung für Amazon Kinesis

Üben Sie die Nutzung eines Clickstream-Labors mit Apache Flink und Apache Kafka

Ein durchgängiges Labor für Clickstream-Anwendungsfälle mit Amazon Managed Streaming für Apache Kafka als Streaming-Speicher und Managed Service für Apache Flink für Apache-Flink-Anwendungen für die Stream-Verarbeitung.

Clickstream-Labor

Richten Sie benutzerdefinierte Skalierung mit Application Auto Scaling ein

Zwei Beispiele, die Ihnen zeigen, wie Sie Ihren Managed Service für Apache Flink-Anwendungen mithilfe von Application Auto Scaling automatisch skalieren können. Auf diese Weise können Sie benutzerdefinierte Skalierungsrichtlinien und benutzerdefinierte Skalierungsattribute einrichten.

- Verwalteter Dienst für Apache Flink App Autoscaling
- Geplante Skalierung

Weitere Informationen dazu, wie Sie eine benutzerdefinierte Skalierung durchführen können, finden Sie unter Aktivieren der metrikbasierten und geplanten Skalierung für Amazon Managed Service for Apache Flink.

Sehen Sie sich ein Beispiel für ein CloudWatch Amazon-Dashboard an

Ein CloudWatch Beispiel-Dashboard für die Überwachung von Managed Service für Apache Flink-Anwendungen. Das Beispiel-Dashboard enthält auch eine <u>Demo-Anwendung</u>, mit der Sie die Funktionalität des Dashboards demonstrieren können.

Metrik-Dashboard für den verwalteten Dienst für Apache Flink

Verwenden Sie Vorlagen für die AWS Streaming-Datenlösung für Amazon MSK

Die AWS Streaming-Datenlösung für Amazon MSK bietet AWS CloudFormation Vorlagen, in denen Daten durch Produzenten, Streaming-Speicher, Verbraucher und Ziele fließen.

AWS Streaming-Datenlösung für Amazon MSK

Weitere Managed Service für Apache Flink-Lösungen finden Sie unter GitHub

Die folgenden end-to-end Beispiele zeigen erweiterte Managed Service für Apache Flink-Lösungen. Sie sind verfügbar unter: GitHub

- Amazon Managed Service für Apache Flink Benchmarking-Programm
- Snapshot Manager Amazon Managed Service für Apache Flink
- Streamen von ETL mit Apache Flink und Amazon Managed Service für Apache Flink
- Stimmungsanalyse von Kundenfeedback in Echtzeit

Nutzen Sie praktische Hilfsprogramme für Managed Service für Apache Flink

Die folgenden Dienstprogramme können die Verwendung des Services von Managed Service für Apache Flink vereinfachen:

Themen

- Snapshot-Manager
- Benchmarking

Snapshot-Manager

Es ist eine bewährte Methode für Flink-Anwendungen, regelmäßig Savepoints/Snapshots zu initiieren, um eine reibungslosere Wiederherstellung nach einem Ausfall zu ermöglichen. Der Snapshot-Manager automatisiert diese Aufgabe und bietet folgende Vorteile:

- erstellt einen neuen Snapshot einer laufenden Anwendung, die Managed Service f
 ür Apache Flink nutzt
- ruft eine Anzahl von Anwendungs-Snapshots ab
- prüft, ob die Anzahl die erforderliche Anzahl von Snapshots übersteigt
- · löscht ältere Snapshots, die älter als die erforderliche Anzahl sind

Ein Beispiel finden Sie unter Snapshot-Manager.

Benchmarking

Das Benchmarking-Dienstprogramm von Managed Service für Apache Flink hilft bei der Kapazitätsplanung, bei Integrationstests und beim Benchmarking von Anwendungen, die Managed Service für Apache Flink nutzen.

Ein Beispiel finden Sie unter Benchmarking

Beispiele für die Erstellung und Arbeit mit Managed Service für Apache Flink-Anwendungen

Dieser Abschnitt enthält Beispiele für das Erstellen und Arbeiten mit Anwendungen im Managed Service für Apache Flink. Sie enthalten Beispielcode und step-by-step Anweisungen, die Ihnen helfen, Managed Service für Apache Flink-Anwendungen zu erstellen und Ihre Ergebnisse zu testen.

Bevor Sie sich mit diesen Beispielen befassen, empfehlen wir Ihnen, zunächst Folgendes zu lesen:

- Funktionsweise
- Tutorial: Erste Schritte mit der DataStream API in Managed Service für Apache Flink

Note

Bei diesen Beispielen wird davon ausgegangen, dass Sie die Region USA Ost (Nord-Virginia) (us-east-1) verwenden. Wenn Sie eine andere Region verwenden, aktualisieren Sie Ihren Anwendungscode, Ihre Befehle und IAM-Rollen entsprechend.

Themen

- Java-Beispiele für Managed Service für Apache Flink
- Python-Beispiele für Managed Service für Apache Flink
- Scala-Beispiele für Managed Service für Apache Flink

Java-Beispiele für Managed Service für Apache Flink

Die folgenden Beispiele zeigen, wie in Java geschriebene Anwendungen erstellt werden.

Note

Die meisten Beispiele sind so konzipiert, dass sie sowohl lokal auf Ihrem Entwicklungscomputer und der IDE Ihrer Wahl als auch auf Amazon Managed Service für Apache Flink ausgeführt werden können. Sie zeigen die Mechanismen, mit denen Sie Anwendungsparameter übergeben können, und zeigen, wie Sie die Abhängigkeit richtig einstellen, um die Anwendung in beiden Umgebungen ohne Änderungen auszuführen.

Verbessern Sie die Serialisierungsleistung, indem Sie benutzerdefiniert definieren TypeInfo

Dieses Beispiel zeigt, wie Sie Benutzerdefiniert für Ihren Datensatz oder Ihr Statusobjekt definieren, um zu verhindern, dass bei der Serialisierung TypeInfo auf die weniger effiziente Kryo-Serialisierung zurückgegriffen wird. Dies ist beispielsweise erforderlich, wenn Ihre Objekte ein oder enthalten. List Map Weitere Informationen finden Sie unter <u>Datentypen und Serialisierung</u> in der Apache Flink-Dokumentation. Das Beispiel zeigt auch, wie Sie testen können, ob die Serialisierung Ihres Objekts auf die weniger effiziente Kryo-Serialisierung zurückfällt.

Code-Beispiel: CustomTypeInfo

Fangen Sie mit der DataStream API an

Dieses Beispiel zeigt eine einfache Anwendung, die mithilfe der API aus einem Kinesis-Datenstream liest und in einen anderen Kinesis-Datenstream schreibt. DataStream Das Beispiel zeigt, wie Sie die Datei mit den richtigen Abhängigkeiten einrichten, das Uber-JAR erstellen und dann die Konfigurationsparameter analysieren, sodass Sie die Anwendung sowohl lokal, in Ihrer IDE als auch auf Amazon Managed Service for Apache Flink ausführen können.

Codebeispiel: GettingStarted

Erste Schritte mit der Tabellen-API und SQL

Dieses Beispiel zeigt eine einfache Anwendung, die die Table API und SQL verwendet. Es zeigt, wie die DataStream API mit der Table API oder SQL in derselben Java-Anwendung integriert wird. Es zeigt auch, wie der DataGen Konnektor verwendet wird, um zufällige Testdaten aus der Flink-Anwendung selbst heraus zu generieren, ohne dass ein externer Datengenerator erforderlich ist.

Vollständiges Beispiel: GettingStartedTable

Verwenden Sie S3Sink (API) DataStream

Dieses Beispiel zeigt, wie die DataStream APIs verwendet werden, FileSink um JSON-Dateien in einen S3-Bucket zu schreiben.

Codebeispiel: S3Sink

Verwenden Sie eine Kinesis-Quelle, einen Standard- oder EFO-Verbraucher und eine Senke (API) DataStream

Dieses Beispiel zeigt, wie eine Quelle konfiguriert wird, die einen Kinesis-Datenstream nutzt, entweder mit dem Standard-Consumer oder EFO, und wie eine Senke für den Kinesis-Datenstream eingerichtet wird.

Codebeispiel: KinesisConnectors

Verwenden Sie eine Amazon Data Firehose-Senke (DataStreamAPI)

Dieses Beispiel zeigt, wie Daten an Amazon Data Firehose (früher bekannt als Kinesis Data Firehose) gesendet werden.

Codebeispiel: KinesisFirehoseSink

Verwenden Sie den Prometheus-Spülbeckenanschluss

Dieses Beispiel demonstriert die Verwendung des <u>Prometheus-Sink-Connectors zum Schreiben von</u> Zeitreihendaten in Prometheus.

Codebeispiel: PrometheusSink

Verwenden Sie Fensteraggregationen (API) DataStream

In diesem Beispiel werden vier Typen der Windowing-Aggregation in der API demonstriert. DataStream

- 1. Verschiebbares Fenster, das auf der Verarbeitungszeit basiert
- 2. Schiebefenster basierend auf der Ereigniszeit
- 3. TaumeIndes Fenster basierend auf der Verarbeitungszeit
- 4. Tumbling Window basiert auf der Uhrzeit des Ereignisses

Codebeispiel: Windowing

Verwenden benutzerdefinierter Metriken

Dieses Beispiel zeigt, wie Sie Ihrer Flink-Anwendung benutzerdefinierte Metriken hinzufügen und sie an CloudWatch Metriken senden.

Code-Beispiel: CustomMetrics

Verwenden Sie Kafka-Konfigurationsanbieter, um zur Laufzeit einen benutzerdefinierten Keystore und Truststore für MTLs abzurufen

Dieses Beispiel zeigt, wie Sie Kafka-Konfigurationsanbieter verwenden können, um einen benutzerdefinierten Keystore und Truststore mit Zertifikaten für die mTLS-Authentifizierung für den Kafka-Connector einzurichten. Mit dieser Technik können Sie die erforderlichen benutzerdefinierten Zertifikate aus Amazon S3 und die Secrets laden, AWS Secrets Manager wenn die Anwendung gestartet wird.

Codebeispiel: Kafka-MTLS-Keystore - ConfigProviders

Verwenden Sie Kafka-Konfigurationsanbieter, um Geheimnisse für die SASL/SCRAM-Authentifizierung zur Laufzeit abzurufen

Dieses Beispiel zeigt, wie Sie Kafka Configuration Providers verwenden können, um Anmeldeinformationen von Amazon S3 abzurufen AWS Secrets Manager und den Truststore von Amazon S3 herunterzuladen, um die SASL/SCRAM-Authentifizierung auf einem Kafka-Connector einzurichten. Mit dieser Technik können Sie die erforderlichen benutzerdefinierten Zertifikate aus Amazon S3 und die Secrets laden, AWS Secrets Manager wenn die Anwendung gestartet wird.

Codebeispiel: Kafka- - SASL_SSL ConfigProviders

Verwenden Sie Kafka-Konfigurationsanbieter, um zur Laufzeit mit Table API/SQL einen benutzerdefinierten Keystore und Truststore für MTLs abzurufen

Dieses Beispiel zeigt, wie Sie Kafka-Konfigurationsanbieter in der Tabellen-API /SQL verwenden können, um einen benutzerdefinierten Keystore und Truststore mit Zertifikaten für die mTLS-Authentifizierung für den Kafka-Konnektor einzurichten. Mit dieser Technik können Sie die erforderlichen benutzerdefinierten Zertifikate aus Amazon S3 und die Secrets laden, AWS Secrets Manager wenn die Anwendung gestartet wird.

Codebeispiel: <u>Kafka-MTLS-Keystore-SQL</u> - ConfigProviders

Verwenden Sie Side Outputs, um einen Stream aufzuteilen

Dieses Beispiel zeigt, wie <u>Side Outputs</u> in Apache Flink genutzt werden können, um einen Stream nach bestimmten Attributen aufzuteilen. Dieses Muster ist besonders nützlich, wenn versucht wird, das Konzept der Dead Letter Queues (DLQ) in Streaming-Anwendungen zu implementieren.

Codebeispiel: SideOutputs

Verwenden Sie Async I/O, um einen externen Endpunkt aufzurufen

Dieses Beispiel zeigt, wie <u>Apache Flink Async I/O</u> verwendet wird, um einen externen Endpunkt blockierungsfrei aufzurufen, wobei bei behebbaren Fehlern Wiederholungen durchgeführt werden.

Codebeispiel: AsynclO

Python-Beispiele für Managed Service für Apache Flink

Die folgenden Beispiele zeigen, wie in Python geschriebene Anwendungen erstellt werden.

Note

Die meisten Beispiele sind so konzipiert, dass sie sowohl lokal auf Ihrem Entwicklungscomputer und der IDE Ihrer Wahl als auch auf Amazon Managed Service für Apache Flink ausgeführt werden können. Sie demonstrieren den einfachen Mechanismus, mit dem Sie Anwendungsparameter übergeben können, und zeigen, wie Sie die Abhängigkeit richtig einstellen, um die Anwendung in beiden Umgebungen ohne Änderungen auszuführen.

Abhängigkeiten von Projekten

Die meisten PyFlink Beispiele erfordern eine oder mehrere Abhängigkeiten als JAR-Dateien, zum Beispiel für Flink-Konnektoren. Diese Abhängigkeiten müssen dann zusammen mit der Anwendung verpackt werden, wenn sie auf Amazon Managed Service für Apache Flink bereitgestellt werden.

Die folgenden Beispiele enthalten bereits die Tools, mit denen Sie die Anwendung lokal ausführen können, um sie zu entwickeln und zu testen und die erforderlichen Abhängigkeiten korrekt zu verpacken. Dieses Tooling erfordert die Verwendung von Java JDK11 und Apache Maven. Die spezifischen Anweisungen finden Sie in der README-Datei, die in jedem Beispiel enthalten ist.

Beispiele

Fangen Sie an mit PyFlink

Dieses Beispiel demonstriert die grundlegende Struktur einer PyFlink Anwendung, die SQL verwendet, die in Python-Code eingebettet ist. Dieses Projekt bietet auch ein Grundgerüst für jede

PyFlink Anwendung, die JAR-Abhängigkeiten wie Konnektoren enthält. Der README-Abschnitt enthält detaillierte Anleitungen dazu, wie Sie Ihre Python-Anwendung lokal für die Entwicklung ausführen können. Das Beispiel zeigt auch, wie Sie eine einzelne JAR-Abhängigkeit, in diesem Beispiel den Kinesis-SQL-Connector, in Ihre PyFlink Anwendung einbeziehen können.

Codebeispiel: GettingStarted

Python-Abhängigkeiten hinzufügen

Dieses Beispiel zeigt, wie Sie Ihrer PyFlink Anwendung auf allgemeinste Weise Python-Abhängigkeiten hinzufügen können. Diese Methode funktioniert für einfache Abhängigkeiten wie Boto3 oder komplexe Abhängigkeiten, die C-Bibliotheken enthalten, wie z. PyArrow

Codebeispiel: PythonDependencies

Verwenden Sie Fensteraggregationen (API) DataStream

Dieses Beispiel demonstriert vier Typen der Fensteraggregation in SQL, eingebettet in eine Python-Anwendung.

- 1. Sliding Window auf der Grundlage der Verarbeitungszeit
- 2. Schiebefenster basierend auf der Ereigniszeit
- 3. TaumeIndes Fenster basierend auf der Verarbeitungszeit
- 4. Tumbling Window basiert auf der Uhrzeit des Ereignisses

Codebeispiel: Windowing

Verwenden Sie eine S3-Senke

Dieses Beispiel zeigt, wie Sie Ihre Ausgabe als JSON-Dateien in Amazon S3 schreiben, indem Sie SQL verwenden, das in eine Python-Anwendung eingebettet ist. Sie müssen Checkpointing aktivieren, damit die S3-Senke Dateien auf Amazon S3 schreiben und rotieren kann.

Codebeispiel: S3Sink

Verwenden Sie eine benutzerdefinierte Funktion (UDF)

Dieses Beispiel zeigt, wie Sie eine benutzerdefinierte Funktion definieren, sie in Python implementieren und sie in SQL-Code verwenden, der in einer Python-Anwendung ausgeführt wird.

Codebeispiel: UDF

Verwenden Sie eine Amazon Data Firehose-Senke

Dieses Beispiel zeigt, wie Daten mithilfe von SQL an Amazon Data Firehose gesendet werden.

Code-Beispiel: FirehoseSink

Scala-Beispiele für Managed Service für Apache Flink

In den folgenden Beispielen wird die Erstellung von Anwendungen über Scala mit Apache Flink gezeigt.

Richten Sie eine mehrstufige Anwendung ein

Dieses Beispiel zeigt, wie eine Flink-Anwendung in Scala eingerichtet wird. Es zeigt, wie das SBT-Projekt so konfiguriert wird, dass es Abhängigkeiten enthält und das Uber-JAR erstellt.

Code-Beispiel: GettingStarted

Amazon Managed Service für Apache Flink verwenden

Cloud-Sicherheit hat AWS bei höchste Priorität. Als AWS -Kunde profitieren Sie von einer Rechenzentrums- und Netzwerkarchitektur, die zur Erfüllung der Anforderungen von Organisationen entwickelt wurden, für die Sichherheit eine kritische Bedeutung hat.

Sicherheit ist eine übergreifende Verantwortlichkeit zwischen AWS und Ihnen. Das <u>Modell der</u> <u>geteilten Verantwortung</u> beschreibt dies als Sicherheit der Cloud und Sicherheit in der Cloud:

- Sicherheit der Cloud AWS ist zuständig für den Schutz der Infrastruktur, die AWS -Services in der AWS -Cloud ausführt. AWS stellt Ihnen Dienste bereit, die Sie sicher verwenden können. Die Wirksamkeit unserer Sicherheitsfunktionen wird regelmäßig von externen Prüfern im Rahmen des <u>AWS -Compliance-Programms getestet und überprüft</u>. Weitere Informationen zu den für Managed Service für Apache Flink geltenden Compliance-Programmen finden Sie unter <u>Im Rahmen des</u> <u>Compliance-Programms zugelassene AWS -Services</u>.
- Sicherheit in der Cloud Ihr Verantwortungsumfang wird durch den AWS -Service bestimmt, den Sie verwenden. In Ihre Verantwortung fallen außerdem weitere Faktoren, wie z. B. die Vertraulichkeit der Daten, die Anforderungen Ihrer Organisation sowie geltende Gesetze und Vorschriften.

Diese Dokumentation hilft Ihnen zu verstehen, wie Sie das Modell der geteilten Verantwortung bei der Verwendung von Managed Service für Apache Flink einsetzen können. Die folgenden Themen veranschaulichen, wie Sie Managed Service für Apache Flink zur Erfüllung Ihrer Sicherheits- und Compliance-Ziele konfigurieren können. Sie erfahren außerdem, wie Sie andere Amazon-Services verwenden können, die Ihnen beim Überwachen und Sichern Ihrer Managed Service für Apache Flink-Ressourcen helfen.

Themen

- Datenschutz in Amazon Managed Service für Apache Flink
- Identity and Access Management für Amazon Managed Service für Apache Flink
- <u>Compliance-Validierung für Amazon Managed Service für Apache Flink</u>
- Ausfallsicherheit in Amazon Managed Service für Apache Flink
- Infrastruktursicherheit in Managed Service für Apache Flink
- Bewährte Methoden für die Sicherheit für Managed Service für Apache Flink

Datenschutz in Amazon Managed Service für Apache Flink

Sie können Ihre Daten mithilfe von Tools schützen, die von bereitgestellt werden AWS. Managed Service für Apache Flink kann mit Diensten zusammenarbeiten, die die Verschlüsselung von Daten unterstützen, einschließlich Firehose und Amazon S3.

Datenverschlüsselung in Managed Service für Apache Flink

Verschlüsselung im Ruhezustand

Beachten Sie die folgenden Informationen zur Verschlüsselung von Daten im Ruhezustand mit Managed Service für Apache Flink:

- Sie können Daten im eingehenden Kinesis-Datenstrom mit verschlüsseln. <u>StartStreamEncryption</u> Weitere Informationen finden Sie unter <u>Was bedeutet eine serverseitige Verschlüsselung in</u> Kinesis-Daten-Streams?.
- Ausgabedaten können mithilfe von Firehose im Ruhezustand verschlüsselt werden, um Daten in einem verschlüsselten Amazon-S3-Bucket zu speichern. Sie können den Schlüssel angeben, der von Ihrem Amazon-S3-Bucket zur Verschlüsselung verwendet wird. Weitere Informationen hierzu finden Sie unter <u>Daten schützen durch serverseitige Verschlüsselung mit KMS-verwalteten</u> Schlüsseln (SSE-KMS).
- Managed Service f
 ür Apache Flink kann von jeder Streaming-Quelle lesen und in jedes Streamingoder Datenbankziel schreiben. Stellen Sie sicher, dass Ihre Quellen und Ziele alle Daten w
 ährend der Übertragung und alle Daten im Ruhezustand verschl
 üsseln.
- Der Code Ihrer Anwendung wird im Ruhezustand verschlüsselt.
- Der langlebige Anwendungsspeicher wird im Ruhezustand verschlüsselt.
- Der laufende Anwendungsspeicher ist im Ruhezustand verschlüsselt.

Verschlüsselung während der Übertragung

Managed Service für Apache Flink verschlüsselt alle Daten während der Übertragung. Die Verschlüsselung während der Übertragung ist für alle Managed Service für Apache Flink-Anwendungen aktiviert und kann nicht deaktiviert werden.

Managed Service für Apache Flink verschlüsselt Daten während der Übertragung in den folgenden Szenarien:

- Daten werden von Kinesis Data Streams an Managed Service für Apache Flink übertragen.
- Daten werden zwischen internen Komponenten innerhalb von Managed Service für Apache Flink übertragen.
- Daten werden zwischen Managed Service für Apache Flink und Firehose übertragen.

Schlüsselverwaltung

Die Datenverschlüsselung in Managed Service für Apache Flink verwendet vom Service verwaltete Schlüssel. Vom Kunden verwaltete Schlüssel werden nicht unterstützt.

Identity and Access Management für Amazon Managed Service für Apache Flink

AWS Identity and Access Management (IAM) ist ein AWS-Service, mit dem ein Administrator den Zugriff auf AWS -Ressourcen sicher steuern kann. IAM-Administratoren steuern, wer für die Verwendung von Managed Service für Apache Flink-Ressourcen authentifiziert (angemeldet) und autorisiert (Berechtigungen haben) sein kann. IAM ist ein AWS-Service, den Sie ohne zusätzliche Kosten verwenden können.

Themen

- Zielgruppe
- Authentifizierung mit Identitäten
- Verwalten des Zugriffs mit Richtlinien
- So funktioniert Amazon Managed Service für Apache Flink mit IAM
- Beispiele für identitätsbasierte Richtlinien für Amazon Managed Service für Apache Flink
- Problembehandlung bei Identität und Zugriff auf Amazon Managed Service für Apache Flink
- Serviceübergreifende Confused-Deputy-Prävention

Zielgruppe

Wie Sie AWS Identity and Access Management (IAM) verwenden, unterscheidet sich je nach Ihrer Arbeit in Managed Service für Apache Flink.

Service-Benutzer – Wenn Sie den Managed Service für Apache Flink-Service zur Ausführung von Aufgaben verwenden, stellt Ihnen Ihr Administrator die Anmeldeinformationen und Berechtigungen bereit, die Sie benötigen. Wenn Sie für Ihre Arbeit weitere Features von Managed Service für Apache Flink verwenden, benötigen Sie möglicherweise zusätzliche Berechtigungen. Wenn Sie die Funktionsweise der Zugriffskontrolle nachvollziehen, wissen Sie bereits, welche Berechtigungen Sie von Ihrem Administrator anfordern müssen. Wenn Sie nicht auf ein Feature in Managed Service für Apache Flink zugreifen können, informieren Sie sich unter Problembehandlung bei Identität und Zugriff auf Amazon Managed Service für Apache Flink.

Service-Administrator – Wenn Sie in Ihrem Unternehmen für Managed Service für Apache Flink-Ressourcen verantwortlich sind, haben Sie wahrscheinlich vollständigen Zugriff auf Managed Service für Apache Flink. Es ist Ihre Aufgabe, zu bestimmen, auf welche Features und Ressourcen von Managed Service für Apache Flink Ihre Service-Benutzer zugreifen sollen. Anschließend müssen Sie Anforderungen an Ihren IAM-Administrator senden, um die Berechtigungen der Servicebenutzer zu ändern. Lesen Sie die Informationen auf dieser Seite, um die Grundkonzepte von IAM nachzuvollziehen. Weitere Informationen dazu, wie Ihr Unternehmen IAM mit Managed Service für Apache Flink verwenden kann, finden Sie unter <u>So funktioniert Amazon Managed Service für</u> Apache Flink mit IAM.

IAM-Administrator – Wenn Sie als IAM-Administrator fungieren, sollten Sie Einzelheiten dazu kennen, wie Sie Richtlinien zur Verwaltung des Zugriffs auf Managed Service für Apache Flink verfassen können. Beispiele für identitätsbasierte Managed Service für Apache Flink-Richtlinien, die Sie in IAM verwenden können, finden Sie unter <u>Beispiele für identitätsbasierte Richtlinien für Amazon Managed</u> Service für Apache Flink.

Authentifizierung mit Identitäten

Die Authentifizierung ist die Art und Weise, wie Sie sich AWS mit Ihren Anmeldeinformationen bei anmelden. Die Authentifizierung (Anmeldung bei AWS) muss als Root-Benutzer des AWS-Kontos, als IAM-Benutzer oder durch Übernahme einer IAM-Rolle erfolgen.

Sie können sich bei AWS als Verbundidentität mit Anmeldeinformationen anmelden, die über eine Identitätsquelle bereitgestellt werden. Verwenden Sie die Anmeldeinformationen aus, die über eine Identitätsquelle bereitgestellt werden. Verwenden Sie die Anmeldeinformationen AWS IAM Identity Center (IAM Identity Center), die Single-Sign-on-Authentifizierung Ihres Unternehmens und Anmeldeinformationen für Google oder Facebook sind Beispiele für Verbundidentitäten. Wenn Sie sich als Verbundidentität anmelden, hat der Administrator vorher mithilfe von IAM-Rollen einen Identitätsverbund eingerichtet. Wenn Sie auf AWS mithilfe des Verbunds zugreifen, übernehmen Sie indirekt eine Rolle.

Je nachdem, welcher Benutzertyp Sie sind, können Sie sich bei der AWS Management Console oder beim AWS -Zugriffsportal anmelden. Weitere Informationen zur Anmeldung finden Sie AWS unter <u>So</u> melden Sie sich bei Ihrem an AWS-Konto im AWS-Anmeldung Benutzerhandbuch.

Bei AWS programmgesteuerten Zugriff auf AWS bietet ein Software Development Kit (SDK) und eine Befehlszeilenschnittstelle (Command Line Interface, CLI) um Ihrer Anfragen mit Ihren Anmeldeinformationen kryptographisch zu signieren. Wenn Sie keine AWS -Tools verwenden, müssen Sie Anforderungen selbst signieren. Weitere Informationen zur Verwendung der empfohlenen Methode für die Selbstsignierung von Anforderungen finden Sie unter <u>AWS Signature</u> <u>Version 4 für API-Anforderungen</u> im IAM-Benutzerhandbuch.

Unabhängig von der verwendeten Authentifizierungsmethode müssen Sie möglicherweise zusätzliche Sicherheitsinformationen bereitstellen. AWS empfiehlt beispielsweise die Verwendung von Multi-Factor Authentication (MFA), um die Sicherheit Ihres Kontos zu verbessern. Weitere Informationen finden Sie unter <u>Multi-Faktor-Authentifizierung</u> im AWS IAM Identity Center - Benutzerhandbuch und <u>AWS Multi-Faktor-Authentifizierung (MFA) in IAM</u> im IAM-Benutzerhandbuch.

AWS-Konto -Stammbenutzer

Wenn Sie ein erstellen AWS-Konto, beginnen Sie mit einer Anmeldeidentität, die vollständigen Zugriff auf alle AWS-Services und Ressourcen des Kontos hat. Diese Identität wird als AWS-Konto Root-Benutzer bezeichnet. Für den Zugriff auf den Root-Benutzer müssen Sie sich mit der E-Mail-Adresse und dem Passwort anmelden, die zur Erstellung des Kontos verwendet wurden. Wir raten ausdrücklich davon ab, den Root-Benutzer für Alltagsaufgaben zu verwenden. Schützen Sie Ihre Root-Benutzer-Anmeldeinformationen. Verwenden Sie diese nur, um die Aufgaben auszuführen, die nur der Root-Benutzer ausführen kann. Eine vollständige Liste der Aufgaben, für die Sie sich als Root-Benutzer anmelden müssen, finden Sie unter Aufgaben, die Root-Benutzer-Anmeldeinformationen im IAM-Benutzerhandbuch.

Verbundidentität

Als bewährte Methode empfiehlt es sich, menschliche Benutzer, einschließlich Benutzer, die Administratorzugriff benötigen, aufzufordern, den Verbund mit einem Identitätsanbieter zu verwenden, AWS-Services um auf mit temporären Anmeldeinformationen zuzugreifen.

Eine Verbundidentität ist ein Benutzer aus dem Benutzerverzeichnis Ihres Unternehmens, ein Web Identity Provider, AWS Directory Service, das Identity-Center-Verzeichnis oder jeder Benutzer, der mit Anmeldeinformationen, die über eine AWS-Services Identitätsquelle bereitgestellt werden, auf zugreift. Wenn Verbundidentitäten auf zugreifen AWS-Konten, übernehmen sie Rollen und die Rollen stellen temporäre Anmeldeinformationen bereit.

Für die zentrale Zugriffsverwaltung empfehlen wir Ihnen, AWS IAM Identity Center zu verwenden. Sie können Benutzer und Gruppen in IAM Identity Center erstellen oder Sie können eine Verbindung mit einer Gruppe von Benutzern und Gruppen in Ihrer eigenen Identitätsquelle herstellen und synchronisieren, um sie in allen AWS-Konten und Anwendungen zu verwenden. Informationen zu IAM Identity Center finden Sie unter <u>Was ist IAM Identity Center?</u> im AWS IAM Identity Center -Benutzerhandbuch.

IAM-Benutzer und -Gruppen

Ein <u>IAM-Benutzer</u> ist eine Entität in Ihrem AWS-Konto mit bestimmten Berechtigungen für eine einzelne Person oder eine einzelne Anwendung. Wenn möglich, empfehlen wir, temporäre Anmeldeinformationen zu verwenden, anstatt IAM-Benutzer zu erstellen, die langfristige Anmeldeinformationen wie Passwörter und Zugriffsschlüssel haben. Bei speziellen Anwendungsfällen, die langfristige Anmeldeinformationen mit IAM-Benutzern erfordern, empfehlen wir jedoch, die Zugriffsschlüssel zu rotieren. Weitere Informationen finden Sie unter <u>Regelmäßiges</u> <u>Rotieren von Zugriffsschlüsseln für Anwendungsfälle, die langfristige Anmeldeinformationen erfordern</u> im IAM-Benutzerhandbuch.

Eine <u>IAM-Gruppe</u> ist eine Identität, die eine Sammlung von IAM-Benutzern angibt. Sie können sich nicht als Gruppe anmelden. Mithilfe von Gruppen können Sie Berechtigungen für mehrere Benutzer gleichzeitig angeben. Gruppen vereinfachen die Verwaltung von Berechtigungen, wenn es zahlreiche Benutzer gibt. Sie könnten beispielsweise einer Gruppe einen Namen geben IAMAdminsund dieser Gruppe Berechtigungen zum Verwalten von IAM-Ressourcen erteilen.

Benutzer unterscheiden sich von Rollen. Ein Benutzer ist einer einzigen Person oder Anwendung eindeutig zugeordnet. Eine Rolle kann von allen Personen angenommen werden, die sie benötigen. Benutzer besitzen dauerhafte Anmeldeinformationen. Rollen stellen temporäre Anmeldeinformationen bereit. Weitere Informationen finden Sie unter <u>Anwendungsfälle für IAM-Benutzer</u> im IAM-Benutzerhandbuch.

IAM-Rollen

Eine <u>IAM-Rolle</u> ist eine Identität innerhalb von Ihnen AWS-Konto , die über bestimmte Berechtigungen verfügt. Sie ist einem IAM-Benutzer vergleichbar, jedoch nicht mit einer bestimmten Person verknüpft. Um vorübergehend eine IAM-Rolle in der zu übernehmen AWS Management Console, können Sie von einem Benutzer zu einer IAM-Rolle (Konsole) wechseln. Sie können eine Rolle annehmen, indem Sie eine - AWS CLI oder AWS -API-Operation aufrufen oder eine benutzerdefinierte URL verwenden. Weitere Informationen zu Methoden für die Verwendung von Rollen finden Sie unter Methoden für die Übernahme einer Rolle im IAM-Benutzerhandbuch.

IAM-Rollen mit temporären Anmeldeinformationen sind in folgenden Situationen hilfreich:

- Verbundbenutzerzugriff Um einer Verbundidentität Berechtigungen zuzuweisen, erstellen Sie eine Rolle und definieren Berechtigungen für die Rolle. Wird eine Verbundidentität authentifiziert, so wird die Identität der Rolle zugeordnet und erhält die von der Rolle definierten Berechtigungen. Informationen zu Rollen für den Verbund finden Sie unter <u>Erstellen von Rollen für externe</u> <u>Identitätsanbieter (Verbund)</u> im IAM-Benutzerhandbuch. Wenn Sie IAM Identity Center verwenden, konfigurieren Sie einen Berechtigungssatz. Wenn Sie steuern möchten, worauf Ihre Identitäten nach der Authentifizierung zugreifen können, korreliert IAM Identity Center den Berechtigungssatz mit einer Rolle in IAM. Informationen zu Berechtigungssätzen finden Sie unter <u>Berechtigungssätze</u> im AWS IAM Identity Center -Benutzerhandbuch.
- Temporäre IAM-Benutzerberechtigungen Ein IAM-Benutzer oder eine -Rolle kann eine IAM-Rolle übernehmen, um vorübergehend andere Berechtigungen für eine bestimmte Aufgabe zu erhalten.
- Kontoübergreifender Zugriff Sie können eine IAM-Rolle verwenden, um einem vertrauenswürdigen Prinzipal in einem anderen Konto den Zugriff auf Ressourcen in Ihrem Konto zu ermöglichen. Rollen stellen die primäre Möglichkeit dar, um kontoübergreifendem Zugriff zu gewähren. In einigen können Sie AWS-Services jedoch eine Richtlinie direkt an eine Ressource anfügen (anstatt eine Rolle als Proxy zu verwenden). Informationen zu den Unterschieden zwischen Rollen und ressourcenbasierten Richtlinien für den kontoübergreifenden Zugriff finden Sie unter Kontoübergreifender Ressourcenzugriff in IAM im IAM-Benutzerhandbuch.
- Serviceübergreifender Zugriff Einige AWS-Services verwenden Funktionen in anderen AWS-Services. Wenn Sie beispielsweise einen Aufruf in einem Service tätigen, führt dieser Service häufig Anwendungen in Amazon aus EC2 oder speichert Objekte in Amazon S3. Ein Dienst kann dies mit den Berechtigungen des aufrufenden Prinzipals mit einer Servicerolle oder mit einer serviceverknüpften Rolle tun.
 - Forward Access Sessions (FAS) Wenn Sie einen IAM-Benutzer oder eine IAM-Rolle zum Ausführen von Aktionen in verwenden AWS, gelten Sie als Prinzipal. Bei einigen Services könnte es Aktionen geben, die dann eine andere Aktion in einem anderen Service initiieren. FAS verwendet die Berechtigungen des Prinzipals, der einen aufruft AWS-Service, in Kombination mit der Anforderung an den, Anforderungen AWS-Service an nachgelagerte Services zu stellen. FAS-Anforderungen werden nur dann gestellt, wenn ein Dienst eine Anforderung erhält, die

Interaktionen mit anderen AWS-Services oder Ressourcen erfordert, um abgeschlossen werden zu können. In diesem Fall müssen Sie über Berechtigungen zum Ausführen beider Aktionen verfügen. Einzelheiten zu den Richtlinien für FAS-Anfragen finden Sie unter Zugriffssitzungen weiterleiten.

- Servicerolle Eine Servicerolle ist eine <u>IAM-Rolle</u>, die ein Service übernimmt, um Aktionen in Ihrem Namen auszuführen. Ein IAM-Administrator kann eine Servicerolle innerhalb von IAM erstellen, ändern und löschen. Weitere Informationen finden Sie unter <u>Erstellen einer Rolle zum</u> <u>Delegieren von Berechtigungen an einen AWS-Service</u> im IAM-Benutzerhandbuch.
- Serviceverknüpfte Rolle Eine serviceverknüpfte Rolle ist ein Typ von Servicerolle, die mit einem verknüpft ist. AWS-Service Der Service kann die Rolle übernehmen, um eine Aktion in Ihrem Namen auszuführen. Serviceverknüpfte Rollen werden in Ihrem angezeigt AWS-Konto und gehören zum Service. Ein IAM-Administrator kann die Berechtigungen für Service-verknüpfte Rollen anzeigen, aber nicht bearbeiten.
- Anwendungen in Amazon EC2 Sie können eine IAM-Rolle nutzen, um temporäre Anmeldeinformationen für Anwendungen zu verwalten, die auf einer EC2 Instance ausgeführt werden und AWS CLI oder AWS -API-Anforderungen durchführen. Das ist empfehlenswerter als Zugriffsschlüssel innerhalb der EC2 Instance zu speichern. Erstellen Sie ein Instance-Profil, das an die EC2 Instance angefügt ist, um eine AWS -Rolle einer -Instance zuzuweisen und die Rolle für sämtliche Anwendungen der Instance bereitzustellen. Ein Instance-Profil enthält die Rolle und ermöglicht Programmen, die auf der EC2 Instance ausgeführt werden, temporäre Anmeldeinformationen zu erhalten. Weitere Informationen finden Sie unter <u>Verwenden einer IAM-Rolle zum Erteilen von Berechtigungen für Anwendungen, die auf EC2 Amazon-Instances ausgeführt werden im IAM-Benutzerhandbuch.</u>

Verwalten des Zugriffs mit Richtlinien

Für die Zugriffssteuerung in AWS erstellen Sie Richtlinien und weisen sie den AWS -Identitäten oder -Ressourcen zu. Eine Richtlinie ist ein Objekt in, AWS das, wenn es einer Identität oder Ressource zugeordnet wird, deren Berechtigungen definiert. AWS wertet diese Richtlinien aus, wenn ein Prinzipal (Benutzer, Root-Benutzer oder Rollensitzung) eine Anforderung stellt. Die Berechtigungen in den Richtlinien legen fest, ob eine Anforderung zugelassen oder abgelehnt wird. Die meisten Richtlinien werden in AWS als JSON-Dokumente gespeichert. Weitere Informationen zu Struktur und Inhalten von JSON-Richtliniendokumenten finden Sie unter <u>Übersicht über JSON-Richtlinien</u> im IAM-Benutzerhandbuch.

Administratoren können mithilfe von AWS -JSON-Richtlinien festzulegen, welche Personen zum Zugriff auf welche Ressourcen berechtigt sind. Das heißt, welcher Prinzipal Aktionen für welche Ressourcen und unter welchen Bedingungen ausführen kann.

Standardmäßig haben Benutzer, Gruppen und Rollen keine Berechtigungen. Ein IAM-Administrator muss IAM-Richtlinien erstellen, die Benutzern die Berechtigung erteilen, Aktionen für die Ressourcen auszuführen, die sie benötigen. Der Administrator kann dann die IAM-Richtlinien zu Rollen hinzufügen, und Benutzer können die Rollen annehmen.

IAM-Richtlinien definieren Berechtigungen für eine Aktion unabhängig von der Methode, die Sie zur Ausführung der Aktion verwenden. Angenommen, es gibt eine Richtlinie, die Berechtigungen für die iam:GetRole-Aktion erteilt. Ein Benutzer mit dieser Richtlinie kann Rolleninformationen von der AWS Management Console AWS CLI, der oder der AWS API abrufen.

Identitätsbasierte Richtlinien

Identitätsbasierte Richtlinien sind JSON-Berechtigungsrichtliniendokumente, die Sie einer Identität anfügen können, wie z. B. IAM-Benutzern, -Benutzergruppen oder -Rollen. Diese Richtlinien steuern, welche Aktionen die Benutzer und Rollen für welche Ressourcen und unter welchen Bedingungen ausführen können. Informationen zum Erstellen identitätsbasierter Richtlinien finden Sie unter Definieren benutzerdefinierter IAM-Berechtigungen mit vom Kunden verwalteten Richtlinien im IAM-Benutzerhandbuch.

Identitätsbasierte Richtlinien können weiter als Inline-Richtlinien oder verwaltete Richtlinien kategorisiert werden. Inline-Richtlinien sind direkt in einen einzelnen Benutzer, eine einzelne Gruppe oder eine einzelne Rolle eingebettet. Verwaltete Richtlinien sind eigenständige Richtlinien, die Sie mehreren Benutzern, Gruppen und Rollen in Ihrem anfügen können AWS-Konto. Verwaltete Richtlinien umfassen von AWS verwaltete und von Kunden verwaltete Richtlinien. Informationen dazu, wie Sie zwischen einer verwalteten Richtlinie und einer Inline-Richtlinie wählen, finden Sie unter Auswählen zwischen verwalteten und eingebundenen Richtlinien im IAM-Benutzerhandbuch.

Ressourcenbasierte Richtlinien

Ressourcenbasierte Richtlinien sind JSON-Richtliniendokumente, die Sie an eine Ressource anfügen. Beispiele für ressourcenbasierte Richtlinien sind IAM-Rollen-Vertrauensrichtlinien und Amazon-S3-Bucket-Richtlinien. In Services, die ressourcenbasierte Richtlinien unterstützen, können Service-Administratoren sie verwenden, um den Zugriff auf eine bestimmte Ressource zu steuern. Für die Ressource, an welche die Richtlinie angehängt ist, legt die Richtlinie fest, welche Aktionen ein bestimmter Prinzipal unter welchen Bedingungen für diese Ressource ausführen kann. Sie müssen in einer ressourcenbasierten Richtlinie <u>einen Prinzipal angeben</u>. Prinzipale können Konten, Benutzer, Rollen, Verbundbenutzer oder umfassen. AWS-Services

Ressourcenbasierte Richtlinien sind Richtlinien innerhalb dieses Diensts. Sie können AWS - verwaltete Richtlinien von IAM nicht in einer ressourcenbasierten Richtlinie verwenden.

Zugriffskontrolllisten (ACLs)

Zugriffskontrolllisten (ACLs) steuern, welche Prinzipale (Kontomitglieder, Benutzer oder Rollen) auf eine Ressource zugreifen können. ACLs sind ähnlich wie ressourcenbasierten Richtlinien, verwenden jedoch nicht das JSON-Richtliniendokumentformat.

Amazon S3 AWS WAF, und Amazon VPC sind Beispiele für Services, die Unterstützung ACLs von. Weitere Informationen ACLs dazu finden Sie unter <u>Zugriffskontrollliste (ACL) — Übersicht (Access</u> <u>Control List) — Übersicht</u> im Entwicklerhandbuch zu Amazon Simple Storage Service.

Weitere Richtlinientypen

AWS unterstützt zusätzliche, weniger häufig verwendete Richtlinientypen. Diese Richtlinientypen können die maximalen Berechtigungen festlegen, die Ihnen von den häufiger verwendeten Richtlinientypen erteilt werden können.

- Berechtigungsgrenzen Eine Berechtigungsgrenze ist ein erweitertes Feature, mit der Sie die maximalen Berechtigungen festlegen können, die eine identitätsbasierte Richtlinie einer IAM-Entität (IAM-Benutzer oder -Rolle) erteilen kann. Sie können eine Berechtigungsgrenze für eine Entität festlegen. Die daraus resultierenden Berechtigungen sind der Schnittpunkt der identitätsbasierten Richtlinien einer Entität und ihrer Berechtigungsgrenzen. Ressourcenbasierte Richtlinien, die den Benutzer oder die Rolle im Feld Principal angeben, werden nicht durch Berechtigungsgrenzen eingeschränkt. Eine explizite Zugriffsverweigerung in einer dieser Richtlinien setzt eine Zugriffserlaubnis außer Kraft. Weitere Informationen über Berechtigungsgrenzen finden Sie unter Berechtigungsgrenzen für IAM-Entitäten im IAM-Benutzerhandbuch.
- Service-Kontrollrichtlinien (SCPs) SCPs sind JSON-Richtlinien, die die maximalen Berechtigungen f
 ür eine Organisation oder Organisationseinheit (OU) in angeben AWS Organizations. AWS Organizations ist ein Service f
 ür die Gruppierung und zentrale Verwaltung AWS-Konten der Ihres Unternehmens. Wenn Sie innerhalb einer Organisation alle Funktionen aktivieren, k
 önnen Sie Service-Kontrollrichtlinien (SCPs) auf einzelne oder alle Ihrer Konten anwenden. Eine SCP beschr
 änkt die Berechtigungen f
 ür Entit
 äten in Mitgliedskonten, einschlie
 ßlich des jeweiligen Root-Benutzer des AWS-Kontos. Weitere Informationen zu

Organizations und SCPs finden Sie unter <u>Richtlinien zur Servicesteuerung</u> im AWS Organizations Benutzerhandbuch.

- Ressourcenkontrollrichtlinien (RCPs) RCPs sind JSON-Richtlinien, mit denen Sie die maximal verfügbare Zahl von Berechtigungen für Ressourcen in Ihren Konten festlegen können, ohne die IAM-Richtlinien aktualisieren zu müssen, die jeder Ressource in Ihrem Besitz angefügt sind. Die RCP schränkt die Berechtigungen für Ressourcen in Mitgliedskonten ein und kann sich auf die effektiven Berechtigungen für Identitäten auswirken, einschließlich der Root-Benutzer des AWS-Kontos, unabhängig davon, ob sie zu Ihrer Organisation gehören. Weitere Informationen zu Organizations RCPs, einschließlich einer Liste AWS-Services dieser Support-Leistungen RCPs, finden Sie unter <u>Resource Control Policies (RCPs)</u> im AWS Organizations Benutzerhandbuch.
- Sitzungsrichtlinien Sitzungsrichtlinien sind erweiterte Richtlinien, die Sie als Parameter übergeben, wenn Sie eine temporäre Sitzung für eine Rolle oder einen verbundenen Benutzer programmgesteuert erstellen. Die resultierenden Sitzungsberechtigungen sind eine Schnittmenge der auf der Identität des Benutzers oder der Rolle basierenden Richtlinien und der Sitzungsrichtlinien. Berechtigungen können auch aus einer ressourcenbasierten Richtlinie stammen. Eine explizite Zugriffsverweigerung in einer dieser Richtlinien setzt eine Zugriffserlaubnis außer Kraft. Weitere Informationen finden Sie unter <u>Sitzungsrichtlinien</u> im IAM-Benutzerhandbuch.

Mehrere Richtlinientypen

Wenn mehrere auf eine Anforderung mehrere Richtlinientypen angewendet werden können, sind die entsprechenden Berechtigungen komplizierter. Informationen dazu, wie AWS die Zulässigkeit einer Anforderung ermittelt, wenn mehrere Richtlinientypen beteiligt sind, finden Sie unter Logik für die Richtlinienauswertung im IAM-Benutzerhandbuch.

So funktioniert Amazon Managed Service für Apache Flink mit IAM

Bevor Sie IAM zum Verwalten des Zugriffs auf Managed Service für Apache Flink verwenden, erfahren Sie, welche IAM-Features Sie mit Managed Service for Apache Flink verwenden können.

IAM-Features, die Sie mit Amazon Managed Service für Apache Flink verwenden können

IAM-Feature	Support für Managed Service für Apache Flink
Identitätsbasierte Richtlinien	Ja

IAM-Feature	Support für Managed Service für Apache Flink
Ressourcenbasierte Richtlinien	Nein
Richtlinienaktionen	Ja
Richtlinienressourcen	Ja
Bedingungsschlüssel für die Richtlinie	Nein
ACLs	Nein
ABAC (Tags in Richtlinien)	Ja
Temporäre Anmeldeinformationen	Ja
Prinzipalberechtigungen	Ja
Servicerollen	Nein
Serviceverknüpfte Rollen	Nein

Einen Überblick über das Zusammenwirken von Managed Service für Apache Flink und anderen AWS -Services mit den meisten IAM-Features finden Sie unter <u>AWS -Services, die mit IAM</u> <u>funktionieren im Handbuch für IAM-Benutzer</u>.

Identitätsbasierte Richtlinien für Managed Service für Apache Flink

Unterstützt Richtlinien auf Identitätsbasis: Ja

Identitätsbasierte Richtlinien sind JSON-Berechtigungsrichtliniendokumente, die Sie einer Identität anfügen können, wie z. B. IAM-Benutzern, -Benutzergruppen oder -Rollen. Diese Richtlinien steuern, welche Aktionen die Benutzer und Rollen für welche Ressourcen und unter welchen Bedingungen ausführen können. Informationen zum Erstellen identitätsbasierter Richtlinien finden Sie unter Definieren benutzerdefinierter IAM-Berechtigungen mit vom Kunden verwalteten Richtlinien im IAM-Benutzerhandbuch.

Mit identitätsbasierten IAM-Richtlinien können Sie angeben, welche Aktionen und Ressourcen zugelassen oder abgelehnt werden. Darüber hinaus können Sie die Bedingungen festlegen, unter denen Aktionen zugelassen oder abgelehnt werden. Sie können den Prinzipal nicht in einer

identitätsbasierten Richtlinie angeben, da er für den Benutzer oder die Rolle gilt, dem er zugeordnet ist. Informationen zu sämtlichen Elementen, die Sie in einer JSON-Richtlinie verwenden, finden Sie in der IAM-Referenz für JSON-Richtlinienelemente im IAM-Benutzerhandbuch.

Beispiele für identitätsbasierte Richtlinien für Managed Service für Apache Flink

Beispiele für identitätsbasierte Managed Service für Apache Flink-Richtlinien, finden Sie unter Beispiele für identitätsbasierte Richtlinien für Amazon Managed Service für Apache Flink.

Ressourcenbasierte Richtlinien in Managed Service für Apache Flink

Amazon Managed Service für Apache Flink unterstützt derzeit keine ressourcenbasierte Zugriffskontrolle.

Kontoübergreifender Zugriff auf -Ressourcen aus der Anwendung Managed Service für Apache Flink

Um einer Managed Service for Apache Flink-Anwendung Zugriff auf eine Ressource wie einen Amazon Kinesis Kinesis-Stream oder einen Amazon S3 S3-Bucket zu gewähren, müssen Sie eine IAM-Rolle im Konto der Ressource erstellen. Die Rolle muss über IAM-Berechtigungen für den Zugriff auf die Ressource verfügen. Sie müssen auch eine Vertrauensrichtlinie hinzufügen, die das gesamte Konto der Anwendung Managed Service for Apache Flink autorisiert, die Rolle zu übernehmen.

Darüber hinaus muss die IAM-Rolle, die der Anwendung Managed Service für Apache Flink zugewiesen wurde, die Übernahme der Rolle im Ressourcenkonto ermöglichen.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "AllowAssumingRoleInStreamAccount",
            "Effect": "Allow",
            "Action": "sts:AssumeRole",
            "Resource": "arn:aws:iam::Stream-account-ID:role/Role-to-assume"
        }
    ]
}
```

Weitere Informationen finden Sie unter Kontoübergreifender Ressourcenzugriff in IAM im IAM-Benutzerhandbuch.

Richtlinienaktionen für Managed Service für Apache Flink

Unterstützt Richtlinienaktionen: Ja

Administratoren können mithilfe von AWS -JSON-Richtlinien festzulegen, welche Personen zum Zugriff auf welche Ressourcen berechtigt sind. Das heißt, welcher Prinzipal Aktionen für welche Ressourcen und unter welchen Bedingungen ausführen kann.

Das Element Action einer JSON-Richtlinie beschreibt die Aktionen, mit denen Sie den Zugriff in einer Richtlinie zulassen oder verweigern können. Richtlinienaktionen haben normalerweise denselben Namen wie die zugehörige AWS -API-Operation. Es gibt einige Ausnahmen, z. B. Aktionen, die nur mit Genehmigung durchgeführt werden können und für die es keinen passenden API-Vorgang gibt. Es gibt auch einige Operationen, die mehrere Aktionen in einer Richtlinie erfordern. Diese zusätzlichen Aktionen werden als abhängige Aktionen bezeichnet.

Schließen Sie Aktionen in eine Richtlinie ein, um Berechtigungen zur Durchführung der zugeordneten Operation zu erteilen.

Eine Liste der Managed Service für Apache Flink-Aktionen finden Sie unter <u>Von Amazon Managed</u> Service für Apache Flink definierte Aktionen in der Referenz für die Service-Autorisierung.

Richtlinienaktionen in Managed Service für Apache Flink verwenden das folgende Präfix vor der Aktion:

Kinesis Analytics

So funktioniert Amazon Managed Service für Apache Flink mit IAM

Um mehrere Aktionen in einer einzigen Anweisung anzugeben, trennen Sie sie mit Kommata:

```
"Action": [
    "Kinesis Analytics:action1",
    "Kinesis Analytics:action2"
    ]
```

Sie können auch Platzhalter verwenden, um mehrere Aktionen anzugeben. Beispielsweise können Sie alle Aktionen festlegen, die mit dem Wort Describe beginnen, einschließlich der folgenden Aktion:

"Action": "Kinesis Analytics:Describe*"

Beispiele für identitätsbasierte Managed Service für Apache Flink-Richtlinien, finden Sie unter Beispiele für identitätsbasierte Richtlinien für Amazon Managed Service für Apache Flink.

Richtlinienressourcen für Managed Service für Apache Flink

Unterstützt Richtlinienressourcen: Ja

Administratoren können mithilfe von AWS -JSON-Richtlinien festzulegen, welche Personen zum Zugriff auf welche Ressourcen berechtigt sind. Das heißt, welcher Prinzipal Aktionen für welche Ressourcen und unter welchen Bedingungen ausführen kann.

Das JSON-Richtlinienelement Resource gibt die Objekte an, auf welche die Aktion angewendet wird. Anweisungen müssen entweder ein – Resourceoder ein NotResource-Element enthalten. Als bewährte Methode geben Sie eine Ressource mit dem zugehörigen <u>Amazon-Ressourcennamen</u> (<u>ARN</u>) an. Sie können dies für Aktionen tun, die einen bestimmten Ressourcentyp unterstützen, der als Berechtigungen auf Ressourcenebene bezeichnet wird.

Verwenden Sie für Aktionen, die keine Berechtigungen auf Ressourcenebene unterstützen, z. B. Auflistungsoperationen, einen Platzhalter (*), um anzugeben, dass die Anweisung für alle Ressourcen gilt.

"Resource": "*"

Eine Liste der Managed Service für Apache Flink Ressourcentypen und ihrer ARNs finden Sie unter Von Amazon Managed Service für Apache Flink definierte Ressourcen in der Referenz für die
Service-Autorisierung. Informationen zu den Aktionen, mit denen Sie den ARN einzelner Ressourcen angeben können, finden Sie unter <u>Von Amazon Managed Service für Apache Flink definierte</u> <u>Aktionen</u>.

Beispiele für identitätsbasierte Managed Service für Apache Flink-Richtlinien, finden Sie unter Beispiele für identitätsbasierte Richtlinien für Amazon Managed Service für Apache Flink.

Richtlinienbedingungsschlüssel für Managed Service für Apache Flink

Unterstützt servicespezifische Richtlinienbedingungsschlüssel: Ja

Administratoren können mithilfe von AWS -JSON-Richtlinien festzulegen, welche Personen zum Zugriff auf welche Ressourcen berechtigt sind. Das heißt, welcher Prinzipal kann Aktionen für welche Ressourcen und unter welchen Bedingungen ausführen.

Das Element Condition (oder Condition block) ermöglicht Ihnen die Angabe der Bedingungen, unter denen eine Anweisung wirksam ist. Das Element Condition ist optional. Sie können bedingte Ausdrücke erstellen, die <u>Bedingungsoperatoren</u> verwenden, z. B. ist gleich oder kleiner als, damit die Bedingung in der Richtlinie mit Werten in der Anforderung übereinstimmt.

Wenn Sie mehrere Condition-Elemente in einer Anweisung oder mehrere Schlüssel in einem einzelnen Condition-Element angeben, wertet AWS diese mittels einer logischen AND-Operation aus. Wenn Sie mehrere Werte für einen einzelnen Bedingungsschlüssel angeben, AWS wertet die Bedingung mittels einer logischen OR -Operation aus. Alle Bedingungen müssen erfüllt werden, bevor die Berechtigungen der Anweisung gewährt werden.

Sie können auch Platzhaltervariablen verwenden, wenn Sie Bedingungen angeben. Beispielsweise können Sie einem IAM-Benutzer die Berechtigung für den Zugriff auf eine Ressource nur dann gewähren, wenn sie mit dessen IAM-Benutzernamen gekennzeichnet ist. Weitere Informationen finden Sie unter IAM-Richtlinienelemente: Variablen und Tags im IAM-Benutzerhandbuch.

AWS unterstützt globale Bedingungsschlüssel und servicespezifische Bedingungsschlüssel. Eine Liste aller AWS globalen -Bedingungsschlüssel finden Sie unter <u>AWS Globale -</u> Bedingungskontextschlüssel im IAM-Benutzerhandbuch.

Eine Liste der Managed Service für Apache Flink-Bedingungsschlüssel finden Sie unter <u>Bedingungsschlüssel für Amazon Managed Service für Apache Flink</u> in der Referenz für die Service-Autorisierung. Informationen dazu, mit welchen Aktionen und Ressourcen Sie einen Bedingungsschlüssel verwenden können, finden Sie unter Von Amazon Managed Service für Apache Flink definierte Aktionen.

Beispiele für identitätsbasierte Managed Service für Apache Flink-Richtlinien, finden Sie unter Beispiele für identitätsbasierte Richtlinien für Amazon Managed Service für Apache Flink.

Zugriffskontrolllisten (ACLs) in Managed Service für Apache Flink

Unterstützt ACLs: Nein

Zugriffskontrolllisten (ACLs) steuern, welche Prinzipale (Kontomitglieder, Benutzer oder Rollen) auf eine Ressource zugreifen können. ACLs sind ähnlich wie ressourcenbasierten Richtlinien, verwenden jedoch nicht das JSON-Richtliniendokumentformat.

Attributbasierte Zugriffskontrolle (ABAC) mit Managed Service für Apache Flink

Unterstützt ABAC (Tags in Richtlinien): Ja

Die attributbasierte Zugriffskontrolle (ABAC) ist eine Autorisierungsstrategie, bei der Berechtigungen basierend auf Attributen definiert werden. In AWS werden diese Attribute als Tags bezeichnet. Sie können Tags an IAM-Entitäten (Benutzer oder Rollen) und mehrere AWS -Ressourcen anhängen. Das Markieren von Entitäten und Ressourcen ist der erste Schritt von ABAC. Anschließend entwerfen Sie ABAC-Richtlinien, um Operationen zuzulassen, wenn das Tag des Prinzipals mit dem Tag der Ressource übereinstimmt, auf die sie zugreifen möchten.

ABAC ist in Umgebungen hilfreich, die schnell wachsen, und unterstützt Sie in Situationen, in denen die Richtlinienverwaltung mühsam wird.

Um den Zugriff auf der Grundlage von Tags zu steuern, geben Sie im Bedingungselement einer <u>Richtlinie Tag-Informationen</u> an, indem Sie die Schlüssel aws:ResourceTag/*key-name*, aws:RequestTag/*key-name*, oder Bedingung aws:TagKeys verwenden.

Wenn ein Service alle drei Bedingungsschlüssel für jeden Ressourcentyp unterstützt, lautet der Wert für den Service Ja. Wenn ein Service alle drei Bedingungsschlüssel für nur einige Ressourcentypen unterstützt, lautet der Wert Teilweise.

Weitere Informationen zu ABAC finden Sie unter <u>Definieren von Berechtigungen mit ABAC-</u> <u>Autorisierung</u> im IAM-Benutzerhandbuch. Um ein Tutorial mit Schritten zur Einstellung von ABAC anzuzeigen, siehe Attributbasierte Zugriffskontrolle (ABAC) verwenden im IAM-Benutzerhandbuch.

Temporäre Anmeldeinformationen mit Managed Service für Apache Flink verwenden

Unterstützt temporäre Anmeldeinformationen: Ja

Einige funktionieren AWS-Services nicht, wenn Sie sich mit temporären Anmeldeinformationen anmelden. Weitere Informationen, darunter welche mit temporären Anmeldeinformationen AWS-Services funktionieren, finden Sie unter, <u>AWS-Services die mit IAM funktionieren</u> im IAM-Benutzerhandbuch.

Sie verwenden temporäre Anmeldeinformationen, wenn Sie sich mit einer anderen AWS Management Console Methode als einem Benutzernamen und einem Passwort bei der anmelden. Wenn Sie beispielsweise AWS über den Single Sign-On (SSO) -Link Ihres Unternehmens auf zugreifen, erstellt dieser Prozess automatisch temporäre Anmeldeinformationen. Sie erstellen auch automatisch temporäre Anmeldeinformationen, wenn Sie sich als Benutzer bei der Konsole anmelden und dann die Rollen wechseln. Weitere Informationen zum Wechseln von Rollen finden Sie unter Wechseln von einer Benutzerrolle zu einer IAM-Rolle (Konsole) im IAM-Benutzerhandbuch.

Sie können mithilfe der - AWS CLI oder AWS -API manuell temporäre Anmeldeinformationen erstellen. Sie können diese temporären Anmeldeinformationen dann für den Zugriff verwenden AWS. AWS empfiehlt, dass Sie temporäre Anmeldeinformationen dynamisch generieren, anstatt langfristige Zugriffsschlüssel zu verwenden. Weitere Informationen finden Sie unter <u>Temporäre</u> Sicherheitsanmeldeinformationen in IAM.

Serviceübergreifende Prinzipal-Berechtigungen für Managed Service für Apache Flink

Unterstützt Forward Access Sessions (FAS): Ja

Wenn Sie einen IAM-Benutzer oder eine IAM-Rolle zum Ausführen von Aktionen in verwenden AWS, gelten Sie als Prinzipal. Bei einigen Services könnte es Aktionen geben, die dann eine andere Aktion in einem anderen Service initiieren. FAS verwendet die Berechtigungen des Prinzipals, der einen aufruft AWS-Service, in Kombination mit der Anforderung an den, Anforderungen AWS-Service an nachgelagerte Services zu stellen. FAS-Anforderungen werden nur dann gestellt, wenn ein Dienst eine Anforderung erhält, die Interaktionen mit anderen AWS-Services oder Ressourcen erfordert, um abgeschlossen werden zu können. In diesem Fall müssen Sie über Berechtigungen zum Ausführen beider Aktionen verfügen. Einzelheiten zu den Richtlinien für FAS-Anfragen finden Sie unter Zugriffssitzungen weiterleiten.

Servicerollen für Managed Service für Apache Flink

Unterstützt Servicerollen: Ja

So funktioniert Amazon Managed Service für Apache Flink mit IAM

Eine Servicerolle ist eine <u>IAM-Rolle</u>, die ein Service annimmt, um Aktionen in Ihrem Namen auszuführen. Ein IAM-Administrator kann eine Servicerolle innerhalb von IAM erstellen, ändern und löschen. Weitere Informationen finden Sie unter <u>Erstellen einer Rolle zum Delegieren von</u> Berechtigungen an einen AWS-Service im IAM-Benutzerhandbuch.

🔥 Warning

Das Ändern der Berechtigungen für eine Servicerolle könnte die Funktionalität von Managed Service für Apache Flink beeinträchtigen. Bearbeiten Sie Servicerollen nur, wenn Managed Service für Apache Flink dazu Anleitungen gibt.

Serviceverknüpfte Rollen für Managed Service für Apache Flink

Unterstützt dienstbezogene Rollen: Ja

Eine serviceverknüpfte Rolle ist eine Art von Servicerolle, die mit einem AWS-Service verknüpft ist. Der Service kann die Rolle übernehmen, um eine Aktion in Ihrem Namen auszuführen. Serviceverknüpfte Rollen werden in Ihrem angezeigt AWS-Konto und gehören zum Service. Ein IAM-Administrator kann die Berechtigungen für Service-verknüpfte Rollen anzeigen, aber nicht bearbeiten.

Details zum Erstellen oder Verwalten von serviceverknüpften Rollen finden Sie unter <u>AWS -Services</u>, <u>die mit IAM funktionieren</u>. Suchen Sie in der Tabelle nach einem Service mit einem Yes in der Spalte Service-linked role (Serviceverknüpfte Rolle). Wählen Sie den Link Yes (Ja) aus, um die Dokumentation für die serviceverknüpfte Rolle für diesen Service anzuzeigen.

Beispiele für identitätsbasierte Richtlinien für Amazon Managed Service für Apache Flink

Benutzer und Rollen besitzen standardmäßig keine Berechtigungen zum Erstellen oder Ändern von Managed Service für Apache Flink-Ressourcen. Sie können auch keine Aufgaben mithilfe der AWS API AWS Management Console, AWS Command Line Interface (AWS CLI) oder ausführen. Ein IAM-Administrator muss IAM-Richtlinien erstellen, die Benutzern die Berechtigung erteilen, Aktionen für die Ressourcen auszuführen, die sie benötigen. Der Administrator kann dann die IAM-Richtlinien zu Rollen hinzufügen, und Benutzer können die Rollen annehmen.

Informationen dazu, wie Sie unter Verwendung dieser beispielhaften JSON-Richtliniendokumente eine identitätsbasierte IAM-Richtlinie erstellen, finden Sie unter <u>Erstellen von IAM-Richtlinien</u> (Konsole) im IAM-Benutzerhandbuch.

Einzelheiten zu den von Managed Service für Apache Flink definierten Aktionen und Ressourcentypen, einschließlich des Formats der ARNs für die einzelnen Ressourcentypen, finden Sie unter <u>Aktionen, Ressourcen und Bedingungsschlüssel für Amazon Managed Service für Apache</u> Flink in der Referenz für die Service-Autorisierung.

Themen

- Bewährte Methoden für Richtlinien
- Nutzung der Managed Service für Apache Flink-Konsole
- Gewähren der Berechtigung zur Anzeige der eigenen Berechtigungen für Benutzer

Bewährte Methoden für Richtlinien

Identitätsbasierte Richtlinien legen fest, ob jemand Managed Service für Apache Flink-Ressourcen in Ihrem Konto erstellen, darauf zugreifen oder sie löschen kann. Dies kann zusätzliche Kosten für Ihr verursachen AWS-Konto. Befolgen Sie beim Erstellen oder Bearbeiten identitätsbasierter Richtlinien die folgenden Anleitungen und Empfehlungen:

- Erste Schritte mit AWS -verwaltete Richtlinien und Umstellung auf Berechtigungen mit den geringsten Berechtigungen — Um Ihren Benutzern und Workloads Berechtigungen zu gewähren, verwenden Sie die AWS -verwaltete Richtlinien die Berechtigungen für viele häufige Anwendungsfälle gewähren. Sie sind in Ihrem verfügbar. AWS-Konto Wir empfehlen Ihnen, die Berechtigungen weiter zu reduzieren, indem Sie vom AWS Kunden verwaltete Richtlinien definieren, die speziell auf Ihre Anwendungsfälle zugeschnitten sind. Weitere Informationen finden Sie unter <u>AWS -verwaltete Richtlinien</u> oder <u>AWS -verwaltete Richtlinien für Auftrags-Funktionen</u> im IAM-Benutzerhandbuch.
- Anwendung von Berechtigungen mit den geringsten Rechten Wenn Sie mit IAM-Richtlinien Berechtigungen festlegen, gewähren Sie nur die Berechtigungen, die für die Durchführung einer Aufgabe erforderlich sind. Sie tun dies, indem Sie die Aktionen definieren, die für bestimmte Ressourcen unter bestimmten Bedingungen durchgeführt werden können, auch bekannt als die geringsten Berechtigungen. Weitere Informationen zur Verwendung von IAM zum Anwenden von Berechtigungen finden Sie unter <u>Richtlinien und Berechtigungen in IAM</u> im IAM-Benutzerhandbuch.
- Verwenden von Bedingungen in IAM-Richtlinien zur weiteren Einschränkung des Zugriffs Sie können Ihren Richtlinien eine Bedingung hinzufügen, um den Zugriff auf Aktionen und Ressourcen zu beschränken. Sie können beispielsweise eine Richtlinienbedingung schreiben, um festzulegen, dass alle Anforderungen mithilfe von SSL gesendet werden müssen. Sie können

auch Bedingungen verwenden, um den Zugang zu Dienstaktionen zu gewähren, wenn diese durch ein bestimmtes AWS-Service, wie beispielsweise, verwendet werden AWS CloudFormation. Weitere Informationen finden Sie unter <u>IAM-JSON-Richtlinienelemente: Bedingung</u> im IAM-Benutzerhandbuch.

- Verwenden von IAM Access Analyzer zur Validierung Ihrer IAM-Richtlinien, um sichere und funktionale Berechtigungen zu gewährleisten – IAM Access Analyzer validiert neue und vorhandene Richtlinien, damit die Richtlinien der IAM-Richtliniensprache (JSON) und den bewährten IAM-Methoden entsprechen. IAM Access Analyzer stellt mehr als 100 Richtlinienprüfungen und umsetzbare Empfehlungen zur Verfügung, damit Sie sichere und funktionale Richtlinien erstellen können. Weitere Informationen finden Sie unter <u>Richtlinienvalidierung mit IAM Access Analyzer</u> im IAM-Benutzerhandbuch.
- Bedarf einer Multi-Faktor-Authentifizierung (MFA) Wenn Sie ein Szenario haben, das IAM-Benutzer oder Root-Benutzer in Ihrem erfordert AWS-Konto, aktivieren Sie MFA für zusätzliche Sicherheit. Um MFA beim Aufrufen von API-Vorgängen anzufordern, fügen Sie Ihren Richtlinien MFA-Bedingungen hinzu. Weitere Informationen finden Sie unter <u>Sicherer API-Zugriff mit MFA</u> im IAM-Benutzerhandbuch.

Weitere Informationen zu bewährten Methoden in IAM finden Sie unter <u>Bewährte Methoden für die</u> <u>Sicherheit in IAM</u> im IAM-Benutzerhandbuch.

Nutzung der Managed Service für Apache Flink-Konsole

Um auf die Amazon Managed Service für Apache Flink-Konsole zugreifen zu können, müssen Sie über einen Mindestsatz von Berechtigungen verfügen. Diese Berechtigungen müssen Ihnen das Auflisten und Anzeigen von Details zu den Managed Service für Apache Flink-Ressourcen in Ihrem

AWS-Konto gestatten. Wenn Sie eine identitätsbasierte Richtlinie erstellen, die strenger ist als die mindestens erforderlichen Berechtigungen, funktioniert die Konsole nicht wie vorgesehen für Entitäten (Benutzer oder Rollen) mit dieser Richtlinie.

Für Benutzer, die nur Aufrufe an die AWS CLI oder AWS -API durchführen, müssen Sie keine Mindestberechtigungen in der Konsole erteilen. Stattdessen sollten Sie nur Zugriff auf die Aktionen zulassen, die der API-Operation entsprechen, die die Benutzer ausführen möchten.

Um sicherzustellen, dass Benutzer und Rollen weiterhin die Managed Service für Apache Flink-Konsole verwenden können, fügen Sie den Entitäten auch den Managed Service für Apache Flink - ConsoleAccess oder ReadOnly AWS -Managed Service für Apache Flink-Richtlinie hinzu. Weitere Informationen finden Sie unter <u>Hinzufügen von Berechtigungen zu einem Benutzer</u> im IAM-Benutzerhandbuch.

Gewähren der Berechtigung zur Anzeige der eigenen Berechtigungen für Benutzer

In diesem Beispiel wird gezeigt, wie Sie eine Richtlinie erstellen, die IAM-Benutzern die Berechtigung zum Anzeigen der eingebundenen Richtlinien und verwalteten Richtlinien gewährt, die ihrer Benutzeridentität angefügt sind. Diese Richtlinie enthält Berechtigungen für die Ausführung dieser Aktion auf der Konsole oder für die programmgesteuerte Ausführung über die AWS CLI oder AWS die -API.

```
{
    "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": "*"
        }
    ]
```

Problembehandlung bei Identität und Zugriff auf Amazon Managed Service für Apache Flink

Verwenden Sie die folgenden Informationen, um häufige Probleme zu diagnostizieren und zu beheben, die beim Arbeiten mit Managed Service für Apache Flink und IAM auftreten könnten.

Themen

}

- Ich bin nicht berechtigt, eine Aktion in Managed Service für Apache Flink durchzuführen
- Ich bin nicht zur Ausführung von iam autorisiert: PassRole
- Ich möchte Personen außerhalb meines AWS -Kontos Zugriff auf meine Managed Service für Apache Flink-Ressourcen erteilen

Ich bin nicht berechtigt, eine Aktion in Managed Service für Apache Flink durchzuführen

Wenn die Ihnen AWS Management Console mitteilt, dass Sie nicht zur Ausführung einer Aktion autorisiert sind, müssen Sie sich an Ihren Administrator wenden, um Unterstützung zu erhalten. Ihr Administrator ist die Person, die Ihnen Ihren Benutzernamen und Ihr Passwort bereitgestellt hat.

Der folgende Beispielfehler tritt auf, wenn der mateojackson-Benutzer versucht, die Konsole zum Anzeigen von Details zu einer fiktiven *my-example-widget*-Ressource zu verwenden, jedoch nicht über Kinesis Analytics: *GetWidget*-Berechtigungen verfügt.

```
User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform: Kinesis Analytics:GetWidget on resource: my-example-widget
```

In diesem Fall bittet Mateo seinen Administrator um die Aktualisierung seiner Richtlinien, um unter Verwendung der Aktion *my-example-widget* auf die Ressource Kinesis Analytics: *GetWidget* zugreifen zu können.

Ich bin nicht zur Ausführung von iam autorisiert: PassRole

Wenn Sie die Fehlermeldung erhalten, dass Sie nicht zum Durchführen der iam: PassRole-Aktion autorisiert sind, müssen Ihre Richtlinien aktualisiert werden, um eine Rolle an Managed Service für Apache Flink übergeben zu können.

Einige AWS-Services erlauben die Übergabe einer vorhandenen Rolle an diesen Service, sodass keine neue Servicerolle oder serviceverknüpfte Rolle erstellt werden muss. Hierzu benötigen Sie Berechtigungen für die Übergabe der Rolle an den Dienst.

Der folgende Beispielfehler tritt auf, wenn ein IAM-Benutzer mit dem Namen marymajor versucht, die Konsole zu verwenden, um eine Aktion in Managed Service für Apache Flink auszuführen. Die Aktion erfordert jedoch, dass der Service über Berechtigungen verfügt, die durch eine Servicerolle gewährt werden. Mary besitzt keine Berechtigungen für die Übergabe der Rolle an den Dienst.

```
User: arn:aws:iam::123456789012:user/marymajor is not authorized to perform: iam:PassRole
```

In diesem Fall müssen die Richtlinien von Mary aktualisiert werden, um die Aktion iam: PassRole ausführen zu können.

Wenden Sie sich an Ihren AWS -Administrator, falls Sie weitere Unterstützung benötigen. Ihr Administrator hat Ihnen Ihre Anmeldeinformationen zur Verfügung gestellt.

Ich möchte Personen außerhalb meines AWS -Kontos Zugriff auf meine Managed Service für Apache Flink-Ressourcen erteilen

Sie können eine Rolle erstellen, die Benutzer in anderen Konten oder Personen außerhalb Ihrer Organisation für den Zugriff auf Ihre Ressourcen verwenden können. Sie können festlegen, wem die Übernahme der Rolle anvertraut wird. Bei Services, die ressourcenbasierte Richtlinien oder Zugriffskontrolllisten (ACLs) unterstützen, können Sie diese Richtlinien verwenden, um Personen Zugriff auf Ihre Ressourcen zu gewähren.

Weitere Informationen dazu finden Sie hier:

- Informationen dazu, ob Managed Service f
 ür Apache Flink diese Features unterst
 ützt, finden Sie unter So funktioniert Amazon Managed Service f
 ür Apache Flink mit IAM.
- Informationen zum Gewähren des Zugriffs auf Ihre Ressourcen f
 ür alle AWS-Konten Ihre finden Sie unter <u>Gewähren des Zugriffs f
 ür einen IAM-Benutzer in einem anderen AWS-Konto Ihrer</u> im IAM-Benutzerhandbuch.

- Informationen dazu, wie Sie -Drittanbieter Zugriff auf Ihre Ressourcen <u>bereitstellen AWS-</u> <u>Konten, finden Sie unter AWS-Konten Gewähren von Zugriff auf von externen</u> Benutzern im IAM-Benutzerhandbuch.
- Informationen dazu, wie Sie über einen Identitätsverbund Zugriff gewähren, finden Sie unter <u>Gewähren von Zugriff für extern authentifizierte Benutzer (Identitätsverbund)</u> im IAM-Benutzerhandbuch.
- Informationen zum Unterschied zwischen der Verwendung von Rollen und ressourcenbasierten Richtlinien für den kontoübergreifenden Zugriff finden Sie unter <u>Kontoübergreifender</u> <u>Ressourcenzugriff in IAM</u> im IAM-Benutzerhandbuch.

Serviceübergreifende Confused-Deputy-Prävention

Ein dienstübergreifender Identitätswechsel kann in auftreten AWS, wenn ein Dienst (der aufrufende Dienst) einen anderen Dienst aufruft (den aufgerufenen Dienst). Der aufrufende Service kann so manipuliert werden, dass er auf die Ressourcen eines anderen Kunden reagiert, obwohl er nicht über die entsprechenden Berechtigungen verfügen sollte, was zu einem Verwirrter-Stellvertreter-Problem führt.

Zur Confused-Deputy-Prävention AWS stellt Tools zur Verfügung, die Ihnen helfen, Ihre Daten für alle Services zu schützen, die Serviceprinzipale verwenden, die Zugriff auf Ressourcen in Ihrem Konto erhalten haben. In diesem Abschnitt wird speziell für Managed Service für Apache Flink die Vermeidung von serviceübergreifenden Problemen mit confused Deputys behandelt. Weitere Informationen zu diesem Thema finden Sie jedoch im IAM-Benutzerhandbuch im Abschnitt Das Problem mit confused Deputys.

Im Kontext von Managed Service für Apache Flink empfehlen wir, die SourceAccount globalen Bedingungskontextschlüssel <u>aws: SourceArn</u> <u>und aws:</u> in Ihrer Rollenvertrauensrichtlinie zu verwenden, um den Zugriff auf die Rolle nur auf die Anfragen zu beschränken, die von erwarteten Ressourcen generiert werden.

Verwenden Sie aws:SourceArn, wenn Sie nur eine Ressource mit dem betriebsübergreifenden Zugriff verknüpfen möchten. Verwenden Sie aws:SourceAccount, wenn Sie zulassen möchten, dass Ressourcen in diesem Konto mit der betriebsübergreifenden Verwendung verknüpft werden.

Der Wert von aws:SourceArn muss die ARN der von Managed Service für Apache Flink verwendeten Ressource sein, die im folgenden Format angegeben wird: arn:aws:kinesisanalytics:region:account:resource. Der effektivste Weg, um sich vor dem Confused-Deputy-Problem zu schützen, ist die Verwendung des globalen aws:SourceArn-Bedingungskontextschlüssels mit dem vollständigen ARN der Ressource.

Wenn Sie den vollständigen ARN der Ressource nicht kennen oder wenn Sie mehrere Ressourcen angeben, verwenden Sie den globalen aws:SourceArn-Schlüssel mit Platzhalterzeichen (*) für die unbekannten Teile des ARN. Beispiel: arn:aws:kinesisanalytics::111122223333:*.

Richtlinien für Rollen, die Sie Managed Service für Apache Flink zur Verfügung stellen, sowie Vertrauensrichtlinien für Rollen, die für Sie generiert wurden, können diese Schlüssel verwenden.

Um sich vor dem Confused-Deputy-Problem zu schützen, führen Sie die folgenden Schritte durch:

Schutz vor dem Verwirrter-Stellvertreter-Problem

- 1. Melden Sie sich bei der AWS -Managementkonsole an und öffnen Sie die IAM-Konsole unter https://console.aws.amazon.com/iam/.
- 2. Wählen Sie Rollen und dann die Rolle aus, die Sie ändern möchten.
- 3. Wählen Sie Vertrauensrichtlinie bearbeiten aus.
- 4. Ersetzen Sie auf der Seite Vertrauensrichtlinie bearbeiten die Standard-JSON-Richtlinie durch eine Richtlinie, die einen oder beide der globalen Bedingungskontextschlüssel aws:SourceArn und die aws:SourceAccount verwendet. Im Folgenden ist eine Beispielrichtlinie aufgeführt:
- 5. Wählen Sie Richtlinie aktualisieren.

```
{
   "Version":"2012-10-17",
   "Statement":[
      {
         "Effect":"Allow",
         "Principal":{
            "Service": "kinesisanalytics.amazonaws.com"
         },
         "Action":"sts:AssumeRole",
         "Condition":{
            "StringEquals":{
               "aws:SourceAccount":"Account ID"
            },
            "ArnEquals":{
               "aws:SourceArn":"arn:aws:kinesisanalytics:us-
east-1:123456789012:application/my-app"
            }
```

}

]	}	
}			

Compliance-Validierung für Amazon Managed Service für Apache Flink

Externe Prüfer bewerten im Rahmen verschiedener AWS -Compliance-Programme die Sicherheit und Compliance von Amazon Managed Service für Apache Flink. Zu diesen Programmen gehören SOC, PCI, HIPAA und andere.

Eine Liste der AWS -Services, die in den Geltungsbereich bestimmter Compliance-Programme fallen, finden Sie unter. Allgemeine Informationen finden Sie unter <u>AWS -Compliance-Programme</u>.

Die Auditberichte von Drittanbietern lassen sich mit herunterlade AWS Artifact. Weitere Informationen finden Sie unter Herunterladen von Berichten in AWS Artifact.

Ihre Compliance-Verantwortung bei Verwendung von Managed Service für Apache Flink hängt von der Vertraulichkeit der Daten, den Compliance-Zielen des Unternehmens und den geltenden Gesetzen und Vorschriften ab. Wenn Ihre Nutzung von Managed Service für Apache Flink von der Einhaltung von Standards wie HIPAA oder PCI abhängig ist, stellt AWS Ressourcen zur Unterstützung bereit:

- Kurzanleitungen f
 ür Sicherheit und Compliance In diesen Bereitstellungsleitf
 äden finden Sie wichtige Überlegungen zur Architektur sowie die einzelnen Schritte zur Bereitstellung von sicherheits- und Compliance-orientierten Basisumgebungen in. AWS
- <u>Erstellen von Architekturen f
 ür HIPAA-Sicherheit und -Compliance in Amazon Web Services</u>. Dieses Whitepaper beschreibt, wie Unternehmen mithilfe von AWS HIPAA-konforme Anwendungen erstellen.
- <u>AWS -Compliance-Ressourcen</u> Diese Arbeitsbücher und Leitfäden könnten für Ihre Branche und Ihren Standort interessant sein.
- <u>AWS Config</u>— Dieser AWS -Service bewertet, zu welchem Grad die Konfiguration Ihrer Ressourcen den internen Vorgehensweisen, Branchenrichtlinien und Vorschriften entspricht.
- <u>AWS Security Hub</u>— Dieser AWS -Service liefert einen umfassenden Überblick über den Sicherheitsstatus in. So können Sie AWS die Compliance mit den Sicherheitsstandards in der Branche und den bewährten Methoden abgleichen.

FedRAMP

Das AWS -FedRAMP-Compliance-Programm umfasst Managed Service für Apache Flink als FedRAMP-konformen Service. Wenn Sie ein Bundeskunde oder gewerblicher Kunde sind, können Sie den Service verwenden, um sensible Workloads innerhalb der Autorisierungsgrenze der Region AWS GovCloud (US) mit Daten bis zur höchsten Einflussstufe sowie den Regionen USA Ost (Nord-Virginia), USA West (Nordkalifornien) und USA West (Oregon) mit Daten bis zur moderaten Stufe zu verarbeiten und speichern.

Sie können den Zugang zu den AWS -FedRAMP-Sicherheitspaketen über das FedRAMP PMO, Ihren AWS -Sales-Account-Manager beantragen oder Sie können über -Artifact unter -Artifact unter -Artifact unter -Artifact heruntergeladen werden. AWSAWS

Weitere Informationen finden Sie unter FedRAMP.

Ausfallsicherheit in Amazon Managed Service für Apache Flink

Im Zentrum der AWS globalen -Infrastruktur stehen AWS Regionen und Availability Zones (Verfügbarkeitszonen, AZs). AWS Regionen stellen mehrere physisch getrennte und isolierte Availability Zones bereit, die über hoch redundante Netzwerke mit niedriger Latenz und hohen Durchsätzen verbunden sind. Mithilfe von Availability Zones können Sie Anwendungen und Datenbanken erstellen und ausführen, die automatisch Failover zwischen Availability Zones ausführen, ohne dass es zu Unterbrechungen kommt. Availability Zones sind besser hoch verfügbar, fehlertoleranter und skalierbarer als herkömmliche Infrastrukturen mit einem oder mehreren Rechenzentren.

Weitere Informationen zu AWS Regionen und Availability Zones finden Sie unter <u>AWS Globale -</u> Infrastruktur.

Zusätzlich zur AWS globalen -Infrastruktur stellt Managed Service für Apache Flink verschiedene Features bereit, um Ihren Anforderungen in Bezug auf Ausfallsicherheit und Datensicherung zu erfüllen.

Notfallwiederherstellung

Managed Service für Apache Flink wird in einem Serverless-Modus ausgeführt und bietet dank der automatischen Migration Unterstützung bei Host-Leistungsverschlechterungen, Availability-Zone-Verfügbarkeit und anderen infrastrukturbezogenen Problemen. Managed Service für Apache Flink erreicht dies mithilfe mehrerer redundanter Mechanismen. Jede Managed Service für Apache FlinkAnwendung wird in einem Apache Flink-Cluster mit einem Mandanten ausgeführt. Der Apache Flink-Cluster wird JobMananger im Hochverfügbarkeitsmodus unter Verwendung von Zookeeper in mehreren Verfügbarkeitszonen ausgeführt. Managed Service für Apache Flink stellt Apache Flink mithilfe von Amazon EKS bereit. In Amazon EKS werden für jede AWS -Region in allen Verfügbarkeitszonen mehrere Kubernetes-Pods verwendet. Im Falle eines Fehlers versucht Managed Service für Apache Flink zunächst, die Anwendung innerhalb des laufenden Apache Flink-Clusters mithilfe der Prüfpunkte Ihrer Anwendung, sofern verfügbar, wiederherzustellen.

Managed Service für Apache Flink sichert den Anwendungsstatus mithilfe von Prüfpunkten und Snapshots:

- Prüfpunkte sind Backups des Anwendungsstatus, die Managed Service für Apache Flink automatisch in regelmäßigen Abständen erstellt und zur Wiederherstellung nach Fehlern verwendet.
- Snapshots sind Backups des Anwendungsstatus, die Sie manuell erstellen und anhand derer Sie manuell wiederherstellen.

Weitere Informationen zu Prüfpunkten und Snapshots finden Sie unter Implementieren Sie Fehlertoleranz.

Versionsverwaltung

Gespeicherte Versionen des Anwendungsstatus werden wie folgt versioniert:

- Prüfpunkte werden vom Service automatisch versioniert. Wenn der Service einen Prüfpunkt verwendet, um die Anwendung neu zu starten, wird der neueste Prüfpunkt verwendet.
- Savepoints werden anhand des Aktionsparameters versioniert.
 SnapshotNameCreateApplicationSnapshot

Managed Service für Apache Flink verschlüsselt Daten, die in Prüfpunkten und Savepoints gespeichert sind.

Infrastruktursicherheit in Managed Service für Apache Flink

Als verwalteter Service ist Amazon Managed Service für Apache Flink durch die AWS globalen -Netzwerksicherheit-Verfahren geschützt, die im Whitepaper <u>Amazon Web Services: Überblick über</u> <u>Sicherheitsprozesse</u> beschrieben sind. Sie verwenden durch AWS veröffentlichte API-Aufrufe, um über das Netzwerk auf Managed Service für Apache Flink zuzugreifen. Alle API-Aufrufe an Managed Service für Apache Flink werden über Transport Layer Security (TLS) gesichert und über IAM authentifiziert. Kunden müssen TLS 1.2 oder höher unterstützen. Clients müssen außerdem Verschlüsselungssammlungen mit PFS (Perfect Forward Secrecy) wie DHE (Ephemeral Diffie-Hellman) oder ECDHE (Elliptic Curve Ephemeral Diffie-Hellman) unterstützen. Die meisten modernen Systemen wie Java 7 und höher unterstützen diese Modi.

Außerdem müssen Anforderungen mit einer Zugriffsschlüssel-ID und einem geheimen Zugriffsschlüssel signiert sein, der einem IAM-Prinzipal zugeordnet ist. Alternativ können Sie mit <u>AWS</u> <u>Security Token Service</u> (AWS STS) temporäre Sicherheitsanmeldeinformationen erstellen, um die Anforderungen zu signieren.

Bewährte Methoden für die Sicherheit für Managed Service für Apache Flink

Amazon Managed Service für Apache Flink enthält eine Reihe von Sicherheitsfeatures, die Sie bei der Entwicklung und Implementierung Ihrer eigenen Sicherheitsrichtlinien berücksichtigen sollten. Die folgenden bewährten Methoden sind allgemeine Richtlinien und keine vollständige Sicherheitslösung. Da diese bewährten Methoden für Ihre Umgebung möglicherweise nicht angemessen oder ausreichend sind, sollten Sie sie als hilfreiche Überlegungen und nicht als bindend ansehen.

Implementieren des Zugriffs mit geringsten Berechtigungen

Beim Erteilen von Berechtigungen entscheiden Sie, wer welche Berechtigungen für welche Managed Service für Apache Flink-Ressourcen erhält. Sie aktivieren die spezifischen Aktionen, die daraufhin für die betreffenden Ressourcen erlaubt sein sollen. Aus diesem Grund sollten Sie nur Berechtigungen gewähren, die zum Ausführen einer Aufgabe erforderlich sind. Die Implementierung der geringstmöglichen Zugriffsrechte ist eine grundlegende Voraussetzung zum Reduzieren des Sicherheitsrisikos und der Auswirkungen, die aufgrund von Fehlern oder böswilligen Absichten entstehen könnten.

Verwenden von IAM-Rollen zum Zugriff auf andere Amazon-Services

Ihre Managed Service für Apache Flink-Anwendung muss über gültige Anmeldeinformationen für den Zugriff auf Ressourcen in anderen Services, wie z. B. Kinesis-Datenströmen, Firehose-Streams oder Amazon-S3-Buckets verfügen. AWS -Anmeldeinformationen sollten Sie nicht direkt in der

Anwendung oder in einem Amazon-S3-Bucket speichern. Dabei handelt es sich um langfristige Anmeldeinformationen, die nicht automatisch rotiert werden und bedeutende geschäftliche Auswirkungen haben könnten, wenn sie kompromittiert werden.

Stattdessen sollten Sie mithilfe einer IAM-Rolle temporäre Anmeldeinformationen für Ihre Anwendung für den Zugriff auf andere Ressourcen verwalten. Wenn Sie eine Rolle verwenden, müssen Sie keine langfristigen Anmeldeinformationen für den Zugriff auf andere Ressourcen verwenden.

Weitere Informationen finden Sie unter folgenden Themen im IAM-Benutzerhandbuch:

- IAM-Rollen
- Gängige Szenarien für Rollen: Benutzer, Anwendungen und Services

Implementieren der serverseitigen Verschlüsselung in abhängigen Ressourcen

Daten im Ruhezustand und Daten während der Übertragung werden in Managed Service für Apache Flink verschlüsselt, und diese Verschlüsselung kann nicht deaktiviert werden. Sie sollten die serverseitige Verschlüsselung bei abhängigen Ressourcen, wie z. B. Kinesis-Datenströmen, Firehose-Streams und Amazon-S3-Buckets implementieren. Weitere Informationen zum Implementieren der serverseitigen Verschlüsselung bei abhängigen Ressourcen finden Sie unter Datenschutz.

Wird zur Überwachung von API-Aufrufen verwendet CloudTrail

Managed Service für Apache Flink ist in integriert AWS CloudTrail, einen Service, der die Aktionen eines Benutzers, einer Rolle oder eines Amazon-Services in Managed Service für Apache Flink aufzeichnet.

Mit den von CloudTrail erfassten Informationen können Sie die an Managed Service für Apache Flink gestellte Anfrage, die IP-Adresse, von der die Anfrage gestellt wurde, den Initiator der Anfrage, den Zeitpunkt der Anfrage und zusätzliche Details bestimmen.

Weitere Informationen finden Sie unter <u>the section called "Log Managed Service für Apache Flink</u> <u>API-Aufrufe mit AWS CloudTrail"</u>.

Protokollierung und Überwachung in Amazon Managed Service für Apache Flink

Die Überwachung ist wichtig, um Zuverlässigkeit, Verfügbarkeit und Leistung Ihrer Managed Service für Apache Flink-Anwendungen aufrechtzuerhalten. Sie sollten Überwachungsdaten aus allen Teilen Ihrer AWS Lösung sammeln, damit Sie einen etwaigen Mehrpunktfehler leichter debuggen können.

Bevor Sie mit der Überwachung von Managed Service für Apache Flink beginnen, sollten Sie einen Überwachungsplan mit Antworten auf die folgenden Fragen erstellen:

- Was sind Ihre Ziele bei der Überwachung?
- · Welche Ressourcen werden überwacht?
- Wie oft werden diese Ressourcen überwacht?
- Welche Überwachungstools werden verwendet?
- · Wer soll die Überwachungsaufgaben ausführen?
- Wer soll benachrichtigt werden, wenn Fehler auftreten?

Der nächste Schritt besteht darin, eine Baseline für normale Managed Service für Apache Flink-Performance in Ihrer Umgebung aufzustellen. Dies geschieht, indem Sie die Leistung zu verschiedenen Zeiten und unter verschiedenen Lastbedingungen messen. Sie können bei der Überwachung von Managed Service für Apache Flink historische Überwachungsdaten speichern. Sie können diese dann mit aktuellen Leistungsdaten vergleichen, normale Leistungsmuster und Leistungsanomalien identifizieren sowie Verfahren für den Umgang mit Problemen entwickeln.

Themen

- Anmeldung bei Managed Service für Apache Flink
- Überwachung im Managed Service für Apache Flink
- · Anwendungsprotokollierung in Managed Service für Apache Flink einrichten
- Analysieren Sie Logs mit CloudWatch Logs Insights
- Metriken und Dimensionen in Managed Service für Apache Flink
- Schreiben Sie benutzerdefinierte Nachrichten in CloudWatch Logs
- Log Managed Service für Apache Flink API-Aufrufe mit AWS CloudTrail

Anmeldung bei Managed Service für Apache Flink

Die Protokollierung ist wichtig für Produktionsanwendungen, um Fehler und Ausfälle zu verstehen. Das Logging-Subsystem muss jedoch Protokolleinträge sammeln und an Logs weiterleiten. Ein gewisses CloudWatch Logging ist zwar in Ordnung und wünschenswert, aber eine umfangreiche Protokollierung kann den Dienst überlasten und dazu führen, dass die Flink-Anwendung ins Hintertreffen gerät. Das Protokollieren von Ausnahmen und Warnungen ist sicherlich eine gute Idee. Sie können jedoch nicht für jede einzelne Nachricht, die von der Flink-Anwendung verarbeitet wird, eine Protokollnachricht generieren. Flink ist für hohen Durchsatz und geringe Latenz optimiert, das Protokollierungs-Subsystem nicht. Falls es wirklich erforderlich ist, für jede verarbeitete Nachricht eine Protokollausgabe zu generieren, verwenden Sie eine zusätzliche Ausgabe DataStream innerhalb der Flink-Anwendung und eine geeignete Senke, um die Daten an Amazon S3 oder CloudWatch zu senden. Verwenden Sie das Java-Protokollierungs-System nicht für diesen Zweck. Darüber hinaus generiert die Debug Monitoring Log Level-Einstellung von Managed Service für Apache Flink eine große Menge an Datenverkehr, was zu Gegendruck führen kann. Sie sollten sie nur verwenden, wenn Sie aktiv Probleme mit der Anwendung untersuchen.

Logs mit CloudWatch Logs Insights abfragen

CloudWatch Logs Insights ist ein leistungsstarker Dienst, um Logs in großem Umfang abzufragen. Kunden sollten seine Funktionen nutzen, um Protokolle schnell zu durchsuchen, um Fehler bei Betriebsereignissen zu identifizieren und zu beheben.

Die folgende Abfrage sucht in allen Task-Manager-Protokollen nach Ausnahmen und ordnet sie nach dem Zeitpunkt, zu dem sie aufgetreten sind.

```
fields @timestamp, @message
| filter isPresent(throwableInformation.0) or isPresent(throwableInformation) or
  @message like /(Error|Exception)/
| sort @timestamp desc
```

Weitere nützliche Abfragen finden Sie unter Beispielabfragen.

Überwachung im Managed Service für Apache Flink

Wenn Sie Streaming-Anwendungen in der Produktion ausführen, möchten Sie die Anwendung kontinuierlich und unbegrenzt ausführen. Es ist wichtig, die Überwachung und korrekte Alarmierung aller Komponenten zu implementieren, nicht nur der Flink-Anwendung. Andernfalls riskieren Sie, aufkommende Probleme frühzeitig zu übersehen und ein operatives Ereignis erst dann zu erkennen, wenn es vollständig aufgelöst und viel schwieriger zu beheben ist. Zu den allgemeinen Dingen, die es zu überwachen gilt, gehören:

- Nimmt die Quelle Daten auf?
- Werden Daten aus der Quelle gelesen (aus der Perspektive der Quelle)?
- Empfängt die Flink-Anwendung Daten?
- Kann die Flink-Anwendung Schritt halten oder gerät sie ins Hintertreffen?
- Speichert die Flink-Anwendung Daten dauerhaft in der Senke (aus Sicht der Anwendung)?
- Empfängt die Senke Daten?

Spezifischere Metriken sollten dann für die Flink-Anwendung in Betracht gezogen werden. Dieses <u>CloudWatch Dashboard</u> bietet einen guten Ausgangspunkt. Weitere Informationen darüber, welche Metriken für Produktionsanwendungen überwacht werden sollten, finden Sie unter <u>Verwenden Sie</u> <u>CloudWatch Alarme mit Amazon Managed Service für Apache Flink</u>. Zu diesen Metriken gehören:

- records_lag_max und millisbehindLatest Wenn die Anwendung von Kinesis oder Kafka konsumiert, geben diese Metriken an, ob die Anwendung hinterherhinkt und abskaliert werden muss, um mit der aktuellen Auslastung Schritt zu halten. Dies ist eine gute generische Metrik, die für alle Arten von Anwendungen leicht nachzuverfolgen ist. Sie kann jedoch nur für reaktive Skalierung verwendet werden, d. h. wenn die Anwendung bereits ins Hintertreffen geraten ist.
- cpuUtilization und heapMemoryUtilization— Diese Metriken geben einen guten Hinweis auf die Gesamtressourcenauslastung der Anwendung und können für eine proaktive Skalierung verwendet werden, sofern die Anwendung nicht I/O-gebunden ist.
- downtime Eine Ausfallzeit von mehr als Null bedeutet, dass die Anwendung ausgefallen ist. Wenn der Wert größer als 0 ist, verarbeitet die Anwendung keine Daten.
- lastCheckpointSizeund lastCheckpointDuration— Diese Metriken überwachen, wie viele Daten im Status gespeichert sind und wie lange es dauert, bis ein Checkpoint erreicht wird. Wenn die Anzahl der Prüfpunkte zunimmt oder lange dauert, verbringt die Anwendung kontinuierlich Zeit mit Prüfpunkten und hat weniger Zyklen für die eigentliche Verarbeitung. An manchen Stellen können Prüfpunkte zu groß werden oder so lange dauern, dass sie ausfallen. Neben der Überwachung absoluter Werte sollten Kunden auch erwägen, die Änderungsrate mit RATE(lastCheckpointSize) und RATE(lastCheckpointDuration) zu überwachen.
- numberOfFailedCheckpoints Diese Metrik zählt die Anzahl der fehlgeschlagenen Checkpoints seit dem Start der Anwendung. Je nach Anwendung kann es toleriert werden, dass Prüfpunkte

gelegentlich fehlschlagen. Wenn Prüfpunkte jedoch regelmäßig ausfallen, ist die Anwendung wahrscheinlich fehlerhaft und benötigt weitere Aufmerksamkeit. Wir empfehlen die Überwachung von RATE(numberOfFailedCheckpoints), dass der Alarm anhand des Gefälles und nicht anhand absoluter Werte ausgelöst wird.

Anwendungsprotokollierung in Managed Service für Apache Flink einrichten

Indem Sie Ihrer Managed Service for Apache Flink-Anwendung eine CloudWatch Amazon-Protokollierungsoption hinzufügen, können Sie Anwendungsereignisse oder Konfigurationsprobleme überwachen.

In diesem Thema wird beschrieben, wie Sie Ihre Anwendung so konfigurieren, dass Anwendungsereignisse in einen CloudWatch Logs-Stream geschrieben werden. Eine CloudWatch Protokollierungsoption ist eine Sammlung von Anwendungseinstellungen und Berechtigungen, mit denen Ihre Anwendung konfiguriert, wie Anwendungsereignisse in CloudWatch Protokolle geschrieben werden. Sie können eine CloudWatch Protokollierungsoption entweder mit dem AWS Management Console oder dem AWS Command Line Interface (AWS CLI) hinzufügen und konfigurieren.

Beachten Sie beim Hinzufügen einer CloudWatch Protokollierungsoption zu Ihrer Anwendung Folgendes:

- Wenn Sie mithilfe der Konsole eine CloudWatch Protokollierungsoption hinzufügen, erstellt Managed Service for Apache Flink die CloudWatch Protokollgruppe und den Protokollstream für Sie und fügt die Berechtigungen hinzu, die Ihre Anwendung zum Schreiben in den Protokollstream benötigt.
- Wenn Sie mithilfe der API eine CloudWatch Protokollierungsoption hinzufügen, müssen Sie auch die Protokollgruppe und den Protokollstream der Anwendung erstellen und die Berechtigungen hinzufügen, die Ihre Anwendung zum Schreiben in den Protokollstream benötigt.

Richten Sie die CloudWatch Protokollierung mithilfe der Konsole ein

Wenn Sie die CloudWatch Protokollierung für Ihre Anwendung in der Konsole aktivieren, werden eine CloudWatch Protokollgruppe und ein Protokollstream für Sie erstellt. Außerdem wird die

Berechtigungsrichtlinie Ihrer Anwendung mit den Berechtigungen zum Schreiben in den Stream aktualisiert.

Managed Service for Apache Flink erstellt eine Protokollgruppe, die nach der folgenden Konvention benannt *ApplicationName* wird, wobei der Name Ihrer Anwendung verwendet wird.

/aws/kinesis-analytics/ApplicationName

Managed Service für Apache Flink erstellt einen Protokollstream in der neuen Protokollgruppe mit dem folgenden Namen.

kinesis-analytics-log-stream

Sie legen die Ebene der Anwendungsüberwachungsmetriken und die Protokollebene mit dem Abschnitt Überwachung der Protokollebene der Seite Anwendung konfigurieren fest. Hinweise zu den Protokollebenen von Anwendungen finden Sie unter <u>the section called "Steuern Sie die Ebenen der Anwendungsüberwachung"</u>.

CloudWatch Logging mit der CLI einrichten

Um eine CloudWatch Protokollierungsoption mit dem hinzuzufügen AWS CLI, gehen Sie wie folgt vor:

- Erstellen Sie eine CloudWatch Protokollgruppe und einen Protokollstream.
- Fügen Sie eine Protokollierungsoption hinzu, wenn Sie mithilfe der <u>CreateApplication</u>Aktion eine Anwendung erstellen, oder fügen Sie mithilfe der <u>AddApplicationCloudWatchLoggingOption</u>Aktion einer vorhandenen Anwendung eine Protokollierungsoption hinzu.
- Fügen Sie der Richtlinie Ihrer Anwendung Berechtigungen zum Schreiben in die Protokolle hinzu.

Erstellen Sie eine CloudWatch Protokollgruppe und einen Protokollstream

Sie erstellen eine CloudWatch Protokollgruppe und streamen entweder mit der CloudWatch Logs-Konsole oder der API. Informationen zum Erstellen einer CloudWatch Protokollgruppe und eines Protokollstreams finden Sie unter Arbeiten mit Protokollgruppen und Protokollströmen.

Arbeiten Sie mit den Optionen für die CloudWatch Anwendungsprotokollierung

Verwenden Sie die folgenden API-Aktionen, um einer neuen oder vorhandenen Anwendung eine CloudWatch Protokolloption hinzuzufügen oder eine Protokolloption für eine bestehende Anwendung Managed Service für Apache Flink

zu ändern. Weitere Informationen zur Verwendung einer JSON-Datei für die Eingabe einer API-Aktion finden Sie unter Beispielcode für Managed Service für Apache Flink API.

Fügen Sie beim Erstellen einer Anwendung eine CloudWatch Protokolloption hinzu

Das folgende Beispiel zeigt, wie Sie die CreateApplication Aktion verwenden, um beim Erstellen einer Anwendung eine CloudWatch Protokolloption hinzuzufügen. Im Beispiel, ersetzen Sie Amazon Resource Name (ARN) of the CloudWatch Log stream to add to the new application mit Ihren eigenen Informationen. Weitere Informationen zur Aktion finden Sie unter CreateApplication.

```
{
    "ApplicationName": "test",
    "ApplicationDescription": "test-application-description",
    "RuntimeEnvironment": "FLINK-1_15",
    "ServiceExecutionRole": "arn:aws:iam::123456789123:role/myrole",
    "ApplicationConfiguration": {
        "ApplicationCodeConfiguration": {
            "CodeContent": {
                "S3ContentLocation":{
                               "BucketARN": "arn:aws:s3:::amzn-s3-demo-bucket",
                               "FileKey": "myflink.jar"
                }
            },
            "CodeContentType": "ZIPFILE"
        }
    },
    "CloudWatchLoggingOptions": [{
      "LogStreamARN": "<Amazon Resource Name (ARN) of the CloudWatch log stream to add
 to the new application>"
 }]
}
```

Fügen Sie einer vorhandenen Anwendung eine CloudWatch Protokolloption hinzu

Das folgende Beispiel zeigt, wie die AddApplicationCloudWatchLoggingOption Aktion verwendet wird, um einer vorhandenen Anwendung eine CloudWatch Protokolloption hinzuzufügen. Ersetzen Sie im Beispiel jede Information *user input placeholder* durch Ihre eigenen Informationen. Weitere Informationen zur Aktion finden Sie unter <u>AddApplicationCloudWatchLoggingOption</u>.

{

```
"ApplicationName": "<Name of the application to add the log option to>",
   "CloudWatchLoggingOption": {
      "LogStreamARN": "<ARN of the log stream to add to the application>"
    },
    "CurrentApplicationVersionId": <Version of the application to add the log to>
}
```

Aktualisieren Sie eine bestehende CloudWatch Protokolloption

Das folgende Beispiel zeigt, wie die UpdateApplication Aktion verwendet wird, um eine bestehende CloudWatch Protokolloption zu ändern. Ersetzen Sie im Beispiel jede *user input placeholder* durch Ihre eigenen Informationen. Weitere Informationen zur Aktion finden Sie unter UpdateApplication.

```
{
    "ApplicationName": "<Name of the application to update the log option for>",
    "CloudWatchLoggingOptionUpdates": [
        {
            "CloudWatchLoggingOptionId": "<ID of the logging option to modify>",
            "LogStreamARNUpdate": "<ARN of the new log stream to use>"
        }
        ],
      "CurrentApplicationVersionId": <ID of the application version to modify>
}
```

Löschen Sie eine CloudWatch Protokolloption aus einer Anwendung

Das folgende Beispiel zeigt, wie die DeleteApplicationCloudWatchLoggingOption Aktion zum Löschen einer vorhandenen CloudWatch Protokolloption verwendet wird. Ersetzen Sie im Beispiel jede *user input placeholder* durch Ihre eigenen Informationen. Weitere Informationen zur Aktion finden Sie unter DeleteApplicationCloudWatchLoggingOption.

```
{
    "ApplicationName": "<Name of application to delete log option from>",
    "CloudWatchLoggingOptionId": "<ID of the application log option to delete>",
    "CurrentApplicationVersionId": <Version of the application to delete the log option
    from>
}
```

Stellen Sie die Protokollierungsebene der Anwendung ein

Um die Ebene der Anwendungsprotokollierung festzulegen, verwenden Sie den <u>MonitoringConfiguration</u>-Parameter der <u>CreateApplication</u>-Aktion oder den <u>MonitoringConfigurationUpdate</u>-Parameter der UpdateApplication-Aktion.

Hinweise zu den Protokollebenen von Anwendungen finden Sie unter <u>the section called "Steuern Sie</u> die Ebenen der Anwendungsüberwachung".

Legen Sie die Anwendungsprotokollierungsebene fest, wenn Sie eine Anwendung erstellen

In der folgenden Beispielanforderung für die <u>CreateApplication</u>-Aktion wird die Protokollebene der Anwendung auf INFO festgelegt.

```
{
   "ApplicationName": "MyApplication",
   "ApplicationDescription": "My Application Description",
   "ApplicationConfiguration": {
      "ApplicationCodeConfiguration":{
      "CodeContent":{
        "S3ContentLocation":{
          "BucketARN": "arn: aws: s3::: amzn-s3-demo-bucket",
          "FileKey": "myflink.jar",
          "ObjectVersion": "AbCdEfGhIjKlMnOpQrStUvWxYz12345"
        }
      },
      "CodeContentType":"ZIPFILE"
      },
      "FlinkApplicationConfiguration":
         "MonitoringConfiguration": {
            "ConfigurationType": "CUSTOM",
            "LogLevel": "INFO"
         }
      },
   "RuntimeEnvironment": "FLINK-1_15",
   "ServiceExecutionRole": "arn:aws:iam::123456789123:role/myrole"
}
```

Aktualisieren Sie die Protokollierungsebene der Anwendung

In der folgenden Beispielanforderung für die <u>UpdateApplication</u>-Aktion wird die Protokollebene der Anwendung auf INFO festgelegt.

Fügen Sie Berechtigungen hinzu, um in den CloudWatch Protokollstream zu schreiben

Managed Service for Apache Flink benötigt Berechtigungen zum Schreiben von Fehlern bei Fehlkonfigurationen. CloudWatch Sie können diese Berechtigungen der AWS Identity and Access Management (IAM-) Rolle hinzufügen, die Managed Service for Apache Flink annimmt.

Weitere Informationen zur Verwendung einer IAM-Rolle für Managed Service für Apache Flink finden Sie unter. Identity and Access Management für Amazon Managed Service für Apache Flink

Vertrauensrichtlinie

Zum Erteilen von Managed Service für Apache Flink-Berechtigungen, um eine IAM-Rolle anzunehmen, können Sie an die Serviceausführungs-Rolle die folgende Vertrauensrichtlinie anhängen.

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

}

Berechtigungsrichtlinie

Um einer Anwendung Berechtigungen zum Schreiben von Protokollereignissen CloudWatch aus einer Managed Service for Apache Flink-Ressource zu erteilen, können Sie die folgende IAM-Berechtigungsrichtlinie verwenden. Geben Sie die richtigen Amazon-Ressourcennamen (ARNs) für Ihre Protokollgruppe und Ihren Stream ein.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Sid": "Stmt0123456789000",
            "Effect": "Allow",
            "Action": [
                "logs:PutLogEvents",
                "logs:DescribeLogGroups",
                "logs:DescribeLogStreams"
            ],
            "Resource": [
                "arn:aws:logs:us-east-1:123456789012:log-group:my-log-group:log-
stream:my-log-stream*",
                "arn:aws:logs:us-east-1:123456789012:log-group:my-log-group:*",
                "arn:aws:logs:us-east-1:123456789012:log-group:*",
            ]
        }
    ]
}
```

Steuern Sie die Ebenen der Anwendungsüberwachung

Sie steuern die Generierung von Anwendungsprotokollmeldungen mithilfe von Überwachung der Metrikebene und Überwachung der Protokollebene der Anwendung.

Die Überwachung der Metrikebene der Anwendung steuert die Granularität der Protokollnachrichten. Die Überwachung der Metrikebenen sind wie folgt definiert:

- Anwendung: Metriken beziehen sich auf die gesamte Anwendung.
- Aufgabe: Metriken beziehen sich auf jede Aufgabe. Weitere Informationen zu Aufgaben finden Sie unter the section called "Implementieren Sie Anwendungsskalierung".

- Operator: Metriken sind auf jeden Operator beschränkt. Weitere Informationen zu Operatoren finden Sie unter <u>the section called "Operatoren"</u>.
- Parallelität: Metriken sind auf Anwendungsparallelität beschränkt. Sie können diese Metrikebene nur mithilfe des <u>MonitoringConfigurationUpdate UpdateApplication</u>API-Parameters festlegen. Diese Metrikebene kann nicht mithilfe der Konsole festgelegt werden. Informationen zur Parallelität finden Sie unter the section called "Implementieren Sie Anwendungsskalierung".

Die Überwachung der Protokollebene der Anwendung steuert die Ausführlichkeit des Anwendungsprotokolls. Die Überwachung der Protokollebene ist wie folgt definiert:

- Fehler: Mögliche katastrophale Ereignisse der Anwendung.
- Warnung: Potenziell schädliche Situationen der Anwendung.
- Info: Informative und vorübergehende Ausfälle der Anwendung. Wir empfehlen die Verwendung dieser Protokollierungsebene.
- Debug: Detaillierte Informationsereignisse, die für das Debuggen einer Anwendung am nützlichsten sind. Hinweis: Verwenden Sie diese Ebene nur für temporäre Debugging-Zwecke.

Wenden Sie bewährte Methoden für die Protokollierung an

Wir empfehlen, dass Ihre Anwendung die Protokollierungsebene Info verwendet. Wir empfehlen diese Stufe, um sicherzustellen, dass Sie Apache Flink-Fehler sehen, die auf der Informations-Ebene und nicht auf der Fehler-Ebene protokolliert werden.

Wir empfehlen, die Debug-Ebene nur vorübergehend zu verwenden, um Anwendungsprobleme zu untersuchen. Wechseln Sie zurück zur Informations-Ebene, wenn das Problem behoben ist. Die Verwendung der Debug-Protokollierungsebene wirkt sich erheblich auf die Leistung Ihrer Anwendung aus.

Eine übermäßige Protokollierung kann sich auch erheblich auf die Anwendungsleistung auswirken. Wir empfehlen beispielsweise, nicht für jeden verarbeiteten Datensatz einen Protokolleintrag zu schreiben. Eine übermäßige Protokollierung kann zu schwerwiegenden Engpässen bei der Datenverarbeitung und zu einem Gegendruck beim Lesen von Daten aus den Quellen führen.

Führen Sie eine Fehlerbehebung bei der Protokol

Wenn Anwendungsprotokolle nicht in den Protokollstream geschrieben werden, überprüfen Sie Folgendes:

- Stellen Sie sicher, dass die IAM-Rolle und die Richtlinien Ihrer Anwendung korrekt sind. Die Richtlinie Ihrer Anwendung benötigt die folgenden Berechtigungen, um auf Ihren Protokollstream zugreifen zu können:
 - logs:PutLogEvents
 - logs:DescribeLogGroups
 - logs:DescribeLogStreams

Weitere Informationen finden Sie unter <u>the section called "Fügen Sie Berechtigungen hinzu, um in</u> den CloudWatch Protokollstream zu schreiben".

- Überprüfen Sie, dass Ihre Anwendung ausgeführt wird. Um den Status Ihrer Anwendung zu überprüfen, rufen Sie die Seite Ihrer Anwendung in der Konsole auf oder verwenden Sie die ListApplicationsAktionen DescribeApplicationoder.
- Überwachen Sie CloudWatch Messwertedowntime, um beispielsweise andere Anwendungsprobleme zu diagnostizieren. Informationen zum Lesen von CloudWatch Metriken finden Sie unter???.

Verwenden Sie CloudWatch Logs Insights

Nachdem Sie die CloudWatch Protokollierung in Ihrer Anwendung aktiviert haben, können Sie CloudWatch Logs Insights verwenden, um Ihre Anwendungsprotokolle zu analysieren. Weitere Informationen finden Sie unter <u>the section called "Analysieren Sie Logs mit CloudWatch Logs</u> Insights".

Analysieren Sie Logs mit CloudWatch Logs Insights

Nachdem Sie Ihrer Anwendung eine CloudWatch Protokollierungsoption hinzugefügt haben, wie im vorherigen Abschnitt beschrieben, können Sie CloudWatch Logs Insights verwenden, um Ihre Log-Streams nach bestimmten Ereignissen oder Fehlern abzufragen.

CloudWatch Logs Insights ermöglicht es Ihnen, Ihre Protokolldaten in CloudWatch Logs interaktiv zu suchen und zu analysieren.

Informationen zu den ersten Schritten mit CloudWatch Logs Insights finden Sie unter <u>Analysieren von</u> Protokolldaten mit CloudWatch Logs Insights.

Verwenden Sie CloudWatch Logs Insights

Ausführen einer Beispielabfrage

In diesem Abschnitt wird beschrieben, wie Sie eine CloudWatch Logs Insights-Beispielabfrage ausführen.

Voraussetzungen

- Bestehende Protokollgruppen und Protokollstreams, die in CloudWatch Logs eingerichtet wurden.
- Bestehende Protokolle, die in CloudWatch Logs gespeichert sind.

Wenn Sie Dienste wie AWS CloudTrail Amazon Route 53 oder Amazon VPC verwenden, haben Sie wahrscheinlich bereits Protokolle von diesen Diensten eingerichtet, um sie unter CloudWatch Logs zu speichern. Weitere Informationen zum Senden von Protokollen an CloudWatch Logs finden Sie unter Erste Schritte mit CloudWatch Logs.

Abfragen in CloudWatch Logs Insights geben entweder eine Reihe von Feldern aus Protokollereignissen oder das Ergebnis einer mathematischen Aggregation oder eines anderen Vorgangs zurück, der mit Protokollereignissen ausgeführt wurde. Dieser Abschnitt demonstriert eine Abfrage, die eine Liste von Protokollereignissen zurückgibt.

Um eine CloudWatch Logs Insights-Beispielabfrage auszuführen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie im Navigationsbereich Insights aus.
- Der Abfrage-Editor fast am oberen Ende des Bildschirms enthält eine Standardabfrage, die die 20 letzten Protokollereignisse zurückgibt. Wählen Sie oberhalb des Abfrage-Editors eine Protokollgruppe zur Abfrage aus.

Wenn Sie eine Protokollgruppe auswählen, erkennt CloudWatch Logs Insights automatisch Felder in den Daten in der Protokollgruppe und zeigt sie im rechten Bereich unter Entdeckte Felder an. Dort finden Sie auch ein Balkendiagramm der Protokollereignisse in dieser Protokollgruppe im Zeitverlauf. Dieses Balkendiagramm zeigt die Verteilung der Ereignisse in der Protokollgruppe, die Ihrer Abfrage und Ihrem Zeitraum entspricht, nicht nur die in der Tabelle angezeigten Ereignisse.

4. Wählen Sie Abfrage ausführen.

Die Ergebnisse der Abfrage werden angezeigt. In diesem Beispiel sind die Ergebnisse die letzten 20 Protokollereignisse aller Art.

5. Um alle Felder eines der zurückgegebenen Protokollereignisse anzuzeigen, wählen Sie den Pfeil links neben diesem Protokollereignis aus.

Weitere Informationen zum Ausführen und Ändern von CloudWatch Logs Insights-Abfragen finden Sie unter Ausführen und Ändern einer Beispielabfrage.

Sehen Sie sich Beispielabfragen an

Dieser Abschnitt enthält CloudWatch Logs Insights-Beispielabfragen zur Analyse der Anwendungsprotokolle von Managed Service for Apache Flink. Diese Abfragen suchen nach mehreren Beispielfehlerbedingungen und dienen als Vorlagen für das Schreiben von Abfragen, die andere Fehlerbedingungen finden.

1 Note

Ersetzen Sie Region (*us-west-2*), Konto-ID (*012345678901*) und Anwendungsname (*YourApplication*) in den folgenden Abfragebeispielen durch die Region Ihrer Anwendung und Ihre Konto-ID.

Dieses Thema enthält die folgenden Abschnitte:

- Analysieren Sie den Betrieb: Verteilung der Aufgaben
- Operationen analysieren: Änderung der Parallelität
- Fehler analysieren: Zugriff verweigert
- Fehler analysieren: Quelle oder Senke nicht gefunden
- Fehler analysieren: Fehler im Zusammenhang mit Anwendungsaufgaben

Analysieren Sie den Betrieb: Verteilung der Aufgaben

Die folgende CloudWatch Logs Insights-Abfrage gibt die Anzahl der Aufgaben zurück, die der Apache Flink Job Manager auf die Taskmanager verteilt. Sie müssen den Zeitrahmen der Abfrage so einstellen, dass er einer Jobausführung entspricht, sodass die Abfrage keine Aufgaben aus früheren Jobs zurückgibt. Informationen zur Parallelität finden Sie unter Implementieren Sie Anwendungsskalierung.

```
fields @timestamp, message
| filter message like /Deploying/
| parse message " to flink-taskmanager-*" as @tmid
| stats count(*) by @tmid
| sort @timestamp desc
| limit 2000
```

Die folgende CloudWatch Logs Insights-Abfrage gibt die Unteraufgaben zurück, die jedem Task Manager zugewiesen sind. Die Gesamtzahl der Unteraufgaben ist die Summe der Parallelität jeder Aufgabe. Die Aufgabenparallelität wird aus der Operatorparallelität abgeleitet und entspricht standardmäßig der Parallelität der Anwendung, sofern Sie sie nicht im Code durch Angabe von setParallelism ändern. Informationen zur Einstellung der Operatorparallelität finden Sie unter Einstellen der Parallelität: Operatorebene in der Dokumentation von Apache Flink.

```
fields @timestamp, @tmid, @subtask
| filter message like /Deploying/
| parse message "Deploying * to flink-taskmanager-*" as @subtask, @tmid
| sort @timestamp desc
| limit 2000
```

Informationen zu Aufgabenplanung finden Sie unter <u>Aufträge und Planung</u> in der <u>Apache-Flink-</u> <u>Dokumentation</u>.

Operationen analysieren: Änderung der Parallelität

Die folgende CloudWatch Logs Insights-Abfrage gibt Änderungen an der Parallelität einer Anwendung zurück (z. B. aufgrund der automatischen Skalierung). Diese Abfrage gibt auch manuelle Änderungen an der Parallelität der Anwendung zurück. Weitere Informationen zum Auto Scaling finden Sie unter the section called "Verwenden Sie die automatische Skalierung".

```
fields @timestamp, @parallelism
| filter message like /property: parallelism.default, /
| parse message "default, *" as @parallelism
| sort @timestamp asc
```

Fehler analysieren: Zugriff verweigert

Die folgende CloudWatch Logs Insights-Abfrage gibt Access Denied Protokolle zurück.

```
fields @timestamp, @message, @messageType
| filter applicationARN like /arn:aws:kinesisanalyticsus-
west-2:012345678901:application\/YourApplication/
| filter @message like /AccessDenied/
| sort @timestamp desc
```

Fehler analysieren: Quelle oder Senke nicht gefunden

Die folgende CloudWatch Logs Insights-Abfrage gibt ResourceNotFound Protokolle zurück. ResourceNotFoundprotokolliert das Ergebnis, wenn eine Kinesis-Quelle oder -Senke nicht gefunden wird.

```
fields @timestamp,@message
| filter applicationARN like /arn:aws:kinesisanalyticsus-
west-2:012345678901:application\/YourApplication/
| filter @message like /ResourceNotFoundException/
| sort @timestamp desc
```

Fehler analysieren: Fehler im Zusammenhang mit Anwendungsaufgaben

Die folgende CloudWatch Logs Insights-Abfrage gibt die aufgabenbezogenen Fehlerprotokolle einer Anwendung zurück. Diese Protokolle entstehen, wenn der Status einer Anwendung von RUNNING zu wechselt RESTARTING.

```
fields @timestamp,@message
| filter applicationARN like /arn:aws:kinesisanalyticsus-
west-2:012345678901:application\/YourApplication/
| filter @message like /switched from RUNNING to RESTARTING/
| sort @timestamp desc
```

Bei Anwendungen, die Apache Flink Version 1.8.2 und früher verwenden, führen aufgabenbezogene Fehler dazu, dass der Anwendungsstatus stattdessen von RUNNING zu wechselt FAILED. Wenn Sie Apache Flink 1.8.2 und frühere Versionen verwenden, verwenden Sie die folgende Abfrage, um nach Fehlern im Zusammenhang mit der Anwendungsaufgabe zu suchen:

```
fields @timestamp,@message
```

```
| filter applicationARN like /arn:aws:kinesisanalyticsus-
west-2:012345678901:application\/YourApplication/
| filter @message like /switched from RUNNING to FAILED/
| sort @timestamp desc
```

Metriken und Dimensionen in Managed Service für Apache Flink

Wenn Ihr Managed Service für Apache Flink eine Datenquelle verarbeitet, meldet Managed Service for Apache Flink die folgenden Metriken und Dimensionen an Amazon. CloudWatch

Anwendungsmetriken

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
backPress uredTimeM sPerSecon d*	Millisekunden	Die Zeit (in Milliseku nden), in der diese Aufgabe oder dieser Operator pro Sekunde unter Gegendruck gesetzt wird.	Aufgabe, Operator, Parallelität	*Nur für Managed Service für Apache Flink- Anwendungen verfügbar, auf denen Flink Version 1.13 ausgeführt wird. Diese Metriken können nützlich sein, um Engpässe in einer Anwendung zu identifizieren.	
busyTimeM sPerSecon d*	Millisekunden	Die Zeit (in Milliseku nden), in der diese Aufgabe	Aufgabe, Operator, Parallelität	*Nur für Managed Service für Apache Flink-	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
		oder dieser Operator pro Sekunde beschäftigt (weder inaktiv noch unter Gegendruck gesetzt) ist. Kann NaN sein, wenn der Wert nicht berechnet werden konnte.		Anwendungen verfügbar, auf denen Flink Version 1.13 ausgeführt wird. Diese Metriken können nützlich sein, um Engpässe in einer Anwendung zu identifizieren.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
cpuUtiliz ation	Prozentsatz	Prozentsatz der CPU-Ausla stung in allen Task-Mana gern. Wenn es beispiels weise fünf Taskmanager gibt, veröffent licht Managed Service für Apache Flink pro Berichtsi ntervall fünf Beispiele dieser Metrik.	Anwendung	Sie können diese Metrik verwenden, um die minimale, durchschn ittliche und maximale CPU-Ausla stung in Ihrer Anwendung zu überwache n. Die CPUUtiliz ation Metrik berücksichtigt nur die CPU- Auslastung des TaskManag er JVM-Proze sses, der im Container ausgeführt wird.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
container CPUUtiliz ation	Prozentsatz	Gesamtpro zentsatz der CPU-Ausla stung in allen Task-Mana ger-Containern im Flink-Anw endungscl uster. Wenn es beispiels weise fünf Taskmanag er gibt, gibt es entsprech end fünf TaskManag er Container, und Managed Service for Apache Flink veröffentlicht pro Berichtsi ntervall von 1 Minute 2 x fünf Stichproben dieser Metrik.	Anwendung	Sie wird pro Container wie folgt berechnet: Gesamt-CP U-Zeit (in Sekunden), die vom Container verbraucht wird * 100/Conta iner-CPU-Limit (in CPUs / Sekunden) Die CPUUtiliz ation Metrik berücksichtigt nur die CPU- Auslastung des TaskManag er JVM-Proze sses, der im Container ausgeführ t wird. Es gibt andere Komponenten, die außerhalb der JVM	
Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
--------	---------	--------------	-------	---	--
				werden. Die container CPUUtiliz ation -Metrik gibt Ihnen ein vollständ igeres Bild, einschließlich aller Prozesse im Hinblick auf die CPU- Auslastung im Container und die daraus resultierenden Ausfälle.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
container MemoryUti lization	Prozentsatz	Gesamtpro zentsatz der Speichera uslastung in allen Task- Manager- Containern im Flink-Anw endungscl uster. Wenn es beispiels weise fünf Taskmanag er gibt, gibt es entsprech end fünf TaskManag er Container, und Managed Service for Apache Flink veröffentlicht pro Berichtsi ntervall von 1 Minute 2 x fünf Stichproben dieser Metrik.	Anwendung	Sie wird pro Container wie folgt berechnet: Speichern utzung des Containers (Byte) * 100/ Container- Speicherlimit gemäß der Pod-Berei tstellung sspezifikation (in Byte) Die ManagedMe moryUtilz ations Metriken HeapMemor yUtilizat ion und berücksic htigen nur bestimmte Speicherm etriken wie die Heap-Spei cherausla stung von TaskManag er JVM oder

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
				Managed Memory (Speicher nutzung außerhalb von JVM für native Prozesse wie RocksDB State Backend). Die container MemoryUti lization - Metrik gibt Ihnen ein vollständigeres Bild, da sie den festgelegten Arbeitsspeicher mit einbezieh t, wodurch die gesamte Speichere rschöpfun g besser erfasst werden kann. Wenn es erschöpft ist, führt es	
				der Pod kaputt geht. Out of Memory	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
				Error TaskManager
container DiskUtili zation	Prozentsatz	Gesamtpro zentsatz der Festplatt enauslastung in allen Task- Manager- Containern im Flink-Anw endungscl uster. Wenn es beispiels weise fünf Taskmanag er gibt, gibt es entsprech end fünf TaskManag er Container, und Managed Service for Apache Flink veröffentlicht pro Berichtsi ntervall von einer Minute 2 x fünf Stichproben dieser Metrik.	Anwendung	Sie wird pro Container wie folgt berechnet: Festplatt ennutzung in Byte * 100/ Festplattenlimit für Container in Byte Bei Container n steht dies für die Nutzung des Dateisyst ems, auf dem das Root- Volume des Containers eingerichtet ist.

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
currentIn putWaterm ark	Millisekunden	Das letzte Wasserzei chen, das diese Datei erhalten hat application/ operator/task/t hread	Anwendung , Operator, Aufgabe, Parallelität	Dieser Datensatz wird nur für Dimension en mit zwei Eingaben ausgegeben. Dies ist der Mindestwe rt der zuletzt empfangen en Wasserzei chen.	
currentOu tputWater mark	Millisekunden	Das letzte Wasserzei chen, das dadurch application/ operator/ task/thread ausgegeben wurde	Anwendung , Operator, Aufgabe, Parallelität		

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
downtime	Millisekunden	Bei Aufträgen , die sich derzeit in einer Situation befinden, in der ein Fehler aufgetreten ist oder der wiederher gestellt wird, ist dies die Zeit, die während dieses Ausfalls verstrichen ist.	Anwendung	Diese Kennzahl misst die Zeit, die verstrichen ist, während ein Job ausfällt oder wiederher gestellt wird. Diese Metrik gibt 0 für laufende Jobs und -1 für abgeschlo ssene Jobs zurück. Wenn diese Metrik nicht 0 oder -1 ist, bedeutet dies, dass der Apache Flink- Job für die Anwendung nicht ausgeführ t werden konnte.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
fullResta rts	Anzahl	Gibt an, wie oft dieser Job seit seiner Übermittlung vollständig neu gestartet wurde. Mit dieser Metrik werden keine detaillierten Neustarts gemessen.	Anwendung	Sie können diese Metrik verwenden, um den allgemein en Zustand von Anwendungen zu bewerten. Neustarts können während der internen Wartung durch Managed Service für Managed Service für Apache Flink erfolgen. Neustarts, die höher als normal sind, können auf ein Problem mit der Anwendung hinweisen.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
heapMemor yUtilizat ion	Prozentsatz	Gesamtaus lastung des Heap-Spei chers in allen Task-Mana gern. Wenn es beispiels weise fünf Taskmanager gibt, veröffent licht Managed Service für Apache Flink pro Berichtsi ntervall fünf Beispiele dieser Metrik.	Anwendung	Sie können diese Metrik verwenden, um die minimale, durchschn ittliche und maximale Heap-Spei cherausla stung in Ihrer Anwendung zu überwache n. Das HeapMemor yUtilizat ion einzige Konto berücksichtigt bestimmte Speicherm etriken wie die Heap-Spei cherausla stung von TaskManager JVM.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
idleTimeM sPerSecon d*	Millisekunden	Die Zeit (in Millisekunden), in der sich diese Task oder dieser Operator pro Sekunde im Leerlauf befindet (keine Zu verarbeit enden Daten hat). Bei der Leerlaufzeit wird die Zeit nicht berücksic htigt, in der Gegendruck ausgeübt wird, wenn also die Aufgabe unter Gegendruck steht, handelt es sich nicht um Inaktivität.	Aufgabe, Operator, Parallelität	*Nur für Managed Service für Apache Flink- Anwendungen verfügbar, auf denen Flink Version 1.13 ausgeführt wird. Diese Metriken können nützlich sein, um Engpässe in einer Anwendung zu identifizieren.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
lastCheck pointSize	Bytes	Die Gesamtgröße des letzten Prüfpunkts	Anwendung	Sie können diese Metrik verwenden, um die Speichera uslastung laufender Anwendungen zu ermitteln. Wenn der Wert dieser Metrik steigt, kann dies darauf hindeuten , dass ein Problem mit Ihrer Anwendung vorliegt, z. B. ein Speicherl eck oder ein Engpass.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
lastCheck pointDura tion	Millisekunden	Die Zeit, die benötigt wurde, um den letzten Prüfpunkt abzuschließen	Anwendung	Diese Kennzahl misst die Zeit, die benötigt wurde, um den letzten Prüfpunkt abzuschließen. Wenn der Wert dieser Metrik steigt, kann dies darauf hindeuten , dass ein Problem mit Ihrer Anwendung vorliegt, z. B. ein Speicherl eck oder ein Engpass. In einigen Fällen können Sie dieses Problem beheben, indem Sie die Prüfpunkt	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
managedMe moryUsed*	Bytes	Die derzeit verwendet e verwaltet e Speicherm enge.	Anwendung , Operator, Aufgabe, Parallelität	*Nur für Managed Service für Apache Flink- Anwendungen verfügbar, auf denen Flink Version 1.13 ausgeführt wird. Dies bezieht sich auf Speicher, der von Flink außerhalb des Java-Heaps verwaltet wird. Es wird für das RocksDB-S tate-Backend verwendet und ist auch für Anwendungen verfügbar.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
<pre>managedMe moryTotal *</pre>	Bytes	Die Gesamtgrö ße des verwalteten Speichers.	Anwendung , Operator, Aufgabe, Parallelität	*Nur für Managed Service für Apache Flink- Anwendungen verfügbar, auf denen Flink Version 1.13 ausgeführt wird.
				Dies bezieht sich auf Speicher, der von Flink außerhalb des Java-Heaps verwaltet wird. Es wird für das RocksDB-S tate-Backend verwendet und ist auch für Anwendungen
				ManagedMe moryUtilz ations - Metrik berücksichtigt nur bestimmte Speicherm etriken wie Managed

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
				Memory (Speicher nutzung außerhalb von JVM für native Prozesse wie <u>RocksDB State</u> Backend)	
<pre>managedMe moryUtili zation*</pre>	Prozentsatz	Abgeleitet von/ managedMe moryUsedm anagedMem oryTotal	Anwendung , Operator, Aufgabe, Parallelität	*Nur für Managed Service für Apache Flink- Anwendungen verfügbar, auf denen Flink Version 1.13 ausgeführt wird. Dies bezieht sich auf Speicher, der von Flink außerhalb des Java-Heaps verwaltet wird. Es wird für das RocksDB-S tate-Backend verwendet und ist auch für Anwendungen verfügbar.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
numberOfF ailedChec kpoints	Anzahl	Gibt an, wie oft die Prüfpunkt überprüfung fehlgeschlagen ist.	Anwendung	Sie können diese Metrik verwenden, um den Zustand und den Fortschritt von Anwendungen zu überwache n. Prüfpunkt e können aufgrund von Anwendung sproblemen wie Durchsatz- oder Berechtig ungsprobleme fehlschlagen.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
numRecord sIn*	Anzahl	Die Gesamtzah I der Datensätz e, die diese Anwendung , dieser Operator oder diese Aufgabe erhalten hat.	Anwendung , Operator, Aufgabe, Parallelität	*Um die SUM-Statistik über einen bestimmte n Zeitraum (Sekunde/ Minute) anzuwenden: • Wählen Sie die Metrik auf der richtigen Ebene aus. Wenn Sie die Metrik für einen Operator verfolgen , müssen Sie die entsprech enden Operator- Metriken auswählen. • Da Managed Service für Apache Flink 4 Metrik- Snapshots pro Minute erstellt, sollte die folgende	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
				Metrikmat hematik verwendet werden: m1/4, wobei m1 die SUM- Statistik über einen Zeitraum (Sekunde/ Minute) ist	
				Die Ebene der Metrik gibt an, ob diese Metrik die Gesamtzah I der Datensätz e misst, die die gesamte Anwendung, ein bestimmte r Operator oder eine bestimmte Aufgabe empfangen hat.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
numRecord sInPerSec ond*	Anzahl/Se kunde	Die Gesamtzah I der Datensätz e, die diese Anwendung , dieser Operator oder diese Aufgabe pro Sekunde erhalten hat.	Anwendung , Operator, Aufgabe, Parallelität	 *Um die SUM-Statistik über einen bestimmte n Zeitraum (Sekunde/ Minute) anzuwenden: Wählen Sie die Metrik auf der richtigen Ebene aus. Wenn Sie die Metrik für einen Operator verfolgen , müssen Sie die entsprech enden Operator- Metriken auswählen. Da Managed Service für Apache Flink 4 Metrik- Snapshots pro Minute erstellt, sollte die folgende 	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
				Metrikmat hematik verwendet werden: m1/4, wobei m1 die SUM- Statistik über einen Zeitraum (Sekunde/ Minute) ist Die Ebene der Metrik gibt an, ob diese Metrik die Gesamtzah I der Datensätz e misst, die die gesamte Anwendung, ein bestimmte r Operator oder eine bestimmte r Operator oder eine bestimmte r Operator oder eine bestimmte r Operator oder eine bestimmte r Aufgabe pro Sekunde empfangen hat.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
numRecord sOut*	Anzahl	Die Gesamtzah I der Datensätz e, die diese Anwendung , dieser Operator oder diese Aufgabe ausgegeben hat.	Anwendung , Operator, Aufgabe, Parallelität	*Um die SUM-Statistik über einen bestimmte n Zeitraum (Sekunde/ Minute) anzuwenden: • Wählen Sie die Metrik auf der richtigen Ebene aus. Wenn Sie die Metrik für einen Operator verfolgen , müssen Sie die entsprech enden Operator- Metriken auswählen. • Da Managed Service für Apache Flink 4 Metrik- Snapshots pro Minute erstellt, sollte die folgende

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
				Metrikmat hematik verwendet werden: m1/4, wobei m1 die SUM- Statistik über einen Zeitraum (Sekunde/ Minute) ist	
				Die Ebene der Metrik gibt an, ob diese Metrik die Gesamtzah I der Datensätz e misst, die die gesamte Anwendung, ein bestimmte r Operator oder eine bestimmte Aufgabe ausgegeben hat.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
numLateRe cordsDrop ped*	Anzahl	Anwendung , Operator, Aufgabe, Parallelität		*Um die SUM-Statistik über einen bestimmte n Zeitraum (Sekunde/ Minute) anzuwenden: • Wählen Sie die Metrik auf der richtigen Ebene aus. Wenn Sie die Metrik für einen Operator verfolgen , müssen Sie die entsprech enden Operator- Metriken auswählen. • Da Managed Service für Apache Flink 4 Metrik- Snapshots pro Minute erstellt, sollte	
				-	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
				Metrikmat hematik verwendet werden: m1/4, wobei m1 die SUM- Statistik über einen Zeitraum (Sekunde/ Minute) ist	
				Die Anzahl der Datensätz e, die dieser Operator oder diese Aufgabe aufgrund einer verspätet en Ankunft gelöscht hat.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
numRecord sOutPerSe cond*	Anzahl/Se kunde	Die Gesamtzah I der Datensätz e, die diese Anwendung , dieser Operator oder diese Aufgabe pro Sekunde ausgegeben hat.	Anwendung , Operator, Aufgabe, Parallelität	*Um die SUM-Statistik über einen bestimmte n Zeitraum (Sekunde/ Minute) anzuwenden: • Wählen Sie die Metrik auf der richtigen Ebene aus. Wenn Sie die Metrik für einen Operator verfolgen , müssen Sie die entsprech enden Operator- Metriken auswählen. • Da Managed Service für Apache Flink 4 Metrik- Snapshots pro Minute erstellt, sollte die folgende

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
				Metrikmat hematik verwendet werden: m1/4, wobei m1 die SUM- Statistik über einen Zeitraum (Sekunde/ Minute) ist Die Ebene der Metrik gibt an, ob diese Metrik die Gesamtzah I der Datensätz e misst, die die gesamte Anwendung, ein bestimmte r Operator oder eine bestimmte r Operator oder eine bestimmte Aufgabe pro Sekunde ausgegeben hat.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
oldGenera tionGCCou nt	Anzahl	Die Gesamtzah I der alten Garbage- Collection- Vorgänge, die in allen Task- Managern stattgefunden haben.	Anwendung		
oldGenera tionGCTim e	Millisekunden	Die Gesamtzei t, die für die Durchführung alter Garbage- Collection -Vorgänge aufgewendet wurde.	Anwendung	Sie können diese Metrik verwenden, um die Summe, den Durchschn itt und die maximale Zeit für die Garbage Collection zu überwachen.	

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
threadCou nt	Anzahl	Die Gesamtzah I der von der Anwendung verwendeten Live-Threads.	Anwendung	Diese Metrik misst die Anzahl der Threads, die vom Anwendung scode verwendet werden. Dies ist nicht dasselbe wie Anwendung sparallelität.
uptime	Millisekunden	Die Zeit, zu der der Job ohne Unterbrechung ausgeführt wurde.	Anwendung	Sie können diese Metrik verwenden, um festzuste llen, ob ein Job erfolgrei ch ausgeführ t wird. Diese Metrik gibt -1 für abgeschlo ssene Jobs zurück.

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise	
KPUs *	Anzahl	Die Gesamtzah I der von der Anwendung KPUs verwendeten.	Anwendung	*Für diese Kennzahl wird eine Stichprobe pro Abrechnun gszeitraum (eine Stunde) verwendet. Verwenden Sie MAX oder AVG KPUs über einen Zeitraum von mindesten s einer (1) Stunde, um die Anzahl der Ereignisse im Laufe der Zeit zu visualisi eren. Die KPU- Anzahl beinhaltet die orchestra tion KPU. Weitere Informationen finden Sie unter Preise für Managed Service for Apache Flink.	

Metriken des Kinesis Data Streams Streams-Konnektors

AWS gibt alle Datensätze für Kinesis Data Streams zusätzlich zu den folgenden aus:

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
millisbeh indLatest	Millisekunden	Die Anzahl der Milliseku nden, die der Verbraucher hinter der Spitze des Streams zurückliegt. Dies zeigt an, wie weit der Verbrauch er hinter der aktuellen Zeit zurückliegt.	Anwendung (für Stream), Parallelismus (für) ShardId	 Der Wert 0 gibt an, dass die Datenvera rbeitung aktuell ist und dass zurzeit keine neuen zu verarbeitenden Datensätze vorhanden sind. Die Metrik eines bestimmte n Shards kann durch den Stream- Namen und die Shard-ID angegeben werden. Ein Wert von -1 gibt an, dass der Service noch keinen Wert für die Metrik gemeldet hat.

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
bytesRequ estedPerF etch	Bytes	Die in einem einzigen Aufruf an getRecord s angeforderten Bytes.	Anwendung (für Stream), Paralleli tät (für) ShardId	

Amazon MSK-Connector-Metriken

AWS gibt alle Datensätze für Amazon MSK zusätzlich zu den folgenden aus:

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
currentof fsets	N/A	Der aktuelle Lese-Offset des Verbrauchers für jede Partition. Die Metrik einer bestimmten Partition kann anhand des Themennamens und der Partition s-ID angegeben werden.	Anwendung (für Thema), Paralleli tät (für) Partition Id	
commitsFa iled	N/A	Die Gesamtzahl der Fehler beim Offset-Commit an Kafka, wenn Offset-Commit und Prüfpunkt	Anwendung , Operator, Aufgabe, Parallelität	Das Zurücksch reiben von Offsets an Kafka ist nur ein Mittel, um den Verbrauch erfortschritt

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
		prüfung aktiviert sind.		aufzudecken. Ein Commit-Fe hler beeinträc htigt also nicht die Integrität der Prüfpunkt- Partitions-Offsets von Flink.
commitsSu cceeded	N/A	Die Gesamtzah I erfolgreichen Offset-Commits an Kafka, wenn Offset-Commit und Prüfpunkt prüfung aktiviert sind.	Anwendung , Operator, Aufgabe, Parallelität	
committed offsets	N/A	Die letzten erfolgreich an Kafka übergeben en Offsets für jede Partition. Die Metrik einer bestimmten Partition kann anhand des Themennamens und der Partition s-ID angegeben werden.	Anwendung (für Thema), Paralleli tät (für) Partition Id	

Managed Service für Apache Flink

Metrik	Einheit	Beschreibung	Level	Nutzungsh inweise
records_l ag_max	Anzahl	Die maximale Verzögerung in Bezug auf die Anzahl der Datensätze für jede Partition in diesem Fenster	Anwendung , Operator, Aufgabe, Parallelität	
bytes_con sumed_rate	Bytes	Die durchschn ittliche Anzahl von Bytes, die pro Sekunde für ein Thema verbraucht werden	Anwendung , Operator, Aufgabe, Parallelität	

Apache Zeppelin-Metriken

Gibt für AWS Studio-Notebooks die folgenden Metriken auf Anwendungsebene aus:KPUs,,cpuUtilization, heapMemoryUtilizationoldGenerationGCTime, oldGenerationGCCount und. threadCount Darüber hinaus werden die in der folgenden Tabelle aufgeführten Metriken auch auf Anwendungsebene ausgegeben.

Metrik	Einheit	Beschreibung	Prometheus-Name
zeppelinC puUtilization	Prozentsatz	Gesamtprozentsatz der CPU-Auslastung auf dem Apache Zeppelin-Server.	process_c pu_usage
zeppelinH eapMemory Utilization	Prozentsatz	Gesamtprozentsatz der Heap-Spei cherauslastung für	jvm_memor y_used_bytes

Managed Service für Apache Flink

Metrik	Einheit	Beschreibung	Prometheus-Name
		den Apache Zeppelin- Server.	
zeppelinT hreadCount	Anzahl	Die Gesamtzahl der vom Apache Zeppelin-Server verwendeten Live- Threads.	jvm_threa ds_live_t hreads
zeppelinW aitingJobs	Anzahl	Die Anzahl der Apache Zeppelin-Jobs in der Warteschlange, die auf einen Thread warten.	jetty_thr eads_jobs
zeppelinS erverUptime	Sekunden	Die Gesamtzeit, in der der Server betriebsb ereit war.	process_u ptime_seconds

Metriken anzeigen CloudWatch

Sie können CloudWatch Metriken für Ihre Anwendung über die CloudWatch Amazon-Konsole oder die anzeigen AWS CLI.

Um Metriken über die CloudWatch Konsole anzuzeigen

- 1. Öffnen Sie die CloudWatch Konsole unter https://console.aws.amazon.com/cloudwatch/.
- 2. Wählen Sie im Navigationsbereich Metrics (Metriken) aus.
- 3. Wählen Sie im Bereich "CloudWatch Metriken nach Kategorie" für Managed Service for Apache Flink eine Metrikkategorie aus.
- 4. Führen Sie im oberen Bereich einen Bildlauf durch, um die vollständige Liste der Metriken anzuzeigen.

Um Metriken anzuzeigen, verwenden Sie AWS CLI

• Geben Sie als Eingabeaufforderung den folgenden Befehl ein.

aws cloudwatch list-metrics --namespace "AWS/KinesisAnalytics" --region *region*

Legen Sie Berichtsebenen für CloudWatch Kennzahlen fest

Sie können die Ebene der Anwendungsmetriken steuern, die Ihre Anwendung erstellt. Managed Service für Apache Flink unterstützt die folgenden Metrikebenen:

- Anwendung: Die Anwendung meldet f
 ür jede Anwendung nur die h
 öchste Stufe an Metriken. Die Metriken von Managed Service f
 ür Apache Flink werden standardm
 äßig auf Anwendungsebene veröffentlicht.
- Aufgabe: Die Anwendung meldet aufgabenspezifische Metrikdimensionen f
 ür Metriken, die mit der Berichtsebene Aufgaben-Metrik definiert wurden, wie z. B. die Anzahl der Datensätze pro Sekunde, die in die Anwendung ein- und von ihr ausgehen.
- Operator: Die Anwendung meldet operatorspezifische Metrikdimensionen f
 ür Metriken, die mit der Berichtsebene Operator-Metrik definiert wurden, wie z. B. Metriken f
 ür jeden Filter- oder Zuordnungsvorgang.
- Parallelität: Die Anwendung erstellt Task- und Operator-Ebenen-Metriken f
 ür jeden Ausf
 ührungsthread. Diese Berichtsebene wird wegen
 überm
 äßiger Kosten nicht f
 ür Anwendungen mit Parallelit
 ätseinstellung
 über 64 empfohlen.

1 Note

Aufgrund der Menge an Metrikdaten, die der Service generiert, sollten Sie diese Metrikebene nur zur Fehlerbehebung verwenden. Sie können diese Metrikebene nur mit der CLI festlegen. Diese Metrikebene ist in der Konsole nicht verfügbar.

Die Standardebene ist Anwendung. Die Anwendung meldet Metriken auf der aktuellen Ebene und allen höheren Ebenen. Wenn die Berichtsebene beispielsweise auf Operator gesetzt ist, meldet die Anwendung Anwendungs-, Aufgaben-, and Operator-Metriken.

Sie legen die Berichtsebene für CloudWatch Metriken mithilfe des MonitoringConfiguration <u>CreateApplication</u>Aktionsparameters oder des MonitoringConfigurationUpdate <u>UpdateApplication</u>Aktionsparameters fest. In der folgenden Beispielanforderung für die <u>UpdateApplication</u>Aktion wird die Berichtsebene für die CloudWatch Metriken auf Aufgabe festgelegt:

Sie können die Protokollierungsebene auch mithilfe des LogLevel-Parameters der Aktion <u>CreateApplication</u> oder des LogLevelUpdate-Parameters der Aktion <u>UpdateApplication</u> konfigurieren. Sie können die folgenden Protokollebenen verwenden:

- ERROR: Protokolliert potenziell behebbare Fehlerereignisse.
- WARN: Protokolliert Warnereignisse, die zu einem Fehler führen könnten.
- INF0: Protokolliert Informationsereignisse.
- DEBUG: Protokolliert allgemeine Debugging-Ereignisse.

Weitere Informationen zu Log4j-Protokollierungsebenen finden Sie unter <u>Benutzerdefinierte</u> Protokollebenen in der Apache Log4j-Dokumentation.

Verwenden Sie benutzerdefinierte Metriken mit Amazon Managed Service für Apache Flink

Managed Service für Apache Flink stellt 19 Metriken zur Verfügung CloudWatch, darunter Metriken für Ressourcennutzung und Durchsatz. Darüber hinaus können Sie Ihre eigenen Metriken erstellen, um anwendungsspezifische Daten zu verfolgen, z. B. Verarbeitungsereignisse oder den Zugriff auf externe Ressourcen.

Dieses Thema enthält die folgenden Abschnitte:

- Funktionsweise
- Sehen Sie sich Beispiele für die Erstellung einer Mapping-Klasse an
- Benutzerdefinierte Metriken anzeigen

Funktionsweise

Benutzerdefinierte Metriken in Managed Service für Apache Flink verwenden das Apache Flink-Metriksystem. Apache Flink-Metriken haben die folgenden Attribute:

 Typ: Der Typ einer Metrik beschreibt, wie Daten gemessen und gemeldet werden. Zu den verfügbaren Apache Flink-Metriktypen gehören Anzahl, Diagramm, Histogramm und Messung. Weitere Informationen zu den Metriktypen von Apache Flink finden Sie unter <u>Metriktypen.</u>

Note

AWS CloudWatch Metrics unterstützt den Metriktyp Histogramm Apache Flink nicht. CloudWatch kann nur Apache Flink-Metriken der Typen Count, Gauge und Meter anzeigen.

- Umfang: Der Geltungsbereich einer Metrik besteht aus ihrer Kennung und einer Reihe von Schlüssel-Wert-Paaren, die angeben, wie die Metrik gemeldet werden soll. CloudWatch Die Kennung einer Metrik enthält die folgenden Elemente:
 - Einen Systembereich, der die Ebene angibt, auf der die Metrik gemeldet wird (z. B. Operator).
 - Einen Benutzerbereich, der Attribute wie Benutzervariablen oder Metrikgruppennamen definiert. Diese Attribute werden mit <u>MetricGroup.addGroup(key, value)</u> oder MetricGroup.addGroup(name) definiert.

Weitere Informationen zu Metrikbereichen finden Sie unter Bereich.

Weitere Informationen zu Apache Flink-Metriken finden Sie unter <u>Metriken</u> in der <u>Apache Flink-</u> <u>Dokumentation</u>.

Um eine benutzerdefinierte Metrik in Ihrem Managed Service für Apache Flink zu erstellen, können Sie von jeder Benutzerfunktion aus, die RichFunction erweitert, durch Aufrufen von <u>GetMetricGroup</u> auf das Apache Flink-Metriksystem zugreifen. Diese Methode gibt ein <u>MetricGroup</u>Objekt zurück, mit dem Sie benutzerdefinierte Metriken erstellen und registrieren können. Managed Service for Apache Flink meldet alle Metriken, die mit dem Gruppenschlüssel
KinesisAnalytics für erstellt wurden. CloudWatch Benutzerdefinierte Metriken, die Sie definieren, weisen folgende Merkmale auf:

- Ihre benutzerdefinierte Metrik hat einen Metriknamen und einen Gruppennamen. Diese Namen müssen gemäß den Benennungsregeln von Prometheus aus alphanumerischen Zeichen bestehen.
- Attribute, die Sie im Benutzerbereich definieren (mit Ausnahme der KinesisAnalytics Metrikgruppe), werden als Dimensionen veröffentlicht. CloudWatch
- Benutzerdefinierte Metriken werden standardmäßig auf der Application-Ebene veröffentlicht.
- Dimensionen (Aufgabe/Operator/Parallelismus) werden der Metrik auf der Grundlage der Überwachungsebene der Anwendung hinzugefügt. Sie legen die Überwachungsebene der Anwendung mithilfe des <u>MonitoringConfiguration</u>Aktionsparameters oder des <u>CreateApplicationMonitoringConfigurationUpdate</u>Aktionsparameters oder der <u>UpdateApplicationAktion fest</u>.

Sehen Sie sich Beispiele für die Erstellung einer Mapping-Klasse an

Die folgenden Codebeispiele zeigen, wie Sie eine Mapping-Klasse erstellen, die eine benutzerdefinierte Metrik erstellt und inkrementiert, und wie Sie die Mapping-Klasse in Ihrer Anwendung implementieren, indem Sie sie einem DataStream Objekt hinzufügen.

Benutzerdefinierte Metrik für die Anzahl der Datensätze

Das folgende Codebeispiel zeigt, wie eine Mapping-Klasse erstellt wird, die eine Metrik erstellt, die Datensätze in einem Datenstrom zählt (dieselbe Funktionalität wie die numRecordsIn-Metrik):

```
private static class NoOpMapperFunction extends RichMapFunction<String, String> {
    private transient int valueToExpose = 0;
    private final String customMetricName;

    public NoOpMapperFunction(final String customMetricName) {
        this.customMetricName = customMetricName;
    }

    @Override
    public void open(Configuration config) {
        getRuntimeContext().getMetricGroup()
            .addGroup("KinesisAnalytics")
            .addGroup("Program", "RecordCountApplication")
            .addGroup("NoOpMapperFunction")
            .gauge(customMetricName, (Gauge<Integer>) () -> valueToExpose);
```

```
}
@Override
public String map(String value) throws Exception {
    valueToExpose++;
    return value;
}
```

Im vorherigen Beispiel wird die valueToExpose-Variable für jeden Datensatz, den die Anwendung verarbeitet, inkrementiert.

Nachdem Sie Ihre Mapping-Klasse definiert haben, erstellen Sie einen anwendungsinternen Stream, der die Map implementiert:

```
DataStream<String> noopMapperFunctionAfterFilter =
    kinesisProcessed.map(new NoOpMapperFunction("FilteredRecords"));
```

Den vollständigen Code für diese Anwendung finden Sie unter <u>Datensatzanzahl benutzerdefinierte</u> Metrikanwendung.

Benutzerdefinierte Metrik für die Anzahl der Wörter

Das folgende Codebeispiel zeigt, wie eine Mapping-Klasse erstellt wird, die eine Metrik erstellt, die Wörter in einem Datenstrom zählt:

```
private static final class Tokenizer extends RichFlatMapFunction<String, Tuple2<String,
Integer>> {
    private transient Counter counter;
    @Override
    public void open(Configuration config) {
        this.counter = getRuntimeContext().getMetricGroup()
            .addGroup("KinesisAnalytics")
            .addGroup("Service", "WordCountApplication")
            .addGroup("Tokenizer")
            .counter("TotalWords");
    }
    @Override
    public void flatMap(String value, Collector<Tuple2<String, Integer>>out) {
```

```
// normalize and split the line
String[] tokens = value.toLowerCase().split("\\W+");
// emit the pairs
for (String token : tokens) {
    if (token.length() > 0) {
        counter.inc();
        out.collect(new Tuple2<>(token, 1));
    }
}
```

Im vorherigen Beispiel wird die counter-Variable für jedes Wort, das die Anwendung verarbeitet, inkrementiert.

Nachdem Sie Ihre Mapping-Klasse definiert haben, erstellen Sie einen anwendungsinternen Stream, der die Map implementiert:

```
// Split up the lines in pairs (2-tuples) containing: (word,1), and
// group by the tuple field "0" and sum up tuple field "1"
DataStream<Tuple2<String, Integer>> wordCountStream = input.flatMap(new
Tokenizer()).keyBy(0).sum(1);
```

```
// Serialize the tuple to string format, and publish the output to kinesis sink
wordCountStream.map(tuple -> tuple.toString()).addSink(createSinkFromStaticConfig());
```

Den vollständigen Code für diese Anwendung finden Sie unter <u>Wortanzahl benutzerdefinierte</u> Metrikanwendung.

Benutzerdefinierte Metriken anzeigen

Benutzerdefinierte Metriken für Ihre Anwendung werden in der CloudWatch Metrics-Konsole im AWS/ KinesisAnalyticsDashboard unter der Metrikgruppe "Anwendung".

Verwenden Sie CloudWatch Alarme mit Amazon Managed Service für Apache Flink

Mithilfe von Amazon CloudWatch Metric Alarms beobachten Sie eine CloudWatch Metrik über einen von Ihnen angegebenen Zeitraum. Der Alarm führt eine oder mehrere Aktionen durch, die vom Wert der Metrik oder des Ausdrucks im Vergleich zu einem Schwellenwert in einer Reihe von Zeiträumen

abhängt. Eine Aktion könnte beispielsweise der Versand einer Benachrichtigung an ein Amazon Simple Notification Service (Amazon SNS)-Thema sein.

Weitere Informationen zu CloudWatch Alarmen finden Sie unter <u>Amazon CloudWatch Alarms</u> <u>verwenden</u>.

Lesen Sie die empfohlenen Alarme

Dieser Abschnitt enthält die empfohlenen Alarme für die Überwachung von Managed Service für Apache Flink-Anwendungen.

Die Tabelle beschreibt die empfohlenen Alarme und enthält die folgenden Spalten:

- Metrikausdruck: Die Metrik oder der Metrikausdruck, der anhand des Schwellenwerts getestet werden soll.
- Statistik: Die Statistik, die zur Überprüfung der Metrik verwendet wird, z. B. Durchschnitt.
- Schwellenwert: Für die Verwendung dieses Alarms müssen Sie einen Schwellenwert festlegen, der die Grenze der erwarteten Anwendungsleistung definiert. Sie müssen diesen Schwellenwert ermitteln, indem Sie Ihre Anwendung unter normalen Bedingungen überwachen.
- Beschreibung: Ursachen, die diesen Alarm auslösen könnten, und mögliche Lösungen für diesen Zustand.

Metrikausdruck	Statistik	Threshold	Beschreibung
downtime>0	Durchschnitt	0	Eine Ausfallzeit von mehr als Null bedeutet, dass die Anwendung ausgefall en ist. Wenn der Wert größer als 0 ist, verarbeitet die Anwendung keine Daten. Für alle Anwendung en empfohlen. Die Downtime Metrik misst die Dauer

Metrikausdruck	Statistik	Threshold	Beschreibung
			eines Ausfalls. Eine
			Ausfallzeit von mehr
			als Null bedeutet,
			dass die Anwendung
			ausgefallen ist.
			Informationen zur
			Problembehandlung
			finden Sie unter <mark>Die</mark>
			Anwendung wird neu
			gestartet.

Metrikausdruck	Statistik	Threshold	Beschreibung
<pre>Metrikausdruck RATE (numberOf FailedChe ckpoints) > 0</pre>	Statistik Durchschnitt	Threshold	Beschreibung Diese Metrik zählt die Anzahl der fehlgesch lagenen Checkpoin ts seit dem Start der Anwendung. Je nach Anwendung kann es toleriert werden, dass Prüfpunkte gelegentl ich fehlschlagen. Wenn Prüfpunkte jedoch regelmäßi g ausfallen, ist die Anwendung wahrscheinlich fehlerhaft und benötigt weitere Aufmerksa mkeit. Wir empfehlen , RATE (numberOf FailedCheckpoints) so zu überwachen, dass der Alarm auf dem Gradienten und nicht auf absoluten Werten basiert. Für alle Anwendung en empfohlen.
			Verwenden Sie diese Metrik. um
			den Zustand der Anwendung und
			den Fortschritt der Checkpoints
			zu überwachen. Die Anwendung

bei den Eingabeda ten nicht die erwartete n Fortschritte erzielt.

Informationen zur Problembehandlung finden Sie unterDer

Durchsatz ist zu

langsam.

Metrikausdruck		Statistik	Threshold	Beschreibung
				speichert Statusdat en an Checkpoints, wenn sie fehlerfre i ist. Checkpointing kann aufgrund von Timeouts fehlschla gen, wenn die Anwendung bei der Verarbeitung der Eingabedaten keine Fortschritte macht. Informationen zur Problembehandlung finden Sie unter. <u>Beim</u> <u>Checkpointing kommt</u> es zu einer Zeitübers chreitung
Operator. numRecord sOutPerSecond Schwellenwert	<	Durchschnitt	Die Mindestanzahl von Datensätzen, die unter normalen Bedingungen von der Anwendung gesendet werden.	Für alle Anwendung en empfohlen. Ein Unterschreiten dieses Schwellenwerts kann darauf hindeuten, dass die Anwendung

Metrikausdruck	Statistik	Threshold	Beschreibung
<pre>records_l ag_max mi llisbehin dLatest > Schwellenwert</pre>	Maximum	Die maximal zu erwartende Latenz unter normalen Bedingungen.	Wenn die Anwendung viel Kinesis oder Kafka verbraucht, geben diese Metriken an, ob die Anwendung hinterherhinkt und skaliert werden muss, um mit der aktuellen Auslastung Schritt zu halten. Dies ist eine gute generisch e Metrik, die für alle Arten von Anwendung en leicht nachzuver folgen ist. Sie kann jedoch nur für reaktive Skalierung verwendet werden, d. h. wenn die Anwendung bereits ins Hintertre ffen geraten ist. Für alle Anwendung en empfohlen. Verwenden Sie die records_1 ag_max Metrik für eine Kafka-Quelle oder die millisbeh indLatest für eine Kinesis-S tream-Quelle. Eine Überschreitung dieses Schwellenwerts kann darauf hindeuten,

Metrikausdruck	Statistik	Threshold	Beschreibung
			dass die Anwendung bei den Eingabeda ten nicht die erwartete n Fortschritte erzielt. Informationen zur Problembehandlung finden Sie unter <u>Der</u> <u>Durchsatz ist zu</u> <u>langsam</u> .

Metrikausdruck		Statistik	Threshold	Beschreibung
lastCheck pointDuration Schwellenwert	>	Maximum	Die maximal zu erwartende Checkpoint-Dauer unter normalen Bedingungen.	Überwacht, wie viele Daten im Status gespeichert sind und wie lange es dauert, bis ein Checkpoint abgeschlossen ist. Wenn die Anzahl der Prüfpunkte zunimmt oder lange dauert, verbringt die Anwendung kontinuie rlich Zeit mit Prüfpunkt en und hat weniger Zyklen für die eigentlic he Verarbeitung. An manchen Stellen können Prüfpunkte zu groß werden oder so lange dauern, dass sie ausfallen. Neben der Überwachung absoluter Werte sollten Kunden auch erwägen, die Änderungsrate mit RATE(last Checkpoin tSize) und RATE(last Checkpoin tDuration) zu überwachen. Wenn der Wert lastCheck pointDura

Metrikausdruck	Statistik	Threshold	Beschreibung
			tion kontinuierlich ansteigt, kann ein Überschreiten dieses Schwellenwerts darauf hinweisen, dass die Anwendung
			bei den Eingabeda ten nicht die erwartete n Fortschritte erzielt
			oder dass Probleme mit dem Zustand der Anwendung
			vorliegen, wie z. B. Gegendruck. Informati onen zur Problembe handlung finden Sie unter <u>Unbegrenztes</u> <u>Staatswachstum</u> .
			Staatswachstuff.

Metrikausdruck	Statistik	Threshold	Beschreibung
<pre>lastCheck pointSize > Schwellenwert</pre>	Maximum	Die maximal zu erwartende Checkpoint-Größe unter normalen Bedingungen.	Überwacht, wie viele Daten im Status gespeichert sind und wie lange es dauert, bis ein Checkpoint abgeschlossen ist. Wenn die Anzahl der Prüfpunkte zunimmt oder lange dauert, verbringt die Anwendung kontinuie rlich Zeit mit Prüfpunkt en und hat weniger Zyklen für die eigentlic he Verarbeitung. An manchen Stellen können Prüfpunkte zu groß werden oder so lange dauern, dass sie ausfallen. Neben der Überwachung absoluter Werte sollten Kunden auch erwägen, die Änderungsrate mit RATE(last Checkpoin tSize) und RATE(last Checkpoin tDuration) zu überwachen. Wenn der Wert lastCheck pointSize

Metrikausdruck	Statistik	Threshold	Beschreibung
			kontinuierlich
			ansteigt, kann ein
			Überschreiten dieses
			Schwellenwerts
			darauf hinweisen,
			dass die Anwendung
			Zustandsdaten
			sammelt. Wenn die
			Zustandsdaten zu
			groß werden, kann
			der Anwendung bei
			der Wiederherstellung
			von einem Checkpoin
			t der Speicherplatz
			ausgehen, oder die
			Wiederherstellung
			von einem Checkpoin
			t kann zu lange
			dauern. Informati
			onen zur Problembe
			handlung finden Sie
			unter. Unbegrenztes
			Staatswachstum

Metrikausdruck	Statistik	Threshold	Beschreibung
heapMemor yUtilization > Schwellenwert	Maximum	Dies gibt einen guten Hinweis auf die gesamte Ressource nauslastung der Anwendung und kann für eine proaktive Skalierung verwendet werden, sofern die Anwendung nicht I/ O-gebunden ist. Die maximale heapMemor yUtilization Größe, die unter normalen Bedingung en erwartet wird, mit einem empfohlenen Wert von 90 Prozent.	Sie können diese Metrik verwenden , um die maximale Speicherauslastung von Task-Managern in der gesamten Anwendung zu überwachen. Wenn die Anwendung diesen Schwellen wert erreicht, müssen Sie mehr Ressource n bereitstellen. Sie tun dies, indem Sie die automatische Skalierung aktivieren oder die Anwendung sparallelität erhöhen. Weitere Informationen zur Erhöhung der Ressourcen finden Sie unter. Implement ieren Sie Anwendung

sskalierung

Metrikausdruck	Statistik	Threshold	Beschreibung
Methiddodiddid	Oldiolik		Desencioung
<pre>cpuUtilization > Schwellenwert</pre>	Maximum	Dies gibt einen guten Hinweis auf die gesamte Ressource nauslastung der Anwendung und kann für eine proaktive Skalierung verwendet werden, sofern die Anwendung nicht I/ O-gebunden ist. Die maximale cpuUtiliz ation Größe, die unter normalen Bedingungen erwartet wird, mit einem empfohlenen Wert von 80 Prozent.	Sie können diese Metrik verwenden , um die maximale CPU-Auslastung von Task-Managern in der gesamten Anwendung zu überwachen. Wenn die Anwendung diesen Schwellen wert erreicht, müssen Sie mehr Ressource n bereitstellen. Dazu aktivieren Sie die automatis che Skalierung oder erhöhen die Anwendungsparallel ität. Weitere Informati onen zur Erhöhung der Ressourcen finden Sie unter. Implementieren Sie Anwendungsskalieru

Metrikausdruck	Statistik	Threshold	Beschreibung
<pre>threadsCount > Schwellenwert</pre>	Maximum	Die maximal zu erwartende threadsCount Größe unter normalen Bedingungen.	Sie können diese Metrik verwenden , um in Task-Mana gern in der gesamten Anwendung nach Thread-Leaks Ausschau zu halten. Wenn diese Metrik diesen Schwellenwert erreicht, überprüfen Sie Ihren Anwendung scode auf Threads, die erstellt wurden, ohne geschlossen zu werden.
<pre>(oldGarba geCollect ionTime * 100)/60_0 00 over 1 min period')> Schwellenwert</pre>	Maximum	Die maximale erwartete oldGarbag eCollecti onTime Dauer. Wir empfehlen, einen Schwellen wert so festzulegen, dass die typische Garbage-Collection -Zeit 60 Prozent des angegebenen Schwellenwerts beträgt. Der richtige Schwellenwert für Ihre Anwendung kann jedoch variieren.	Wenn diese Kennzahl kontinuierlich steigt, kann dies darauf hindeuten, dass in den Task-Mana gern der gesamten Anwendung ein Speicherverlust vorliegt.

Unteraufgabe seit immer längerer Zeit kein Wasserzeichen mehr gesendet hat.

Metrikausdruck		Statistik	Threshold	Beschreibung
RATE(oldG arbageCol lectionCount) > Schwellenwert		Maximum	Das oldGarbag eCollecti onCount unter normalen Bedingung en zu erwartende Maximum. Der richtige Schwellenwert für Ihre Anwendung wird variieren.	Wenn diese Kennzahl kontinuierlich steigt, kann dies darauf hindeuten, dass in den Task-Mana gern der gesamten Anwendung ein Speicherverlust vorliegt.
Operator. currentOu tputWatermark - Operator. currentIn putWatermark Schwellenwert	>	Minimum	Der minimale zu erwartende Anstieg des Wasserzeichens unter normalen Bedingungen. Der richtige Schwellenwert für Ihre Anwendung wird variieren.	Wenn diese Kennzahl kontinuierlich steigt, kann dies darauf hindeuten, dass entweder die Anwendung immer ältere Ereignisse verarbeitet oder dass eine vorgelagerte

Schreiben Sie benutzerdefinierte Nachrichten in CloudWatch Logs

Sie können benutzerdefinierte Nachrichten in das Protokoll Ihrer Managed Service for Apache Flink-Anwendung schreiben. CloudWatch Sie tun dies, indem Sie die Apache <u>log4j</u>-Bibliothek oder die <u>Simple Logging Facade for Java (SLF4J)</u>-Bibliothek verwenden.

Themen

- Schreiben Sie mit CloudWatch Log4J in Protokolle
- Schreiben Sie mit J in CloudWatch Logs SLF4

Schreiben Sie mit CloudWatch Log4J in Protokolle

1. Fügen Sie der pom. xml-Datei Ihrer Anwendung die folgenden Abhängigkeiten hinzu:

```
<dependency>
    <groupId>org.apache.logging.log4j</groupId>
    <artifactId>log4j-api</artifactId>
    <version>2.6.1</version>
</dependency>
    <groupId>org.apache.logging.log4j</groupId>
    <artifactId>log4j-core</artifactId>
    <version>2.6.1</version>
</dependency>
</d
```

2. Fügen Sie das Objekt aus der Bibliothek hinzu:

import org.apache.logging.log4j.Logger;

3. Instanziieren Sie das Logger-Objekt und übergeben Sie Ihre Anwendungsklasse:

```
private static final Logger log =
  LogManager.getLogger.getLogger(YourApplicationClass.class);
```

4. Schreiben Sie mit log.info in das Protokoll. Eine große Anzahl von Nachrichten wird in das Anwendungsprotokoll geschrieben. Verwenden Sie die INFO-Anwendungsprotokollebene, damit Ihre benutzerdefinierten Nachrichten einfacher gefiltert werden können.

log.info("This message will be written to the application's CloudWatch log");

Die Anwendung schreibt einen Datensatz in das Protokoll mit einer Meldung wie der folgenden:

```
{
    "locationInformation": "com.amazonaws.services.managed-
flink.StreamingJob.main(StreamingJob.java:95)",
    "logger": "com.amazonaws.services.managed-flink.StreamingJob",
    "message": "This message will be written to the application's CloudWatch log",
    "threadName": "Flink-DispatcherRestEndpoint-thread-2",
    "applicationARN": "arn:aws:kinesisanalyticsus-east-1:123456789012:application/test",
    "applicationVersionId": "1", "messageSchemaVersion": "1",
    "messageType": "INFO"
```

}

Schreiben Sie mit J in CloudWatch Logs SLF4

1. Fügen Sie der pom. xml-Datei Ihrer Anwendung die folgende Abhängigkeit hinzu:

```
<dependency>
<groupId>org.slf4j</groupId>
<artifactId>slf4j-log4j12</artifactId>
<version>1.7.7</version>
<scope>runtime</scope>
</dependency>
```

2. Fügen Sie die Objekte aus der Bibliothek hinzu:

```
import org.slf4j.Logger;
import org.slf4j.LoggerFactory;
```

3. Instanziieren Sie das Logger-Objekt und übergeben Sie Ihre Anwendungsklasse:

```
private static final Logger log =
  LoggerFactory.getLogger(YourApplicationClass.class);
```

4. Schreiben Sie mit log.info in das Protokoll. Eine große Anzahl von Nachrichten wird in das Anwendungsprotokoll geschrieben. Verwenden Sie die INFO-Anwendungsprotokollebene, damit Ihre benutzerdefinierten Nachrichten einfacher gefiltert werden können.

log.info("This message will be written to the application's CloudWatch log");

Die Anwendung schreibt einen Datensatz in das Protokoll mit einer Meldung wie der folgenden:

```
{
    "locationInformation": "com.amazonaws.services.managed-
flink.StreamingJob.main(StreamingJob.java:95)",
    "logger": "com.amazonaws.services.managed-flink.StreamingJob",
    "message": "This message will be written to the application's CloudWatch log",
    "threadName": "Flink-DispatcherRestEndpoint-thread-2",
    "applicationARN": "arn:aws:kinesisanalyticsus-east-1:123456789012:application/test",
    "applicationVersionId": "1", "messageSchemaVersion": "1",
    "messageType": "INFO"
```

}

Log Managed Service für Apache Flink API-Aufrufe mit AWS CloudTrail

Managed Service for Apache Flink ist in einen Dienst integriert AWS CloudTrail, der eine Aufzeichnung der Aktionen bereitstellt, die von einem Benutzer, einer Rolle oder einem AWS Dienst in Managed Service für Apache Flink ausgeführt wurden. CloudTrail erfasst alle API-Aufrufe für Managed Service for Apache Flink als Ereignisse. Zu den erfassten Aufrufen gehören Aufrufe von der Konsole Managed Service für Apache Flink und Codeaufträge an Managed Service für Apache-Flink-API-Operationen. Wenn Sie einen Trail erstellen, können Sie die kontinuierliche Bereitstellung von CloudTrail Ereignissen an einen Amazon S3 S3-Bucket aktivieren, einschließlich Ereignissen für Managed Service for Apache Flink. Wenn Sie keinen Trail konfigurieren, können Sie die neuesten Ereignisse trotzdem in der CloudTrail Konsole im Ereignisverlauf anzeigen. Anhand der von gesammelten Informationen können Sie die Anfrage CloudTrail, die an Managed Service for Apache Flink gestellt wurde, die IP-Adresse, von der aus die Anfrage gestellt wurde, wer die Anfrage gestellt hat, wann sie gestellt wurde, und weitere Details ermitteln.

Weitere Informationen CloudTrail dazu finden Sie im <u>AWS CloudTrail Benutzerhandbuch</u>.

Informationen zu Managed Service für Apache Flink finden Sie unter CloudTrail

CloudTrail ist in Ihrem AWS Konto aktiviert, wenn Sie das Konto erstellen. Wenn in Managed Service für Apache Flink eine Aktivität auftritt, wird diese Aktivität zusammen mit anderen AWS Dienstereignissen im CloudTrail Ereignisverlauf in einem Ereignis aufgezeichnet. Sie können aktuelle Ereignisse in Ihrem AWS Konto anzeigen, suchen und herunterladen. Weitere Informationen finden Sie unter Ereignisse mit CloudTrail Ereignisverlauf anzeigen.

Für eine fortlaufende Aufzeichnung der Ereignisse in Ihrem AWS Konto, einschließlich der Ereignisse für Managed Service for Apache Flink, erstellen Sie einen Trail. Ein Trail ermöglicht CloudTrail die Übermittlung von Protokolldateien an einen Amazon S3 S3-Bucket. Wenn Sie einen Trail in der Konsole erstellen, gilt der Trail standardmäßig für alle AWS Regionen. Der Trail protokolliert Ereignisse aus allen Regionen der AWS Partition und übermittelt die Protokolldateien an den von Ihnen angegebenen Amazon S3 S3-Bucket. Darüber hinaus können Sie andere AWS Dienste konfigurieren, um die in den CloudTrail Protokollen gesammelten Ereignisdaten weiter zu analysieren und darauf zu reagieren. Weitere Informationen finden Sie hier:

- Übersicht zum Erstellen eines Trails
- <u>CloudTrail Unterstützte Dienste und Integrationen</u>
- Konfiguration von Amazon SNS SNS-Benachrichtigungen für CloudTrail
- <u>Empfangen von CloudTrail Protokolldateien aus mehreren Regionen</u> und <u>Empfangen von</u> CloudTrail Protokolldateien von mehreren Konten

Alle Managed Service for Apache Flink-Aktionen werden von der <u>API-Referenz zu Managed</u> <u>Service for Apache Flink</u> protokolliert CloudTrail und sind in dieser Dokumentation dokumentiert. Beispielsweise generieren Aufrufe der <u>UpdateApplication</u> Aktionen <u>CreateApplication</u> und Einträge in den CloudTrail Protokolldateien.

Jeder Ereignis- oder Protokolleintrag enthält Informationen zu dem Benutzer, der die Anforderung generiert hat. Die Identitätsinformationen unterstützen Sie bei der Ermittlung der folgenden Punkte:

- Ob die Anfrage mit Root- oder AWS Identity and Access Management (IAM-) Benutzeranmeldedaten gestellt wurde.
- Gibt an, ob die Anforderung mit temporären Sicherheitsanmeldeinformationen für eine Rolle oder einen Verbundbenutzer gesendet wurde.
- Ob die Anfrage von einem anderen AWS Dienst gestellt wurde.

Weitere Informationen finden Sie unter CloudTrail userIdentity-Element.

Verstehen Sie die Einträge in der Protokolldatei von Managed Service for Apache Flink

Ein Trail ist eine Konfiguration, die die Übertragung von Ereignissen als Protokolldateien an einen von Ihnen angegebenen Amazon S3 S3-Bucket ermöglicht. CloudTrail Protokolldateien enthalten einen oder mehrere Protokolleinträge. Ein Ereignis stellt eine einzelne Anforderung aus einer beliebigen Quelle dar und enthält Informationen über die angeforderte Aktion, Datum und Uhrzeit der Aktion, Anforderungsparameter usw. CloudTrail Protokolldateien sind kein geordneter Stack-Trace der öffentlichen API-Aufrufe, sodass sie nicht in einer bestimmten Reihenfolge angezeigt werden.

Das folgende Beispiel zeigt einen CloudTrail Protokolleintrag, der die <u>DescribeApplication</u>Aktionen AddApplicationCloudWatchLoggingOptionund demonstriert.

"Records": [

{

```
{
            "eventVersion": "1.05",
            "userIdentity": {
                "type": "IAMUser",
                "principalId": "EX_PRINCIPAL_ID",
                "arn": "arn:aws:iam::012345678910:user/Alice",
                "accountId": "012345678910",
                "accessKeyId": "EXAMPLE_KEY_ID",
                "userName": "Alice"
            },
            "eventTime": "2019-03-07T01:19:47Z",
            "eventSource": "kinesisanlaytics.amazonaws.com",
            "eventName": "AddApplicationCloudWatchLoggingOption",
            "awsRegion": "us-east-1",
            "sourceIPAddress": "127.0.0.1",
            "userAgent": "aws-sdk-java/unknown-version Linux/x.xx",
            "requestParameters": {
                "applicationName": "cloudtrail-test",
                "currentApplicationVersionId": 1,
                "cloudWatchLoggingOption": {
                    "logStreamARN": "arn:aws:logs:us-east-1:012345678910:log-
group:cloudtrail-test:log-stream:flink-cloudwatch"
                }
            },
            "responseElements": {
                "cloudWatchLoggingOptionDescriptions": [
                    {
                        "cloudWatchLoggingOptionId": "2.1",
                        "logStreamARN": "arn:aws:logs:us-east-1:012345678910:log-
group:cloudtrail-test:log-stream:flink-cloudwatch"
                    }
                ],
                "applicationVersionId": 2,
                "applicationARN": "arn:aws:kinesisanalyticsus-
east-1:012345678910:application/cloudtrail-test"
            },
            "requestID": "18dfb315-4077-11e9-afd3-67f7af21e34f",
            "eventID": "d3c9e467-db1d-4cab-a628-c21258385124",
            "eventType": "AwsApiCall",
            "apiVersion": "2018-05-23",
            "recipientAccountId": "012345678910"
        },
        {
            "eventVersion": "1.05",
```

]

}

```
"userIdentity": {
        "type": "IAMUser",
        "principalId": "EX_PRINCIPAL_ID",
        "arn": "arn:aws:iam::012345678910:user/Alice",
        "accountId": "012345678910",
        "accessKeyId": "EXAMPLE_KEY_ID",
        "userName": "Alice"
   },
    "eventTime": "2019-03-12T02:40:48Z",
    "eventSource": "kinesisanlaytics.amazonaws.com",
    "eventName": "DescribeApplication",
    "awsRegion": "us-east-1",
    "sourceIPAddress": "127.0.0.1",
    "userAgent": "aws-sdk-java/unknown-version Linux/x.xx",
    "requestParameters": {
        "applicationName": "sample-app"
    },
    "responseElements": null,
    "requestID": "3e82dc3e-4470-11e9-9d01-e789c4e9a3ca",
    "eventID": "90ffe8e4-9e47-48c9-84e1-4f2d427d98a5",
    "eventType": "AwsApiCall",
    "apiVersion": "2018-05-23",
    "recipientAccountId": "012345678910"
}
```

Optimieren Sie die Leistung in Amazon Managed Service für Apache Flink

Dieser Abschnitt beschreibt Techniken zur Überwachung und Verbesserung der Leistung Ihrer Anwendung, die Managed Service für Apache Flink nutzt.

Themen

- Beheben Sie Leistungsprobleme
- Verwenden Sie bewährte Methoden zur Leistungssteigerung
- Überwachen Sie die Leistung

Beheben Sie Leistungsprobleme

Dieser Abschnitt enthält eine Liste von Symptomen, anhand derer Sie Leistungsprobleme diagnostizieren und beheben können.

Wenn es sich bei Ihrer Datenquelle um einen Kinesis-Stream handelt, zeigen sich Leistungsprobleme in der Regel als hohe oder ansteigende millisbehindLatest-Metrik. Bei anderen Quellen können Sie eine ähnliche Metrik überprüfen, die die Verzögerung beim Lesen aus der Quelle darstellt.

Verstehen Sie den Datenpfad

Wenn Sie ein Leistungsproblem mit Ihrer Anwendung untersuchen, sollten Sie den gesamten Pfad berücksichtigen, den Ihre Daten zurücklegen. Die folgenden Anwendungskomponenten können zu Leistungsengpässen und Gegendruck führen, wenn sie nicht richtig konzipiert oder bereitgestellt werden:

- Datenquellen und Ziele: Stellen Sie sicher, dass die externen Ressourcen, mit denen Ihre Anwendung interagiert, ordnungsgemäß für den Durchsatz bereitgestellt werden, den Ihre Anwendung erfährt.
- Zustandsdaten: Stellen Sie sicher, dass Ihre Anwendung nicht zu häufig mit dem Zustandsspeicher interagiert.

Sie können den Serializer optimieren, den Ihre Anwendung verwendet. Der standardmäßige Kryo-Serializer kann jeden serialisierbaren Typ verarbeiten, aber Sie können einen leistungsfähigeren Serializer verwenden, wenn Ihre Anwendung nur Daten in POJO-Typen speichert. Informationen zu Apache Flink-Serialisierern finden Sie unter <u>Datentypen und Serialisierung</u> in der Apache Flink-Dokumentation.

 Operatoren: Stellen Sie sicher, dass die von Ihren Operatoren implementierte Geschäftslogik nicht zu kompliziert ist oder dass Sie nicht für jeden verarbeiteten Datensatz Ressourcen erstellen oder verwenden. Stellen Sie außerdem sicher, dass Ihre Anwendung nicht zu häufig gleitende oder rollierende Fenster erzeugt.

Lösungen zur Fehlerbehebung bei der Leistung

Dieser Abschnitt enthält mögliche Lösungen für Leistungsprobleme.

Themen

- <u>CloudWatch Überwachungsebenen</u>
- CPU-Metrik für die Anwendung
- Parallelität von Anwendungen
- <u>Anwendungsprotokollierung</u>
- Parallelität der Operatoren
- Anwendungslogik
- Speicher der Anwendung

CloudWatch Überwachungsebenen

Stellen Sie sicher, dass die CloudWatch Überwachungsebenen nicht zu ausführlich eingestellt sind.

Die Einstellung Debug der Überwachungsprotokollebene generiert eine große Menge an Datenverkehr, was zu Gegendruck führen kann. Sie sollten sie nur verwenden, wenn Sie aktiv Probleme mit der Anwendung untersuchen.

Wenn Ihre Anwendung eine hohe Parallelism-Einstellung hat, erzeugt die Verwendung der Ebene Parallelism der Überwachungsmetriken ebenfalls eine große Menge an Datenverkehr, was zu Gegendruck führen kann. Verwenden Sie diese Metrikebene nur, wenn Parallelism für Ihre Anwendung niedrig ist oder wenn Sie Probleme mit der Anwendung untersuchen.

Weitere Informationen finden Sie unter Steuern Sie die Ebenen der Anwendungsüberwachung.

CPU-Metrik für die Anwendung

Überprüfen Sie die CPU-Metrik der Anwendung. Wenn diese Metrik über 75 Prozent liegt, können Sie der Anwendung erlauben, mehr Ressourcen für sich selbst zuzuweisen, indem Sie Auto Scaling aktivieren.

Wenn Auto Scaling aktiviert ist, weist die Anwendung mehr Ressourcen zu, wenn die CPU-Auslastung 15 Minuten lang über 75 Prozent liegt. Weitere Informationen zur Skalierung finden Sie im folgenden Abschnitt <u>Richtiges Verwalten der Skalierung</u> und unter <u>Implementieren Sie</u> <u>Anwendungsskalierung</u>.

Note

Eine Anwendung wird nur als Reaktion auf die CPU-Auslastung automatisch skaliert. Die Anwendung skaliert nicht automatisch als Reaktion auf andere Systemmetriken, wie z. B. heapMemoryUtilization. Wenn Ihre Anwendung häufig andere Metriken verwendet, erhöhen Sie die Parallelität Ihrer Anwendung manuell.

Parallelität von Anwendungen

Erhöhen Sie die Parallelität der Anwendung. Sie aktualisieren die Parallelität der Anwendung mithilfe des ParallelismConfigurationUpdate Aktionsparameters. <u>UpdateApplication</u>

Das Maximum KPUs für eine Anwendung ist standardmäßig 64 und kann erhöht werden, indem eine Erhöhung des Limits beantragt wird.

Es ist wichtig, jedem Operator auch auf der Grundlage seines Workloads Parallelität zuzuweisen, anstatt nur die Anwendungsparallelität allein zu erhöhen. Weitere Informationen finden Sie im Nachfolgenden unter Parallelität der Operatoren.

Anwendungsprotokollierung

Prüfen Sie, ob die Anwendung für jeden Datensatz, der verarbeitet wird, einen Eintrag protokolliert. Das Schreiben eines Protokolleintrags für jeden Datensatz in Zeiten, in denen die Anwendung einen hohen Durchsatz hat, kann zu schwerwiegenden Engpässen bei der Datenverarbeitung führen. Um diesen Zustand zu überprüfen, fragen Sie Ihre Protokolle auf Protokolleinträge ab, die Ihre Anwendung bei jedem verarbeiteten Datensatz schreibt. Weitere Informationen zum Auslesen von Anwendungsprotokollen finden Sie unter <u>the section called "Analysieren Sie Logs mit CloudWatch</u> Logs Insights".

Parallelität der Operatoren

Stellen Sie sicher, dass der Workload Ihrer Anwendung gleichmäßig auf die Worker-Prozesse verteilt ist.

Informationen zur Optimierung des Workloads der Operatoren Ihrer Anwendung finden Sie unter Operatorenskalierung.

Anwendungslogik

Untersuchen Sie Ihre Anwendungslogik auf ineffiziente oder leistungsschwache Operationen, wie z. B. den Zugriff auf eine externe Abhängigkeit (z. B. eine Datenbank oder einen Webservice), den Zugriff auf den Anwendungszustand usw. Eine externe Abhängigkeit kann auch die Leistung beeinträchtigen, wenn sie nicht performant ist oder nicht zuverlässig zugänglich ist, was dazu führen kann, dass die externe Abhängigkeit HTTP 500-Fehler zurückgibt.

Wenn Ihre Anwendung eine externe Abhängigkeit verwendet, um eingehende Daten anzureichern oder anderweitig zu verarbeiten, sollten Sie stattdessen asynchrone E/A verwenden. Weitere Informationen finden Sie unter Async E/A in der Apache-Flink-Dokumentation.

Speicher der Anwendung

Überprüfen Sie Ihre Anwendung auf Ressourcenlecks. Wenn Ihre Anwendung Threads oder Speicher nicht ordnungsgemäß entsorgt, kann es sein, dass die Metriken millisbehindLatest, CheckpointSize und CheckpointDuration steil ansteigen oder allmählich zunehmen. Dieser Zustand kann auch zu Fehlern im Aufgaben- oder Auftragsmanager führen.

Verwenden Sie bewährte Methoden zur Leistungssteigerung

In diesem Abschnitt werden besondere Überlegungen zum Entwerfen einer Anwendung im Hinblick auf die Leistung beschrieben.

Richtiges Verwalten der Skalierung

Dieser Abschnitt enthält Informationen zur Verwaltung der Skalierung auf Anwendungs- und Operatorenebene.

In diesem Abschnitt werden folgende Themen behandelt:

- <u>Richtiges Verwalten der Anwendungsskalierung</u>
- Richtiges Verwalten der Operatorenskalierung

Richtiges Verwalten der Anwendungsskalierung

Sie können Auto Scaling verwenden, um unerwartete Spitzen bei der Anwendungsaktivität zu bewältigen. Die Anzahl Ihrer KPUs Bewerbungen wird automatisch erhöht, wenn die folgenden Kriterien erfüllt sind:

- Auto Scaling ist für die Anwendung aktiviert.
- Die CPU-Auslastung bleibt 15 Minuten lang über 75 Prozent.

Wenn Autoscaling aktiviert ist, die CPU-Auslastung aber nicht auf diesem Schwellenwert bleibt, wird die Anwendung nicht KPUs hochskaliert. Wenn Sie einen Anstieg der CPU-Auslastung feststellen, der diesen Schwellenwert nicht erreicht, oder einen Anstieg bei einer anderen Auslastungsmetrik, z. B. heapMemoryUtilization, erhöhen Sie die Skalierung manuell, damit Ihre Anwendung Aktivitätsspitzen bewältigen kann.

1 Note

Wenn die Anwendung durch Auto Scaling automatisch mehr Ressourcen hinzugefügt hat, gibt die Anwendung die neuen Ressourcen nach einer gewissen Zeit der Inaktivität frei. Das Herunterskalieren von Ressourcen wirkt sich vorübergehend auf die Leistung aus.

Weitere Informationen zur Skalierung finden Sie unter Implementieren Sie Anwendungsskalierung.

Richtiges Verwalten der Operatorenskalierung

Sie können die Leistung Ihrer Anwendung verbessern, indem Sie sicherstellen, dass der Workload Ihrer Anwendung gleichmäßig auf die Worker-Prozesse verteilt ist und dass die Operatoren in Ihrer Anwendung über die Systemressourcen verfügen, die sie für einen stabilen und performanten Betrieb benötigen.

Mithilfe der parallelism-Einstellung können Sie die Parallelität für jeden Operator im Code Ihrer Anwendung festlegen. Wenn Sie die Parallelität für einen Operator nicht festlegen, wird die Parallelitätseinstellung auf Anwendungsebene verwendet. Operatoren, die die Parallelitätseinstellung auf Anwendungsebene verwenden, können potenziell alle für die Anwendung verfügbaren Systemressourcen nutzen, wodurch die Anwendung instabil wird.

Um die Parallelität für jeden Operator optimal zu bestimmen, sollten die relativen Ressourcenanforderungen des Operators im Vergleich zu anderen Operatoren in der Anwendung berücksichtigt werden. Stellen Sie für ressourcenintensivere Operatoren eine höhere Einstellung für die Operatorenparallelität ein als für weniger ressourcenintensive Operatoren.

Die gesamte Operatorenparallelität für die Anwendung ist die Summe der Parallelität für alle Operatoren in der Anwendung. Sie optimieren die gesamte Operatorenparallelität für Ihre Anwendung, indem Sie das beste Verhältnis zwischen ihr und der Gesamtzahl der für Ihre Anwendung verfügbaren Aufgabenslots ermitteln. Ein typisches stabiles Verhältnis zwischen der gesamten Operatorenparallelität und den Aufgabenslots ist 4:1, d. h. in der Anwendung steht für jeweils vier verfügbare Operator-Unteraufgaben ein Aufgabenslot zur Verfügung. Eine Anwendung mit ressourcenintensiveren Operatoren benötigt möglicherweise ein Verhältnis von 3:1 oder 2:1, während eine Anwendung mit weniger ressourcenintensiven Operatoren mit einem Verhältnis von 10:1 stabil sein kann.

Sie können das Verhältnis für den verwendeten Operator mittels <u>Verwenden Sie</u> <u>Laufzeiteigenschaften</u> festlegen, sodass Sie die Parallelität des Operators anpassen können, ohne Ihren Anwendungscode kompilieren und hochladen zu müssen.

Das folgende Beispiel zeigt, wie Sie die Operatorenparallelität als einstellbares Verhältnis zur aktuellen Anwendungsparallelität festlegen:

```
Map<String, Properties> applicationProperties =
  KinesisAnalyticsRuntime.getApplicationProperties();
operatorParallelism =
   StreamExecutionEnvironment.getParallelism() /
   Integer.getInteger(
   applicationProperties.get("OperatorProperties").getProperty("MyOperatorParallelismRatio")
   );
```

Informationen zu Unteraufgaben, Aufgabenslots und anderen Anwendungsressourcen finden Sie unter Überprüfen Sie die Anwendungsressourcen von Managed Service für Apache Flink.

Verwenden Sie die Parallelism-Einstellung und die KeyBy-Partitionsmethode, um die Verteilung des Workloads auf die Worker-Prozesse Ihrer Anwendung zu steuern. Weitere Informationen finden Sie in den folgenden Themen in der Apache-Flink-Dokumentation:

- Parallele Ausführung
- DataStream Transformationen

Überwachen der Nutzung externer Abhängigkeitsressourcen

Wenn an einem Ziel (wie Kinesis Streams, Firehose, DynamoDB oder OpenSearch Service) ein Leistungsengpass auftritt, wird Ihre Anwendung einem Gegendruck ausgesetzt. Stellen Sie sicher, dass Ihre externen Abhängigkeiten für Ihren Anwendungsdurchsatz ordnungsgemäß bereitgestellt wurden.

Note

Fehler in anderen Services können zu Fehlern in Ihrer Anwendung führen. Wenn Sie Fehler in Ihrer Anwendung feststellen, überprüfen Sie die CloudWatch Protokolle für Ihre Zieldienste auf Fehler.

Lokales Ausführen Ihrer Apache-Flink-Anwendung

Um Speicherprobleme zu beheben, können Sie Ihre Anwendung in einer lokalen Flink-Installation ausführen. Dadurch erhalten Sie Zugriff auf Debugging-Tools wie Stack-Trace und Heap-Dumps, die nicht verfügbar sind, wenn Sie Ihre Anwendung in Managed Service für Apache Flink ausführen.

Informationen zum Erstellen einer lokalen Flink-Installation finden Sie unter <u>Standalone</u> in der Apache Flink-Dokumentation.

Überwachen Sie die Leistung

In diesem Abschnitt werden Tools zur Überwachung der Leistung einer Anwendung beschrieben.

Überwachen Sie die Leistung anhand von CloudWatch Kennzahlen

Mithilfe von CloudWatch Metriken überwachen Sie die Ressourcennutzung, den Durchsatz, das Checkpointing und die Ausfallzeiten Ihrer Anwendung. Informationen zur Verwendung von CloudWatch Metriken mit Ihrer Managed Service for Apache Flink-Anwendung finden Sie unter. ???

Überwachen Sie die Leistung mithilfe von CloudWatch Protokollen und Alarmen

Mithilfe von CloudWatch Protokollen überwachen Sie Fehlerbedingungen, die möglicherweise zu Leistungsproblemen führen könnten.

Fehlerbedingungen werden in Protokolleinträgen angezeigt, wenn der Status des Apache-Flink-Auftrags vom Zustand RUNNING zum Zustand FAILED wechselt.

Sie verwenden CloudWatch Alarme, um Benachrichtigungen für Leistungsprobleme zu erstellen, z. B. bei Ressourcenverbrauch oder Checkpoint-Messwerten, die einen sicheren Schwellenwert überschreiten, oder bei unerwarteten Änderungen des Anwendungsstatus.

Informationen zum Erstellen von CloudWatch Alarmen für eine Managed Service for Apache Flink-Anwendung finden Sie unter. ???

Managed Service für Apache Flink und Studio Notebook-Kontingent

Note

Die Apache Flink-Versionen 1.6, 1.8 und 1.11 wurden seit über drei Jahren nicht mehr von der Apache Flink-Community unterstützt. Wir planen nun, die Unterstützung für diese Versionen in Amazon Managed Service für Apache Flink einzustellen. Ab dem 5. November 2024 können Sie keine neuen Anwendungen für diese Flink-Versionen erstellen. Sie können bestehende Anwendungen derzeit weiter ausführen.

Für alle Regionen mit Ausnahme der Regionen China und der ab dem AWS GovCloud (US) Regions5. Februar 2025 können Sie keine Anwendungen mehr mit diesen Versionen von Apache Flink in Amazon Managed Service für Apache Flink erstellen, starten oder ausführen. Für die Regionen China und die AWS GovCloud (US) Regions ab dem 19. März 2025 können Sie mit diesen Versionen von Apache Flink in Amazon Managed Service für Apache Flink keine Anwendungen mehr erstellen, starten oder ausführen.

Mithilfe der Funktion für direkte Versionsupgrades in Managed Service für Apache Flink können Sie Ihre Anwendungen statusmäßig aktualisieren. Weitere Informationen finden Sie unter Verwenden Sie direkte Versionsupgrades für Apache Flink.

Beachten Sie bei der Arbeit mit Amazon Managed Service für Apache Flink das folgende Kontingent:

 Sie können in Ihrem Konto bis zu 100 Managed Service f
ür Apache Flink-Anwendungen pro Region erstellen. Sie können einen Fall erstellen, um weitere Anwendungen
über das Formular zur Erhöhung Ihres Service Quotas anzufordern. Weitere Informationen erhalten Sie im <u>AWS -Support</u> Center.

Eine Liste der Regionen, die Managed Service für Apache Flink unterstützen, finden Sie unter Managed Service für Apache Flink Regionen und Endpunkte.

 Die Anzahl der Kinesis Processing Units (KPU) ist standardmäßig auf 64 begrenzt. Anweisungen zum Anfordern einer Erhöhung dieses Kontingents finden Sie unter So fordern Sie eine Kontingenterhöhung an in <u>Service Quotas</u>. Stellen Sie sicher, dass Sie das Anwendungspräfix angeben, auf das das neue KPU-Limit angewendet werden muss. Bei Managed Service für Apache Flink werden Ihrem AWS Konto zugewiesene Ressourcen und nicht die Ressourcen, die Ihre Anwendung verwendet, in Rechnung gestellt. Ihnen wird ein Stundensatz berechnet, der auf der maximalen Anzahl von Ressourcen basiert, die für KPUs die Ausführung Ihrer Streamverarbeitungsanwendung verwendet werden. Eine einzelne KPU bietet Ihnen 1 vCPU und 4 GB Arbeitsspeicher. Für jede KPU stellt der Dienst außerdem 50 GB Speicher für laufende Anwendungen bereit.

- Sie können bis zu 1.000 Managed Service for Apache Flink-Snapshots pro Anwendung erstellen. Weitere Informationen finden Sie unter <u>Anwendungs-Backups mithilfe von Snapshots verwalten</u>.
- Sie können bis zu 50 Tags pro Anwendung zuweisen.
- Die maximale Größe für eine Anwendungs-JAR-Datei beträgt 512 MB. Wenn Sie dieses Kontingent überschreiten, kann Ihre Anwendung nicht gestartet werden.

Für Studio-Notebooks gelten die folgenden Kontingente. Um ein höheres Kontingent anzufordern, erstellen Sie einen Support-Fall.

- websocketMessageSize = 5 MB
- noteSize = 5 MB
- noteCount = 1000
- Max cumulative UDF size = 100 MB
- Max cumulative dependency jar size = 300 MB

Wartungsaufgaben für Managed Service für Apache Flink verwalten

Managed Service for Apache Flink patcht Ihre Anwendungen regelmäßig mit Betriebssystemund Container-Image-Sicherheitsupdates, um die Einhaltung der Vorschriften zu gewährleisten und die Sicherheitsziele zu erreichen. AWS Ein Wartungsfenster für eine Managed Service for Apache Flink-Anwendung ist ein Zeitfenster von 8 Stunden, in dem Managed Service for Apache Flink Anwendungswartungsaktivitäten an einer Anwendung durchführt. Die Wartung kann an verschiedenen Tagen und je nach Zeitplan des Serviceteams beginnen. AWS-Regionen Die Zeitfenster für die Wartung finden Sie in der Tabelle im folgenden Abschnitt.

Im Rahmen des Wartungsvorgangs wird Ihre Managed Service for Apache Flink-Anwendung neu gestartet. Dies führt zu einer Ausfallzeit von 10 bis 30 Sekunden während des Wartungsfensters der Anwendung. Die tatsächliche Dauer der Ausfallzeit hängt vom Status, der Größe und der Aktualität von Snapshots/Checkpoints der Anwendung ab. Informationen darüber, wie Sie die Auswirkungen dieser Ausfallzeit minimieren können, finden Sie unter <u>the section called "Fehlertoleranz: Prüfpunkte</u> <u>und Savepoints"</u>. Mithilfe der API können Sie herausfinden, ob Managed Service for Apache Flink eine Wartungsaktion an Ihrer Anwendung durchgeführt hat. ListApplicationOperations Weitere Informationen finden Sie unter <u>Identifizieren Sie, wann Wartungsarbeiten an Ihrer</u> Anwendung stattgefunden haben.

Zeitfenster für Wartungsarbeiten in AWS-Regionen

AWS-Region	Wartungszeitfenster
AWS GovCloud (US-West)	06:00 - 14:00 UTC
AWS GovCloud (US-Ost)	03:00 - 11:00 UTC
USA Ost (Nord-Virginia)	03:00 bis 11:00 Uhr UTC
USA Ost (Ohio)	03:00 bis 11:00 Uhr UTC
USA West (Nordkalifornien)	06:00 - 14:00 UTC
USA West (Oregon)	06:00 - 14:00 UTC
Asien-Pazifik (Hongkong)	13:00 - 21:00 UTC

AWS-Region	Wartungszeitfenster
Asien-Pazifik (Mumbai)	16:30 - 00:30 UTC
Asien-Pazifik (Hyderabad)	16:30 - 00:30 UTC
Asien-Pazifik (Seoul)	13:00 - 21:00 UTC
Asien-Pazifik (Singapur)	14:00 - 22:00 UTC
Asien-Pazifik (Sydney)	12:00 - 20:00 UTC
Asien-Pazifik (Jakarta)	15:00 - 23:00 UTC
Asien-Pazifik (Tokio)	13:00 - 21:00 UTC
Kanada (Zentral)	03:00 bis 11:00 Uhr UTC
China (Peking)	13:00 - 21:00 UTC
China (Ningxia)	13:00 - 21:00 UTC
Europa (Frankfurt)	06:00 - 14:00 UTC
Europa (Zürich)	20:00 - 04:00 UTC
Europa (Irland)	22:00 - 06:00 UTC
Europa (London)	22:00 bis 06:00 Uhr UTC
Europa (Stockholm)	23:00 - 07:00 UTC
Europa (Milan)	21:00 - 05:00 UTC
Europa (Spain)	21:00 - 05:00 UTC
Afrika (Kapstadt)	20:00 - 04:00 UTC
Europa (Irland)	22:00 - 06:00 UTC
Europa (London)	23:00 - 07:00 UTC

Managed Service für Apache Flink

AWS-Region	Wartungszeitfenster
Europa (Paris)	23:00 - 07:00 UTC
Europa (Stockholm)	23:00 - 07:00 UTC
Naher Osten (Bahrain)	13:00 - 21:00 UTC
Naher Osten (VAE)	18:00 - 02:00 UTC
Südamerika (São Paulo)	19:00 - 03:00 UTC
Israel (Tel Aviv)	20:00 - 04:00 UTC

Wählen Sie ein Wartungsfenster

Managed Service for Apache Flink informiert Sie per E-Mail und AWS Health Benachrichtigungen über bevorstehende geplante Wartungsereignisse. In Managed Service für Apache Flink können Sie die Tageszeit ändern, zu der die Wartung beginnt, indem Sie die UpdateApplicationMaintenanceConfiguration API verwenden und die Konfiguration Ihres Wartungsfensters aktualisieren. Weitere Informationen finden Sie unter <u>UpdateApplicationMaintenanceConfiguration</u>. Managed Service für Apache Flink verwendet die aktualisierte Wartungskonfiguration, wenn er das nächste Mal Wartungsarbeiten für die Anwendung plant. Wenn Sie diesen Vorgang aufrufen, nachdem der Dienst bereits eine Wartung geplant hat, wendet der Dienst das Konfigurationsupdate an, wenn er das nächste Mal eine Wartung für die Anwendung plant.

Note

Um ein Höchstmaß an Sicherheit zu gewährleisten, unterstützt Managed Service für Apache Flink keine Ausnahme, um sich von der Wartung abzumelden, die Wartung zu unterbrechen oder Wartungsarbeiten an bestimmten Tagen durchzuführen.
Ermitteln Sie, wann an Ihrer Anwendung Wartungsarbeiten durchgeführt wurden

Mithilfe der ListApplicationOperations API können Sie herausfinden, ob Managed Service for Apache Flink eine Wartungsaktion an Ihrer Anwendung durchgeführt hat.

Im Folgenden finden Sie ein Beispiel für eine AnfrageListApplicationOperations, mit der Sie die Liste für Wartungsarbeiten in der Anwendung filtern können:

```
{
    "ApplicationName": "MyApplication",
    "operation": "ApplicationMaintenance"
}
```

Erzielen Sie die Produktionsreife Ihres Managed Service für Apache Flink-Anwendungen

Dies ist eine Sammlung wichtiger Aspekte der Ausführung von Produktionsanwendungen auf Managed Service für Apache Flink. Es handelt sich nicht um eine vollständige Liste, sondern um das absolute Minimum dessen, worauf Sie achten sollten, bevor Sie eine Anwendung in Produktion nehmen.

Testen Sie Ihre Anwendungen unter Last

Einige Probleme mit Anwendungen treten nur bei hoher Auslastung auf. Wir haben Fälle gesehen, in denen Anwendungen funktionstüchtig zu sein schienen, aber ein Betriebsereignis die Belastung der Anwendung erheblich erhöhte. Dies kann völlig unabhängig von der Anwendung selbst geschehen. Wenn die Datenquelle oder die Datensenke für ein paar Stunden nicht verfügbar ist, kann die Flink-Anwendung keine Fortschritte machen. Wenn dieses Problem behoben ist, hat sich ein Stau an unverarbeiteten Daten angesammelt, wodurch die verfügbaren Ressourcen vollständig ausgeschöpft werden können. Die Belastung kann dann Fehler oder Leistungsprobleme verstärken, die zuvor nicht aufgetreten waren.

Es ist daher wichtig, dass Sie die richtigen Auslastungstests für Produktionsanwendungen durchführen. Zu den Fragen, die bei diesen Lasttests beantwortet werden sollten, gehören:

- · Ist die Anwendung bei anhaltend hoher Last stabil?
- · Kann die Anwendung bei Spitzenlast immer noch einen Savepoint verwenden?
- Wie lange braucht die Verarbeitung eines Rückstands von 1 Stunde? Und wie lange von 24 Stunden (abhängig von der maximalen Aufbewahrung der Daten im Stream)?
- Steigt der Durchsatz der Anwendung, wenn die Anwendung skaliert wird?

Beim Verbrauch aus einem Datenstrom können diese Szenarien simuliert werden, indem sie für einige Zeit in den Stream übertragen werden. Starten Sie dann die Anwendung und lassen Sie sie von Anfang an Daten verbrauchen. Verwenden Sie beispielsweise TRIM_HORIZON im Fall eines Kinesis-Datenstroms die Startposition von.

Definieren Sie Max. Parallelität

Die maximale Parallelität definiert die maximale Parallelität, auf die eine zustandsbehaftete Anwendung skalieren kann. Dies wird definiert, wenn der Zustand erstmalig erstellt wird, und es gibt keine Möglichkeit, den Operator über dieses Maximum hinaus zu skalieren, ohne den Zustand zu verwerfen.

Die maximale Parallelität wird festgelegt, wenn der Status zum ersten Mal erstellt wird.

Standardmäßig ist Max. Parallelität auf Folgendes gesetzt:

- 128, wenn Parallelität <= 128
- MIN(nextPowerOfTwo(parallelism + (parallelism / 2)), 2^15): wenn Parallelität > 128

Wenn Sie planen, Ihre Anwendung auf > 128 Parallelität zu skalieren, sollten Sie die maximale Parallelität explizit definieren.

Sie können die maximale Parallelität auf Anwendungsebene mit oder mit einem einzelnen Operator definieren. env.setMaxParallelism(x) Sofern nicht anders angegeben, erben alle Operatoren die maximale Parallelität der Anwendung.

Weitere Informationen finden Sie unter <u>Setting the Maximum Parallelism in der Apache Flink-</u> Dokumentation.

Festlegen einer UUID für alle Operatoren

Eine UUID wird bei dem Vorgang verwendet, bei dem Flink einen Savepoint auf einen einzelnen Operator abbildet. Wenn Sie für jeden Operator eine bestimmte UUID festlegen, erhalten Sie eine stabile Zuordnung für den wiederherzustellenden Savepoint-Prozess.

.map(...).uid("my-map-function")

Weitere Informationen finden Sie unter Checkliste zur Produktionsbereitschaft.

Pflegen von Bewährte Methoden für Managed Service für Apache Flink-Anwendungen

Dieser Abschnitt enthält Informationen und Empfehlungen für die Entwicklung eines stabilen, performanten Managed Service für Apache Flink-Anwendungen.

Themen

- Minimiere die Größe des Uber-JAR
- Fehlertoleranz: Prüfpunkte und Savepoints
- Nicht unterstützte Konnektor-Versionen
- Leistung und Parallelität
- Parallelität pro Operator festlegen
- Protokollierung
- Codierung
- Verwalten von Anmeldeinformationen.
- · Lesen aus Quellen mit wenigen Shards/Partitionen
- <u>Aktualisierungsintervall für Studio-Notebooks</u>
- Optimale Leistung des Studio-Notebooks
- Wie sich Strategien mit Wasserzeichen und ungenutzte Shards auf Zeitfenster auswirken
- Festlegen einer UUID für alle Operatoren
- Zum Maven ServiceResourceTransformer Shade-Plugin hinzufügen

Minimiere die Größe des Uber-JAR

Java/Scala application must be packaged in an uber (super/fat) JAR und schließt alle zusätzlichen erforderlichen Abhängigkeiten ein, die nicht bereits von der Laufzeit bereitgestellt werden. Die Größe der Uber-JAR wirkt sich jedoch auf die Start- und Neustartzeiten der Anwendung aus und kann dazu führen, dass die JAR die Grenze von 512 MB überschreitet.

Um die Bereitstellungszeit zu optimieren, sollte Ihr Uber-JAR Folgendes nicht enthalten:

- Alle von der Laufzeit bereitgestellten Abhängigkeiten, wie im folgenden Beispiel dargestellt. Sie sollten einen provided Geltungsbereich in der POM-Datei oder compile0nly in Ihrer Gradle-Konfiguration haben.
- Alle Abhängigkeiten, die nur zum Testen verwendet werden, zum Beispiel JUnit oder Mockito. Sie sollten einen test Geltungsbereich in der POM-Datei oder testImplementation in Ihrer Gradle-Konfiguration haben.
- Alle Abhängigkeiten, die von Ihrer Anwendung nicht tatsächlich verwendet werden.
- Alle statischen Daten oder Metadaten, die f
 ür Ihre Anwendung erforderlich sind. Statische Daten sollten von der Anwendung zur Laufzeit geladen werden, beispielsweise aus einem Datenspeicher oder aus Amazon S3.
- Einzelheiten zu den vorherigen Konfigurationseinstellungen finden Sie in dieser POM-Beispieldatei.

Bereitgestellte Abhängigkeiten

Die Managed Service für Apache Flink-Laufzeit bietet eine Reihe von Abhängigkeiten. Diese Abhängigkeiten sollten nicht in der Fat-JAR enthalten sein und müssen einen provided Gültigkeitsbereich in der POM-Datei haben oder in der maven-shade-plugin Konfiguration explizit ausgeschlossen werden. Jede dieser Abhängigkeiten, die in der Fat-JAR enthalten sind, wird zur Laufzeit ignoriert, erhöht jedoch die Größe der JAR, was den Mehraufwand während der Bereitstellung erhöht.

Von der Runtime bereitgestellte Abhängigkeiten in den Runtime-Versionen 1.18, 1.19 und 1.20:

- org.apache.flink:flink-core
- org.apache.flink:flink-java
- org.apache.flink:flink-streaming-java
- org.apache.flink:flink-scala_2.12
- org.apache.flink:flink-table-runtime
- org.apache.flink:flink-table-planner-loader
- org.apache.flink:flink-json
- org.apache.flink:flink-connector-base
- org.apache.flink:flink-connector-files
- org.apache.flink:flink-clients

- org.apache.flink:flink-runtime-web
- org.apache.flink:flink-metrics-code
- org.apache.flink:flink-table-api-java
- org.apache.flink:flink-table-api-bridge-base
- org.apache.flink:flink-table-api-java-bridge
- org.apache.logging.log4j:log4j-slf4j-impl
- org.apache.logging.log4j:log4j-api
- org.apache.logging.log4j:log4j-core
- org.apache.logging.log4j:log4j-1.2-api

Darüber hinaus stellt die Runtime die Bibliothek bereit, die zum Abrufen der Laufzeiteigenschaften von Anwendungen in Managed Service for Apache Flink, verwendet wird. com.amazonaws:aws-kinesisanalytics-runtime:1.2.0

Alle von der Runtime bereitgestellten Abhängigkeiten müssen die folgenden Empfehlungen befolgen, um sie nicht in die Uber-JAR aufzunehmen:

- Verwenden provided Sie in Maven (pom.xml) und SBT (build.sbt) scope.
- Verwenden Sie in Gradle (build.gradle) die Konfiguration. compileOnly

Jede angegebene Abhängigkeit, die versehentlich in der Uber-JAR enthalten ist, wird zur Laufzeit ignoriert, da die übergeordnete Klasse von Apache Flink geladen wird. Weitere Informationen finden Sie parent-first-patternsin der Apache Flink-Dokumentation.

Konnektoren

Die meisten Konnektoren, mit Ausnahme des FileSystem Konnektors, die nicht in der Runtime enthalten sind, müssen in der POM-Datei mit dem Standardbereich (compile) enthalten sein.

Andere Empfehlungen

In der Regel sollte Ihr Apache Flink Uber JAR, das Managed Service for Apache Flink zur Verfügung gestellt wird, den Mindestcode enthalten, der für die Ausführung der Anwendung erforderlich ist. Einschließlich Abhängigkeiten, die die Quellklassen, Testdatensätze oder den Bootstrapping-Status beinhalten, sollten nicht in dieser JAR-Datei enthalten sein. Wenn statische Ressourcen zur Laufzeit abgerufen werden müssen, trennen Sie dieses Problem in eine Ressource wie Amazon S3. Beispiele hierfür sind State Bootstraps oder ein Inferenzmodell.

Nehmen Sie sich etwas Zeit, um Ihren umfassenden Abhängigkeitsbaum zu betrachten und Abhängigkeiten zu entfernen, die nicht zur Laufzeit gehören.

Managed Service for Apache Flink unterstützt zwar Jar-Größen von 512 MB, dies sollte jedoch als Ausnahme von der Regel angesehen werden. Apache Flink unterstützt derzeit in seiner Standardkonfiguration Jar-Größen von ~104 MB, und das sollte die maximale Zielgröße für ein Jar sein, das benötigt wird.

Fehlertoleranz: Prüfpunkte und Savepoints

Verwenden Sie Prüfpunkte und Savepoints, um Fehlertoleranz in Ihrer Anwendung von Managed Service für Apache Flink zu implementieren. Berücksichtigen Sie bei Entwicklung und Wartung Ihrer Anwendung Folgendes:

- Stellen Sie <u>ApplicationSnapshotConfiguration:: SnapshotsEnabled</u> false während der Anwendungsentwicklung oder Fehlerbehebung ein. Bei jedem Anwendungsstopp wird ein Snapshot erstellt. Dies kann zu Problemen führen, wenn sich die Anwendung in einem fehlerhaften Zustand befindet oder nicht leistungsfähig ist. Setzen Sie SnapshotsEnabled auf true, wenn die Anwendung in Produktion und stabil ist.

1 Note

Wir empfehlen, dass Sie Ihre Anwendung so einrichten, dass sie mehrmals täglich einen Snapshot erstellt, um einen ordnungsgemäßen Neustart mit den korrekten Statusdaten zu gewährleisten. Die richtige Häufigkeit für Ihre Snapshots hängt von der Geschäftslogik Ihrer Anwendung ab. Durch häufiges Erstellen von Snapshots können Sie neuere Daten wiederherstellen. Dies erhöht jedoch die Kosten und erfordert mehr Systemressourcen.

Informationen zur Überwachung von Anwendungsausfällen finden Sie unter ???.

Weitere Informationen zur Implementierung der Fehlertoleranz finden Sie unter Implementieren Sie Fehlertoleranz.

Nicht unterstützte Konnektor-Versionen

Ab Apache Flink Version 1.15 oder höher verhindert Managed Service für Apache Flink automatisch den Start oder die Aktualisierung von Anwendungen, wenn sie nicht unterstützte Kinesis-Konnektor-Versionen verwenden, die in der Anwendung gebündelt sind. JARs Stellen Sie beim Upgrade auf Managed Service für Apache Flink Version 1.15 oder höher sicher, dass Sie den neuesten Kinesis-Konnektor verwende. Dies ist jede Version, die Version 1.15.2 entspricht oder neuer ist. Alle anderen Versionen werden von Managed Service fü Apache Flink nicht unterstützt, da sie zu Konsistenzproblemen oder Ausfällen mit der Funktion Mit Savepoint beenden führen können, wodurch saubere Stop-/Aktualisierungsvorgänge verhindert werden. Weitere Informationen zur Connector-Kompatibilität in Amazon Managed Service für Apache Flink-Versionen finden Sie unter Apache Flink-Konnektoren.

Leistung und Parallelität

Ihre Anwendung kann so skaliert werden, dass sie jedes Durchsatzniveau erreicht, indem Sie die Parallelität Ihrer Anwendung optimieren und Leistungsprobleme vermeiden. Berücksichtigen Sie bei Entwicklung und Wartung Ihrer Anwendung Folgendes:

- Stellen Sie sicher, dass alle Ihre Anwendungsquellen und -senken ausreichend bereitgestellt sind und nicht gedrosselt werden. Wenn es sich bei den Quellen und Senken um andere AWS -Services handelt, überwachen Sie diese Services mittels <u>CloudWatch</u>.
- Prüfen Sie bei Anwendungen mit sehr hoher Parallelität, ob die hohen Parallelitätsebenen auf alle Operatoren in der Anwendung angewendet werden. Standardmäßig wendet Apache Flink dieselbe Anwendungsparallelität für alle Operatoren im Anwendungsdiagramm an. Dies kann entweder zu Problemen bei der Bereitstellung auf Quellen oder Senken oder zu Engpässen bei der Datenverarbeitung durch die Operatoren führen. Sie können die Parallelität der einzelnen Operatoren im Code mit setParallelism ändern.
- Machen Sie sich mit der Bedeutung der Parallelitätseinstellungen für die Operatoren in Ihrer Anwendung vertraut. Wenn Sie die Parallelität für einen Operator ändern, können Sie die Anwendung möglicherweise nicht aus einem Snapshot wiederherstellen, der erstellt wurde, als der Operator eine Parallelität hatte, die mit den aktuellen Einstellungen nicht kompatibel ist. Weitere Informationen zum Einstellen der Operatorparallelität finden Sie unter <u>Explizite Festlegung der</u> maximalen Parallelität für Operatoren.

Weitere Informationen über die Implementierung von Skalierung finden Sie unter Implementieren Sie Anwendungsskalierung.

Parallelität pro Operator festlegen

Standardmäßig ist die Parallelität für alle Operatoren auf Anwendungsebene festgelegt. Sie können die Parallelität eines einzelnen Operators mithilfe der DataStream API unter Verwendung von verwenden. .setParallelism(x) Sie können eine Operatorparallelität auf eine beliebige Parallelität festlegen, die gleich oder niedriger als die Anwendungsparallelität ist.

Wenn möglich, definieren Sie die Operatorparallelität als Funktion der Anwendungsparallelität. Auf diese Weise variiert die Operatorparallelität mit der Anwendungsparallelität. Wenn Sie beispielsweise automatische Skalierung verwenden, variieren alle Operatoren ihre Parallelität im gleichen Verhältnis:

```
int appParallelism = env.getParallelism();
...
...ops.setParalleism(appParallelism/2);
```

In einigen Fällen möchten Sie möglicherweise die Operatorparallelität auf eine Konstante setzen. Stellen Sie beispielsweise die Parallelität einer Kinesis Stream-Quelle auf die Anzahl der Shards ein. In diesen Fällen sollten Sie erwägen, die Operator-Parallelität als Anwendungskonfigurationsparameter zu übergeben, um sie zu ändern, ohne den Code zu ändern, beispielsweise um den Quellstream resharden zu können.

Protokollierung

Sie können die Leistung und die Fehlerbedingungen Ihrer Anwendung mithilfe von CloudWatch Protokollen überwachen. Berücksichtigen Sie bei der Konfiguration der Protokollierung für Ihre Anwendung Folgendes:

- Aktivieren CloudWatch Sie die Protokollierung f
 ür die Anwendung, damit alle Laufzeitprobleme debugged werden k
 önnen.
- Erstellen Sie nicht f
 ür jeden Datensatz, der in der Anwendung verarbeitet wird, einen Protokolleintrag. Dies f
 ührt zu schwerwiegenden Engp
 ässen bei der Verarbeitung und kann zu Gegendruck bei der Datenverarbeitung f
 ühren.
- Erstellen Sie CloudWatch Alarme, um Sie zu benachrichtigen, wenn Ihre Anwendung nicht ordnungsgemäß ausgeführt wird. Weitere Informationen finden Sie unter ???.

Weitere Informationen über die Implementierung von Protokollierung finden Sie unter ???.

Codierung

Sie können Ihre Anwendung leistungsfähig und stabil machen, indem Sie empfohlene Programmierpraktiken anwenden. Berücksichtigen Sie beim Schreiben von Anwendungscode Folgendes:

• Verwenden Sie system.exit() in Ihrem Anwendungscode nicht, weder in der main-Methode Ihrer Anwendung noch in benutzerdefinierten Funktionen. Wenn Sie Ihre Anwendung aus dem Code heraus beenden möchten, lösen Sie eine von Exception oder RuntimeException abgeleitete Ausnahme aus, die eine Meldung darüber enthält, was bei der Anwendung schiefgelaufen ist.

Beachten Sie Folgendes darüber, wie der Service mit dieser Ausnahme umgeht:

- Wenn die Ausnahme von der main-Methode Ihrer Anwendung ausgelöst wird, wird sie vom Service beim Übergang der Anwendung in den RUNNING-Status in eine ProgramInvocationException eingeschlossen, und der Job-Manager kann den Job nicht weiterleiten.
- Wenn die Ausnahme von einer benutzerdefinierten Funktion ausgelöst wird, schlägt der Job-Manager den Job fehl und startet ihn neu. Die Details der Ausnahme werden in das Ausnahmeprotokoll geschrieben.
- Erwägen Sie, die JAR-Datei Ihrer Anwendung und die darin enthaltenen Abhängigkeiten zu schattieren. Das Schattieren wird empfohlen, wenn es potenzielle Konflikte bei den Paketnamen zwischen Ihrer Anwendung und der Apache Flink-Laufzeit gibt. Wenn ein Konflikt auftritt, können Ihre Anwendungsprotokolle eine Ausnahme des Typs java.util.concurrent.ExecutionException enthalten. Weitere Informationen zum Schattieren Ihrer Anwendungs-JAR-Datei finden Sie unter <u>Apache Maven Shade-Plugin</u>.

Verwalten von Anmeldeinformationen.

Sie sollten keine langfristigen Anmeldeinformationen in Produktionsanwendungen (oder andere Anwendungen) integrieren. Langfristige Anmeldeinformationen werden wahrscheinlich in ein Versionskontrollsystem eingecheckt und können leicht verloren gehen. Stattdessen können Sie der Anwendung Managed Service für Apache Flink eine Rolle zuordnen und dieser Rolle Berechtigungen gewähren. Die laufende Flink-Anwendung kann dann temporäre Anmeldeinformationen mit den entsprechenden Berechtigungen aus der Umgebung auswählen. <u>Falls eine Authentifizierung für</u> einen Service erforderlich ist, der nicht nativ in IAM integriert ist, z. B. für eine Datenbank, die einen Benutzernamen und ein Passwort für die Authentifizierung benötigt, sollten Sie erwägen, Secrets in AWS Secrets Manager zu speichern.

Viele AWS -native Services unterstützen die Authentifizierung:

- Kinesis Data Streams .java ProcessTaxiStream
- Amazon MSK <u>https://github.com/aws/aws-msk-iam-authusing-the-amazon-msk/#</u> library-foriam-authentication
- Amazon Elasticsearch Service .java AmazonElasticsearchSink
- Amazon S3 funktioniert direkt mit Managed Service für Apache Flink

Lesen aus Quellen mit wenigen Shards/Partitionen

Beim Lesen aus Apache Kafka oder einem Kinesis Data Stream kann es zu einer Diskrepanz zwischen der Parallelität des Streams (der Anzahl der Partitionen für Kafka und der Anzahl der Shards für Kinesis) und der Parallelität der Anwendung kommen. Bei einem naiven Design kann die Parallelität einer Anwendung nicht über die Parallelität eines Streams skalieren: Jede Unteraufgabe eines Quelloperators kann nur aus 1 oder mehreren Shards/Partitionen lesen. Das bedeutet für einen Stream mit nur 2 Shards und eine Anwendung mit einer Parallelität von 8, dass nur zwei Unteraufgaben den Stream tatsächlich verbrauchen und 6 Unteraufgaben inaktiv bleiben. Dies kann den Durchsatz der Anwendung erheblich einschränken, insbesondere wenn die Deserialisierung teuer ist und von der Quelle durchgeführt wird (was die Standardeinstellung ist).

Um diesen Effekt zu mildern, können Sie den Stream entweder skalieren. Dies ist jedoch möglicherweise nicht immer wünschenswert oder möglich. Alternativ können Sie die Quelle so umstrukturieren, dass sie keine Serialisierung durchführt und nur die byte[] weitergibt. Anschließend können Sie die Daten <u>umverteilen</u>, um sie gleichmäßig auf alle Aufgaben zu verteilen, und die Daten dann dort deserialisieren. Auf diese Weise können Sie alle Unteraufgaben für die Deserialisierung nutzen und dieser potenziell teure Vorgang ist nicht mehr an die Anzahl der Shards/ Partitionen des Streams gebunden.

Aktualisierungsintervall für Studio-Notebooks

Wenn Sie das Aktualisierungsintervall für die Absatzergebnisse ändern, setzen Sie es auf einen Wert, der mindestens 1000 Millisekunden beträgt.

Optimale Leistung des Studio-Notebooks

Wir haben mit der folgenden Aussage getestet und die optimale Leistung erhalten, wenn mit events-per-second multipliziert unter number-of-keys 25.000.000 ergab. Das war bei events-per-second weniger als 150.000.

SELECT key, sum(value) FROM key-values GROUP BY key

Wie sich Strategien mit Wasserzeichen und ungenutzte Shards auf Zeitfenster auswirken

Beim Lesen von Ereignissen aus Apache Kafka und Kinesis Data Streams kann die Quelle die Ereigniszeit basierend auf den Attributen des Streams festlegen. Im Fall von Kinesis entspricht die Ereigniszeit der ungefähren Ankunftszeit von Ereignissen. Die Festlegung der Ereigniszeit an der Quelle für Ereignisse reicht jedoch nicht aus, damit eine Flink-Anwendung die Ereigniszeit verwenden kann. Die Quelle muss außerdem Wasserzeichen erzeugen, die Informationen über die Ereigniszeit von der Quelle an alle anderen Operatoren weitergeben. Die <u>Flink-Dokumentation</u> bietet einen guten Überblick darüber, wie dieser Prozess funktioniert.

Standardmäßig ist der Zeitstempel eines aus Kinesis gelesenen Ereignisses auf die ungefähre Ankunftszeit gesetzt, die von Kinesis bestimmt wird. Eine zusätzliche Voraussetzung dafür, dass die Ereigniszeit in der Anwendung funktioniert, ist eine Wasserzeichen-Strategie.

```
WatermarkStrategy<String> s = WatermarkStrategy
    .<String>forMonotonousTimestamps()
    .withIdleness(Duration.ofSeconds(...));
```

Die Wasserzeichenstrategie wird dann auf einen DataStream mit der Methode assignTimestampsAndWatermarks angewendet. Es gibt einige nützliche integrierte Strategien:

- forMonotonousTimestamps() verwendet einfach die Uhrzeit des Ereignisses (ungefähre Ankunftszeit) und gibt in regelmäßigen Abständen den Maximalwert als Wasserzeichen aus (für jede spezifische Unteraufgabe)
- forBoundedOutOfOrderness(Duration.ofSeconds(...)) ähnelt der vorherigen Strategie, verwendet jedoch die Ereigniszeit – Dauer f
 ür die Generierung von Wasserzeichen.

Aus der Flink-Dokumentation:

Jede parallel Unteraufgabe einer Quellfunktion generiert ihre Wasserzeichen normalerweise unabhängig. Diese Wasserzeichen definieren die Ereigniszeit an dieser bestimmten parallelen Quelle.

Während die Wasserzeichen durch das Streaming-Programm fließen, verschieben sie die Ereigniszeit bei den Operatoren, wo sie ankommen. Immer wenn ein Betreiber seine Ereigniszeit vorverlegt, generiert er nachgelagert ein neues Wasserzeichen für seine nachfolgenden Operatoren.

Manche Operatoren verbrauchen mehrere Eingabestreams; zum Beispiel eine Union oder Operatoren, die einer keyBy(...)- oder partition(...)-Funktion folgen. Die aktuelle Ereigniszeit eines solchen Operators ist das Minimum der Ereigniszeiten seiner Eingabestreams. Wenn seine Eingabestreams ihre Ereigniszeiten aktualisieren, tut dies auch der Operator.

Das heißt, wenn eine Quell-Unteraufgabe von einem inaktiven Shard aus konsumiert, erhalten nachgeschaltete Operatoren keine neuen Wasserzeichen von dieser Unteraufgabe, sodass die Verarbeitung für alle nachgeschalteten Operatoren, die Zeitfenster verwenden, zum Stillstand kommt. Um dies zu vermeiden, können Kunden die withIdleness-Option zur Wasserzeichenstrategie hinzufügen. Mit dieser Option schließt ein Operator bei der Berechnung der Ereigniszeit des Operators die Wasserzeichen aus ungenutzten Upstream-Unteraufgaben aus. Die Unteraufgabe im Leerlauf blockiert somit nicht mehr die Weiterleitung der Ereigniszeit bei nachgeschalteten Operatoren.

Je nachdem, welchen Shard-Zuweiser Sie verwenden, werden einigen Arbeitern möglicherweise keine Kinesis-Shards zugewiesen. In diesem Fall zeigen diese Worker das Verhalten der Quelle im Leerlauf, auch wenn alle Kinesis-Shards kontinuierlich Ereignisdaten liefern. Sie können dieses Risiko abschwächen indem Sie es uniformShardAssigner mit dem Quell-Operator verwenden. Dadurch wird sichergestellt, dass alle Quell-Unteraufgaben über zu verarbeitende Shards verfügen, sofern die Anzahl der Worker kleiner oder gleich der Anzahl der aktiven Shards ist.

Die Idleness-Option mit den integrierten Wasserzeichen-Strategien verschiebt die Ereigniszeit jedoch nicht nach vorn, wenn keine Unteraufgabe ein Ereignis liest, d. h. es keine Ereignisse im Stream gibt. Dies wird besonders bei Testfällen sichtbar, in denen eine begrenzte Menge von Ereignissen aus dem Stream gelesen wird. Da die Ereigniszeit nach dem Lesen des letzten Ereignisses nicht vorverlegt wird, wird das letzte Fenster (das das letzte Ereignis enthält) nicht geschlossen.

Übersicht

- Diese withIdleness Einstellung generiert keine neuen Wasserzeichen, falls ein Shard inaktiv ist. Sie schließt das letzte Wasserzeichen aus, das von Unteraufgaben im Leerlauf gesendet wurde, bei der Berechnung des Mindestwasserzeichens in nachgeschalteten Operatoren.
- Bei den integrierten Wasserzeichen-Strategien wird das zuletzt geöffnete Fenster nicht geschlossen (es sei denn, es werden neue Ereignisse gesendet, die das Wasserzeichen weiterleiten, aber dadurch wird ein neues Fenster erstellt, das dann geöffnet bleibt).
- Selbst wenn die Zeit durch den Kinesis-Stream festgelegt wird, können spät eintreffende Ereignisse immer noch auftreten, wenn ein Shard schneller verbraucht wird als andere (z. B. während der App-Initialisierung oder bei der Verwendung, TRIM_HORIZON wo alle vorhandenen Shards parallel konsumiert werden, wobei ihre Eltern/Kind-Beziehung ignoriert wird).
- Die withIdleness Einstellungen der Watermark-Strategie scheinen die quellenspezifischen Kinesis-Einstellungen für inaktive Shards zu unterbrechen. (ConsumerConfigConstants.SHARD_IDLE_INTERVAL_MILLIS

Beispiel

Die folgende Anwendung liest aus einem Stream und erstellt Sitzungsfenster auf der Grundlage der Ereigniszeit.

```
Properties consumerConfig = new Properties();
consumerConfig.put(AWSConfigConstants.AWS_REGION, "eu-west-1");
consumerConfig.put(ConsumerConfigConstants.STREAM_INITIAL_POSITION, "TRIM_HORIZON");
FlinkKinesisConsumer<String> consumer = new FlinkKinesisConsumer<>("...", new
SimpleStringSchema(), consumerConfig);
WatermarkStrategy<String> s = WatermarkStrategy
.<String>forMonotonousTimestamps()
.withIdleness(Duration.ofSeconds(15));
env.addSource(consumer)
.assignTimestampsAndWatermarks(s)
.map(new MapFunction<String, Long>() {
    @Override
    public Long map(String s) throws Exception {
        return Long.parseLong(s);
    }
```

```
})
  .keyBy(1 -> 01)
   .window(EventTimeSessionWindows.withGap(Time.seconds(10)))
   .process(new ProcessWindowFunction<Long, Object, Long, TimeWindow>() {
      @Override
      public void process(Long aLong, ProcessWindowFunction<Long, Object, Long,</pre>
TimeWindow>.Context context, Iterable<Long>iterable, Collector<Object> collector)
throws Exception {
          long count = StreamSupport.stream(iterable.spliterator(), false).count();
          long timestamp = context.currentWatermark();
          System.out.println("; Watermark: " + timestamp + ", " +
Instant.ofEpochMilli(timestamp));
          for (Long 1 : iterable) {
             System.out.println(1);
          }
      }
  });
```

Im folgenden Beispiel werden 8 Ereignisse in einen Stream mit 16 Shards geschrieben (die ersten 2 und das letzte Ereignis landen zufällig im selben Shard).

```
$ aws kinesis put-record --stream-name hp-16 --partition-key 1 --data MQ==
$ aws kinesis put-record --stream-name hp-16 --partition-key 2 --data Mg==
$ aws kinesis put-record --stream-name hp-16 --partition-key 3 --data Mw==
$ date
{
    "ShardId": "shardId-00000000012",
    "SequenceNumber": "49627894338614655560500811028721934184977530127978070210"
}
{
    "ShardId": "shardId-00000000012",
    "SequenceNumber": "49627894338614655560500811028795678659974022576354623682"
}
{
    "ShardId": "shardId-00000000014",
    "SequenceNumber": "49627894338659257050897872275134360684221592378842022114"
}
Wed Mar 23 11:19:57 CET 2022
```

```
$ sleep 10
$ aws kinesis put-record --stream-name hp-16 --partition-key 4 --data NA==
$ aws kinesis put-record --stream-name hp-16 --partition-key 5 --data NQ==
$ date
{
    "ShardId": "shardId-0000000000010",
    "SequenceNumber": "49627894338570054070103749783042116732419934393936642210"
}
{
    "ShardId": "shardId-00000000014",
    "SequenceNumber": "49627894338659257050897872275659034489934342334017700066"
}
Wed Mar 23 11:20:10 CET 2022
$ sleep 10
$ aws kinesis put-record --stream-name hp-16 --partition-key 6 --data Ng==
$ date
{
    "ShardId": "shardId-00000000001",
    "SequenceNumber": "49627894338369347363316974173886988345467035365375213586"
}
Wed Mar 23 11:20:22 CET 2022
$ sleep 10
$ aws kinesis put-record --stream-name hp-16 --partition-key 7 --data Nw==
$ date
{
    "ShardId": "shardId-00000000008",
    "SequenceNumber": "49627894338525452579706688535878947299195189349725503618"
}
Wed Mar 23 11:20:34 CET 2022
$ sleep 60
$ aws kinesis put-record --stream-name hp-16 --partition-key 8 --data OA==
$ date
{
    "ShardId": "shardId-00000000012",
    "SequenceNumber": "49627894338614655560500811029600823255837371928900796610"
}
```

Wed Mar 23 11:21:27 CET 2022

Diese Eingabe sollte zu 5 Sitzungsfenstern führen: Ereignis 1,2,3; Ereignis 4,5; Ereignis 6; Ereignis 7; Ereignis 8. Das Programm liefert jedoch nur die ersten 4 Fenster.

11:59:21,529 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 5 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-0000000006,HashKeyRange: {StartingHashKey: 127605887595351923798765477786913079296, EndingHashKey: 148873535527910577765226390751398592511}, SequenceNumberRange: {StartingSequenceNumber: 49627894338480851089309627289524549239292625588395704418,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,530 INFO org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 5 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-0000000006,HashKeyRange: {StartingHashKey: 127605887595351923798765477786913079296, EndingHashKey: 148873535527910577765226390751398592511}, SequenceNumberRange: {StartingSequenceNumber: 49627894338480851089309627289524549239292625588395704418,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 0 11:59:21,530 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 6 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000007,HashKeyRange: {StartingHashKey: 148873535527910577765226390751398592512, EndingHashKey: 170141183460469231731687303715884105727}, SequenceNumberRange: {StartingSequenceNumber: 49627894338503151834508157912666084957565273949901684850,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,530 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 6 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-000000000000,HashKeyRange: {StartingHashKey: 212676479325586539664609129644855132160, EndingHashKey: 233944127258145193631070042609340645375}, SequenceNumberRange: {StartingSequenceNumber: 49627894338570054070103749782090692112383219034419626146,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,530 INFO org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 6 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000007,HashKeyRange: {StartingHashKey: 148873535527910577765226390751398592512, EndingHashKey: 170141183460469231731687303715884105727}, SequenceNumberRange: {StartingSequenceNumber: 49627894338503151834508157912666084957565273949901684850,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 0

11:59:21,531 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 4 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-000000000005,HashKeyRange: {StartingHashKey: 106338239662793269832304564822427566080, EndingHashKey: 127605887595351923798765477786913079295}, SequenceNumberRange: {StartingSequenceNumber: 49627894338458550344111096666383013521019977226889723986, }}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,532 INFO org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 4 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000005,HashKeyRange: {StartingHashKey: 106338239662793269832304564822427566080, EndingHashKey: 127605887595351923798765477786913079295}, SequenceNumberRange: {StartingSequenceNumber: 49627894338458550344111096666383013521019977226889723986,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 0 11:59:21,532 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 3 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000004,HashKeyRange: {StartingHashKey: 85070591730234615865843651857942052864, EndingHashKey: 106338239662793269832304564822427566079}, SequenceNumberRange: {StartingSequenceNumber: 49627894338436249598912566043241477802747328865383743554,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,532 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 2 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000003,HashKeyRange: {StartingHashKey: 63802943797675961899382738893456539648, EndingHashKey: 85070591730234615865843651857942052863}, SequenceNumberRange: {StartingSequenceNumber: 49627894338413948853714035420099942084474680503877763122,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,532 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 3 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000015,HashKeyRange: {StartingHashKey: 319014718988379809496913694467282698240, EndingHashKey: 340282366920938463463374607431768211455}, SequenceNumberRange: {StartingSequenceNumber: 49627894338681557796096402897798370703746460841949528306,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,532 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 2 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000014,HashKeyRange: {StartingHashKey: 297747071055821155530452781502797185024, EndingHashKey: 319014718988379809496913694467282698239}, SequenceNumberRange: {StartingSequenceNumber: 49627894338659257050897872274656834985473812480443547874,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM

11:59:21,532 INFO
<pre>org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -</pre>
Subtask 3 will start consuming seeded shard StreamShardHandle{streamName='hp-16',
shard='{ShardId: shardId-0000000000004,HashKeyRange: {StartingHashKey:
85070591730234615865843651857942052864, EndingHashKey:
106338239662793269832304564822427566079}, SequenceNumberRange: {StartingSequenceNumber:
49627894338436249598912566043241477802747328865383743554.}}'} from sequence number
FARITEST SECUENCE NUM with ShardConsumer 0
11.59.21 532 TNEO
org apache flink streaming connectors kinesis internals KinesisDataFetcher [] -
Subtack 2 will start consuming seeded shard StreamShardHandle/streamName='bp_16'
subtask 2 will stalt consuming seeded shard streamshardhandre(streamwame- hp-10,
Sharu- (Sharuru, Sharuru-WWWWWWWWWWWWW, Hashkeykange, (Startrighashkey,
05002945/9/0/5901099502/50095450559040, Ellutingnasinkey.
650/0591/5025461566564565165/942052665}, SequenceNumberRange. {StartingSequenceNumber.
4962/894558415948855/140554200999420844/46805058///65122,}} } Itom sequence number
EARLIEST_SEQUENCE_NUM with Shardconsumer 0
11:59:21,532 INFO org.apache.Tlink.streaming.connectors.kinesis.FlinkkinesisConsumer
[] - Subtask 0 will be seeded with initial shard StreamShardHandle{streamName='hp-16',
shard='{ShardId: shardId-00000000001,HashKeyRange: {StartingHashKey:
21267647932558653966460912964485513216, EndingHashKey:
42535295865117307932921825928971026431}, SequenceNumberRange: {StartingSequenceNumber:
49627894338369347363316974173816870647929383780865802258,}}'}, starting state set as
sequence number EARLIEST_SEQUENCE_NUM
11:59:21,532 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer
[] - Subtask 0 will be seeded with initial shard StreamShardHandle{streamName='hp-16',
shard='{ShardId: shardId-0000000000009,HashKeyRange: {StartingHashKey:
191408831393027885698148216680369618944,EndingHashKey:
212676479325586539664609129644855132159},SequenceNumberRange: {StartingSequenceNumber:
49627894338547753324905219158949156394110570672913645714,}}'}, starting state set as
sequence number EARLIEST_SEQUENCE_NUM
11:59:21,532 INF0 org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer
<pre>[] - Subtask 7 will be seeded with initial shard StreamShardHandle{streamName='hp-16',</pre>
<pre>shard='{ShardId: shardId-00000000000000,HashKeyRange: {StartingHashKey: 0,EndingHashKey:</pre>
21267647932558653966460912964485513215}, SequenceNumberRange: {StartingSequenceNumber:
49627894338347046618118443550675334929656735419359821826,}}'}, starting state set as
sequence number EARLIEST_SEQUENCE_NUM
11:59:21,533 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer
[] - Subtask 0 will be seeded with initial shard StreamShardHandle{streamName='hp-16',
shard='{ShardId: shardId-00000000000012,HashKeyRange: {StartingHashKey:
255211775190703847597530955573826158592, EndingHashKey:
276479423123262501563991868538311671807}, SequenceNumberRange: {StartingSequenceNumber:
49627894338614655560500811028373763548928515757431587010.}}'}. starting state set as
sequence number EARLIEST_SEQUENCE_NUM

11:59:21,533 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 7 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-000000000008,HashKeyRange: {StartingHashKey: 170141183460469231731687303715884105728, EndingHashKey: 191408831393027885698148216680369618943}, SequenceNumberRange: {StartingSequenceNumber: 49627894338525452579706688535807620675837922311407665282,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,533 INFO org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 0 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000001,HashKeyRange: {StartingHashKey: 21267647932558653966460912964485513216, EndingHashKey: 42535295865117307932921825928971026431}, SequenceNumberRange: {StartingSequenceNumber: 49627894338369347363316974173816870647929383780865802258,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 0 11:59:21,533 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 7 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000011,HashKeyRange: {StartingHashKey: 233944127258145193631070042609340645376, EndingHashKey: 255211775190703847597530955573826158591}, SequenceNumberRange: {StartingSequenceNumber: 49627894338592354815302280405232227830655867395925606578,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,533 INFO org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 7 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000000,HashKeyRange: {StartingHashKey: 0,EndingHashKey: 21267647932558653966460912964485513215}, SequenceNumberRange: {StartingSequenceNumber: 49627894338347046618118443550675334929656735419359821826,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 0 11:59:21,568 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 1 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000002,HashKeyRange: {StartingHashKey: 42535295865117307932921825928971026432, EndingHashKey: 63802943797675961899382738893456539647}, SequenceNumberRange: {StartingSequenceNumber: 49627894338391648108515504796958406366202032142371782690, }}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM 11:59:21,568 INFO org.apache.flink.streaming.connectors.kinesis.FlinkKinesisConsumer [] - Subtask 1 will be seeded with initial shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000013,HashKeyRange: {StartingHashKey: 276479423123262501563991868538311671808, EndingHashKey: 297747071055821155530452781502797185023}, SequenceNumberRange: {StartingSequenceNumber: 49627894338636956305699341651515299267201164118937567442,}}'}, starting state set as sequence number EARLIEST_SEQUENCE_NUM

11:59:21,568 INFO
org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -
Subtask 1 will start consuming seeded shard StreamShardHandle{streamName='hp-16',
shard='{ShardId: shardId-0000000000002,HashKeyRange: {StartingHashKey:
42535295865117307932921825928971026432, EndingHashKey:
63802943797675961899382738893456539647}, SequenceNumberRange: {StartingSequenceNumber:
49627894338391648108515504796958406366202032142371782690,}}'} from sequence number
EARLIEST SEQUENCE NUM with ShardConsumer Ø
11:59:23.209 INFO
org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -
Subtask 0 will start consuming seeded shard StreamShardHandle{streamName='hp-16'.
shard='{ShardId: shardId-0000000000009.HashKevRange: {StartingHashKev:
191408831393027885698148216680369618944, EndingHashKev:
212676479325586539664609129644855132159}, SequenceNumberRange: {StartingSequenceNumber:
49627894338547753324905219158949156394110570672913645714,}}'} from sequence number
EARLIEST SEQUENCE NUM with ShardConsumer 1
11:59:23,244 INFO
<pre>org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -</pre>
Subtask 6 will start consuming seeded shard StreamShardHandle{streamName='hp-16',
shard='{ShardId: shardId-00000000000000000000000000000000000
212676479325586539664609129644855132160, EndingHashKey:
233944127258145193631070042609340645375}, SequenceNumberRange: {StartingSequenceNumber:
49627894338570054070103749782090692112383219034419626146,}}'} from sequence number
EARLIEST_SEQUENCE_NUM with ShardConsumer 1
event: 6; timestamp: 1648030822428, 2022-03-23T10:20:22.428Z
11:59:23,377 INFO
<pre>org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -</pre>
Subtask 3 will start consuming seeded shard StreamShardHandle{streamName='hp-16',
<pre>shard='{ShardId: shardId-00000000015,HashKeyRange: {StartingHashKey:</pre>
319014718988379809496913694467282698240, EndingHashKey:
340282366920938463463374607431768211455}, SequenceNumberRange: {StartingSequenceNumber:
49627894338681557796096402897798370703746460841949528306,}}'} from sequence number
EARLIEST_SEQUENCE_NUM with ShardConsumer 1
11:59:23,405 INFO
org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -
Subtask 2 will start consuming seeded shard StreamShardHandle{streamName='hp-16',
<pre>shard='{ShardId: shardId-00000000014,HashKeyRange: {StartingHashKey:</pre>
297747071055821155530452781502797185024, EndingHashKey:
319014718988379809496913694467282698239}, SequenceNumberRange: {StartingSequenceNumber:
49627894338659257050897872274656834985473812480443547874,}}'} from sequence number
EARLIEST_SEQUENCE_NUM with ShardConsumer 1
11:59:23,581 INFO
org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -
Subtask 7 will start consuming seeded shard StreamShardHandle{streamName='hp-16'.

Managed Service für Apache Flink

shard='{ShardId: shardId-00000000008,HashKeyRange: {StartingHashKey: 170141183460469231731687303715884105728, EndingHashKey: 191408831393027885698148216680369618943}, SequenceNumberRange: {StartingSequenceNumber: 49627894338525452579706688535807620675837922311407665282,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 1 11:59:23,586 INF0 org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 1 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000013,HashKeyRange: {StartingHashKey: 276479423123262501563991868538311671808, EndingHashKey: 297747071055821155530452781502797185023}, SequenceNumberRange: {StartingSequenceNumber: 49627894338636956305699341651515299267201164118937567442,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 1 11:59:24,790 INFO org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 0 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000012,HashKeyRange: {StartingHashKey: 255211775190703847597530955573826158592, EndingHashKey: 276479423123262501563991868538311671807}, SequenceNumberRange: {StartingSequenceNumber: 49627894338614655560500811028373763548928515757431587010,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 2 event: 4; timestamp: 1648030809282, 2022-03-23T10:20:09.282Z event: 3; timestamp: 1648030797697, 2022-03-23T10:19:57.697Z event: 5; timestamp: 1648030810871, 2022-03-23T10:20:10.871Z 11:59:24,907 INFO org.apache.flink.streaming.connectors.kinesis.internals.KinesisDataFetcher [] -Subtask 7 will start consuming seeded shard StreamShardHandle{streamName='hp-16', shard='{ShardId: shardId-00000000011,HashKeyRange: {StartingHashKey: 233944127258145193631070042609340645376, EndingHashKey: 255211775190703847597530955573826158591}, SequenceNumberRange: {StartingSequenceNumber: 49627894338592354815302280405232227830655867395925606578,}}'} from sequence number EARLIEST_SEQUENCE_NUM with ShardConsumer 2 event: 7; timestamp: 1648030834105, 2022-03-23T10:20:34.105Z event: 1; timestamp: 1648030794441, 2022-03-23T10:19:54.441Z event: 2; timestamp: 1648030796122, 2022-03-23T10:19:56.122Z event: 8; timestamp: 1648030887171, 2022-03-23T10:21:27.171Z XXXXXXXXXXXXXXXXX Window with 3 events; Watermark: 1648030809281, 2022-03-23T10:20:09.281Z 3 1 2 XXXXXXXXXXXXXXXX Window with 2 events; Watermark: 1648030834104, 2022-03-23T10:20:34.104Z 4 5 6

Die Ausgabe zeigt nur 4 Fenster (es fehlt das letzte Fenster, das Ereignis 8 enthält). Das liegt an der Ereigniszeit und der Wasserzeichen-Strategie. Das letzte Fenster kann nicht geschlossen werden, da die vorgefertigten Wasserzeichen darauf abzielen, dass die Zeit nie über den Zeitpunkt des letzten Ereignisses hinausgeht, das aus dem Stream gelesen wurde. Damit das Fenster geschlossen werden kann, muss die Zeit jedoch um mehr als 10 Sekunden über das letzte Ereignis hinausgehen. In diesem Fall ist das letzte Wasserzeichen 2022-03-23T 10:21:27.170 Z, aber damit das Sitzungsfenster geschlossen werden kann, ist ein Wasserzeichen 10s und 1ms später erforderlich.

Wenn die withIdleness Option aus der Wasserzeichenstrategie entfernt wird, wird kein Sitzungsfenster jemals geschlossen, da das "globale Wasserzeichen" des Fensteroperators nicht vorrücken kann.

Wenn die Flink-Anwendung startet (oder wenn es zu Datenverzerrungen kommt), werden einige Shards möglicherweise schneller verbraucht als andere. Dies kann dazu führen, dass einige Wasserzeichen zu früh von einer Unteraufgabe ausgegeben werden (die Unteraufgabe kann das Wasserzeichen basierend auf dem Inhalt eines Shards ausgeben, ohne die anderen Shards, die sie abonniert hat, verbraucht zu haben). Um dies zu verhindern, gibt es verschiedene Strategien mit Wasserzeichen, die einen Sicherheitspuffer hinzufügen oder verspätet eintreffende Ereignisse ausdrücklich zulassen. (forBoundedOutOfOrderness(Duration.ofSeconds(30)) (allowedLateness(Time.minutes(5))

Festlegen einer UUID für alle Operatoren

Wenn Managed Service für Apache Flink einen Flink-Auftrag für eine Anwendung mit einem Snapshot startet, kann der Flink-Auftrag aufgrund bestimmter Probleme nicht gestartet werden. Eines davon ist die Nichtübereinstimmung der Operator-ID. Flink erwartet explizite, konsistente Operatoren IDs für Flink-Auftragsdiagramm-Operatoren. Wenn nicht explizit gesetzt, generiert Flink eine ID für die Operatoren. Das liegt daran, dass Flink diese Operatoren verwendet IDs , um die Operatoren in einem Auftragsdiagramm eindeutig zu identifizieren, und sie verwendet, um den Zustand jedes Operators in einem Savepoint zu speichern.

Das Problem der Nichtübereinstimmung der Operator-ID tritt auf, wenn Flink keine 1:1 -Zuordnung zwischen dem Operator IDs eines Auftragsdiagramms und dem in einem Savepoint IDs definierten

Operator findet. Dies passiert, wenn keine expliziten konsistenten Operatoren gesetzt IDs sind und Flink Operatoren generiert IDs, die möglicherweise nicht bei jeder Auftragsdiagramm-Erstellung konsistent sind. Die Wahrscheinlichkeit, dass Anwendungen bei Wartungsarbeiten auf dieses Problem stoßen, ist hoch. Um dies zu vermeiden, empfehlen wir Kunden, die UUID für alle Operatoren im Flink-Code festzulegen. Weitere Informationen finden Sie im Abschnitt Festlegen einer UUID für alle Operatoren unter <u>Produktionsbereitschaft</u>.

Zum Maven ServiceResourceTransformer Shade-Plugin hinzufügen

Flink verwendet die <u>Service Provider Interfaces (SPI)</u> von Java, um Komponenten wie Konnektoren und Formate zu laden. Mehrere Flink-Abhängigkeiten, die SPI verwenden, <u>können zu Konflikten</u> <u>im uber-jar und zu unerwartetem Anwendungsverhalten führen</u>. Wir empfehlen, dass Sie das <u>ServiceResourceTransformer</u>Maven-Shade-Plugin hinzufügen, das in der Datei pom.xml definiert ist.

```
<build>
    <plugins>
        <plugin>
            <groupId>org.apache.maven.plugins</groupId>
            <artifactId>maven-shade-plugin</artifactId>
                <executions>
                    <execution>
                        <id>shade</id>
                        <phase>package</phase>
                        <goals>
                             <goal>shade</goal>
                        </goals>
                        <configuration>
                             <transformers combine.children="append">
                                 <!-- The service transformer is needed to merge META-
INF/services files -->
                                 <transformer
 implementation="org.apache.maven.plugins.shade.resource.ServicesResourceTransformer"/>
                                 <!-- ... -->
                             </transformers>
                        </configuration>
                    </execution>
                </executions>
        </plugin>
```

Stateful-Funktionen von Apache Flink

<u>Stateful Functions</u> ist eine API, die die Erstellung verteilter zustandsbehafteter Anwendungen vereinfacht. Sie basiert auf Funktionen mit persistentem Status, die dynamisch mit starken Konsistenzgarantien interagieren können.

Eine Stateful-Functions-Anwendung ist im Grunde lediglich eine Apache-Flink-Anwendung und kann daher in Managed Service für Apache Flink bereitgestellt werden. Es gibt jedoch einige Unterschiede zwischen der Paketierung von Stateful Functions für einen Kubernetes-Cluster und für Managed Service für Apache Flink. Der wichtigste Aspekt einer Stateful-Functions-Anwendung ist, dass die <u>Modulkonfiguration</u> alle erforderlichen Laufzeitinformationen zur Konfiguration der Stateful-Functions-Laufzeit enthält. Diese Konfiguration wird normalerweise in einen Stateful-Functions-spezifischen Container gepackt und auf Kubernetes bereitgestellt. Aber das ist mit Managed Service für Apache Flink nicht möglich.

Es folgt eine Anpassung des StateFun Python-Beispiels für Managed Service für Apache Flink:

Apache Flink-Anwendungsvorlage

Anstatt einen Kundencontainer für die Stateful-Functions-Laufzeit zu verwenden, können Kunden eine Flink-Anwendungs-JAR-Datei kompilieren, die lediglich die Stateful-Functions-Laufzeit aufruft und die erforderlichen Abhängigkeiten enthält. Für Flink 1.13 sehen die erforderlichen Abhängigkeiten etwa wie folgt aus:

```
<dependency>
<groupId>org.apache.flink</groupId>
<artifactId>statefun-flink-distribution</artifactId>
<version>3.1.0</version>
<exclusions>
<exclusions>
<groupId>org.slf4j</groupId>
<artifactId>slf4j-log4j12</artifactId>
</exclusion>
<exclusion>
<groupId>log4j</groupId>
<artifactId>log4j</artifactId>
</exclusion>
</exclusion>
</exclusion>
</exclusion>
```

Und die Hauptmethode der Flink-Anwendung zum Aufrufen der Stateful-Function-Laufzeit sieht so aus:

```
public static void main(String[] args) throws Exception {
  final StreamExecutionEnvironment env =
    StreamExecutionEnvironment.getExecutionEnvironment();
    StatefulFunctionsConfig stateFunConfig = StatefulFunctionsConfig.fromEnvironment(env);
    stateFunConfig.setProvider((StatefulFunctionsUniverseProvider) (classLoader,
    statefulFunctionsConfig) -> {
    Modules modules = Modules.loadFromClassPath();
    return modules.createStatefulFunctionsUniverse(stateFunConfig);
    });
    StatefulFunctionsJob.main(env, stateFunConfig);
}
```

Beachten Sie, dass diese Komponenten generisch und unabhängig von der Logik sind, die in der Stateful Function implementiert ist.

Ort der Modulkonfiguration

Die Konfiguration des Stateful-Functions-Moduls muss im Klassenpfad enthalten sein, damit sie für die Stateful-Functions-Laufzeit auffindbar ist. Am besten fügen Sie es in den Ressourcenordner der Flink-Anwendung ein und packen es in die JAR-Datei.

Ähnlich wie bei einer gewöhnlichen Apache-Flink-Anwendung können Sie dann Maven verwenden, um eine Uber-JAR-Datei zu erstellen und diese auf Managed Service für Apache Flink bereitzustellen.

Apache Flink-Einstellungen

Managed Service für Apache Flink ist eine Implementierung des Apache-Flink-Frameworks. Managed Service für Apache Flink verwendet die in diesem Abschnitt beschriebenen Standardwerte. Einige dieser Werte können vom Managed Service für Apache Flink-Anwendungen im Code festgelegt werden, andere können nicht geändert werden.

Verwenden Sie die Links in diesem Abschnitt, um mehr über die Apache Flink-Einstellungen zu erfahren und zu erfahren, welche Einstellungen geändert werden können.

Dieses Thema enthält die folgenden Abschnitte:

- Apache Flink-Konfiguration
- Bundesstaatliches Backend
- <u>Checkpointing</u>
- Savepointing
- Haufengrößen
- Puffer-Entlastung
- Anpassbare Flink-Konfigurationseigenschaften
- Konfigurierte Flink-Eigenschaften anzeigen

Apache Flink-Konfiguration

Managed Service für Apache Flink bietet eine Standard-Flink-Konfiguration, die aus von Apache Flink empfohlenen Werten für die meisten Eigenschaften und einigen wenigen, die auf gängigen Anwendungsprofilen basieren, besteht. Weitere Informationen zur Flink-Konfiguration finden Sie unter Konfiguration. Die vom Service bereitgestellte Standardkonfiguration funktioniert für die meisten Anwendungen. Um jedoch die Flink-Konfigurationseigenschaften zu optimieren, um die Leistung bestimmter Anwendungen mit hoher Parallelität, hoher Speicher- und Statusauslastung zu verbessern oder neue Debugging-Funktionen in Apache Flink zu aktivieren, können Sie bestimmte Eigenschaften ändern, indem Sie eine Support-Anfrage stellen. Weitere Informationen finden Sie unter <u>AWS Support-Center</u>. Sie können die aktuelle Konfiguration für Ihre Anwendung mithilfe des <u>Apache-Flink-Dashboards</u> überprüfen.

Bundesstaatliches Backend

Managed Service für Apache Flink speichert transiente Daten in einem Zustands-Backend. Managed Service für Apache Flink verwendet das DBStateRocks-Backend. Der Aufruf von setStateBackend, um ein anderes Backend festzulegen, hat keine Auswirkung.

Wir aktivieren die folgenden Features im Zustands-Backend:

- Inkrementelle Zustands-Backend-Snapshots
- Asynchrone Zustands-Backend-Snapshots
- Lokale Wiederherstellung von Checkpoints

Weitere Informationen zu State-Backends finden Sie unter <u>State Backends</u> in der Apache Flink-Dokumentation.

Checkpointing

Managed Service für Apache Flink verwendet eine Checkpoint-Standardkonfiguration mit den folgenden Werten. Einige dieser Werte können mit geändert werden. <u>CheckpointConfiguration</u> Sie CheckpointConfiguration.ConfigurationType müssen CUSTOM für Managed Service for Apache Flink auf einstellen, um modifizierte Checkpoint-Werte zu verwenden.

Einstellung	Kann angepasst werden?	Wie	Standardwert
CheckpointingEnabl ed	Anpassbar	Create Application Update Application AWS CloudFormation	True
CheckpointInterval	Anpassbar	Create ApplicationUpdate ApplicationAWS CloudFormation	60000
MinPauseB etweenCheckpoints	Anpassbar	Create Application	5000

Einstellung	Kann angepasst werden?	Wie	Standardwert
		Update Application	
		AWS CloudFormation	
Nicht ausgerichtete Checkpoints	Anpassbar	Support-Fall	False
Anzahl gleichzeitiger Checkpoints	Nicht anpassbar	N/A	1
Checkpointing-Modus	Nicht anpassbar	N/A	Genau einmal
Checkpoint-Aufbewa hrungsrichtlinie	Nicht anpassbar	N/A	Bei Fehlschlag
Checkpoint-Timeout	Nicht anpassbar	N/A	60 Minuten
Maximale Anzahl aufbewahrter Checkpoints	Nicht anpassbar	N/A	1
Checkpoint- und Savepoint-Speicherort	Nicht anpassbar	N/A	Wir speichern dauerhafte Checkpoin t- und Savepoint -Daten in einem serviceeigenen S3- Bucket.

Savepointing

Bei der Wiederherstellung von einem Savepoint aus versucht der Wiederaufnahmevorgang standardmäßig, den gesamten Zustand des Savepoints dem Programm zuzuordnen, mit dem Sie die Wiederherstellung durchführen. Wenn Sie einen Operator gelöscht haben, schlägt die Wiederherstellung von einem Savepoint, der Daten enthält, die dem fehlenden Operator entsprechen, standardmäßig fehl. Sie können den Vorgang erfolgreich durchführen lassen, indem Sie den AllowNonRestoredStateParameter der Anwendung FlinkRunConfigurationauf true setzen. Dadurch können beim Wiederaufnahmevorgang Zustandsdaten übersprungen werden, die dem neuen Programm nicht zugeordnet werden können.

Weitere Informationen finden Sie unter <u>Nicht wiederhergestellten Status zulassen</u> in der Dokumentation zu Apache Flink.

Haufengrößen

Managed Service für Apache Flink weist jeder KPU 3 GB JVM-Heap zu und reserviert 1 GB für native Code-Zuweisungen. Informationen zur Erhöhung der Anwendungskapazität finden Sie unter <u>the</u> <u>section called "Implementieren Sie Anwendungsskalierung"</u>.

Weitere Informationen über JVM-Heap-Größen finden Sie unter Konfiguration in der Apache-Flink-Dokumentation.

Puffer-Entlastung

Die Puffer-Entlastung kann Anwendungen mit hohem Gegendruck helfen. Wenn in Ihrer Anwendung fehlgeschlagene Checkpoints/Savepoints auftreten, kann es hilfreich sein, dieses Feature zu aktivieren. Reichen Sie dazu einen <u>Support-Fall</u> ein.

Weitere Informationen finden Sie unter Die Puffer-Entlastung in der Apache-Flink-Dokumentation.

Anpassbare Flink-Konfigurationseigenschaften

Im Folgenden finden Sie die Flink-Konfigurationseinstellungen, die Sie mithilfe eines <u>Support-Falls</u> ändern können. Sie können mehr als eine Eigenschaft gleichzeitig und für mehrere Anwendungen gleichzeitig ändern, indem Sie das Anwendungspräfix angeben. Wenn es außerhalb dieser Liste noch andere Flink-Konfigurationseigenschaften gibt, die Sie ändern möchten, geben Sie in Ihrem Fall die genaue Eigenschaft an.

Strategie neu starten

Ab Flink 1.19 und höher verwenden wir standardmäßig die exponential-delay Neustart-Strategie. Alle früheren Versionen verwenden standardmäßig die fixed-delay Neustartstrategie.

```
restart-strategy:
```

```
restart-strategy.fixed-delay.delay:
```

restart-strategy.exponential-delay.backoff-muliplier:

restart-strategy.exponential-delay.initial-backoff:

restart-strategy.exponential-delay.jitter-factor:

restart-strategy.exponential-delay.reset-backoff-threshold:

Checkpoints und Status-Backends

state.backend:

state.backend.fs.memory-threshold:

state.backend.incremental:

Checkpointing

execution.checkpointing.unaligned:

execution.checkpointing.interval-during-backlog:

Native RocksDB-Metriken

RocksDB Native Metrics werden nicht an geliefert. CloudWatch Nach der Aktivierung können diese Metriken entweder über das Flink-Dashboard oder die Flink-REST-API mit benutzerdefinierten Tools abgerufen werden.

Mit Managed Service for Apache Flink können Kunden über die API im schreibgeschützten Modus auf die neueste <u>Flink-REST-API</u> (oder die von Ihnen verwendete unterstützte Version) zugreifen. <u>CreateApplicationPresignedUrl</u> Diese API wird vom eigenen Dashboard von Flink verwendet, kann aber auch von benutzerdefinierten Überwachungstools verwendet werden.

state.backend.rocksdb.metrics.actual-delayed-write-rate:

state.backend.rocksdb.metrics.background-errors:

state.backend.rocksdb.metrics.block-cache-capacity:

state.backend.rocksdb.metrics.block-cache-pinned-usage:

state.backend.rocksdb.metrics.block-cache-usage:

state.backend.rocksdb.metrics.column-family-as-variable: state.backend.rocksdb.metrics.compaction-pending: state.backend.rocksdb.metrics.cur-size-active-mem-table: state.backend.rocksdb.metrics.cur-size-all-mem-tables: state.backend.rocksdb.metrics.estimate-live-data-size: state.backend.rocksdb.metrics.estimate-num-keys: state.backend.rocksdb.metrics.estimate-pending-compaction-bytes: state.backend.rocksdb.metrics.estimate-table-readers-mem: state.backend.rocksdb.metrics.is-write-stopped: state.backend.rocksdb.metrics.mem-table-flush-pending: state.backend.rocksdb.metrics.num-deletes-active-mem-table: state.backend.rocksdb.metrics.num-deletes-imm-mem-tables: state.backend.rocksdb.metrics.num-entries-active-mem-table: state.backend.rocksdb.metrics.num-entries-imm-mem-tables: state.backend.rocksdb.metrics.num-immutable-mem-table: state.backend.rocksdb.metrics.num-live-versions: state.backend.rocksdb.metrics.num-running-compactions: state.backend.rocksdb.metrics.num-running-flushes: state.backend.rocksdb.metrics.num-snapshots: state.backend.rocksdb.metrics.size-all-mem-tables: RocksDB-Optionen

state.backend.rocksdb.compaction.style:

state.backend.rocksdb.memory.partitioned-index-filters:

state.backend.rocksdb.thread.num:

Erweiterte State-Backend-Optionen

state.storage.fs.memory-threshold:

Vollständige Optionen TaskManager

task.cancellation.timeout:

taskmanager.jvm-exit-on-oom:

taskmanager.numberOfTaskSlots:

taskmanager.slot.timeout:

taskmanager.network.memory.fraction:

taskmanager.network.memory.max:

taskmanager.network.request-backoff.initial:

taskmanager.network.request-backoff.max:

taskmanager.network.memory.buffer-debloat.enabled:

taskmanager.network.memory.buffer-debloat.period:

taskmanager.network.memory.buffer-debloat.samples:

taskmanager.network.memory.buffer-debloat.threshold-percentages:

Arbeitsspeicherkonfiguration

taskmanager.memory.jvm-metaspace.size:

taskmanager.memory.jvm-overhead.fraction:

taskmanager.memory.jvm-overhead.max:

taskmanager.memory.managed.consumer-weights:

taskmanager.memory.managed.fraction:

taskmanager.memory.network.fraction:

taskmanager.memory.network.max:

taskmanager.memory.segment-size:

taskmanager.memory.task.off-heap.size:

RPC / Akka

akka.ask.timeout:

akka.client.timeout:

akka.framesize:

akka.lookup.timeout:

akka.tcp.timeout:

Client

client.timeout:

Erweiterte Cluster-Optionen

cluster.intercept-user-system-exit:

cluster.processes.halt-on-fatal-error:

Dateisystemkonfigurationen

fs.s3.connection.maximum:

fs.s3a.connection.maximum:

fs.s3a.threads.max:

s3.upload.max.concurrent.uploads:

Erweiterte Optionen für die Fehlertoleranz

heartbeat.timeout:

jobmanager.execution.failover-strategy:

Arbeitsspeicherkonfiguration

jobmanager.memory.heap.size:

Metriken

metrics.latency.interval:

Erweiterte Optionen für den REST-Endpunkt und -Client

rest.flamegraph.enabled:

rest.server.numThreads:

Erweiterte SSL-Sicherheitsoptionen

security.ssl.internal.handshake-timeout:

Erweiterte Planungsoptionen

slot.request.timeout:

Erweiterte Optionen für die Flink-Weboberfläche

web.timeout:

Konfigurierte Flink-Eigenschaften anzeigen

Sie können die Apache-Flink-Eigenschaften, die Sie selbst konfiguriert haben oder deren Änderung Sie in einem <u>Support-Fall</u> angefordert haben, über das Apache-Flink-Dashboard einsehen. Gehen Sie dazu wie folgt vor:

- 1. Gehen Sie zum Flink-Dashboard
- 2. Wählen Sie im linken Navigationsbereich Auftragsmanager aus.
- 3. Wählen Sie Konfiguration, um die Liste der Flink-Eigenschaften anzuzeigen.

Konfigurieren Sie Managed Service für Apache Flink für den Zugriff auf Ressourcen in einer Amazon VPC

Sie können eine Anwendung, die Managed Service for Apache Flink nutzt, so konfigurieren, dass sie sich mit privaten Subnetzen in einer Virtual Private Cloud (VPC) in Ihrem Konto verbindet. Verwenden Sie Amazon Virtual Private Cloud (Amazon VPC) zum Erstellen eines privaten Netzwerks für Ressourcen wie z. B. Datenbanken, Cache-Instances oder interne Services. Verbinden Sie Ihre Anwendung mit der VPC, um während der Ausführung auf private Ressourcen zuzugreifen.

Dieses Thema enthält die folgenden Abschnitte:

- <u>Amazon VPC-Konzepte</u>
- VPC-Anwendungsberechtigungen
- Internet- und Servicezugriff für eine VPC-verbundene Managed Service for Apache Flink-Anwendung
- Verwenden Sie die Managed Service for Apache Flink VPC-API
- Beispiel: Verwenden Sie eine VPC für den Zugriff auf Daten in einem Amazon MSK-Cluster

Amazon VPC-Konzepte

Amazon VPC ist die Netzwerkschicht für Amazon EC2. Wenn Sie neu bei Amazon sind EC2, finden Sie weitere Informationen unter <u>Was ist Amazon EC2?</u> im EC2 Amazon-Benutzerhandbuch für Linux-Instances, um sich einen kurzen Überblick zu verschaffen.

Im Folgenden finden Sie die wichtigsten Konzepte für VPCs:

- Eine Virtual Private Cloud (VPC) ist ein virtuelles Netzwerk, das Ihrem AWS Konto gewidmet ist.
- Ein Subnetz ist ein Bereich an IP-Adressen in Ihrer VPC.
- Eine Routing-Tabelle enthält eine Reihe von Regeln, so genannte Routen, die festlegen, wohin der Netzwerkdatenverkehr gelenkt wird.
- Ein Internet-Gateway ist eine horizontal skalierte, redundante und hochverfügbare VPC-Komponente, die die Kommunikation zwischen Instances in Ihrer VPC und dem Internet ermöglicht. Sie verursacht daher keine Verfügbarkeitsrisiken oder Bandbreitenbeschränkungen in Ihrem Netzwerkverkehr.
Mit einem VPC-Endpunkt können Sie Ihre VPC privat mit unterstützten AWS Diensten und VPC-Endpunktdiensten verbinden, die von bereitgestellt werden, PrivateLink ohne dass ein Internet-Gateway, ein NAT-Gerät, eine VPN-Verbindung oder eine Verbindung erforderlich ist. AWS Direct Connect Instances in Ihrer VPC benötigen keine öffentlichen IP-Adressen, um mit den Ressourcen in dem Service zu kommunizieren. Der Datenverkehr zwischen Ihrer VPC und dem anderen Service verlässt das Amazon-Netzwerk nicht.

Weitere Informationen zu Amazon-VPC-Service finden Sie im <u>Benutzerhandbuch von Amazon Virtual</u> <u>Private Cloud</u>.

Managed Service für Apache Flink erstellt <u>Elastic-Network-Schnittstellen</u> in einem der Subnetze, die in Ihrer VPC-Konfiguration für die Anwendung bereitgestellt werden. Die Anzahl der in Ihren VPC-Subnetzen erstellten Elastic-Network-Schnittstelle kann je nach Parallelität und Parallelität pro KPU der Anwendung variieren. Weitere Informationen zur Anwendungsskalierung finden Sie unter Implementieren Sie Anwendungsskalierung.

Note

VPC-Konfigurationen werden für SQL-Anwendungen nicht unterstützt.

Note

Der Service von Managed Service für Apache Flink verwaltet den Checkpoint- und Snapshot-Status für Anwendungen, die über eine VPC-Konfiguration verfügen.

VPC-Anwendungsberechtigungen

In diesem Abschnitt werden die Berechtigungsrichtlinien beschrieben, die Ihre Anwendung benötigt, um mit Ihrer VPC zu funktionieren. Weitere Informationen zur Verwendung von Berechtigungsrichtlinien finden Sie unter <u>Identity and Access Management für Amazon Managed</u> <u>Service für Apache Flink</u>.

Die folgende Berechtigungsrichtlinie gewährt Ihrer Anwendung die erforderlichen Berechtigungen für die Interaktion mit einer VPC. Um diese Berechtigungsrichtlinie zu verwenden, fügen Sie sie der Ausführungsrolle Ihrer Anwendung hinzu.

Fügen Sie eine Berechtigungsrichtlinie für den Zugriff auf eine Amazon VPC hinzu

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "VPCReadOnlyPermissions",
      "Effect": "Allow",
      "Action": [
        "ec2:DescribeVpcs",
        "ec2:DescribeSubnets",
        "ec2:DescribeSecurityGroups",
        "ec2:DescribeDhcpOptions"
      ],
      "Resource": "*"
    },
    {
      "Sid": "ENIReadWritePermissions",
      "Effect": "Allow",
      "Action": [
        "ec2:CreateNetworkInterface",
        "ec2:CreateNetworkInterfacePermission",
        "ec2:DescribeNetworkInterfaces",
        "ec2:DeleteNetworkInterface"
      ],
      "Resource": "*"
    }
    ]
}
```

Note

Wenn Sie Anwendungsressourcen mithilfe der Konsole angeben (z. B. CloudWatch Logs oder eine Amazon VPC), ändert die Konsole Ihre Anwendungsausführungsrolle, um die Berechtigung für den Zugriff auf diese Ressourcen zu gewähren. Sie müssen die Ausführungsrolle Ihrer Anwendung nur manuell ändern, wenn Sie Ihre Anwendung erstellen, ohne die Konsole zu verwenden.

Internet- und Servicezugriff für eine VPC-verbundene Managed Service for Apache Flink-Anwendung

Wenn Sie eine Funktion mit einer VPC in Ihrem Konto verbinden, hat sie keinen Zugriff auf das Internet, es sei denn, die VPC bietet Zugriff. Wenn die Anwendung Internetzugriff benötigt, muss Folgendes zutreffen:

- Die Anwendung, die Managed Service für Apache Flink nutzt, darf nur mit privaten Subnetzen konfiguriert werden.
- Die VPC muss ein NAT-Gateway oder eine -Instance in einem öffentlichen Subnetz enthalten.
- In einem öffentlichen Subnetz muss eine Route f
 ür ausgehenden Datenverkehr aus den privaten Subnetzen zum NAT-Gateway vorhanden sein.

Note

Verschiedene Services bieten <u>VPC-Endpunkte</u>. Sie können VPC-Endpunkte verwenden, um Verbindungen zu Amazon-Services aus einer VPC ohne Internetzugriff herzustellen.

Ob ein Subnetz öffentlich oder privat ist, hängt von seiner Routing-Tabelle ab. Jede Routing-Tabelle hat eine Standardroute, die den nächsten Hop für Pakete bestimmt, die ein öffentliches Ziel haben.

- Für ein privates Subnetz: Die Standardroute zeigt auf ein NAT-Gateway (nat-...) oder eine NAT-Instance (eni-...).
- Für ein öffentliches Subnetz: Die Standardroute zeigt auf ein Internet-Gateway (igw-...).

Nachdem Sie Ihre VPC mit einem öffentlichen Subnetz (mit einem NAT) und einem oder mehreren privaten Subnetzen konfiguriert haben, gehen Sie wie folgt vor, um Ihre privaten und öffentlichen Subnetze zu identifizieren:

- Wählen Sie im Navigationsbereich der VPC-Konsole Subnetze.
- Wählen Sie die Subnetze aus und klicken Sie dann auf die Registerkarte Routing-Tabelle.
 Überprüfen Sie die Standardroute:
 - Öffentliches Subnetz: Destination: 0.0.0.0/0, Ziel: igw-...
 - Privates Subnetz: Destination: 0.0.0.0/0, Ziel: nat-... oder eni-...

So verknüpfen Sie die Anwendung, die Managed Service für Apache Flink nutzt, mit privaten Subnetzen:

- Öffnen Sie die Managed Service for Apache Flink-Konsole unter /flink https:// console.aws.amazon.com
- Wählen Sie auf der Seite Anwendungen, die Managed Service für Apache Flink nutzen Ihre Anwendung und anschließend Anwendungsdetails aus.
- Wählen Sie auf der Seite für Ihre Anwendung Konfigurieren aus.
- Wählen Sie im Abschnitt VPC-Konnektivität die VPC, die Ihrer Anwendung zugeordnet werden soll. Wählen Sie die mit Ihrer VPC verknüpften Subnetze und Sicherheitsgruppe aus, die die Anwendung für den Zugriff auf VPC-Ressourcen verwenden soll.
- Wählen Sie Aktualisieren.

Ähnliche Informationen

Erstellen einer VPC mit öffentlichen und privaten Subnetzen

Grundlagen zu NAT-Gateways

Verwenden Sie die Managed Service for Apache Flink VPC-API

Verwenden Sie den folgenden Managed Service für Apache Flink API-Operationen, um Ihre Anwendung VPCs zu verwalten. Weitere Informationen zur Verwendung der API von Managed Service für Apache Flink finden Sie unter <u>API-Beispielcode</u>.

Anwendung erstellen

Verwenden Sie die <u>CreateApplication</u>Aktion, um Ihrer Anwendung während der Erstellung eine VPC-Konfiguration hinzuzufügen.

Der folgende Beispiel-Anforderungscode für die CreateApplication-Aktion schließt eine VPC-Konfiguration ein, wenn die Anwendung erstellt wird:

```
"ApplicationName":"MyApplication",
"ApplicationDescription":"My-Application-Description",
"RuntimeEnvironment":"FLINK-1_15",
```

{

```
"ServiceExecutionRole":"arn:aws:iam::123456789123:role/myrole",
  "ApplicationConfiguration": {
    "ApplicationCodeConfiguration":{
      "CodeContent":{
        "S3ContentLocation":{
          "BucketARN": "arn: aws: s3::: amzn-s3-demo-bucket",
          "FileKey": "myflink.jar",
          "ObjectVersion": "AbCdEfGhIjKlMnOpQrStUvWxYz12345"
        }
      },
      "CodeContentType":"ZIPFILE"
    },
      "FlinkApplicationConfiguration":{
      "ParallelismConfiguration":{
        "ConfigurationType":"CUSTOM",
        "Parallelism":2,
        "ParallelismPerKPU":1,
        "AutoScalingEnabled":true
      }
    },
  "VpcConfigurations": [
         {
            "SecurityGroupIds": [ "sg-0123456789abcdef0" ],
            "SubnetIds": [ "subnet-0123456789abcdef0" ]
         }
      ]
  }
}
```

AddApplicationVpcConfiguration

Verwenden Sie die <u>AddApplicationVpcConfiguration</u>Aktion, um Ihrer Anwendung eine VPC-Konfiguration hinzuzufügen, nachdem sie erstellt wurde.

Der folgende Beispiel-Anforderungscode für die AddApplicationVpcConfiguration-Aktion fügt einer bestehenden Anwendung eine VPC-Konfiguration hinzu:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 9,
    "VpcConfiguration": {
        "SecurityGroupIds": [ "sg-0123456789abcdef0" ],
        "SubnetIds": [ "subnet-0123456789abcdef0" ]
```

}

}

DeleteApplicationVpcConfiguration

Verwenden Sie die <u>DeleteApplicationVpcConfiguration</u>Aktion, um eine VPC-Konfiguration aus Ihrer Anwendung zu entfernen.

Der folgende Beispiel-Anforderungscode für die AddApplicationVpcConfiguration-Aktion entfernt eine bestehende VPC-Konfiguration aus einer Anwendung:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 9,
    "VpcConfigurationId": "1.1"
}
```

Anwendung aktualisieren

Verwenden Sie die <u>UpdateApplication</u>Aktion, um alle VPC-Konfigurationen einer Anwendung gleichzeitig zu aktualisieren.

Der folgende Beispiel-Anforderungscode für die UpdateApplication-Aktion aktualisiert alle VPC-Konfigurationen einer Anwendung:

Beispiel: Verwenden Sie eine VPC für den Zugriff auf Daten in einem Amazon MSK-Cluster

Ein vollständiges Tutorial zum Zugriff auf Daten aus einem Amazon-MSK-Cluster in einer VPC finden Sie unter MSK-Replikation.

Fehlerbehebung bei Managed Service für Apache Flink

Die folgenden Themen können Ihnen bei der Behebung von Problemen helfen, die möglicherweise mit Amazon Managed Service für Apache Flink auftreten.

Wählen Sie das entsprechende Thema aus, um die Lösungen zu überprüfen.

Themen

- Fehlerbehebung bei der Entwicklung
- Fehlerbehebung während der Laufzeit

Fehlerbehebung bei der Entwicklung

Dieser Abschnitt enthält Informationen zur Diagnose und Behebung von Entwicklungsproblemen mit Ihrer Managed Service for Apache Flink-Anwendung.

Themen

- Bewährte Methoden für das Rollback von Systemen
- Bewährte Methoden für die Hudi-Konfiguration
- Apache Flink Flame-Diagramme
- Problem mit dem Anmeldeinformationsanbieter mit dem EFO-Connector 1.15.2
- Anwendungen mit nicht unterstützten Kinesis-Konnektoren
- Kompilierungsfehler: "Abhängigkeiten für das Projekt konnten nicht aufgelöst werden"
- Ungültige Auswahl: "kinesisanalyticsv2"
- UpdateApplication Aktion ist kein erneutes Laden des Anwendungscodes
- <u>S3 StreamingFileSink FileNotFoundExceptions</u>
- FlinkKafkaConsumer Problem mit Stop with Savepoint
- Flink 1.15 Async Sink Deadlock
- Die Quellverarbeitung von Amazon Kinesis Kinesis-Datenstreams ist beim Re-Sharding nicht in der richtigen Reihenfolge
- Häufig gestellte Fragen und Problemlösungen zum Einbetten von Vektoren in Echtzeit

Bewährte Methoden für das Rollback von Systemen

Mit den Funktionen für automatisches System-Rollback und Betriebstransparenz in Amazon Managed Service for Apache Flink können Sie Probleme mit Ihren Anwendungen identifizieren und lösen.

System-Rollbacks

Wenn Ihr Anwendungsupdate oder Ihr Skalierungsvorgang aufgrund eines Kundenfehlers fehlschlägt, z. B. aufgrund eines Codefehlers oder eines Berechtigungsproblems, versucht Amazon Managed Service für Apache Flink automatisch, zur vorherigen laufenden Version zurückzukehren, sofern Sie sich für diese Funktion entschieden haben. Weitere Informationen finden Sie unter <u>Aktivieren Sie</u> <u>System-Rollbacks für Ihre Managed Service for Apache Flink-Anwendung</u>. Wenn dieser automatische Rollback fehlschlägt oder Sie sich nicht angemeldet oder abgemeldet haben, wird Ihre Anwendung in den entsprechenden Status versetzt. READY Gehen Sie wie folgt vor, um Ihre Bewerbung zu aktualisieren:

Manuelles Rollback

Wenn die Anwendung nicht voranschreitet und sich über einen längeren Zeitraum in einem vorübergehenden Zustand befindet oder wenn die Anwendung erfolgreich umgestellt wurdeRunning, Sie aber nachgelagerte Probleme wie Verarbeitungsfehler in einer erfolgreich aktualisierten Flink-Anwendung feststellen, können Sie sie mithilfe der API manuell rückgängig machen. RollbackApplication

- 1. Aufruf RollbackApplication dadurch wird zur vorherigen laufenden Version zurückgesetzt und der vorherige Status wiederhergestellt.
- 2. Überwachen Sie den Rollback-Vorgang mithilfe der DescribeApplicationOperation API.
- 3. Wenn das Rollback fehlschlägt, verwenden Sie die vorherigen System-Rollback-Schritte.

Sichtbarkeit der Abläufe

Die ListApplicationOperations API zeigt den Verlauf aller Kunden- und Systemvorgänge in Ihrer Anwendung.

- 1. Ruft die OperationID des fehlgeschlagenen Vorgangs aus der Liste ab.
- 2. Rufen Sie an DescribeApplicationOperation und überprüfen Sie den Status und die statusDescription.

3. Wenn ein Vorgang fehlgeschlagen ist, weist die Beschreibung auf einen möglichen Fehler hin, der untersucht werden muss.

Häufige Fehler im Fehlercode: Verwenden Sie die Rollback-Funktionen, um zur letzten funktionierenden Version zurückzukehren. Beheben Sie Fehler und versuchen Sie das Update erneut.

Probleme mit Berechtigungen: Verwenden Sie denDescribeApplicationOperation, um die erforderlichen Berechtigungen einzusehen. Aktualisieren Sie die Anwendungsberechtigungen und versuchen Sie es erneut.

Serviceprobleme mit Amazon Managed Service für Apache Flink: Überprüfen Sie den Support-Fall AWS Health Dashboard oder öffnen Sie einen Support-Fall.

Bewährte Methoden für die Hudi-Konfiguration

Um Hudi-Konnektoren auf Managed Service für Apache Flink auszuführen, empfehlen wir die folgenden Konfigurationsänderungen.

Deaktivieren von hoodie.embed.timeline.server

Der Hudi-Connector auf Flink richtet einen eingebetteten Timeline (TM) -Server auf dem Flink Jobmanager (JM) ein, um Metadaten zwischenzuspeichern und so die Leistung bei hoher Jobparallelität zu verbessern. Wir empfehlen, diesen eingebetteten Server im Managed Service für Apache Flink zu deaktivieren, da wir die Nicht-Flink-Kommunikation zwischen JM und TM deaktivieren.

Wenn dieser Server aktiviert ist, versucht Hudi Writes zunächst, eine Verbindung zum eingebetteten Server auf JM herzustellen, und greift dann auf das Lesen von Metadaten aus Amazon S3 zurück. Das bedeutet, dass bei Hudi ein Verbindungs-Timeout auftritt, das Hudi-Schreibvorgänge verzögert und die Leistung von Managed Service for Apache Flink beeinträchtigt.

Apache Flink Flame-Diagramme

Flame-Diagramme sind für Anwendungen in Versionen von Managed Service für Apache Flink, die Flame-Diagramme unterstützen, standardmäßig aktiviert. Flame-Diagramme können die Leistung der Anwendung beeinträchtigen, wenn Sie das Diagramm geöffnet lassen, wie in der <u>Flink-Dokumentation</u> beschrieben.

Wenn Sie Flame-Diagramme für Ihre Anwendung deaktivieren möchten, erstellen Sie einen Fall, um die Deaktivierung für Ihren Anwendungs-ARN anzufordern. Weitere Informationen finden Sie im <u>AWS</u> Support-Center.

Problem mit dem Anmeldeinformationsanbieter mit dem EFO-Connector 1.15.2

Es gibt ein <u>bekanntes Problem</u> mit EFO-Konnektor-Versionen bis 1.15.2 von Kinesis Data Streams, bei dem der FlinkKinesisConsumer die Credential Provider-Konfiguration nicht berücksichtigt. Gültige Konfigurationen werden aufgrund des Problems ignoriert, was dazu führt, dass der AUTO-Anmeldeinformationsanbieter verwendet wird. Dies kann zu Problemen beim kontoübergreifenden Zugriff auf Kinesis mithilfe des EFO-Konnektors führen.

Um diesen Fehler zu beheben, verwenden Sie bitte die EFO-Konnektor-Version 1.15.3 oder höher.

Anwendungen mit nicht unterstützten Kinesis-Konnektoren

Managed Service for Apache Flink for Apache Flink Version 1.15 oder höher <u>lehnt automatisch den</u> <u>Start oder die Aktualisierung von Anwendungen ab, wenn sie nicht unterstützte Kinesis Connector-</u> <u>Versionen (vor Version 1.15.2) verwenden, die in Anwendungen oder</u> Archiven (ZIP) gebündelt sind. JARs

Ablehnungsfehler

Sie erhalten folgende Fehlermeldung, wenn Sie Aufrufe zum Erstellen und Aktualisieren von Anwendungen übermitteln:

An error occurred (InvalidArgumentException) when calling the CreateApplication
 operation: An unsupported Kinesis connector version has been detected in the
 application. Please update flink-connector-kinesis to any version equal to or newer
 than 1.15.2.
For more information refer to connector fix: https://issues.apache.org/jira/browse/
FLINK-23528

Schritte zur Behebung

- Aktualisieren Sie die Abhängigkeit der Anwendung von flink-connector-kinesis. Wenn Sie Maven als Build-Tool für Ihr Projekt verwenden, folgen Sie <u>Aktualisieren einer Maven-Abhängigkeit</u>
 - . Wenn Sie Gradle verwenden, folgen Sie Aktualisieren einer Gradle-Abhängigkeit.

- Verpacken Sie die Anwendung erneut.
- Laden Sie sie in einen Amazon-S3-Bucket hoch.
- Reichen Sie die Anfrage zum Erstellen/Aktualisieren der Anwendung erneut mit der überarbeiteten Anwendung ein, die gerade in den Amazon-S3-Bucket hochgeladen wurde.
- Wenn Sie weiterhin dieselbe Fehlermeldung erhalten, überprüfen Sie Ihre Anwendungsabhängigkeiten erneut. Wenn das Problem weiterhin besteht, erstellen Sie bitte ein Support-Ticket.

Aktualisieren einer Maven-Abhängigkeit

- 1. Öffnen Sie die pom. xml des Projekts.
- 2. Finden Sie die Abhängigkeiten des Projekts. Sie sehen etwa so aus:

3. Aktualisieren Sie flink-connector-kinesis auf Version 1.15.2 oder neuer. Zum Beispiel:

```
<project>
```

```
<dependencies>
....
<dependency>
<groupId>org.apache.flink</groupId>
<artifactId>flink-connector-kinesis</artifactId>
<version>1.15.2</version>
</dependency>
....
</dependencies>
....
</project>
```

Aktualisieren einer Gradle-Abhängigkeit

- Öffnen Sie die build.gradle des Projekts (oder build.gradle.kts f
 ür Kotlin-Anwendungen).
- 2. Finden Sie die Abhängigkeiten des Projekts. Sie sehen etwa so aus:



3. Aktualisieren Sie flink-connector-kinesis auf Version 1.15.2 oder neuer. Zum Beispiel:

```
. . .
```

```
dependencies {
    ...
    implementation("org.apache.flink:flink-connector-kinesis:1.15.2")
    ...
}
...
```

Kompilierungsfehler: "Abhängigkeiten für das Projekt konnten nicht aufgelöst werden"

Um die Beispielanwendungen von Managed Service für Apache Flink zu kompilieren, müssen Sie zuerst den Apache-Flink-Kinesis-Konnektor herunterladen, kompilieren und zu Ihrem lokalen Maven-Repository hinzufügen. Wenn der Konnektor nicht zu Ihrem Repository hinzugefügt wurde, wird ein Kompilierungsfehler ähnlich dem folgenden angezeigt:

```
Could not resolve dependencies for project your project name: Failure to find org.apache.flink:flink-connector-kinesis_2.11:jar:1.8.2 in https:// repo.maven.apache.org/maven2 was cached in the local repository, resolution will not be reattempted until the update interval of central has elapsed or updates are forced
```

Um diesen Fehler zu beheben, müssen Sie den Apache Flink-Quellcode (Version 1.8.2 von <u>https://</u><u>flink.apache.org/downloads.html</u>) für den Connector herunterladen. Anweisungen zum Herunterladen, Kompilieren und Installieren des Apache-Flink-Quellcodes finden Sie unter <u>the section called</u> "Verwenden des Apache Flink Kinesis Streams-Konnektor mit früheren Apache Flink-Versionen".

Ungültige Auswahl: "kinesisanalyticsv2"

Um Version 2 der Managed Service für Apache Flink API zu verwenden, benötigen Sie die neueste Version von AWS Command Line Interface (AWS CLI).

Informationen zur Aktualisierung von finden Sie unter <u>Installation von</u> im AWS CLI Benutzerhandbuch. AWS Command Line InterfaceAWS Command Line Interface

UpdateApplication Aktion ist kein erneutes Laden des Anwendungscodes

Die <u>UpdateApplication</u>Aktion lädt den Anwendungscode mit demselben Dateinamen nicht neu, wenn keine S3-Objektversion angegeben ist. Um den Anwendungscode mit demselben Dateinamen neu zu laden, aktivieren Sie die Versionsverwaltung in Ihrem S3-Bucket und geben Sie die neue Objektversion mithilfe des Parameters ObjectVersionUpdate an. Weitere Informationen zur Aktivierung der Objektversionsverwaltung in einem S3-Bucket finden Sie unter <u>Aktivieren oder</u> <u>Deaktivieren der Versionsverwaltung</u>.

S3 StreamingFileSink FileNotFoundExceptions

Anwendungen, die Managed Service für Apache Flink nutzen, können beim Starten von Snapshots auf den Fehler FileNotFoundException einer Teildatei in Bearbeitung stoßen, wenn eine in Bearbeitung befindliche Teildatei fehlt, auf die ihr Savepoint verweist. Wenn dieser Fehlermodus eintritt, ist der Operatorstatus der Anwendung, die Managed Service für Apache Flink nutzt, normalerweise nicht wiederherstellbar und muss ohne Verwendung eines Snapshots mittels SKIP_RESTORE_FROM_SNAPSHOT neu gestartet werden. Sehen Sie sich den folgenden beispielhaften Stacktrace an:

Flink StreamingFileSink schreibt Datensätze in Dateisysteme, die von den <u>Dateisystemen</u> unterstützt werden. Da die eingehenden Streams unbegrenzt sein können, werden die Daten in Teildateien endlicher Größe organisiert, wobei beim Schreiben der Daten neue Dateien hinzugefügt werden. Der Teil-Lebenszyklus und die Rollover-Richtlinie bestimmen den Zeitpunkt, die Größe und die Benennung der Teildateien. Beim Checkpointing und Savepointing (Snapshotting) werden alle ausstehenden Dateien umbenannt und festgeschrieben. Teildateien, die sich in Bearbeitung befinden, werden jedoch nicht festgeschrieben, sondern umbenannt, und ihr Verweis wird in den Checkpoint- oder Savepoint-Metadaten gespeichert, die bei der Wiederherstellung von Aufträgen verwendet werden. Diese Teildateien, die sich in Bearbeitung befinden, werden irgendwann in den Status Ausstehend verschoben, umbenannt und von einem nachfolgenden Checkpoint oder Savepoint festgeschrieben.

Im Folgenden sind die Hauptursachen und Abhilfemaßnahmen für fehlende Teildateien in Bearbeitung aufgeführt:

- Veralteter Snapshot, der zum Starten der Managed Service for Apache Flink-Anwendung verwendet wurde — nur der letzte System-Snapshot, der beim Beenden oder Aktualisieren einer Anwendung erstellt wurde, kann verwendet werden, um eine Managed Service for Apache Flink-Anwendung mit Amazon S3 zu starten. StreamingFileSink Um diese Art von Fehlern zu vermeiden, verwenden Sie den neuesten System-Snapshot.
 - Dies ist beispielsweise der Fall, wenn Sie während des Stopps oder der Aktualisierung einen Snapshot auswählen, der mit CreateSnapshot statt mit einem vom System ausgelösten Snapshot erstellt wurde. Der Savepoint des älteren Snapshots enthält einen out-of-date Verweis auf die in Bearbeitung befindliche Teildatei, die umbenannt und von einem nachfolgenden Checkpoint oder Savepoint übernommen wurde.
 - Dies kann auch passieren, wenn ein vom System ausgelöster Snapshot ausgewählt wird, der nicht beim letzten Anhalten/Aktualisieren-Ereignis ausgelöst wurde.
 Ein Beispiel ist eine Anwendung, bei der der System-Snapshot deaktiviert, aber RESTORE_FROM_LATEST_SNAPSHOT konfiguriert wurde. Im Allgemeinen StreamingFileSink sollte bei Managed Service für Apache Flink-Anwendungen mit Amazon S3 immer der System-Snapshot aktiviert und RESTORE_FROM_LATEST_SNAPSHOT konfiguriert sein.
- Teildatei in Bearbeitung entfernt Da sich die in Bearbeitung befindliche Teildatei in einem S3-Bucket befindet, kann sie von anderen Komponenten oder Akteuren, die Zugriff auf den Bucket haben, entfernt werden.
 - Dies kann passieren, wenn Sie Ihre App zu lange angehalten haben und die Datei "In Bearbeitung", auf die sich der Savepoint Ihrer App bezieht, durch die <u>S3-Bucket-</u> <u>Lebenszyklusrichtlinie</u> entfernt wurde. MultiPartUpload Um diese Art von Fehlern zu vermeiden, stellen Sie sicher, dass Ihre S3-Bucket-MPU-Lebenszyklusrichtlinie einen ausreichend langen Zeitraum für Ihren Anwendungsfall abdeckt.
 - Dies kann auch passieren, wenn die Teildatei in Bearbeitung manuell oder durch eine andere Komponente Ihres Systems entfernt wurde. Um diese Art von Fehlern zu vermeiden, stellen Sie

bitte sicher, dass die in Bearbeitung befindlichen Teildateien nicht von anderen Akteuren oder Komponenten entfernt werden.

- Wettlaufsituation, bei der nach dem Savepoint ein automatisierter Checkpoint ausgelöst wird dies betrifft Versionen von Managed Service f
 ür Apache Flink bis einschlie
 ßlich 1.13. Dieses Problem wurde in Managed Service f
 ür Apache Flink Version 1.15 behoben. Migrieren Sie Ihre Anwendung auf die neueste Version von Managed Service f
 ür Apache Flink, um ein erneutes Auftreten zu verhindern. Wir empfehlen auch die Migration von nach. StreamingFileSink <u>FileSink</u>
 - Wenn Anwendungen angehalten oder aktualisiert werden, löst Managed Service für Apache Flink einen Savepoint aus und hält die Anwendung in zwei Schritten an. Wenn zwischen den beiden Schritten ein automatisierter Checkpoint ausgelöst wird, ist der Savepoint unbrauchbar, da seine in Bearbeitung befindliche Teildatei umbenannt und möglicherweise festgeschrieben würde.

FlinkKafkaConsumer Problem mit Stop with Savepoint

Wenn Sie die FlinkKafkaConsumer Legacy-Version verwenden, besteht die Möglichkeit, dass Ihre Anwendung beim Aktualisieren, Stoppen oder Skalieren hängen bleibt, wenn Sie System-Snapshots aktiviert haben. Für dieses <u>Problem</u> ist kein veröffentlichter Fix verfügbar. Wir empfehlen Ihnen daher, auf das neue Update zu aktualisieren, <u>KafkaSource</u>um dieses Problem zu beheben.

Wenn Sie den FlinkKafkaConsumer mit aktivierten Snapshots verwenden, besteht die Möglichkeit, dass, wenn der Flink-Auftrag eine API-Anfrage vom Typ Anhalten mit Savepoint verarbeitet, der FlinkKafkaConsumer mit einem Laufzeitfehler fehlschlägt und eine ClosedException meldet. Unter diesen Bedingungen bleibt die Flink-Anwendung hängen, was sich als Fehlgeschlagene Checkpoints äußert.

Flink 1.15 Async Sink Deadlock

Es gibt ein <u>bekanntes Problem</u> mit AWS Konnektoren für die Apache AsyncSink Flink-Implementierungsschnittstelle. Dies betrifft Anwendungen, die Flink 1.15 mit den folgenden Konnektoren verwenden:

- Für Java-Anwendungen:
 - KinesisStreamsSink org.apache.flink:flink-connector-kinesis
 - KinesisStreamsSink org.apache.flink:flink-connector-aws-kinesis-streams
 - KinesisFirehoseSink-org.apache.flink:flink-connector-aws-kinesis-firehose

- DynamoDbSink org.apache.flink:flink-connector-dynamodb
- Flink-AnwendungenSQL/TableAPI/Python:
 - kinesis org.apache.flink:flink-sql-connector-kinesis
 - kinesis org.apache.flink:flink-sql-connector-aws-kinesis-streams
 - firehose org.apache.flink:flink-sql-connector-aws-kinesis-firehose
 - dynamodb org.apache.flink:flink-sql-connector-dynamodb

Bei betroffenen Anwendungen treten die folgenden Symptome auf:

- Der Flink-Auftrag befindet sich im RUNNING-Status, verarbeitet aber keine Daten;
- Es gibt keine Auftragsneustarts;
- Bei Checkpoints kommt es zu Zeitüberschreitungen.

Das Problem wird durch einen <u>Fehler</u> im AWS SDK verursacht, der dazu führt, dass dem Aufrufer bestimmte Fehler nicht angezeigt werden, wenn der asynchrone HTTP-Client verwendet wird. Dies führt dazu, dass die Senke während eines Checkpoint-Flush-Vorgangs auf unbestimmte Zeit darauf wartet, dass eine in Übertragung befindliche Anfrage abgeschlossen wird.

Dieses Problem wurde im AWS SDK ab Version 2.20.144 behoben.

Im Folgenden finden Sie Anweisungen zum Aktualisieren der betroffenen Konnektoren, um die neue Version des AWS SDK in Ihren Anwendungen zu verwenden:

Themen

- Aktualisieren der Java-Anwendungen
- Aktualisieren von Python-Anwendungen

Aktualisieren der Java-Anwendungen

Gehen Sie wie folgt vor, um Java-Anwendungen zu aktualisieren:

flink-connector-kinesis

Wenn die Anwendung flink-connector-kinesis verwendet:

Der Kinesis-Konnektor verwendet Shading, um einige Abhängigkeiten, einschließlich des AWS SDK, in das Connector-JAR zu packen. Gehen Sie wie folgt vor, um die AWS SDK-Version zu aktualisieren, um diese schattierten Klassen zu ersetzen:

Maven

- 1. Fügen Sie den Kinesis-Connector und die erforderlichen AWS SDK-Module als Projektabhängigkeiten hinzu.
- 2. Konfigurieren von maven-shade-plugin:
 - a. Fügen Sie einen Filter hinzu, um schattierte AWS SDK-Klassen auszuschließen, wenn der Inhalt der Kinesis-Connector-Jar kopiert wird.
 - b. Fügen Sie eine Relokationsregel hinzu, um aktualisierte AWS SDK-Klassen in das Paket zu verschieben, was vom Kinesis-Connector erwartet wird.

pom.xml

```
<project>
    <dependencies>
        <dependency>
            <groupId>org.apache.flink</groupId>
            <artifactId>flink-connector-kinesis</artifactId>
            <version>1.15.4</version>
        </dependency>
        <dependency>
            <groupId>software.amazon.awssdk</groupId>
            <artifactId>kinesis</artifactId>
            <version>2.20.144</version>
        </dependency>
        <dependency>
            <groupId>software.amazon.awssdk</groupId>
            <artifactId>netty-nio-client</artifactId>
            <version>2.20.144</version>
        </dependency>
        <dependency>
            <groupId>software.amazon.awssdk</groupId>
            <artifactId>sts</artifactId>
            <version>2.20.144</version>
```

```
</dependency>
        . . .
    </dependencies>
    . . .
    <build>
        . . .
        <plugins>
             . . .
            <plugin>
                 <groupId>org.apache.maven.plugins</groupId>
                 <artifactId>maven-shade-plugin</artifactId>
                 <version>3.1.1</version>
                 <executions>
                     <execution>
                         <phase>package</phase>
                         <goals>
                              <goal>shade</goal>
                         </goals>
                         <configuration>
                              . . .
                             <filters>
                                  . . .
                                  <filter>
                                      <artifact>org.apache.flink:flink-connector-
kinesis</artifact>
                                      <excludes>
                                          <exclude>org/apache/flink/kinesis/
shaded/software/amazon/awssdk/**</exclude>
                                          <exclude>org/apache/flink/kinesis/
shaded/org/reactivestreams/**</exclude>
                                          <exclude>org/apache/flink/kinesis/
shaded/io/netty/**</exclude>
                                          <exclude>org/apache/flink/kinesis/
shaded/com/typesafe/netty/**</exclude>
                                      </excludes>
                                  </filter>
                                  . . .
                              </filters>
                              <relocations>
                                  . . .
                                  <relocation>
```

```
<pattern>software.amazon.awssdk</pattern>
```

```
<shadedPattern>org.apache.flink.kinesis.shaded.software.amazon.awssdk
shadedPattern>
                                 </relocation>
                                 <relocation>
                                     <pattern>org.reactivestreams</pattern>
 <shadedPattern>org.apache.flink.kinesis.shaded.org.reactivestreams
shadedPattern>
                                 </relocation>
                                 <relocation>
                                     <pattern>io.netty</pattern>
 <shadedPattern>org.apache.flink.kinesis.shaded.io.netty</shadedPattern>
                                 </relocation>
                                 <relocation>
                                     <pattern>com.typesafe.netty</pattern>
 <shadedPattern>org.apache.flink.kinesis.shaded.com.typesafe.netty<///r>
shadedPattern>
                                 </relocation>
                                 . . .
                             </relocations>
                            . . .
                         </configuration>
                     </execution>
                </executions>
            </plugin>
            . . .
        </plugins>
        . . .
    </build>
</project>
```

Gradle

- 1. Fügen Sie den Kinesis-Connector und die erforderlichen AWS SDK-Module als Projektabhängigkeiten hinzu.
- 2. Anpassen der ShadowJar-Konfiguration:
 - a. Schließt schattierte AWS SDK-Klassen aus, wenn der Inhalt der Kinesis-Connector-Jar kopiert wird.

b. Verschieben Sie aktualisierte AWS SDK-Klassen in ein Paket, das vom Kinesis-Connector erwartet wird.

build.gradle

```
. . .
dependencies {
    . . .
    flinkShadowJar("org.apache.flink:flink-connector-kinesis:1.15.4")
    flinkShadowJar("software.amazon.awssdk:kinesis:2.20.144")
    flinkShadowJar("software.amazon.awssdk:sts:2.20.144")
    flinkShadowJar("software.amazon.awssdk:netty-nio-client:2.20.144")
    . . .
}
. . .
shadowJar {
    configurations = [project.configurations.flinkShadowJar]
    exclude("software/amazon/kinesis/shaded/software/amazon/awssdk/**/*")
    exclude("org/apache/flink/kinesis/shaded/org/reactivestreams/**/*.class")
    exclude("org/apache/flink/kinesis/shaded/io/netty/**/*.class")
    exclude("org/apache/flink/kinesis/shaded/com/typesafe/netty/**/*.class")
    relocate("software.amazon.awssdk",
 "org.apache.flink.kinesis.shaded.software.amazon.awssdk")
    relocate("org.reactivestreams",
 "org.apache.flink.kinesis.shaded.org.reactivestreams")
    relocate("io.netty", "org.apache.flink.kinesis.shaded.io.netty")
    relocate("com.typesafe.netty",
 "org.apache.flink.kinesis.shaded.com.typesafe.netty")
}
. . .
```

Andere betroffene Konnektoren

Wenn die Anwendung einen anderen betroffenen Konnektor verwendet:

Um die AWS SDK-Version zu aktualisieren, sollte die SDK-Version in der Build-Konfiguration des Projekts durchgesetzt werden.

Maven

Fügen Sie die AWS SDK-Stückliste (BOM) zum Abschnitt zur Abhängigkeitsverwaltung der pom.xml Datei hinzu, um die SDK-Version für das Projekt durchzusetzen.

pom.xml

```
<project>
    . . .
    <dependencyManagement>
        <dependencies>
             . . .
            <dependency>
                 <groupId>software.amazon.awssdk</groupId>
                 <artifactId>bom</artifactId>
                 <version>2.20.144</version>
                 <scope>import</scope>
                 <type>pom</type>
            </dependency>
             . . .
        </dependencies>
    </dependencyManagement>
    . . .
</project>
```

Gradle

Fügen Sie die Plattformabhängigkeit zur AWS SDK-Stückliste (BOM) hinzu, um die SDK-Version für das Projekt durchzusetzen. Dies erfordert Gradle 5.0 oder neuer:

build.gradle

```
...
dependencies {
    ...
    flinkShadowJar(platform("software.amazon.awssdk:bom:2.20.144"))
    ...
}
...
```

Aktualisieren von Python-Anwendungen

Python-Anwendungen können Konnektoren auf zwei verschiedene Arten verwenden: Konnektoren und andere Java-Abhängigkeiten als Teil eines einzelnen uber-Jars verpacken oder Konnektor-JAR direkt verwenden. Beheben von Anwendungsproblemen, die durch Async Sink-Deadlock verursacht werden:

- Wenn die Anwendung ein uber-Jar verwendet, folgen Sie den Anweisungen f
 ür <u>Aktualisieren der</u> Java-Anwendungen.
- Gehen Sie wie folgt vor, um Konnektor-Jars aus dem Quellcode neu zu erstellen:

Erstellen von Konnektoren aus dem Quellcode:

Voraussetzungen, ähnlich den Build-Anforderungen von Flink:

- Java 11
- Maven 3.2.5

flink-sql-connector-kinesis

1. Herunterladen des Quellcodes für Flink 1.15.4:

wget https://archive.apache.org/dist/flink/flink-1.15.4/flink-1.15.4-src.tgz

2. Entpacken des Quellcodes:

tar -xvf flink-1.15.4-src.tgz

3. Navigieren Sie zum Kinesis-Konnektor-Verzeichnis

cd flink-1.15.4/flink-connectors/flink-connector-kinesis/

4. Kompilieren und installieren Sie Connector-Jar unter Angabe der erforderlichen AWS SDK-Version. Um den Build zu beschleunigen, verwenden Sie -DskipTests, um die Testausführung zu überspringen, und -Dfast, um zusätzliche Quellcodeprüfungen zu überspringen:

mvn clean install -DskipTests -Dfast -Daws.sdkv2.version=2.20.144

5. Navigieren Sie zum Kinesis-Konnektor-Verzeichnis

cd ../flink-sql-connector-kinesis

6. Kompilieren und installieren Sie SQL-Konnektor-JAR:

mvn clean install -DskipTests -Dfast

7. Das resultierende JAR wird verfügbar sein unter:

target/flink-sql-connector-kinesis-1.15.4.jar

flink-sql-connector-aws-Kinesis-Streams

1. Herunterladen des Quellcodes für Flink 1.15.4:

wget https://archive.apache.org/dist/flink/flink-1.15.4/flink-1.15.4-src.tgz

2. Entpacken des Quellcodes:

tar -xvf flink-1.15.4-src.tgz

3. Navigieren Sie zum Kinesis-Konnektor-Verzeichnis

cd flink-1.15.4/flink-connectors/flink-connector-aws-kinesis-streams/

4. Kompilieren und installieren Sie Connector-JAR unter Angabe der erforderlichen SDK-Version. AWS Um den Build zu beschleunigen, verwenden Sie -DskipTests, um die Testausführung zu überspringen, und -Dfast, um zusätzliche Quellcodeprüfungen zu überspringen:

mvn clean install -DskipTests -Dfast -Daws.sdk.version=2.20.144

5. Navigieren Sie zum Kinesis-Konnektor-Verzeichnis

cd ../flink-sql-connector-aws-kinesis-streams

6. Kompilieren und installieren Sie SQL-Konnektor-JAR:

mvn clean install -DskipTests -Dfast

7. Das resultierende JAR wird verfügbar sein unter:

target/flink-sql-connector-aws-kinesis-streams-1.15.4.jar

flink-sql-connector-aws-Kinesis-Firehose

1. Herunterladen des Quellcodes für Flink 1.15.4:

wget https://archive.apache.org/dist/flink/flink-1.15.4/flink-1.15.4-src.tgz

2. Entpacken des Quellcodes:

tar -xvf flink-1.15.4-src.tgz

3. Navigieren Sie zum Konnektor-Verzeichnis

cd flink-1.15.4/flink-connectors/flink-connector-aws-kinesis-firehose/

4. Kompilieren und installieren Sie das Connector-JAR unter Angabe der erforderlichen SDK-Version. AWS Um den Build zu beschleunigen, verwenden Sie -DskipTests, um die Testausführung zu überspringen, und -Dfast, um zusätzliche Quellcodeprüfungen zu überspringen:

mvn clean install -DskipTests -Dfast -Daws.sdk.version=2.20.144

5. Navigieren Sie zum SQL-Konnektor-Verzeichnis

cd ../flink-sql-connector-aws-kinesis-firehose

6. Kompilieren und installieren Sie SQL-Konnektor-JAR:

mvn clean install -DskipTests -Dfast

7. Das resultierende JAR wird verfügbar sein unter:

target/flink-sql-connector-aws-kinesis-firehose-1.15.4.jar

flink-sql-connector-dynamodb

1. Herunterladen des Quellcodes für Flink 1.15.4:

```
wget https://archive.apache.org/dist/flink/flink-connector-aws-3.0.0/flink-
connector-aws-3.0.0-src.tgz
```

2. Entpacken des Quellcodes:

tar -xvf flink-connector-aws-3.0.0-src.tgz

3. Navigieren Sie zum Konnektor-Verzeichnis

```
cd flink-connector-aws-3.0.0
```

4. Kompilieren und installieren Sie das Connector-JAR unter Angabe der erforderlichen AWS SDK-Version. Um den Build zu beschleunigen, verwenden Sie -DskipTests, um die Testausführung zu überspringen, und -Dfast, um zusätzliche Quellcodeprüfungen zu überspringen:

```
mvn clean install -DskipTests -Dfast -Dflink.version=1.15.4 -
Daws.sdk.version=2.20.144
```

5. Das resultierende JAR wird verfügbar sein unter:

flink-sql-connector-dynamodb/target/flink-sql-connector-dynamodb-3.0.0.jar

Die Quellverarbeitung von Amazon Kinesis Kinesis-Datenstreams ist beim Re-Sharding nicht in der richtigen Reihenfolge

Die aktuelle FlinkKinesisConsumer Implementierung bietet keine starken Ordnungsgarantien zwischen Kinesis-Shards. Dies kann zu einer out-of-order Verarbeitung beim Re-Sharding von Kinesis Stream führen, insbesondere bei Flink-Anwendungen, bei denen es zu Verarbeitungsverzögerungen kommt. Unter bestimmten Umständen, z. B. bei Windows-Operatoren, die auf Ereigniszeiten basieren, können Ereignisse aufgrund der daraus resultierenden Verspätung verworfen werden.



Dies ist ein <u>bekanntes Problem</u> in Open Source Flink. Stellen Sie sicher, dass Ihre Flink-Anwendungen bei der Neupartitionierung nicht hinter Kinesis Data Streams zurückfallen, bis die Fehlerbehebung für den Konnektor verfügbar ist. Indem Sie sicherstellen, dass die Verarbeitungsverzögerung von Ihren Flink-Apps toleriert wird, können Sie die Auswirkungen der outof-order Verarbeitung und das Risiko eines Datenverlusts minimieren.

Häufig gestellte Fragen und Problemlösungen zum Einbetten von Vektoren in Echtzeit

Lesen Sie die folgenden Abschnitte mit häufig gestellten Fragen und zur Fehlerbehebung, um Probleme mit Blueprints zur Vektoreinbettung in Echtzeit zu beheben. Weitere Informationen zu Blueprints zum Einbetten von Vektoren in Echtzeit finden Sie unter Blueprints zum Einbetten von Vektoren in Echtzeit.

Informationen zur allgemeinen Problembehandlung bei Managed Service für Apache Flink-Anwendungen finden Sie unter -runtime.html. https://docs.aws.amazon.com/managed-flink/ latest/ java/troubleshooting

Themen

- Blueprints zum Einbetten von Vektoren in Echtzeit Häufig gestellte Fragen
- Blueprints zum Einbetten von Vektoren in Echtzeit Problembehebung

Blueprints zum Einbetten von Vektoren in Echtzeit — Häufig gestellte Fragen

Lesen Sie die folgenden häufig gestellten Fragen zu Blueprints zum Einbetten von Vektoren in Echtzeit. Weitere Informationen über Blueprints zum Einbetten von Vektoren in Echtzeit finden Sie unter Blueprints zum Einbetten von Vektoren in Echtzeit.

Häufig gestellte Fragen

- Welche AWS Ressourcen werden mit diesem Blueprint erstellt?
- Was sind meine Aktionen, nachdem die AWS CloudFormation Stack-Bereitstellung abgeschlossen ist?
- Wie sollten die Daten in den Amazon MSK-Quellthemen strukturiert sein?
- Kann ich Teile einer Nachricht angeben, die eingebettet werden sollen?
- Kann ich Daten aus mehreren Amazon MSK-Themen lesen?
- Kann ich Regex verwenden, um Amazon MSK-Themennamen zu konfigurieren?
- Was ist die maximale Größe einer Nachricht, die aus einem Amazon MSK-Thema gelesen werden kann?
- Welcher Typ wird unterstützt? OpenSearch
- <u>Warum muss ich eine Vektorsuchsammlung und einen Vektorindex verwenden und meiner</u> OpenSearch serverlosen Sammlung ein Vektorfeld hinzufügen?
- Was sollte ich als Dimension für mein Vektorfeld festlegen?
- Wie sieht die Ausgabe im konfigurierten OpenSearch Index aus?
- Kann ich Metadatenfelder angeben, die dem im OpenSearch Index gespeicherten Dokument hinzugefügt werden sollen?
- Muss ich mit doppelten Einträgen im OpenSearch Index rechnen?
- Kann ich Daten an mehrere OpenSearch Indizes senden?
- Kann ich mehrere Echtzeit-Vektor-Einbettungsanwendungen in einer einzigen bereitstellen? AWS-Konto
- Können mehrere Anwendungen zur Vektoreinbettung in Echtzeit dieselbe Datenquelle oder Datensenke verwenden?
- Unterstützt die Anwendung kontenübergreifende Konnektivität?

- Unterstützt die Anwendung regionsübergreifende Konnektivität?
- Können sich mein Amazon MSK-Cluster und meine OpenSearch Sammlung in verschiedenen VPCs Subnetzen befinden?
- Welche Einbettungsmodelle werden von der Anwendung unterstützt?
- Kann ich die Leistung meiner Anwendung auf der Grundlage meiner Arbeitslast optimieren?
- Welche Amazon MSK-Authentifizierungstypen werden unterstützt?
- Was ist sink.os.bulkFlushIntervalMillis und wie stelle ich es ein?
- Wenn ich meine Managed Service for Apache Flink-Anwendung bereitstelle, ab welchem Punkt im Amazon MSK-Thema beginnt sie, Nachrichten zu lesen?
- Wie verwende ichsource.msk.starting.offset?
- Welche Chunking-Strategien werden unterstützt?
- Wie lese ich Datensätze in meinem Vektordatenspeicher?
- Wo finde ich neue Updates für den Quellcode?
- Kann ich die AWS CloudFormation Vorlage ändern und die Anwendung Managed Service for Apache Flink aktualisieren?
- Wird die Anwendung in meinem Namen AWS überwacht und gewartet?
- Verschiebt diese Anwendung meine Daten außerhalb meiner AWS-Konto?

Welche AWS Ressourcen werden mit diesem Blueprint erstellt?

Um die in Ihrem Konto bereitgestellten Ressourcen zu finden, navigieren Sie zur AWS CloudFormation Konsole und identifizieren Sie den Stack-Namen, der mit dem Namen beginnt, den Sie für Ihre Managed Service for Apache Flink-Anwendung angegeben haben. Wählen Sie die Registerkarte Ressourcen, um die Ressourcen zu überprüfen, die als Teil des Stacks erstellt wurden. Im Folgenden sind die wichtigsten Ressourcen aufgeführt, die der Stack erstellt:

- Managed Service zur Vektoreinbettung in Echtzeit für die Apache Flink-Anwendung
- Amazon S3 S3-Bucket zum Speichern des Quellcodes für die Echtzeit-Vektor-Einbettungsanwendung
- CloudWatch Protokollgruppe und Protokollstream zum Speichern von Protokollen
- Lambda-Funktionen zum Abrufen und Erstellen von Ressourcen
- IAM-Rollen und -Richtlinien f
 ür Lambdas, Managed Service f
 ür die Apache Flink-Anwendung und den Zugriff auf Amazon Bedrock und Amazon Service OpenSearch

- Datenzugriffsrichtlinie für Amazon OpenSearch Service
- VPC-Endpunkte für den Zugriff auf Amazon Bedrock und Amazon Service OpenSearch

Was sind meine Aktionen, nachdem die AWS CloudFormation Stack-Bereitstellung abgeschlossen ist?

Rufen Sie nach Abschluss der AWS CloudFormation Stack-Bereitstellung die Managed Service for Apache Flink-Konsole auf und suchen Sie nach Ihrer Blueprint-Anwendung Managed Service for Apache Flink. Wählen Sie die Registerkarte "Konfigurieren" und vergewissern Sie sich, dass alle Runtime-Eigenschaften korrekt eingerichtet sind. Sie werden möglicherweise zur nächsten Seite weitergeleitet. Wenn Sie mit den Einstellungen vertraut sind, wählen Sie Ausführen. Die Anwendung beginnt, Nachrichten aus Ihrem Thema aufzunehmen.

Informationen zur Suche nach neuen Versionen finden Sie unter <u>https://github.com/awslabs/real-time-vectorization-of-streaming-data/releases</u>.

Wie sollten die Daten in den Amazon MSK-Quellthemen strukturiert sein?

Wir unterstützen derzeit strukturierte und unstrukturierte Quelldaten.

- Unstrukturierte Daten werden mit in gekennzeichnet. STRING source.msk.data.type Die Daten werden so gelesen, wie sie aus der eingehenden Nachricht stammen.
- Wir unterstützen derzeit strukturierte JSON-Daten, die mit in gekennzeichnet JSON sind. source.msk.data.type Die Daten müssen immer im JSON-Format vorliegen. Wenn die Anwendung ein falsch formatiertes JSON empfängt, schlägt die Anwendung fehl.
- Wenn Sie JSON als Quelldatentyp verwenden, stellen Sie sicher, dass jede Nachricht in allen Quellthemen ein gültiges JSON ist. Wenn Sie mit dieser Einstellung ein oder mehrere Themen abonnieren, die keine JSON-Objekte enthalten, schlägt die Anwendung fehl. Wenn ein oder mehrere Themen eine Mischung aus strukturierten und unstrukturierten Daten enthalten, empfehlen wir, die Quelldaten in der Anwendung Managed Service for Apache Flink als unstrukturiert zu konfigurieren.

Kann ich Teile einer Nachricht angeben, die eingebettet werden sollen?

• Wo sind unstrukturierte Eingabedatensource.msk.data.type? STRING Die Anwendung bettet immer die gesamte Nachricht ein und speichert die gesamte Nachricht im konfigurierten OpenSearch Index.

 Bei strukturierten Eingabedaten (where source.msk.data.type is) können Sie so konfigurierenJSON, embed.input.config.json.fieldsToEmbed dass angegeben wird, welches Feld im JSON-Objekt für die Einbettung ausgewählt werden soll. Dies funktioniert nur für JSON-Felder der obersten Ebene und nicht für verschachtelte Nachrichten JSONs und für Nachrichten, die ein JSON-Array enthalten. Verwenden Sie .*, um das gesamte JSON einzubetten.

Kann ich Daten aus mehreren Amazon MSK-Themen lesen?

Ja, mit dieser Anwendung können Sie Daten aus mehreren Amazon MSK-Themen lesen. Daten aus allen Themen müssen vom gleichen Typ sein (entweder STRING oder JSON). Andernfalls kann die Anwendung fehlschlagen. Daten aus allen Themen werden immer in einem einzigen OpenSearch Index gespeichert.

Kann ich Regex verwenden, um Amazon MSK-Themennamen zu konfigurieren?

source.msk.topic.namesunterstützt keine Liste von Regex. Wir unterstützen entweder eine durch Kommas getrennte Liste von Themennamen oder reguläre Ausdrücke, um alle Themen .* einzubeziehen.

Was ist die maximale Größe einer Nachricht, die aus einem Amazon MSK-Thema gelesen werden kann?

Die maximale Größe einer Nachricht, die verarbeitet werden kann, ist durch das Amazon InvokeModel Bedrock-Textlimit begrenzt, das derzeit auf 25.000.000 festgelegt ist. Weitere Informationen finden Sie unter InvokeModel.

Welcher Typ wird unterstützt? OpenSearch

Wir unterstützen sowohl OpenSearch Domains als auch Sammlungen. Wenn Sie eine OpenSearch Sammlung verwenden, stellen Sie sicher, dass Sie eine Vektorsammlung verwenden, und erstellen Sie einen Vektorindex, der für diese Anwendung verwendet werden soll. Auf diese Weise können Sie die Funktionen der OpenSearch Vektordatenbank für die Abfrage Ihrer Daten verwenden. Weitere Informationen finden Sie unter Erläuterung der Vektordatenbankfunktionen von Amazon OpenSearch Service.

Warum muss ich eine Vektorsuchsammlung und einen Vektorindex verwenden und meiner OpenSearch serverlosen Sammlung ein Vektorfeld hinzufügen?

Der Sammlungstyp der Vektorsuche in OpenSearch Serverless bietet eine skalierbare und leistungsstarke Ähnlichkeitssuche. Es vereinfacht die Entwicklung moderner, erweiterter

Sucherlebnisse für maschinelles Lernen (ML) und generativer Anwendungen für künstliche Intelligenz (KI). Weitere Informationen finden Sie unter Arbeiten mit Sammlungen zur Vektorsuche.

Was sollte ich als Dimension für mein Vektorfeld festlegen?

Stellen Sie die Dimension des Vektorfeldes auf der Grundlage des Einbettungsmodells ein, das Sie verwenden möchten. Sehen Sie sich die folgende Tabelle an und bestätigen Sie diese Werte aus der jeweiligen Dokumentation.

Abmessungen des Vektorfeldes

Modellname zum Einbetten von Amazon Bedrock-Vektoren	Das Modell bietet Unterstützung für Ausgabedi mensionen
Amazon Titan Texteinbettungen V1	1 536
Amazon Titan Texteinbettungen V2	1.024 (Standard), 384, 256
Amazon Titan Multimodal Embeddings G1	1.024 (Standard), 384, 256
Cohere Embed English	1,024
Cohere Embed Multilingual	1,024

Wie sieht die Ausgabe im konfigurierten OpenSearch Index aus?

Jedes Dokument im OpenSearch Index enthält folgende Felder:

 original_data: Die Daten, die zur Generierung von Einbettungen verwendet wurden. Beim Typ STRING ist es die gesamte Nachricht. Bei JSON-Objekten ist es das JSON-Objekt, das für Einbettungen verwendet wurde. Es kann sich um das gesamte JSON in der Nachricht oder um bestimmte Felder im JSON handeln. Wenn der Name beispielsweise so ausgewählt wurde, dass er in eingehende Nachrichten eingebettet werden soll, würde die Ausgabe wie folgt aussehen:

"original_data": "{\"name\":\"John Doe\"}"

- embedded_data: Ein Vektor-Float-Array von Einbettungen, die von Amazon Bedrock generiert wurden
- Datum: UTC-Zeitstempel, in dem das Dokument gespeichert wurde OpenSearch

Kann ich Metadatenfelder angeben, die dem im OpenSearch Index gespeicherten Dokument hinzugefügt werden sollen?

Nein, derzeit unterstützen wir nicht das Hinzufügen zusätzlicher Felder zum endgültigen, im OpenSearch Index gespeicherten Dokument.

Muss ich mit doppelten Einträgen im OpenSearch Index rechnen?

Je nachdem, wie Sie Ihre Anwendung konfiguriert haben, werden möglicherweise doppelte Nachrichten im Index angezeigt. Ein häufiger Grund ist der Neustart der Anwendung. Die Anwendung ist standardmäßig so konfiguriert, dass sie ab der ersten Nachricht im Quellthema mit dem Lesen beginnt. Wenn Sie die Konfiguration ändern, wird die Anwendung neu gestartet und verarbeitet alle Nachrichten im Thema erneut. Informationen zur Vermeidung einer erneuten Verarbeitung finden Sie unter <u>Wie verwende ich</u> source.msk.starting.offset? und stellen Sie den Start-Offset für Ihre Anwendung korrekt ein.

Kann ich Daten an mehrere OpenSearch Indizes senden?

Nein, die Anwendung unterstützt das Speichern von Daten in einem einzigen OpenSearch Index. Um die Vektorisierungsausgabe für mehrere Indizes einzurichten, müssen Sie einen separaten Managed Service für Apache Flink-Anwendungen bereitstellen.

Kann ich mehrere Echtzeit-Vektor-Einbettungsanwendungen in einer einzigen bereitstellen? AWS-Konto

Ja, Sie können mehrere Managed Service für Apache Flink-Anwendungen zur Echtzeit-Vektoreinbettung in einer einzigen Anwendung bereitstellen, AWS-Konto sofern jede Anwendung einen eindeutigen Namen hat.

Können mehrere Anwendungen zur Vektoreinbettung in Echtzeit dieselbe Datenquelle oder Datensenke verwenden?

Ja, Sie können mehrere Managed Services für Apache Flink-Anwendungen zur Echtzeit-Vektoreinbettung erstellen, die Daten aus demselben Thema lesen oder Daten im selben Index speichern.

Unterstützt die Anwendung kontenübergreifende Konnektivität?

Nein, damit die Anwendung erfolgreich ausgeführt werden kann, müssen sich der Amazon MSK-Cluster und die OpenSearch Sammlung dort befinden, AWS-Konto wo Sie versuchen, Ihre Managed Service for Apache Flink-Anwendung einzurichten. Unterstützt die Anwendung regionsübergreifende Konnektivität?

Nein, mit der Anwendung können Sie nur eine Managed Service for Apache Flink-Anwendung mit einem Amazon MSK-Cluster und einer OpenSearch Sammlung in derselben Region wie die Managed Service for Apache Flink-Anwendung bereitstellen.

Können sich mein Amazon MSK-Cluster und meine OpenSearch Sammlung in verschiedenen VPCs Subnetzen befinden?

Ja, wir unterstützen Amazon MSK-Cluster und OpenSearch -Sammlung in verschiedenen VPCs Subnetzen, sofern sie sich in denselben befinden. AWS-Konto Weitere Informationen finden Sie unter (Allgemeine MSF-Fehlerbehebung), um sicherzustellen, dass Ihre Einrichtung korrekt ist.

Welche Einbettungsmodelle werden von der Anwendung unterstützt?

Derzeit unterstützt die Anwendung alle Modelle, die von Bedrock unterstützt werden. Dazu zählen:

- Amazon Titan Embeddings G1 Text
- Amazon Titan Texteinbettungen V2
- Amazon Titan Multimodal Embeddings G1
- Cohere Embed English
- Cohere Embed Multilingual

Kann ich die Leistung meiner Anwendung auf der Grundlage meiner Arbeitslast optimieren?

Ja. Der Durchsatz der Anwendung hängt von einer Reihe von Faktoren ab, die alle von den Kunden gesteuert werden können:

- AWS MSF KPUs: Die Anwendung wird mit dem Standard-Parallelitätsfaktor 2 und Parallelität pro KPU 1 bereitgestellt, wobei die automatische Skalierung aktiviert ist. Wir empfehlen jedoch, die Skalierung für die Anwendung Managed Service for Apache Flink entsprechend Ihren Workloads zu konfigurieren. Weitere Informationen finden Sie unter <u>Überprüfen der Anwendungsressourcen</u> für Managed Service für Apache Flink.
- Amazon Bedrock: Je nach dem ausgewählten Amazon Bedrock On-Demand-Modell können unterschiedliche Kontingente gelten. Sehen Sie sich die Service-Kontingente in Bedrock an, um zu sehen, welche Arbeitslast der Service bewältigen kann. Weitere Informationen finden Sie unter Kontingente für Amazon Bedrock.

3. Amazon OpenSearch Service: Darüber hinaus stellen Sie in einigen Situationen möglicherweise fest, dass dies der Engpass in Ihrer Pipeline OpenSearch ist. Informationen zur Skalierung finden Sie unter OpenSearch Skalierung der Größe von Amazon OpenSearch Service-Domains.

Welche Amazon MSK-Authentifizierungstypen werden unterstützt?

Wir unterstützen nur den Authentifizierungstyp IAM MSK.

Was ist sink.os.bulkFlushIntervalMillis und wie stelle ich es ein?

Beim Senden von Daten an Amazon OpenSearch Service ist das Bulk-Flush-Intervall das Intervall, in dem die Bulk-Anfrage ausgeführt wird, unabhängig von der Anzahl der Aktionen oder der Größe der Anfrage. Der Standardwert ist auf 1 Millisekunde festgelegt.

Die Festlegung eines Aktualisierungsintervalls kann zwar dazu beitragen, sicherzustellen, dass Daten rechtzeitig indexiert werden, kann aber auch zu einem erhöhten Overhead führen, wenn es zu niedrig eingestellt ist. Berücksichtigen Sie bei der Auswahl eines Aktualisierungsintervalls Ihren Anwendungsfall und die Bedeutung einer zeitnahen Indizierung.

Wenn ich meine Managed Service for Apache Flink-Anwendung bereitstelle, ab welchem Punkt im Amazon MSK-Thema beginnt sie, Nachrichten zu lesen?

Die Anwendung beginnt mit dem Lesen von Nachrichten aus dem Amazon MSK-Thema an dem Offset, das durch die in der source.msk.starting.offset Laufzeitkonfiguration der Anwendung festgelegte Konfiguration festgelegt wurde. Wenn dies nicht explizit festgelegt source.msk.starting.offset ist, beginnt die Anwendung standardmäßig mit dem Lesen ab der frühesten verfügbaren Nachricht im Thema.

Wie verwende ichsource.msk.starting.offset?

Setzt s je ource.msk.starting.offset nach gewünschtem Verhalten explizit auf einen der folgenden Werte:

- FRÜHEST: Die Standardeinstellung, bei der vom ältesten Offset in der Partition ausgegangen wird. Dies ist vor allem dann eine gute Wahl, wenn:
 - Sie haben neu Amazon MSK-Themen und Verbraucheranwendungen erstellt.
 - Sie müssen Daten erneut abspielen, damit Sie den Status erstellen oder rekonstruieren können. Dies ist relevant, wenn Sie das Muster für die Ereignisbeschaffung implementieren oder wenn
Sie einen neuen Service initialisieren, für den eine vollständige Ansicht des Datenverlaufs erforderlich ist.

- AKTUELL: Die Anwendung Managed Service for Apache Flink liest Nachrichten vom Ende der Partition. Wir empfehlen diese Option, wenn Sie nur daran interessiert sind, dass neue Nachrichten erstellt werden, und wenn Sie keine historischen Daten verarbeiten müssen. In dieser Einstellung ignoriert der Verbraucher die vorhandenen Nachrichten und liest nur neue Nachrichten, die vom ursprünglichen Hersteller veröffentlicht wurden.
- COMMITTED: Die Anwendung Managed Service for Apache Flink beginnt, Nachrichten aus dem festgeschriebenen Offset der konsumierenden Gruppe zu konsumieren. Wenn der festgeschriebene Offset nicht existiert, wird die EARLEOST-Reset-Strategie verwendet.

Welche Chunking-Strategien werden unterstützt?

Wir verwenden die Langchain-Bibliothek, um Eingaben zu teilen. Das Chunking wird nur angewendet, wenn die Länge der Eingabe größer als die gewählte ist. maxSegmentSizeInChars Wir unterstützen die folgenden fünf Chunking-Typen:

- SPLIT_BY_CHARACTER: Passt so viele Zeichen wie möglich in jeden Chunk, wobei die Länge jedes Chunks nicht größer als ist. maxSegmentSize InChars Leerzeichen sind ihm egal, daher können Wörter abgeschnitten werden.
- SPLIT_BY_WORD: Findet Leerzeichen zum Abteilen. Es werden keine Wörter abgeschnitten.
- SPLIT_BY_SENTENCE: Satzgrenzen werden mithilfe der Apache OpenNLP-Bibliothek mit dem englischen Satzmodell erkannt.
- SPLIT_BY_LINE: Findet neue Zeilenzeichen zum Abteilen.
- SPLIT_BY_PARAGRAPH: Findet aufeinanderfolgende neue Zeilenzeichen, nach denen aufgeteilt werden kann.

Bei den Splitting-Strategien wird auf die vorherige Reihenfolge zurückgegriffen, während bei den größeren Chunking-Strategien eher SPLIT_BY_PARAGRAPH zurückgegriffen wird. SPLIT_BY_CHARACTER Wenn beispielsweise eine Zeile zu lang istSPLIT_BY_LINE, wird die Zeile satzweise unterteilt, wobei jeder Abschnitt in so viele Sätze wie möglich passt. Wenn es Sätze gibt, die zu lang sind, werden sie auf Wortebene aufgeteilt. Wenn ein Wort zu lang ist, wird es nach Zeichen aufgeteilt. Wie lese ich Datensätze in meinem Vektordatenspeicher?

- 1. Wann ist source.msk.data.type STRING
 - original_data: Die gesamte ursprüngliche Zeichenfolge aus der Amazon MSK-Nachricht.
 - embedded_data: Einbettungsvektor, der erstellt wurde, chunk_data wenn er nicht leer ist (Chunking angewendet), oder der erstellt wurde, wenn kein Chunking angewendet wurde. original_data
 - chunk_data: Nur vorhanden, wenn die Originaldaten aufgeteilt wurden. Enthält den Teil der ursprünglichen Nachricht, der zur Erstellung der Einbettung in verwendet wurde. embedded_data
- 2. Wann ist source.msk.data.type JSON
 - original_data: Das gesamte ursprüngliche JSON aus der Amazon MSK-Nachricht, nachdem die JSON-Schlüsselfilterung angewendet wurde.
 - embedded_data: Einbettungsvektor, der erstellt wurde, chunk_data wenn er nicht leer ist (Chunking angewendet), oder erstellt, wenn kein Chunking angewendet wurde. original_data
 - chunk_key: Nur vorhanden, wenn die Originaldaten aufgeteilt wurden. Enthält den JSON-Schlüssel, aus dem der Chunk stammt. original_data Zum Beispiel kann es wie jsonKey1.nestedJsonKeyA bei verschachtelten Schlüsseln oder Metadaten aussehen. original_data
 - chunk_data: Nur vorhanden, wenn die Originaldaten aufgeteilt wurden. Enthält den Teil der ursprünglichen Nachricht, der zur Erstellung der Einbettung in verwendet wurde. embedded_data

Ja, mit dieser Anwendung können Sie Daten aus mehreren Amazon MSK-Themen lesen. Daten aus allen Themen müssen vom gleichen Typ sein (entweder STRING oder JSON). Andernfalls kann die Anwendung fehlschlagen. Daten aus allen Themen werden immer in einem einzigen OpenSearch Index gespeichert.

Wo finde ich neue Updates für den Quellcode?

Gehe zu https://github.com/awslabs/real-time-vectorization-of-streaming-data/releases, um nach neuen Versionen zu suchen.

Kann ich die AWS CloudFormation Vorlage ändern und die Anwendung Managed Service for Apache Flink aktualisieren?

Nein, durch eine Änderung an der AWS CloudFormation Vorlage wird die Anwendung Managed Service for Apache Flink nicht aktualisiert. Jede neue Änderung AWS CloudFormation bedeutet, dass ein neuer Stack bereitgestellt werden muss.

Wird die Anwendung in meinem Namen AWS überwacht und gewartet?

Nein, AWS ich werde diese Anwendung nicht in Ihrem Namen überwachen, skalieren, aktualisieren oder patchen.

Verschiebt diese Anwendung meine Daten außerhalb meiner AWS-Konto?

Alle Daten, die von der Anwendung Managed Service for Apache Flink gelesen und gespeichert werden, verbleiben in Ihrem Konto AWS-Konto und verlassen Ihr Konto niemals.

Blueprints zum Einbetten von Vektoren in Echtzeit — Problembehebung

Lesen Sie die folgenden Themen zur Problembehebung zu Blueprints für das Einbetten von Vektoren in Echtzeit. Weitere Informationen zu Blueprints zum Einbetten von Vektoren in Echtzeit finden Sie unter Blueprints zum Einbetten von Vektoren <u>in Echtzeit</u>.

Themen zur Fehlerbehebung

- Meine CloudFormation Stack-Bereitstellung ist fehlgeschlagen oder wurde rückgängig gemacht.
 Was kann ich tun, um das Problem zu beheben?
- Ich möchte nicht, dass meine Anwendung ab dem Beginn der Amazon MSK-Themen Nachrichten liest. Was soll ich tun?
- Woher weiß ich, ob es ein Problem mit meiner Managed Service for Apache Flink-Anwendung gibt, und wie kann ich es debuggen?
- <u>Was sind die wichtigsten Kennzahlen, die ich für meine Managed Service for Apache Flink-</u> Anwendung überwachen sollte?

Meine CloudFormation Stack-Bereitstellung ist fehlgeschlagen oder wurde rückgängig gemacht. Was kann ich tun, um das Problem zu beheben?

• Gehen Sie zu Ihrem CFN-Stack und finden Sie den Grund für den Stack-Ausfall. Dies könnte unter anderem mit fehlenden Berechtigungen und Kollisionen bei AWS Ressourcennamen

zusammenhängen. Korrigieren Sie die Hauptursache des Bereitstellungsfehlers. Weitere Informationen finden Sie in der Anleitung CloudWatch zur Fehlerbehebung.

- [Optional] Es kann nur einen VPC-Endpunkt pro Service pro VPC geben. Wenn Sie mehrere Echtzeit-Vektoreinbettungs-Blueprints zum Schreiben in die Amazon OpenSearch Service-Sammlungen in derselben VPC bereitgestellt haben, teilen sich diese möglicherweise VPC-Endpunkte. Diese sind entweder bereits in Ihrem Konto für die VPC vorhanden, oder der erste Blueprint-Stack zur Vektoreinbettung in Echtzeit erstellt VPC-Endpunkte für Amazon Bedrock und Amazon OpenSearch Service, die von allen anderen in Ihrem Konto bereitgestellten Stacks verwendet werden. Wenn ein Stack ausfällt, überprüfen Sie, ob dieser Stack VPC-Endpunkte für Amazon Bedrock und Amazon OpenSearch Service erstellt hat, und löschen Sie sie, wenn sie an keiner anderen Stelle in Ihrem Konto verwendet werden. Schritte zum Löschen von VPC-Endpoints finden Sie unter Wie lösche ich meine Anwendung sicher? (löschen).
- Möglicherweise gibt es andere Dienste oder Anwendungen in Ihrem Konto, die den VPC-Endpunkt verwenden. Wenn Sie ihn löschen, kann dies zu Netzwerkunterbrechungen für andere Dienste führen. Gehen Sie beim Löschen dieser Endpunkte vorsichtig vor.

Ich möchte nicht, dass meine Anwendung ab dem Beginn der Amazon MSK-Themen Nachrichten liest. Was soll ich tun?

Je source.msk.starting.offset nach gewünschtem Verhalten müssen Sie explizit einen der folgenden Werte angeben:

- · Frühester Offset: Der älteste Offset in der Partition.
- Letzter Offset: Verbraucher werden Nachrichten vom Ende der Partition lesen.
- Offset festgeschrieben: Liest aus der letzten Nachricht, die der Verbraucher innerhalb einer Partition verarbeitet hat.

Woher weiß ich, ob es ein Problem mit meiner Managed Service for Apache Flink-Anwendung gibt, und wie kann ich es debuggen?

Verwenden Sie den Leitfaden zur Fehlerbehebung bei Managed Service for Apache Flink, um Probleme im Zusammenhang mit Managed Service for Apache Flink mit Ihrer Anwendung zu debuggen. Was sind die wichtigsten Kennzahlen, die ich für meine Managed Service for Apache Flink-Anwendung überwachen sollte?

- Alle Metriken, die f
 ür eine regul
 äre Managed Service for Apache Flink-Anwendung verf
 ügbar sind, k
 önnen Ihnen bei der
 Überwachung Ihrer Anwendung helfen. Weitere Informationen finden Sie unter Metriken und Dimensionen in Managed Service f
 ür Apache Flink.
- Informationen zur Überwachung der Amazon Bedrock-Metriken finden Sie unter <u>CloudWatch</u> <u>Amazon-Metriken für Amazon Bedrock</u>.
- Wir haben zwei neue Metriken zur Leistungsüberwachung bei der Generierung von Einbettungen hinzugefügt. Sie finden sie unter dem Namen der EmbeddingGeneration Operation in. CloudWatch Die beiden Metriken sind:
 - BedrockTitanEmbeddingTokenCount: Anzahl der Token, die in einer einzigen Anfrage an Amazon Bedrock vorhanden sind.
 - BedrockEmbeddingGenerationLatencyMs: Gibt die Zeit in Millisekunden an, die benötigt wurde, um eine Antwort von Amazon Bedrock zu senden und zu empfangen, um Einbettungen zu generieren.
- Für serverlose Sammlungen von Amazon OpenSearch Service können Sie Metriken wie IngestionDataRate IngestionDocumentErrors und andere verwenden. Weitere Informationen finden Sie unter <u>OpenSearch Serverless Monitoring with Amazon CloudWatch</u>.
- OpenSearch Bereitgestellte Metriken finden Sie unter <u>Überwachen von OpenSearch Cluster-</u> Metriken mit Amazon CloudWatch.

Fehlerbehebung während der Laufzeit

Dieser Abschnitt enthält Informationen zum Diagnostizieren und Beheben von Laufzeitproblemen mit Ihrer Anwendung, die Managed Service für Apache Flink nutzt.

Themen

- Tools zur Fehlerbehebung
- Probleme mit der Anwendung
- Die Anwendung wird neu gestartet
- Der Durchsatz ist zu langsam
- Unbegrenztes Staatswachstum
- E/A-gebundene Operatoren

- Upstream- oder Quelldrosselung aus einem Kinesis-Datenstrom
- Checkpoints
- Beim Checkpointing kommt es zu einer Zeitüberschreitung
- Checkpoint-Fehler für Apache-Beam-Anwendung
- Gegendruck
- Verzerrte Datenverteilung
- Zustandsverzerrung
- Integrieren Sie Ressourcen in verschiedenen Regionen

Tools zur Fehlerbehebung

Das wichtigste Tool zur Erkennung von Anwendungsproblemen sind CloudWatch Alarme. Mithilfe von CloudWatch Alarmen können Sie Schwellenwerte für CloudWatch Messwerte festlegen, die auf Fehler oder Engpässe in Ihrer Anwendung hinweisen. Informationen zu empfohlenen CloudWatch Alarmen finden Sie unter. <u>Verwenden Sie CloudWatch Alarme mit Amazon Managed Service für Apache Flink</u>

Probleme mit der Anwendung

Dieser Abschnitt enthält Lösungen für Fehlerbedingungen, die bei Ihrer Anwendung, die Managed Service für Apache Flink nutzt, auftreten können.

Themen

- Die Anwendung steckt in einem vorübergehenden Status fest
- Die Erstellung eines Snapshots schlägt feh
- Auf Ressourcen in einer VPC kann nicht zugegriffen werden
- Beim Schreiben in einen Amazon S3 S3-Bucket gehen Daten verloren
- Die Anwendung befindet sich im Status RUNNING, verarbeitet aber keine Daten
- <u>Fehler beim Snapshot, beim Anwendungsupdate oder beim Beenden der Anwendung:</u> InvalidApplicationConfigurationException
- java.nio.file. NoSuchFileException:/usr/local/openjdk-8/lib/security/cacerts

Die Anwendung steckt in einem vorübergehenden Status fest

Wenn sich Ihre Anwendung in einem vorübergehenden Status (STARTING,UPDATING, oderAUTOSCALING) befindetSTOPPING, können Sie Ihre Anwendung beenden, indem Sie die <u>StopApplication</u>Aktion mit dem Force Parameter auf beenden. true Sie können das Beenden einer Anwendung im Status DELETING nicht erzwingen. Wenn sich die Anwendung im Status UPDATING oder AUTOSCALING befindet, können Sie sie alternativ auf die vorherige laufende Version zurücksetzen. Wenn Sie ein Rollback einer Anwendung durchführen, werden Statusdaten aus dem letzten erfolgreichen Snapshot geladen. Wenn die Anwendung keine Snapshots hat, lehnt Managed Service für Apache Flink die Rollback-Anfrage ab. Weitere Informationen zum Zurücksetzen einer Anwendung finden Sie unter RollbackApplicationAktion.

1 Note

Das erzwungene Beenden Ihrer Anwendung kann zu Datenverlust oder -duplizierung führen. Um Datenverlust oder doppelte Verarbeitung von Daten bei Anwendungsneustarts zu verhindern, empfehlen wir Ihnen, regelmäßig Snapshots Ihrer Anwendung zu erstellen.

Ursachen für hängengebliebene Anwendungen sind unter anderem:

- Anwendungszustand ist zu groß: Ein zu großer oder zu persistenter Anwendungszustand kann dazu führen, dass die Anwendung während eines Checkpoint- oder Snapshot-Vorgangs hängen bleibt. Überprüfen Sie die Metriken lastCheckpointDuration und lastCheckpointSize Ihrer Anwendung auf stetig steigende Werte oder ungewöhnlich hohe Werte.
- Anwendungscode ist zu groß: Stellen Sie sicher, dass die JAR-Datei Ihrer Anwendung kleiner als 512 MB ist. JAR-Dateien, die größer als 512 MB sind, werden nicht unterstützt.
- Erstellung eines Anwendungs-Snapshots schlägt fehl: Managed Service für Apache Flink erstellt während einer <u>UpdateApplication</u>- oder <u>StopApplication</u>-Anfrage einen Snapshot der Anwendung. Der Service verwendet dann diesen Snapshot-Status und stellt die Anwendung mithilfe der aktualisierten Anwendungskonfiguration wieder her, um exakt einmal eine Verarbeitungssemantik bereitzustellen. Falls die automatische Snapshot-Erstellung fehlschlägt, finden Sie im Folgenden unter <u>Die Erstellung eines Snapshots schlägt feh</u> weitere Informationen.
- Wiederherstellung aus einem Snapshot schlägt fehl: Wenn Sie einen Operator in einem Anwendungsupdate entfernen oder ändern und versuchen, eine Wiederherstellung aus einem Snapshot durchzuführen, schlägt die Wiederherstellung standardmäßig fehl, wenn der Snapshot Zustandsdaten für den fehlenden Operator enthält. Darüber hinaus bleibt die Anwendung entweder

im Status STOPPED oder UPDATING hängen. Um dieses Verhalten zu ändern und sicherzustellen, dass die Wiederherstellung erfolgreich ist, ändern Sie den AllowNonRestoredStateParameter der Anwendung <u>FlinkRunConfiguration</u>auftrue. Dadurch können beim Wiederaufnahmevorgang Zustandsdaten übersprungen werden, die dem neuen Programm nicht zugeordnet werden können.

 Anwendungsinitialisierung dauert länger: Managed Service für Apache Flink verwendet ein internes Timeout von 5 Minuten (Soft-Einstellung), während auf den Start eines Flink-Auftrags gewartet wird. Wenn Ihr Job innerhalb dieses Timeouts nicht gestartet werden kann, wird ein CloudWatch Protokoll wie folgt angezeigt:

Flink job did not start within a total timeout of 5 minutes for application: %s under account: %s

Wenn Sie auf den oben genannten Fehler stoßen, bedeutet dies, dass Ihre mit der main-Methode des Flink-Auftrags definierten Operationen mehr als 5 Minuten dauern, was zu einem Timeout bei der Erstellung des Flink-Auftrags auf der Seite von Managed Service für Apache Flink führt. Wir empfehlen Ihnen, sowohl die JobManagerFlink-Logs als auch Ihren Anwendungscode zu überprüfen, um festzustellen, ob mit dieser Verzögerung bei der main Methode zu rechnen ist. Wenn nicht, müssen Sie Maßnahmen ergreifen, um das Problem zu beheben, damit sie in weniger als 5 Minuten abgeschlossen wird.

Sie können den Status Ihrer Anwendung mithilfe der <u>ListApplications</u>- oder der DescribeApplication-Aktion überprüfen.

Die Erstellung eines Snapshots schlägt feh

Der Service von Managed Service für Apache Flink kann unter den folgenden Umständen keinen Snapshot erstellen:

- Die Anwendung hat das Snapshot-Limit überschritten. Das Limit für Snapshots ist 1 000. Weitere Informationen finden Sie unter <u>Anwendungs-Backups mithilfe von Snapshots verwalten</u>.
- Die Anwendung ist nicht berechtigt, auf ihre Quelle oder Senke zuzugreifen.
- Der Anwendungscode funktioniert nicht richtig.
- Bei der Anwendung treten andere Konfigurationsprobleme auf.

Wenn beim Erstellen eines Snapshots während eines Anwendungsupdates oder beim Beenden der Anwendung eine Ausnahme auftritt, setzen Sie die SnapshotsEnabled-Eigenschaft der

<u>ApplicationSnapshotConfiguration</u> Ihrer Anwendung auf false und wiederholen Sie die Anfrage.

Snapshots können fehlschlagen, wenn die Operatoren Ihrer Anwendung nicht ordnungsgemäß bereitgestellt werden. Informationen zur Optimierung der Operatorleistung finden Sie unter Operatorenskalierung.

Wenn die Anwendung wieder in einen fehlerfreien Zustand zurückkehrt, empfehlen wir, die SnapshotsEnabled-Eigenschaft Ihrer Anwendung auf true zu setzen.

Auf Ressourcen in einer VPC kann nicht zugegriffen werden

Wenn Ihre Anwendung eine VPC verwendet, die auf Amazon VPC läuft, gehen Sie wie folgt vor, um zu überprüfen, ob Ihre Anwendung Zugriff auf ihre Ressourcen hat:

• Überprüfen Sie Ihre CloudWatch Protokolle auf den folgenden Fehler. Dieser Fehler weist darauf hin, dass Ihre Anwendung nicht auf Ressourcen in Ihrer VPC zugreifen kann:

org.apache.kafka.common.errors.TimeoutException: Failed to update metadata after 60000 ms.

Wenn Sie diesen Fehler sehen, überprüfen Sie, ob Ihre Routing-Tabellen korrekt eingerichtet sind und ob Ihre Konnektoren die richtigen Verbindungseinstellungen haben.

Informationen zum Einrichten und Analysieren von CloudWatch Protokollen finden Sie unterProtokollierung und Überwachung in Amazon Managed Service für Apache Flink.

Beim Schreiben in einen Amazon S3 S3-Bucket gehen Daten verloren

Beim Schreiben von Ausgaben in einen Amazon-S3-Bucket mit Apache Flink Version 1.6.2 kann es zu Datenverlusten kommen. Wir empfehlen, die neueste unterstützte Version von Apache Flink zu verwenden, wenn Sie Amazon S3 direkt für die Ausgabe verwenden. Um mit Apache Flink 1.6.2 in einen Amazon S3 S3-Bucket zu schreiben, empfehlen wir die Verwendung von Firehose. Weitere Informationen zur Verwendung von Firehose mit Managed Service für Apache Flink finden Sie unter. <u>Firehose Senke</u>

Die Anwendung befindet sich im Status RUNNING, verarbeitet aber keine Daten

Sie können den Status Ihrer Anwendung mithilfe der <u>ListApplications</u>- oder der <u>DescribeApplication</u>-Aktion überprüfen. Wenn Ihre Anwendung den RUNNING Status annimmt, aber keine Daten in Ihre Senke schreibt, können Sie das Problem beheben, indem Sie Ihrer Anwendung einen CloudWatch Amazon-Protokollstream hinzufügen. Weitere Informationen finden Sie unter <u>Arbeiten Sie mit den Optionen für die CloudWatch Anwendungsprotokollierung</u>. Der Protokollstream enthält Meldungen, mit denen Sie Anwendungsprobleme beheben können.

Fehler beim Snapshot, beim Anwendungsupdate oder beim Beenden der Anwendung: InvalidApplicationConfigurationException

Während eines Snapshot-Vorgangs oder während eines Vorgangs, der einen Snapshot erstellt, z. B. beim Aktualisieren oder Beenden einer Anwendung, kann ein Fehler auftreten, der dem folgenden ähnelt:



Dieser Fehler tritt auf, wenn die Anwendung keinen Snapshot erstellen kann.

Wenn dieser Fehler während eines Snapshot-Vorgangs oder eines Vorgangs, der einen Snapshot erstellt, auftritt, gehen Sie wie folgt vor:

- Deaktivieren Sie Snapshots f
 ür Ihre Anwendung. Sie k
 önnen dies entweder in der Managed Service for Apache Flink-Konsole oder mithilfe des SnapshotsEnabledUpdate UpdateApplicationAktionsparameters tun.
- Untersuchen Sie, warum keine Snapshots erstellt werden können. Weitere Informationen finden Sie unter Die Anwendung steckt in einem vorübergehenden Status fest.
- Aktivieren Sie Snapshots erneut, wenn die Anwendung wieder fehlerfrei ist.

java.nio.file. NoSuchFileException:/usr/local/openjdk-8/lib/security/cacerts

Der Speicherort des SSL-Truststores wurde in einer früheren Bereitstellung aktualisiert. Verwenden Sie stattdessen den folgenden Wert für den ssl.truststore.location-Parameter:

/usr/lib/jvm/java-11-amazon-corretto/lib/security/cacerts

Die Anwendung wird neu gestartet

Wenn Ihre Anwendung nicht fehlerfrei ist, schlägt ihr Apache-Flink-Auftrag ständig fehl und wird neu gestartet. In diesem Abschnitt werden Symptome und Schritte zur Behebung dieses Problems beschrieben.

Symptome

Dieses Problem kann folgende Symptome aufweisen:

- Die FullRestarts-Metrik ist nicht Null. Diese Metrik gibt an, wie oft der Auftrag der Anwendung neu gestartet wurde, seit Sie die Anwendung gestartet haben.
- Die Downtime-Metrik ist nicht Null. Diese Metrik stellt die Anzahl der Millisekunden dar, für die sich die Anwendung im Status FAILING oder RESTARTING befindet.
- Das Anwendungsprotokoll enthält Statusänderungen zu RESTARTING oder FAILED. Mit der folgenden CloudWatch Logs Insights-Abfrage können Sie Ihr Anwendungsprotokoll nach diesen Statusänderungen abfragen: <u>Fehler analysieren: Fehler im Zusammenhang mit</u> <u>Anwendungsaufgaben</u>.

Ursachen und Lösungen

Die folgenden Bedingungen können dazu führen, dass Ihre Anwendung instabil wird und wiederholt neu gestartet wird:

 Der Operator löst eine Ausnahme aus: Wenn eine Ausnahme in einem Operator in Ihrer Anwendung nicht behandelt wird, führt die Anwendung ein Failover durch (indem interpretiert wird, dass der Fehler nicht vom Operator behandelt werden kann). Die Anwendung wird vom letzten Checkpoint aus neu gestartet, um die Semantik der Exakt-einmal-Verarbeitung beizubehalten. Daher ist während dieser Neustartphasen Downtime nicht Null. Um dies zu verhindern, empfehlen wir Ihnen, alle wiederholbaren Ausnahmen im Anwendungscode zu behandeln.

Sie können die Ursachen für dieses Problem untersuchen, indem Sie Ihre Anwendungsprotokolle nach Änderungen des Zustands Ihrer Anwendung von RUNNING auf FAILED abfragen. Weitere Informationen finden Sie unter <u>the section called "Fehler analysieren: Fehler im Zusammenhang</u> mit Anwendungsaufgaben".

 Kinesis-Datenstreams werden nicht ordnungsgemäß bereitgestellt: Wenn eine Quelle oder Senke für Ihre Anwendung ein Kinesis-Datenstream ist, überprüfen Sie die <u>Metriken</u> für den Stream auf Fehler. ReadProvisionedThroughputExceeded WriteProvisionedThroughputExceeded

Wenn Sie diese Fehler sehen, können Sie den verfügbaren Durchsatz für den Kinesis-Stream erhöhen, indem Sie die Anzahl der Shards des Streams erhöhen. Weitere Informationen finden Sie unter Wie kann ich die Anzahl der offenen Shards in Kinesis Data Streams ändern?

 Andere Quellen oder Senken werden nicht ordnungsgemäß bereitgestellt oder sind nicht verfügbar: Stellen Sie sicher, dass Ihre Anwendung Quellen und Senken korrekt bereitstellt. Vergewissern Sie sich, dass alle in der Anwendung verwendeten Quellen oder Senken (z. B. andere AWS Dienste oder externe Quellen oder Ziele) ordnungsgemäß bereitgestellt sind, dass keine Leseoder Schreibdrosselung auftritt oder dass sie regelmäßig nicht verfügbar sind.

Wenn Sie Probleme mit dem Durchsatz Ihrer abhängigen Services haben, erhöhen Sie entweder die für diese Services verfügbaren Ressourcen oder untersuchen Sie die Ursache für Fehler oder Nichtverfügbarkeit.

- Operatoren werden nicht ordnungsgemäß bereitgestellt: Wenn der Workload auf den Threads für einen der Operatoren in Ihrer Anwendung nicht richtig verteilt ist, kann der Operator überlastet werden und die Anwendung kann abstürzen. Informationen zur Optimierung der Operatorparallelität finden Sie unter <u>Richtiges Verwalten der Operatorenskalierung</u>.
- Die Anwendung schlägt fehl mit DaemonException: Dieser Fehler wird in Ihrem Anwendungsprotokoll angezeigt, wenn Sie eine Version von Apache Flink vor 1.11 verwenden. Möglicherweise müssen Sie auf eine neuere Version von Apache Flink aktualisieren, damit eine KPL-Version von 0.14 oder höher verwendet wird.
- Die Anwendung schlägt fehl mit TimeoutException FlinkException, oder RemoteTransportException: Diese Fehler können in Ihrem Anwendungsprotokoll erscheinen, wenn Ihre Task-Manager abstürzen. Wenn Ihre Anwendung überlastet ist, kann es bei Ihren Aufgabenmanagern zu einer Überlastung der CPU- oder Speicherressourcen kommen, wodurch sie ausfallen.

Diese Fehler können wie folgt aussehen:

- java.util.concurrent.TimeoutException: The heartbeat of JobManager with id xxx timed out
- org.apache.flink.util.FlinkException: The assigned slot xxx was removed
- org.apache.flink.runtime.io.network.netty.exception.RemoteTransportException:
 Connection unexpectedly closed by remote task manager

Um dieses Problem zu beheben, überprüfen Sie Folgendes:

- Überprüfen Sie Ihre CloudWatch Messwerte auf ungewöhnliche Spitzen bei der CPU- oder Speicherauslastung.
- Überprüfen Sie Ihre Anwendung auf Durchsatzprobleme. Weitere Informationen finden Sie unter Beheben Sie Leistungsprobleme.
- Untersuchen Sie Ihr Anwendungsprotokoll auf unbehandelte Ausnahmen, die Ihr Anwendungscode auslöst.
- Die Anwendung schlägt mit dem Fehler JaxbAnnotationModule Not Found fehl: Dieser Fehler tritt auf, wenn Ihre Anwendung Apache Beam verwendet, aber nicht über die richtigen Abhängigkeiten oder Abhängigkeitsversionen verfügt. Anwendungen, die Managed Service für Apache Flink nutzen und Apache Beam verwenden, müssen die folgenden Versionen von Abhängigkeiten verwenden:

```
<jackson.version>2.10.2</jackson.version>
...
<dependency>
        <groupId>com.fasterxml.jackson.module</groupId>
        <artifactId>jackson-module-jaxb-annotations</artifactId>
        <version>2.10.2</version>
</dependency>
```

Wenn Sie nicht die richtige Version von jackson-module-jaxb-annotations als explizite Abhängigkeit angeben, lädt Ihre Anwendung sie aus den Umgebungsabhängigkeiten, und da die Versionen nicht übereinstimmen, stürzt die Anwendung zur Laufzeit ab.

Weitere Informationen zum Verwenden von Apache Beam mit Managed Service für Apache Flink finden Sie unter Verwenden CloudFormation.

• Die Anwendung schlägt mit java.io fehl. IOException: Unzureichende Anzahl von Netzwerkpuffern

Dies passiert, wenn einer Anwendung nicht genügend Speicher für Netzwerkpuffer zugewiesen ist. Netzwerkpuffer erleichtern die Kommunikation zwischen Unteraufgaben. Sie werden verwendet, um Datensätze vor der Übertragung über ein Netzwerk zu speichern und eingehende Daten zu speichern, bevor sie in Datensätze zerlegt und an Unteraufgaben übergeben werden. Die Anzahl der benötigten Netzwerkpuffer hängt direkt von der Parallelität und Komplexität Ihres Auftragsdiagramms ab. Es gibt eine Reihe von Ansätzen, um dieses Problem zu beheben:

• Sie können einen niedrigeren Wert für parallelismPerKpu konfigurieren, sodass pro Unteraufgabe und Netzwerkpuffer mehr Speicher zugewiesen wird. Beachten Sie, dass eine Senkung des Werts für parallelismPerKpu die KPU und damit die Kosten erhöht. Um dies zu vermeiden, können Sie die gleiche Menge an KPU beibehalten, indem Sie die Parallelität um denselben Faktor verringern.

- Sie können Ihr Auftragsdiagramm vereinfachen, indem Sie die Anzahl der Operatoren reduzieren oder sie so verketten, dass weniger Puffer benötigt werden.
- Andernfalls können Sie sich an https://aws.amazon.com/premiumsupport/ eine benutzerdefinierte Netzwerkpufferkonfiguration wenden.

Der Durchsatz ist zu langsam

Wenn Ihre Anwendung eingehende Streaming-Daten nicht schnell genug verarbeitet, funktioniert sie schlecht und wird instabil. In diesem Abschnitt werden Symptome und Schritte zur Behebung dieses Problems beschrieben.

Symptome

Dieser Zustand kann folgende Symptome aufweisen:

- Wenn die Datenquelle für Ihre Anwendung ein Kinesis-Stream ist, nimmt die millisbehindLatest-Metrik des Streams kontinuierlich zu.
- Wenn es sich bei der Datenquelle f
 ür Ihre Anwendung um einen Amazon-MSK-Cluster handelt, nehmen die Verbraucherverz
 ögerungsmetriken des Clusters kontinuierlich zu. Weitere Informationen finden Sie unter <u>Verbraucherverz
 ögerungs
 überwachung</u> im <u>Amazon MSK</u> Entwicklerhandbuch.
- Wenn es sich bei der Datenquelle für Ihre Anwendung um einen anderen Service oder eine andere Quelle handelt, überprüfen Sie alle verfügbaren Verbraucherverzögerungsmetriken oder –daten.

Ursachen und Lösungen

Es kann viele Ursachen für einen langsamen Anwendungsdurchsatz geben. Wenn Ihre Anwendung mit den Eingaben nicht Schritt hält, überprüfen Sie Folgendes:

 Wenn die Durchsatzverzögerung stark ansteigt und dann abnimmt, überprüfen Sie, ob die Anwendung neu gestartet wird. Ihre Anwendung stoppt die Verarbeitung von Eingaben, während sie neu gestartet wird, was zu einem Anstieg der Verzögerung führt. Weitere Informationen über Anwendungsausfälle finden Sie unter Die Anwendung wird neu gestartet.

- Wenn die Durchsatzverzögerung konstant ist, überprüfen Sie, ob Ihre Anwendung leistungsoptimiert ist. Informationen zur Optimierung der Leistung Ihrer Anwendung finden Sie unter Beheben Sie Leistungsprobleme.
- Wenn die Durchsatzverzögerung nicht in die Höhe schnellt, sondern kontinuierlich zunimmt und Ihre Anwendung leistungsoptimiert ist, müssen Sie Ihre Anwendungsressourcen erhöhen. Informationen zur Erhöhung der Anwendungsressourcen finden Sie unter <u>Implementieren Sie</u> <u>Anwendungsskalierung</u>.
- Wenn Ihre Anwendung aus einem Kafka-Cluster in einer anderen Region liest und FlinkKafkaConsumer oder KafkaSource sich trotz hoher Verbraucherverzögerung größtenteils im Leerlauf befindet (hohe idleTimeMsPerSecond oder niedrige CPUUtilization), können Sie den Wert für receive.buffer.byte erhöhen, z. B. auf 2097152. Weitere Informationen finden Sie im Abschnitt zu einer Umgebung mit hoher Latenz unter <u>Benutzerdefinierte MSK-Konfigurationen</u>.

Schritte zur Problembehebung bei langsamem Durchsatz oder zunehmender Verbraucherverzögerung in der Anwendungsquelle finden Sie unter <u>Beheben Sie Leistungsprobleme</u>.

Unbegrenztes Staatswachstum

Wenn Ihre Anwendung veraltete Zustandsinformationen nicht ordnungsgemäß löscht, sammeln sich diese kontinuierlich an und führen zu Leistungs- oder Stabilitätsproblemen der Anwendung. In diesem Abschnitt werden Symptome und Schritte zur Behebung dieses Problems beschrieben.

Symptome

Dieses Problem kann folgende Symptome aufweisen:

- Die lastCheckpointDuration-Metrik nimmt allmählich zu oder steigt sprunghaft an.
- Die lastCheckpointSize-Metrik nimmt allmählich zu oder steigt sprunghaft an.

Ursachen und Lösungen

Die folgenden Bedingungen können dazu führen, dass Ihre Anwendung Zustandsdaten ansammelt:

- In Ihrer Anwendung werden Zustandsdaten länger aufbewahrt, als sie benötigt werden.
- Ihre Anwendung verwendet Fensterabfragen mit einer zu langen Dauer.

- Sie haben TTL f
 ür Ihre Zustandsdaten nicht festgelegt. Weitere Informationen finden Sie unter State Time-To-Live (TTL) in der Apache Flink-Dokumentation.
- Sie führen eine Anwendung aus, die von Apache Beam Version 2.25.0 oder neuer abhängt. Sie können sich von der neuen Version der Lesetransformation abmelden, indem Sie <u>Ihre BeamApplicationProperties mit den wichtigsten Experimenten und Werten erweitern</u>. use_deprecated_read Weitere Informationen finden Sie in der Apache-Beam-Dokumentation.

Manchmal sind Anwendungen mit einem stetigen Zuwachs der Zustandsgröße konfrontiert, was auf lange Sicht nicht nachhaltig ist (eine Flink-Anwendung läuft schließlich unbegrenzt). Manchmal kann dies darauf zurückgeführt werden, dass Anwendungen Daten im Zustand speichern und alte Informationen nicht ordnungsgemäß veralten lassen. Aber manchmal werden einfach unangemessene Erwartungen an das gestellt, was Flink bieten kann. Anwendungen können Aggregationen über große Zeitfenster hinweg verwenden, die sich über Tage oder sogar Wochen erstrecken. Sofern sie nicht verwendet <u>AggregateFunctions</u>werden, die inkrementelle Aggregationen ermöglichen, muss Flink die Ereignisse des gesamten Fensters im Status halten.

Darüber hinaus muss die Anwendung bei der Verwendung von Prozessfunktionen zur Implementierung benutzerdefinierter Operatoren Daten aus dem Zustand entfernen, die für die Geschäftslogik nicht mehr benötigt werden. In diesem Fall time-to-live kann der <u>Status</u> verwendet werden, um Daten basierend auf der Verarbeitungszeit automatisch zu altern. Managed Service für Apache Flink verwendet inkrementelle Checkpoints, weshalb Zustand TTL auf der <u>RocksDB-Verdichtung</u> basiert. Sie können eine tatsächliche Verringerung der Zustandsgröße (angezeigt durch die Checkpoint-Größe) erst beobachten, nachdem ein Verdichtungsvorgang durchgeführt wurde. Insbesondere bei Checkpoint-Größen unter 200 MB ist es unwahrscheinlich, dass Sie aufgrund des Ablaufs des Zustands eine Verringerung der Checkpoint-Größe feststellen. Savepoints basieren jedoch auf einer sauberen Kopie des Zustands, die keine alten Daten enthält. Sie können also in Managed Service für Apache Flink einen Snapshot auslösen, um die Entfernung eines veralteten Zustands zu erzwingen.

Zu Debugging-Zwecken kann es sinnvoll sein, inkrementelle Checkpoints zu deaktivieren, um schneller zu überprüfen, ob die Checkpoint-Größe tatsächlich abnimmt oder sich stabilisiert (und um den Effekt der Verdichtung in RocksBS zu vermeiden). Dafür ist allerdings ein Ticket an das Serviceteam erforderlich.

E/A-gebundene Operatoren

Es empfiehlt sich, Abhängigkeiten von externen Systemen auf dem Datenpfad zu vermeiden. Es ist oft viel leistungsfähiger, einen Referenzdatensatz im Zustand zu halten, als ein externes System abzufragen, um einzelne Ereignisse anzureichern. Manchmal gibt es jedoch Abhängigkeiten, die nicht einfach in den Zustand versetzt werden können, z. B. wenn Sie Ereignisse mit einem auf Amazon Sagemaker gehosteten Machine-Learning-Modell anreichern möchten.

Operatoren, die über das Netzwerk Schnittstellen zu externen Systemen herstellen, können zu einem Engpass werden und zu Gegendruck führen. Es wird dringend empfohlen, <u>AsynclO</u> zur Implementierung der Funktionalität zu verwenden, um die Wartezeit für einzelne Anrufe zu reduzieren und zu verhindern, dass die gesamte Anwendung langsamer wird.

Darüber hinaus kann es für Anwendungen mit I/O-gebundenen Operatoren auch sinnvoll sein, die <u>ParallelismPerKPU-Einstellung</u> der Anwendung Managed Service for Apache Flink zu erhöhen. Diese Konfiguration beschreibt die Anzahl der parallelen Unteraufgaben, die eine Anwendung pro Kinesis Processing Unit (KPU) ausführen kann. Wenn der Standardwert von 1 auf beispielsweise 4 erhöht wird, nutzt die Anwendung dieselben Ressourcen (und hat dieselben Kosten), kann aber auf das Vierfache der Parallelität skaliert werden. Dies funktioniert gut für E/A-gebundene Anwendungen, verursacht jedoch zusätzlichen Overhead für Anwendungen, die nicht E/A-gebunden sind.

Upstream- oder Quelldrosselung aus einem Kinesis-Datenstrom

Symptom: Die Anwendung stößt auf LimitExceededExceptions aus ihrem Upstream-Kinesis-Datenstrom.

Mögliche Ursache: Die Standardeinstellung für den Kinesis-Konnektor der Apache-Flink-Bibliothek ist so eingestellt, dass er aus der Kinesis-Datenstromquelle liest, wobei eine sehr aggressive Standardeinstellung für die maximale Anzahl von Datensätzen gilt, die pro GetRecords-Aufruf abgerufen werden. Apache Flink ist standardmäßig so konfiguriert, dass 10.000 Datensätze pro GetRecords Aufruf abgerufen werden (dieser Aufruf erfolgt standardmäßig alle 200 ms), obwohl das Limit pro Shard nur 1.000 Datensätze beträgt.

Dieses Standardverhalten kann zu Drosselung führen, wenn versucht wird, Daten aus dem Kinesis-Datenstrom zu verbrauchen, was sich auf die Leistung und Stabilität der Anwendung auswirkt.

Sie können dies überprüfen, indem Sie die CloudWatch ReadProvisionedThroughputExceeded Metrik überprüfen und sich längere oder anhaltende Zeiträume ansehen, in denen diese Metrik größer als Null ist. Sie können dies auch in den CloudWatch Protokollen Ihrer Amazon Managed Service for Apache Flink-Anwendung sehen, indem Sie anhaltende LimitExceededException Fehler beobachten.

Lösung: Sie können eines von zwei Dingen tun, um dieses Szenario zu lösen:

- Senken Sie das Standardlimit für die Anzahl der pro GetRecords Anruf abgerufenen Datensätze
- Aktivieren Sie Adaptive Reads in Ihrer Amazon Managed Service f
 ür Apache Flink-Anwendung. Weitere Informationen zum Feature Adaptive Reads finden Sie unter <u>SHARD_USE_ADAPTIVE_READS</u>

Checkpoints

Checkpoints sind der Mechanismus von Flink, der sicherstellt, dass der Zustand einer Anwendung fehlertolerant ist. Dieser Mechanismus ermöglicht es Flink, den Status der Operatoren wiederherzustellen, falls der Auftrag fehlschlägt, und verleiht der Anwendung dieselbe Semantik wie bei einer fehlerfreien Ausführung. Mit Managed Service für Apache Flink wird der Zustand einer Anwendung in RocksDB gespeichert, einem eingebetteten Schlüssel-Wert-Speicher, der seinen Betriebszustand auf der Festplatte speichert. Wenn ein Checkpoint erreicht wird, wird der Zustand auch auf Amazon S3 hochgeladen. Selbst wenn die Festplatte verloren geht, kann der Checkpoint verwendet werden, um den Zustand der Anwendung wiederherzustellen.

Weitere Informationen finden Sie unter Wie funktionieren Zustand-Snapshots?

Checkpointing-Phasen

Für eine Checkpointing-Operator-Unteraufgabe in Flink gibt es 5 Hauptphasen:

- Warten [Startverzögerung] Flink verwendet Checkpoint-Barrieren, die in den Stream eingefügt werden. Die Zeit in dieser Phase ist also die Zeit, in der der Operator darauf wartet, dass die Checkpoint-Barriere sie erreicht.
- Ausrichtung [Ausrichtungsdauer] In dieser Phase hat die Unteraufgabe eine Barriere erreicht, wartet aber auf Barrieren aus anderen Eingabeströmen.
- Sync-Checkpointing [Sync-Dauer] In dieser Phase nimmt die Unteraufgabe tatsächlich einen Snapshot des Zustands des Operators auf und blockiert alle anderen Aktivitäten in der Unteraufgabe.
- Async-Checkpointing [Async-Dauer] Der Großteil dieser Phase besteht aus der Unteraufgabe, den Zustand auf Amazon S3 hochzuladen. Während dieser Phase ist die Unteraufgabe nicht mehr blockiert und kann Datensätze verarbeiten.

 Bestätigung — In der Regel handelt es sich dabei um eine kurze Phase. Dabei handelt es sich einfach um die Unteraufgabe, die eine Bestätigung an den Server sendet JobManager und auch alle Commit-Nachrichten ausführt (z. B. bei Kafka-Senken).

Jede dieser Phasen (außer Bestätigung) ist einer Dauermetrik für Checkpoints zugeordnet, die über die Flink-WebUI verfügbar ist und die dazu beitragen kann, die Ursache für den langen Checkpoint zu isolieren.

Eine genaue Definition der einzelnen für Checkpoints verfügbaren Metriken finden Sie auf der Registerkarte Verlauf.

Untersuchen

Bei der Untersuchung einer langen Checkpoint-Dauer ist es am wichtigsten, den Engpass für den Checkpoint zu ermitteln, d. h. welcher Operator und welche Unteraufgabe am längsten bis zum Checkpoint benötigt und welche Phase dieser Unteraufgabe länger dauert. Dies kann mithilfe der Flink-WebUI unter der Aufgabe Aufträge Checkpoint ermittelt werden. Die Weboberfläche von Flink bietet Daten und Informationen, die bei der Untersuchung von Checkpoint-Problemen helfen. Eine vollständige Aufschlüsselung finden Sie unter <u>Überwachen des Checkpointing</u>.

Als Erstes sollten Sie sich die Gesamtdauer jedes Operators im Auftragsdiagramm ansehen, um festzustellen, welcher Operator lange braucht, um den Checkpoint zu erreichen, und wo weitere Untersuchungen erforderlich sind. Gemäß der Flink-Dokumentation lautet die Definition der Dauer wie folgt:

Die Dauer vom Trigger-Zeitstempel bis zur letzten Bestätigung (oder n/a, wenn noch keine Bestätigung eingegangen ist). Diese Gesamtdauer für einen vollständigen Checkpoint wird durch die letzte Unteraufgabe bestimmt, die den Checkpoint bestätigt. Diese Zeit ist normalerweise länger, als einzelne Teilaufgaben benötigen, um tatsächlich einen Checkpoint des Zustands zu erstellen.

Die anderen Zeitdauerangaben für den Checkpoint geben auch detailliertere Informationen darüber, wo die Zeit verbracht wird.

Wenn die Sync-Dauer hoch ist, deutet dies darauf hin, dass während der Snapshot-Erstellung etwas passiert. In dieser Phase wird snapshotState() für Klassen aufgerufen, die die SnapshotState-Schnittstelle implementieren. Dabei kann es sich um Benutzercode handeln, sodass Thread-Dumps nützlich sein können, um dies zu untersuchen.

Eine lange Async-Dauer würde darauf hindeuten, dass viel Zeit für das Hochladen des Zustands auf Amazon S3 aufgewendet wird. Dies kann der Fall sein, wenn der Zustand groß ist oder wenn viele Zustandsdateien hochgeladen werden. Wenn dies der Fall ist, lohnt es sich zu untersuchen, wie der Zustand von der Anwendung verwendet wird, und sicherzustellen, dass die systemeigenen Flink-Datenstrukturen verwendet werden, wo immer dies möglich ist (<u>Gekennzeichneten Zustand</u> <u>verwenden</u>). Managed Service für Apache Flink konfiguriert Flink so, dass die Anzahl der Amazon-S3-Aufrufe minimiert wird, um sicherzustellen, dass diese nicht zu lang werden. Im Folgenden finden Sie ein Beispiel für die Checkpoint-Statistiken eines Operators. Es zeigt, dass die Async-Dauer im Vergleich zu den vorherigen Checkpoint-Statistiken für Operatoren relativ lang ist.

SubTasks:	E	nd to En	d Duration	Che	eckpointed Data Size		Sync Duration		Async Dur	atio	n	Processed (persis	stee	d) Data	Alig	nment Durat	ion		Start Delay	
Minimu	im 4	95ms		11.	1 КВ		8ms		357ms			0 B (0 B)			0ms				126ms	
Average	e 8	13ms		586	в КВ		28ms		653ms			0 B (0 B)			0ms				126ms	
Maximu	u m 1	s		1.70	0 MB		69ms		1s			0 B (0 B)			1ms				128ms	
I Ac D	knowledge	¢ be	End to End Duration	\$	Checkpointed Data	S	Sync Duration	As Du	sync uration	÷	Processe Data	ed (persisted)	×	Alignment Duration	\$	Start Delay	*	Unaligi Checkj	ned point	\$
0 20 14	22-03-02 ::16:49		566ms		11.1 KB	8	Bms	42	29ms		0 B (0 B)			Oms		126ms		false		
1 20 1 14	22-03-02 ::16:50		1s		1.70 MB	6	69ms	1s	;		0 B (0 B)			Oms		128ms		false		
2 20 2 14	22-03-02 :16:49		495ms		11.1 КВ	8	Bms	35	57ms		0 B (0 B)			1ms		126ms		false		
- Sink	: Unnamed						1/1 (100%)		2022-03-02 1	4:1	6:49	131ms		0 B		0 B	(0 B)			
SubTasks:																				

Eine hohe Startverzögerung würde bedeuten, dass die meiste Zeit damit verbracht wird, darauf zu warten, dass die Checkpoint-Barriere den Operator erreicht. Dies deutet darauf hin, dass die Anwendung eine Weile benötigt, um Datensätze zu verarbeiten, was bedeutet, dass die Barriere langsam durch das Auftragsdiagramm fließt. Dies ist normalerweise der Fall, wenn der Auftrag Gegendruck erhält oder wenn ein oder mehrere Operatoren ständig beschäftigt sind. Es folgt ein Beispiel für eine, JobGraph bei der der zweite Operator beschäftigt ist. KeyedProcess



Sie können untersuchen, was so lange dauert, indem Sie entweder Flink Flame Graphs oder TaskManager Thread-Dumps verwenden. Sobald der Engpass identifiziert wurde, kann er mithilfe von Flame-Diagrammen oder Thread-Dumps weiter untersucht werden.

Thread-Dumps

Thread-Dumps sind ein weiteres Debugging-Tool auf einer etwas niedrigeren Ebene als Flame-Diagramme. Ein Thread-Dump gibt den Ausführungszustand aller Threads zu einem bestimmten Zeitpunkt aus. Flink nimmt einen JVM-Thread-Dump, der den Ausführungszustand aller Threads innerhalb des Flink-Prozesses darstellt. Der Zustand eines Threads wird durch einen Stack-Trace des Threads sowie durch einige zusätzliche Informationen dargestellt. Flame-Diagramme werden tatsächlich aus mehreren Stack-Traces erstellt, die schnell hintereinander aufgenommen wurden. Das Diagramm ist eine aus diesen Traces erstellte Visualisierung, die es einfach macht, die gemeinsamen Codepfade zu identifizieren.

"KeyedProcess (1/3)#0" prio=5 Id=1423 RUNNABLE

at app//scala.collection.immutable.Range.foreach\$mVc\$sp(Range.scala:154)

at \$line33.\$read\$\$iw\$\$iw\$ExpensiveFunction.processElement(<console>>19)

```
at $line33.$read$$iw$$iw$ExpensiveFunction.processElement(<console>:14)
```

```
at app//
```

\$StreamTaskNetworkOutput.emitRecord(OneInputStreamTask.java:205)

```
at app//
```

- org.apache.flink.streaming.runtime.io.AbstractStreamTaskNetworkInput.processElement(AbstractStr at app//
- org.apache.flink.streaming.runtime.io.StreamOneInputProcessor.processInput(StreamOneInputProces ...

Oben sehen Sie einen Ausschnitt eines Thread-Dumps aus der Flink-Benutzeroberfläche für einen einzelnen Thread. Die erste Zeile enthält einige allgemeine Informationen zu diesem Thread, darunter:

- Der Thread-Name KeyedProcess (1/3) #0
- Priorität des Threads prio=5
- Eine eindeutige Thread-ID Id=1423
- Thread-Status RUNNABLE

Der Name eines Threads gibt normalerweise Auskunft über den allgemeinen Zweck des Threads. Operator-Threads können anhand ihres Namens identifiziert werden, da Operator-Threads denselben Namen wie der Operator haben und außerdem angeben, zu welcher Unteraufgabe sie gehören, z. B. ist der Thread KeyedProcess (1/3) #0 vom KeyedProcessOperator und von der ersten (von 3) Unteraufgabe.

Threads können sich in einem von wenigen Zuständen befinden:

- NEW Der Thread wurde erstellt, aber noch nicht verarbeitet
- RUNNABLE Der Thread wird auf der CPU ausgeführt
- BLOCKED Der Thread wartet darauf, dass ein anderer Thread seine Sperre freigibt
- WAITING Der Thread wartet mit einer wait()-, join()-, oder park()-Methode
- TIMED_WAITING Der Thread wartet mit einer Sleep-, Wait-, Join- oder Park-Methode, jedoch mit einer maximalen Wartezeit.

1 Note

In Flink 1.13 ist die maximale Tiefe eines einzelnen Stack-Trace im Thread-Dump auf 8 begrenzt.

Note

Thread-Dumps sollten das letzte Mittel zum Debuggen von Leistungsproblemen in einer Flink-Anwendung sein, da sie schwierig zu lesen sein können und die Entnahme mehrerer Stichproben und deren manuelle Analyse erfordern. Wenn möglich, ist es vorzuziehen, Flame-Diagramme zu verwenden.

Thread-Dumps in Flink

In Flink kann ein Thread-Dump erstellt werden, indem Sie in der linken Navigationsleiste der Flink-Benutzeroberfläche die Option Aufgabenmanager auswählen, einen bestimmten Aufgabenmanager auswählen und dann zur Registerkarte Thread-Dump navigieren. Der Thread-Dump kann heruntergeladen, in Ihren bevorzugten Texteditor (oder Thread-Dump-Analysator) kopiert oder direkt in der Textansicht in der Flink-Web-UI analysiert werden (diese letzte Option kann jedoch etwas umständlich sein). Um zu bestimmen, welcher Task Manager verwendet werden soll, kann ein Thread-Dump des TaskManagersTabs verwendet werden, wenn ein bestimmter Operator ausgewählt wird. Dies zeigt, dass der Operator für verschiedene Unteraufgaben eines Operators ausgeführt wird und auf verschiedenen Aufgabenmanagern ausgeführt werden kann.



Der Dump wird aus mehreren Stack-Traces bestehen. Bei der Untersuchung des Dumps sind jedoch diejenigen am wichtigsten, die sich auf einen Operator beziehen. Diese können leicht gefunden werden, da Operator-Threads denselben Namen wie der Operator haben und auch angeben, auf welche Unteraufgabe sie sich beziehen. Zum Beispiel stammt der folgende Stack-Trace vom KeyedProcessOperator und ist die erste Unteraufgabe.

```
"KeyedProcess (1/3)#0" prio=5 Id=595 RUNNABLE
at app//scala.collection.immutable.Range.foreach$mVc$sp(Range.scala:155)
at $line360.$read$$iw$$iw$ExpensiveFunction.processElement(<console>:19)
at $line360.$read$$iw$$iw$ExpensiveFunction.processElement(<console>:14)
at app//
org.apache.flink.streaming.api.operators.KeyedProcessOperator.processElement(KeyedProcessOperat
at app//org.apache.flink.streaming.runtime.tasks.OneInputStreamTask
$StreamTaskNetworkOutput.emitRecord(OneInputStreamTask.java:205)
at app//
org.apache.flink.streaming.runtime.io.AbstractStreamTaskNetworkInput.processElement(AbstractStreamTask
at app//
org.apache.flink.streaming.runtime.io.AbstractStreamTaskNetworkInput.emitNext(AbstractStreamTask
at app//
org.apache.flink.streaming.runtime.io.StreamOneInputProcessor.processInput(StreamOneInputProcess
....
```

Dies kann verwirrend werden, wenn es mehrere Operatoren mit demselben Namen gibt, aber wir können Operatoren benennen, um dies zu umgehen. Beispiel:

```
....
.process(new ExpensiveFunction).name("Expensive function")
```

Flame-Diagramme

Flame-Diagramme sind ein nützliches Debugging-Tool, das die Stack-Traces des Zielcodes visualisiert und so die Identifizierung der häufigsten Codepfade ermöglicht. Sie werden erstellt, indem Stack-Traces mehrmals abgetastet werden. Die X-Achse eines Flame-Diagramms zeigt die verschiedenen Stack-Profile, während die Y-Achse die Stack-Tiefe und die Aufrufe des Stack-Trace zeigt. Ein einzelnes Rechteck in einem Flame-Diagramm steht für einen Stack-Frame, und die Breite eines Frames gibt an, wie häufig es in den Stacks vorkommt. Weitere Informationen über Flame-Diagramme und deren Nutzung finden Sie unter Flame-Diagramme.

In Flink kann das Flame-Diagramm für einen Operator über die Weboberfläche aufgerufen werden, indem Sie einen Operator und dann die FlameGraphRegisterkarte auswählen. Sobald genügend Proben gesammelt wurden, wird das Flame-Diagramm angezeigt. Im Folgenden finden Sie das FlameGraph für den ProcessFunction, dessen Checkpoint viel Zeit in Anspruch genommen hat.



Dies ist ein sehr einfaches Flammendiagramm, das zeigt, dass die gesamte CPU-Zeit für einen Blick innerhalb processElement des ExpensiveFunction Bedieners aufgewendet wird. Sie erhalten auch die Zeilennummer, anhand derer Sie feststellen können, wo die Codeausführung stattfindet.

Beim Checkpointing kommt es zu einer Zeitüberschreitung

Wenn Ihre Anwendung nicht optimiert oder ordnungsgemäß bereitgestellt ist, können Checkpoints fehlschlagen. In diesem Abschnitt werden Symptome und Schritte zur Behebung dieses Problems beschrieben.

Symptome

Wenn Checkpoints für Ihre Anwendung fehlschlagen, ist der Wert von numberOfFailedCheckpoints größer als Null.

Checkpoints können entweder aufgrund direkter Fehler, wie Anwendungsfehler, oder aufgrund vorübergehender Fehler, z. B. aufgrund unzureichender Anwendungsressourcen, fehlschlagen. Überprüfen Sie Ihre Anwendungsprotokolle und Metriken auf die folgenden Symptome:

- Fehler in Ihrem Code.
- Fehler beim Zugriff auf die abhängigen Services Ihrer Anwendung.
- Fehler beim Serialisieren von Daten. Wenn der Standard-Serializer Ihre Anwendungsdaten nicht serialisieren kann, schlägt die Anwendung fehl. Informationen zur Verwendung eines benutzerdefinierten Serializers in Ihrer Anwendung finden Sie unter <u>Datentypen und Serialisierung</u> in der Apache Flink-Dokumentation.
- Fehler wegen Speichermangel.
- Spitzen oder stetiger Anstieg der folgenden Metriken:
 - heapMemoryUtilization
 - oldGenerationGCTime
 - oldGenerationGCCount
 - lastCheckpointSize
 - lastCheckpointDuration

Weitere Informationen zur Überwachung von Checkpoints finden Sie unter Monitoring Checkpointing in der Apache Flink-Dokumentation.

Ursachen und Lösungen

Die Fehlermeldungen im Anwendungsprotokoll zeigen die Ursache für direkte Fehler. Vorübergehende Fehler können folgende Ursachen haben:

- Ihre Anwendung verfügt über eine unzureichende KPU-Bereitstellung. Informationen zur Erhöhung der Anwendungsbereitstellung finden Sie unter Implementieren Sie Anwendungsskalierung.
- Die Größe des Anwendungszustands ist zu hoch. Sie können die Größe Ihres Anwendungszustands anhand der lastCheckpointSize-Metrik überwachen.
- Die Zustandsdaten Ihrer Anwendung sind ungleich auf die Schlüssel verteilt. Wenn Ihre Anwendung den KeyBy-Operator verwendet, stellen Sie sicher, dass Ihre eingehenden Daten gleichmäßig auf die Schlüssel aufgeteilt werden. Wenn die meisten Daten einem einzigen Schlüssel zugewiesen werden, entsteht ein Engpass, der zu Fehlern führt.
- Ihre Anwendung leidet unter einem Gegendruck im Speicher oder bei der Garbage Collection. Überwachen Sie heapMemoryUtilization, oldGenerationGCTime und oldGenerationGCCount Ihrer Anwendung auf Spitzen oder stetig steigende Werte.

Checkpoint-Fehler für Apache-Beam-Anwendung

Wenn Ihre Beam-Anwendung auf 0 ms konfiguriert ist, können Checkpoints möglicherweise nicht ausgelöst werden, da sich die Aufgaben im Status "ABGESCHLOSSEN" befinden. <u>shutdownSourcesAfterIdIeMs</u> In diesem Abschnitt werden Symptome und Lösungen für diesen Zustand beschrieben.

Symptom

Rufen Sie die CloudWatch Anwendungsprotokolle Ihres Managed Service for Apache Flink auf und überprüfen Sie, ob die folgende Protokollmeldung protokolliert wurde. Die folgende Protokollmeldung weist darauf hin, dass der Checkpoint nicht ausgelöst werden konnte, da einige Aufgaben abgeschlossen wurden.

```
{
    "locationInformation":
    "org.apache.flink.runtime.checkpoint.CheckpointCoordinator.onTriggerFailure(CheckpointCoordinator",
    "logger": "org.apache.flink.runtime.checkpoint.CheckpointCoordinator",
    "message": "Failed to trigger checkpoint for job your job ID since some
tasks of job your job ID has been finished, abort the checkpoint Failure reason: Not
all required tasks are currently running.",
    "threadName": "Checkpoint Timer",
    "applicationARN": your application ARN,
    "applicationVersionId": "5",
    "messageSchemaVersion": "1",
    "messageType": "INFO"
```

}

Dies kann auch im Flink-Dashboard gefunden werden, wo einige Aufgaben den Zustand "ABGESCHLOSSEN" erreicht haben und Checkpointing nicht mehr möglich ist.

Detail	SubTasks	TaskManagers Wa	atermarks Acc	umulators	BackPressure	Metrics FlameGraph					
ID	Bytes Received	Records Received	👙 Bytes Sent	Records Se	nt 🌲 Attempt	≑ Host	👙 Start Time	÷	Duration	🚊 🗆 Status	👙 More
0	0 B	0	0 B	0	1	sea3-ws-agg-r3-pc-1	2022-06-06	11:16:03	13m 57s	RUNNING	
1	0 B	0	0 B	0	1	sea3-ws-agg-r3-pc-1	2022-06-06	11:16:03	3s	FINISHED	
2	0 B	0	0 B	0	1	sea3-ws-agg-r3-pc-1	2022-06-06	11:16:03	3s	FINISHED	
3	0 B	0	0 B	0	1	sea3-ws-agg-r3-pc-1	2022-06-06	11:16:03	3s	FINISHED	
4	0 B	0	0 B	0	1	sea3-ws-agg-r3-pc-1	2022-06-06	11:16:03	3s	FINISHED	

Ursache

shutdownSourcesAfterIdleMs ist eine Beam-Konfigurationsvariable, die Quellen herunterfährt, die für die konfigurierte Zeit von Millisekunden inaktiv waren. Sobald eine Quelle heruntergefahren wurde, ist Checkpointing nicht mehr möglich. Dies könnte zu einem Checkpoint-Fehler führen.

Einer der Gründe dafür, dass Aufgaben in den Status "FINISHED" wechseln, ist, wenn sie auf 0 ms gesetzt shutdownSourcesAfter IdIeMs ist, was bedeutet, dass Aufgaben, die sich im Leerlauf befinden, sofort heruntergefahren werden.

Lösung

Um zu verhindern, dass Aufgaben sofort in den Status "FERTIG" wechseln, legen Sie den Wert shutdownSourcesAfter IdleMs auf LONG.MAX_VALUE fest. Es gibt zwei Methoden dafür:

 Option 1: Wenn Ihre Beam-Konfiguration auf der Konfigurationsseite Ihrer Managed Service for Apache Flink-Anwendung festgelegt ist, können Sie ein neues Schlüsselwertpaar hinzufügen, um Ms wie folgt festzulegen: shutdpwnSourcesAfteridle

Runtime properties (6)								
You can also group application properties into multiple groups. These are useful to store configuration settings without the need to change application code.								
Q, Find groups, keys, and values								
Group	⊽	Key 🔻	•	Value				
BeamApplicationProperties		ShutdownSourcesAfterIdleMs		9223372036854775807				

 Option 2: Wenn Ihre Beam-Konfiguration in Ihrer JAR-Datei festgelegt ist, können Sie sie wie folgt einstellen: shutdownSourcesAfter IdleMs

Gegendruck

Flink nutzt Gegendruck, um die Verarbeitungsgeschwindigkeit einzelner Operatoren anzupassen.

Der Operator kann aus vielen Gründen Schwierigkeiten haben, das Nachrichtenvolumen, das er empfängt, weiter zu verarbeiten. Der Vorgang benötigt möglicherweise mehr CPU-Ressourcen, als der Operator zur Verfügung hat. Der Operator wartet möglicherweise, bis die E/A-Operationen abgeschlossen sind. Wenn ein Operator Ereignisse nicht schnell genug verarbeiten kann, entsteht ein Gegendruck bei den vorgeschalteten Operatoren, die in den langsamen Operator einspeisen. Dies führt dazu, dass die vorgelagerten Operatoren langsamer werden, wodurch sich der Gegendruck zur Quelle weiter ausbreiten kann und die Quelle sich an den Gesamtdurchsatz der Anwendung anpasst, indem sie ebenfalls langsamer wird. Eine ausführlichere Beschreibung von Gegendruck und seiner Funktionsweise finden Sie unter So handhabt Apache Flink[™] Gegendruck.

Wenn Sie wissen, welche Operatoren in einer Anwendung langsam sind, erhalten Sie wichtige Informationen, um die Ursache von Leistungsproblemen in der Anwendung zu verstehen. Informationen zum Gegendruck werden <u>über das Flink-Dashboard angezeigt</u>. Um den langsamen Operator zu identifizieren, suchen Sie nach dem Operator mit einem hohen Gegendruckwert, der einer Senke am nächsten ist (im folgenden Beispiel Operator B). Der Operator, der die Langsamkeit verursacht, ist dann einer der nachgeschalteten Operatoren (im Beispiel Operator C). B könnte Ereignisse schneller verarbeiten, gerät jedoch unter Druck, da er die Ausgabe nicht an den langsamen Operator C weiterleiten kann.

A (backpressured 93%) -> B (backpressured 85%) -> C (backpressured 11%) -> D (backpressured 0%)

Sobald Sie den langsamen Operator identifiziert haben, versuchen Sie zu verstehen, warum er langsam ist. Es kann viele Gründe dafür geben, und manchmal ist nicht klar, was das Problem ist. Es kann Tage des Debuggens und Profilings erfordern, um das Problem zu lösen. Im Folgenden sind einige offensichtliche und häufigere Gründe aufgeführt, von denen einige im Folgenden näher erläutert werden:

- Der Operator führt langsame E/A durch, z. B. Netzwerkaufrufe (erwägen Sie stattdessen die Verwendung von AsynclO).
- Die Daten sind verzerrt und ein Operator empfängt mehr Ereignisse als andere (überprüfen Sie dies, indem Sie sich die Anzahl der eingehenden/ausgehenden Nachrichten einzelner Unteraufgaben (d. h. Instances desselben Operators) im Flink-Dashboard ansehen.
- Es handelt sich um einen ressourcenintensiven Vorgang (wenn es keine verzerrte Datenverteilung gibt, sollten Sie erwägen, bei CPU-/speichergebundener Arbeit horizontal zu skalieren oder bei E/ A-gebundener Arbeit den Wert von ParallelismPerKPU zu erhöhen).
- Umfangreiche Protokollierung durch den Operator (reduzieren Sie die Protokollierung auf ein Minimum für Produktionsanwendungen oder erwägen Sie, stattdessen die Debug-Ausgabe an einen Datenstrom zu senden).

Testen des Durchsatzes mit dem Discarding Sink

Die <u>Verwurfsenke</u> ignoriert einfach alle Ereignisse, die sie empfängt, während die Anwendung weiterhin ausgeführt wird (eine Anwendung ohne Senke kann nicht ausgeführt werden). Dies ist sehr nützlich für Durchsatztests, zum Profiling und um zu überprüfen, ob die Anwendung ordnungsgemäß skaliert. Es ist außerdem eine sehr pragmatische Plausibilitätsprüfung, um zu überprüfen, ob die Senken einen Gegendruck erzeugen oder die Anwendung (aber die bloße Überprüfung der Gegendruckmetriken ist oft einfacher und unkomplizierter).

Indem Sie alle Senken einer Anwendung durch eine Verwurfsenke ersetzen und eine Mock-Quelle erstellen, die Daten generiert, die Produktionsdaten ähneln, können Sie den maximalen Durchsatz der Anwendung für eine bestimmte Parallelitätseinstellung messen. Sie können dann auch die Parallelität erhöhen, um sicherzustellen, dass die Anwendung ordnungsgemäß skaliert und keinen Engpass aufweist, der erst bei höherem Durchsatz auftritt (z. B. aufgrund einer verzerrten Datenverteilung).

Verzerrte Datenverteilung

Eine Flink-Anwendung wird auf einem Cluster verteilt ausgeführt. Um horizontal auf mehrere Knoten zu skalieren, verwendet Flink das Konzept der verschlüsselten Streams, was im Wesentlichen bedeutet, dass die Ereignisse eines Streams nach einem bestimmten Schlüssel, z. B. einer Kunden-ID, partitioniert werden und Flink dann verschiedene Partitionen auf verschiedenen Knoten verarbeiten kann. Viele der Flink-Operatoren werden dann auf der Grundlage dieser Partitionen ausgewertet, z. B. Keyed Windows, Process Functions und Async I/O.

Die Auswahl eines Partitionsschlüssels hängt häufig von der Geschäftslogik ab. Gleichzeitig gelten viele der Best Practices für z. B. DynamoDB und Spark auch für Flink, darunter:

- Sicherstellung einer hohen Kardinalität der Partitionsschlüssel
- Vermeidung von Verzerrungen im Ereignisvolumen zwischen Partitionen

Sie können Verzerrungen in den Partitionen erkennen, indem Sie die empfangenen/gesendeten Datensätze von Unteraufgaben (d. h. Instances desselben Operators) im Flink-Dashboard vergleichen. Darüber hinaus kann die Überwachung von Managed Service für Apache Flink so konfiguriert werden, dass Metriken auch für numRecordsIn/Out und numRecordsInPerSecond/ OutPerSecond auf Unteraufgabenebene verfügbar gemacht werden.

Zustandsverzerrung

Bei zustandsbehafteten Operatoren, d. h. Operatoren, die den Zustand für ihre Geschäftslogik verwerten, wie z. B. Fenster, führt eine Verzerrung der Datenverteilung immer zu einer Zustandsverzerrung. Einige Unteraufgaben empfangen aufgrund der Verzerrung der Datenverteilung mehr Ereignisse als andere und behalten daher auch mehr Daten im Zustand. Aber selbst bei einer Anwendung mit gleichmäßig ausgeglichenen Partitionen kann es zu Abweichungen bei der Menge der im Zustand gespeicherten Daten kommen. Beispielsweise können bei Sitzungsfenstern einige Benutzer bzw. Sitzungen viel länger sein als andere. Wenn die längeren Sitzungen zufällig Teil derselben Partition sind, kann dies zu einem Ungleichgewicht der Zustandsgröße führen, die von verschiedenen Unteraufgaben desselben Operators verwaltet wird.

Zustandsverzerrungen erhöhen nicht nur die Arbeitsspeicher- und Festplattenressourcen, die für einzelne Unteraufgaben benötigt werden, sondern sie können auch die Gesamtleistung der Anwendung verringern. Wenn eine Anwendung einen Checkpoint oder Savepoint verwendet, wird der Operatorzustand in Amazon S3 gespeichert, um den Zustand vor Knoten- oder Cluster-Fehlern zu schützen. Während dieses Vorgangs (insbesondere bei exakt einmaliger Semantik,

die standardmäßig auf Managed Service for Apache Flink aktiviert ist) kommt die Verarbeitung aus externer Sicht zum Stillstand, bis sie fehlschlagen checkpoint/savepoint has completed. If there is data skew, the time to complete the operation can be bound by a single subtask that has accumulated a particularly high amount of state. In extreme cases, taking checkpoints/savepoints kann, weil eine einzelne Unteraufgabe den Status nicht beibehalten kann.

Ähnlich wie bei einer verzerrten Datenverteilung kann auch eine Zustandsverzerrung eine Anwendung erheblich verlangsamen.

Um Zustandsverzerrungen zu identifizieren, können Sie das Flink-Dashboard nutzen. Suchen Sie in den Details nach einem aktuellen Checkpoint oder Savepoint und vergleichen Sie die Datenmenge, die für einzelne Unteraufgaben gespeichert wurde.

Integrieren Sie Ressourcen in verschiedenen Regionen

Sie können StreamingFileSink für das Schreiben in einen Amazon-S3-Bucket in einer von Ihrer Anwendung, die Managed Service für Apache Flink nutzt, abweichenden Region über eine Einstellung aktivieren, die für die regionsübergreifende Replikation in der Flink-Konfiguration erforderlich ist. Reichen Sie dazu ein Support-Ticket im <u>AWS -Support Center</u> ein.

Dokumentenverlauf für Amazon Managed Service für Apache Flink

In der folgenden Tabelle werden die wichtigen Änderungen an der Dokumentation seit der letzten Version von Managed Service für Apache Flink beschrieben.

- API-Version: 2018-05-23
- Letzte Aktualisierung der Dokumentation: 30. August 2023

Änderung	Beschreibung	Datum
Kinesis Data Analytics ist jetzt als Managed Service für Apache Flink bekannt	Es gibt keine Änderungen an den Service-Endpunkten , der Befehlszeilenschni ttstelle APIs, den IAM-Zugri ffsrichtlinien, den CloudWatch Metriken oder den Abrechnun gs-Dashboards. AWS Ihre vorhandenen Anwendung en funktionieren weiterhin wie zuvor. Weitere Informati onen finden Sie unter <u>Was ist</u> <u>Managed Service für Apache</u> <u>Flink?</u>	30. August 2023
Support für Apache Flink Version 1.15.2	Managed Service für Apache Flink unterstützt jetzt Anwendungen, die Apache Flink Version 1.15.2 verwenden. Erstellen Sie Kinesis Data Analytics- Anwendungen mithilfe der Apache Flink Tabellen-API. Weitere Informationen finden	22. November 2022

Änderung	Beschreibung	Datum				
	Sie unter <u>Erstellen einer</u> <u>Anwendung</u> .					
Support für Apache Flink Version 1.13.2	Managed Service für Apache Flink unterstützt jetzt Anwendungen, die Apache Flink Version 1.13.2 verwenden. Erstellen Sie Kinesis Data Analytics- Anwendungen mithilfe der Apache Flink Tabellen-API. Weitere Informationen finden Sie unter <u>Erste Schritte: Flink</u> <u>1.13.2</u> .	13. Oktober 2021				
Unterstützung für Python	Managed Service für Apache Flink unterstützt jetzt Anwendungen, die Python mit der Apache Flink Tabellen-API und SQL verwenden. Weitere Informationen finden Sie unter Benutze Python.	25. März 2021				
Unterstützung für Apache Flink 1.11.1	Managed Service für Apache Flink unterstützt jetzt Anwendungen, die Apache Flink 1.11.1 verwenden. Erstellen Sie Kinesis Data Analytics-Anwendungen mithilfe der Apache Flink Tabellen-API. Weitere Informationen finden Sie unter Erstellen einer Anwendung.	19. November 2020				

Änderung	Beschreibung	Datum				
Apache Flink-Dashboard	Verwenden Sie das Apache Flink-Dashboard, um den Zustand und die Leistung von Anwendungen zu überwache n. Weitere Informationen finden Sie unter <u>Verwenden</u> <u>Sie das Apache Flink</u> <u>Dashboard</u> .	19. November 2020				
EFO Verbraucher	Erstellen Sie Anwendung en, die einen Enhanced Fan-Out (EFO)-Verbraucher verwenden, um aus einem Kinesis Stream zu lesen. Weitere Informationen finden Sie unter <u>EFO-Verbraucher</u> .	6. Oktober 2020				
Apache Beam	Erstellen Sie Anwendung en, die Apache Beam zur Verarbeitung von Streaming -Daten verwenden. Weitere Informationen finden Sie unter Verwenden CloudFormation.	15. September 2020				
Leistung	Wie man Probleme mit der Anwendungsleistung behebt und wie man eine performan te Anwendung erstellt. Weitere Informationen finden Sie unter ???.	21. Juli 2020				

Änderung	Beschreibung	Datum			
Benutzerdefinierter Keystore	Wie Sie auf einen Amazon MSK-Cluster zugreifen, der einen benutzerdefinierten Keystore für die Verschlüs selung bei der Übertragu ng verwendet. Weitere Informationen finden Sie unter <u>Benutzerdefinierter Truststore</u> .	10. Juni 2020			
CloudWatch Alarme	Empfehlungen für die Erstellun g von CloudWatch Alarmen mit Managed Service für Apache Flink. Weitere Informationen finden Sie unter ???.	5. Juni 2020			
Neue Metriken CloudWatch	Managed Service für Apache Flink gibt jetzt 22 Metriken an Amazon CloudWatch Metrics aus. Weitere Informationen finden Sie unter <u>???</u> .	12. Mai 2020			
Benutzerdefinierte Metriken CloudWatch	Definieren Sie anwendung sspezifische Metriken und geben Sie sie an Amazon CloudWatch Metrics weiter. Weitere Informationen finden Sie unter <u>???</u> .	12. Mai 2020			

Änderung	Beschreibung	Datum
Beispiel: Aus einem Kinesis Stream in einem anderen Konto lesen	Erfahren Sie, wie Sie in Ihrer Managed Service for Apache Flink-Anwendung auf einen Kinesis-Stream in einem anderen AWS Konto zugreifen können. Weitere Informationen finden Sie unter <u>Kontoüber</u> greifend.	30. März 2020
Unterstützung für Apache Flink 1.8.2	Managed Service für Apache Flink unterstützt jetzt Anwendungen, die Apache Flink 1.8.2 verwenden. Verwenden Sie den Streaming FileSink Flink-Anschluss, um die Ausgabe direkt in S3 zu schreiben. Weitere Informati onen finden Sie unter <u>Erstellen</u> <u>einer Anwendung</u> .	17. Dezember 2019
Managed Service für Apache Flink VPC	Konfigurieren Sie eine Anwendung, die Managed Service für Apache Flink nutzt, auf solche Weise, dass sie eine Verbindung zu einer virtuellen privaten Cloud (VPC) herstellt. Weitere Informationen finden Sie unter <u>MSF für den Zugriff auf</u> <u>Ressourcen in einer Amazon</u> <u>VPC konfigurieren</u> .	25. November 2019
Änderung	Beschreibung	Datum
---	--	------------------
Bewährte Methoden für Managed Service für Apache Flink	Bewährte Methoden für die Erstellung und Verwaltung von Managed Service für Apache Flink-Anwendungen. Weitere Informationen finden Sie unter ???.	14. Oktober 2019
Analysieren von Managed Service für Apache Flink-Anw endungsprotokollen	Verwenden Sie CloudWatc h Logs Insights, um Ihre Managed Service for Apache Flink-Anwendung zu überwachen. Weitere Informati onen finden Sie unter <u>???</u> .	26. Juni 2019
Managed Service für Apache Flink-Anwendung Laufzeit- Eigenschaften	Arbeiten Sie mit Laufzeit- Eigenschaften in Managed Service für Apache Flink. Weitere Informationen finden Sie unter <u>Verwenden Sie</u> Laufzeiteigenschaften.	24. Juni 2019
Markieren von Managed Service für Apache Flink-Anw endungen	Verwenden Sie Anwendungs- Tagging zum Bestimmen der Kosten pro Anwendung, zur Kontrolle des Zugriffs oder für benutzerdefinierte Zwecke. Weitere Informationen finden Sie unter <u>Hinzufügen von</u> <u>Tags zu Managed Service für</u> Apache Flink-Anwendungen.	8. Mai 2019

Änderung	Beschreibung	Datum
Protokollierung von Managed Service für Apache Flink API- Aufrufe mit AWS CloudTrail	Managed Service for Apache Flink ist in einen Dienst integriert AWS CloudTrail, der eine Aufzeichnung der Aktionen bereitstellt, die von einem Benutzer, einer Rolle oder einem AWS Dienst in Managed Service für Apache Flink ausgeführt wurden. Weitere Informationen finden Sie unter <u>???</u> .	22. März 2019
Anwendung erstellen (Firehose Sink)	Übung zur Erstellung eines Managed Service für Apache Flink mit einem Amazon Kinesis Kinesis-Datenstream als Quelle und einem Amazon Data Firehose-Stream als Senke. Weitere Informationen finden Sie unter <u>Firehose</u> <u>Senke</u> .	13. Dezember 2018
Öffentliche Freigabe	Dies ist die erste Version des Entwicklerhandbuchs für Managed Service für Apache Flink für Java-Anwendungen.	27. November 2018

Beispielcode für Managed Service für Apache Flink API

Dieses Thema enthält Beispielanforderungsblöcke für Managed Service für Apache Flink-Aktionen.

Um JSON als Eingabe für eine Aktion mit dem AWS Command Line Interface (AWS CLI) zu verwenden, speichern Sie die Anfrage in einer JSON-Datei. Übergeben Sie dann den Dateinamen mithilfe des Parameters --cli-input-json an die Aktion.

Das folgende Beispiel zeigt, wie Sie eine JSON-Datei mit einer Aktion verwenden.

```
$ aws kinesisanalyticsv2 start-application --cli-input-json file://start.json
```

Weitere Informationen zur Verwendung von JSON mit dem AWS CLI finden Sie unter <u>Generate CLI</u> Skeleton und CLI Input JSON Parameters im AWS Command Line Interface Benutzerhandbuch.

Themen

- AddApplicationCloudWatchLoggingOption
- AddApplicationInput
- AddApplicationInputProcessingConfiguration
- AddApplicationOutput
- AddApplicationReferenceDataSource
- AddApplicationVpcConfiguration
- CreateApplication
- CreateApplicationSnapshot
- DeleteApplication
- DeleteApplicationCloudWatchLoggingOption
- <u>DeleteApplicationInputProcessingConfiguration</u>
- DeleteApplicationOutput
- DeleteApplicationReferenceDataSource
- DeleteApplicationSnapshot
- DeleteApplicationVpcConfiguration
- DescribeApplication

- DescribeApplicationSnapshot
- DiscoverInputSchema
- ListApplications
- ListApplicationSnapshots
- StartApplication
- <u>StopApplication</u>
- UpdateApplication

AddApplicationCloudWatchLoggingOption

Der folgende Beispiel-Anforderungscode für die <u>AddApplicationCloudWatchLoggingOption</u>Aktion fügt einer Managed Service for Apache Flink-Anwendung eine CloudWatch Amazon-Protokollierungsoption hinzu:

```
{
    "ApplicationName": "MyApplication",
    "CloudWatchLoggingOption": {
        "LogStreamARN": "arn:aws:logs:us-east-1:123456789123:log-group:my-log-
group:log-stream:My-LogStream"
     },
     "CurrentApplicationVersionId": 2
}
```

AddApplicationInput

Der folgende Beispiel-Anforderungscode für die <u>AddApplicationInput</u>Aktion fügt einer Managed Service for Apache Flink-Anwendung eine Anwendungseingabe hinzu:

```
{
                "Mapping": "$.TICKER",
               "Name": "TICKER_SYMBOL",
               "SqlType": "VARCHAR(50)"
            },
            {
                "SqlType": "REAL",
                "Name": "PRICE",
                 "Mapping": "$.PRICE"
            }
         ],
         "RecordEncoding": "UTF-8",
         "RecordFormat": {
            "MappingParameters": {
               "JSONMappingParameters": {
                   "RecordRowPath": "$"
               }
            },
            "RecordFormatType": "JSON"
         }
      },
      "KinesisStreamsInput": {
         "ResourceARN": "arn:aws:kinesis:us-east-1:012345678901:stream/
ExampleInputStream"
      }
   }
}
```

AddApplicationInputProcessingConfiguration

Der folgende Beispiel-Anforderungscode für die <u>AddApplicationInputProcessingConfiguration</u>Aktion fügt einer Managed Service for Apache Flink-Anwendung eine Konfiguration zur Verarbeitung von Anwendungseingaben hinzu:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 2,
    "InputId": "2.1",
    "InputProcessingConfiguration": {
        "InputLambdaProcessor": {
            "ResourceARN": "arn:aws:lambda:us-
east-1:012345678901:function:MyLambdaFunction"
```

}

```
}
```

AddApplicationOutput

Der folgende Beispiel-Anforderungscode für die <u>AddApplicationOutput</u>Aktion fügt einen Kinesis-Datenstream als Anwendungsausgabe zu einer Managed Service for Apache Flink-Anwendung hinzu:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 2,
    "Output": {
        "DestinationSchema": {
            "RecordFormatType": "JSON"
        },
        "KinesisStreamsOutput": {
            "ResourceARN": "arn:aws:kinesis:us-east-1:012345678901:stream/
ExampleOutputStream"
        },
        "Name": "DESTINATION_SQL_STREAM"
    }
}
```

AddApplicationReferenceDataSource

Der folgende Beispiel-Anforderungscode für die <u>AddApplicationReferenceDataSource</u>Aktion fügt einer Managed Service for Apache Flink-Anwendung eine CSV-Anwendungsreferenzdatenquelle hinzu:

```
"Name": "TICKER",
               "SqlType": "VARCHAR(4)"
            },
            {
               "Mapping": "$.COMPANYNAME",
               "Name": "COMPANY_NAME",
               "SqlType": "VARCHAR(40)"
            },
         ],
         "RecordEncoding": "UTF-8",
         "RecordFormat": {
            "MappingParameters": {
               "CSVMappingParameters": {
                   "RecordColumnDelimiter": " ",
                   "RecordRowDelimiter": "\r\n"
               }
            },
            "RecordFormatType": "CSV"
         }
      },
      "S3ReferenceDataSource": {
         "BucketARN": "arn:aws:s3:::amzn-s3-demo-bucket",
         "FileKey": "TickerReference.csv"
      },
      "TableName": "string"
   }
}
```

AddApplicationVpcConfiguration

Der folgende Beispiel-Anforderungscode für die <u>AddApplicationVpcConfiguration</u>-Aktion fügt einer bestehenden Anwendung eine VPC-Konfiguration hinzu:

```
{
   "ApplicationName": "MyApplication",
   "CurrentApplicationVersionId": 9,
   "VpcConfiguration": {
        "SecurityGroupIds": [ "sg-0123456789abcdef0" ],
        "SubnetIds": [ "subnet-0123456789abcdef0" ]
   }
}
```

CreateApplication

Mit dem folgenden Beispiel-Anforderungscode für die <u>CreateApplication</u>Aktion wird eine Managed Service für Apache Flink-Anwendung erstellt:

```
{
  "ApplicationName": "MyApplication",
  "ApplicationDescription": "My-Application-Description",
  "RuntimeEnvironment":"FLINK-1_15",
  "ServiceExecutionRole":"arn:aws:iam::123456789123:role/myrole",
  "CloudWatchLoggingOptions":[
    {
      "LogStreamARN":"arn:aws:logs:us-east-1:123456789123:log-group:my-log-group:log-
stream:My-LogStream"
    }
  ],
  "ApplicationConfiguration": {
    "EnvironmentProperties":
      {"PropertyGroups":
        Г
          {"PropertyGroupId": "ConsumerConfigProperties",
            "PropertyMap":
              {"aws.region": "us-east-1",
              "flink.stream.initpos": "LATEST"}
          },
          {"PropertyGroupId": "ProducerConfigProperties",
            "PropertyMap":
              {"aws.region": "us-east-1"}
          },
        ]
      },
    "ApplicationCodeConfiguration":{
      "CodeContent":{
        "S3ContentLocation":{
          "BucketARN": "arn: aws: s3::: amzn-s3-demo-bucket",
          "FileKey":"myflink.jar",
          "ObjectVersion": "AbCdEfGhIjKlMnOpQrStUvWxYz12345"
        }
      },
      "CodeContentType":"ZIPFILE"
    },
      "FlinkApplicationConfiguration":{
      "ParallelismConfiguration":{
```

```
"ConfigurationType":"CUSTOM",
    "Parallelism":2,
    "ParallelismPerKPU":1,
    "AutoScalingEnabled":true
    }
  }
}
```

CreateApplicationSnapshot

Der folgende Beispiel-Anforderungscode für die <u>CreateApplicationSnapshot</u>Aktion erstellt eine Momentaufnahme des Anwendungsstatus:

```
{
    "ApplicationName": "MyApplication",
    "SnapshotName": "MySnapshot"
}
```

DeleteApplication

Der folgende Beispiel-Anforderungscode für die <u>DeleteApplication</u>Aktion löscht eine Managed Service for Apache Flink-Anwendung:

```
{"ApplicationName": "MyApplication",
"CreateTimestamp": 12345678912}
```

DeleteApplicationCloudWatchLoggingOption

Der folgende Beispiel-Anforderungscode für die <u>DeleteApplicationCloudWatchLoggingOption</u>Aktion löscht eine CloudWatch Amazon-Protokollierungsoption aus einer Managed Service for Apache Flink-Anwendung:

```
"ApplicationName": "MyApplication",
"CloudWatchLoggingOptionId": "3.1"
"CurrentApplicationVersionId": 3
```

{

}

DeleteApplicationInputProcessingConfiguration

Der folgende Beispiel-Anforderungscode für die <u>DeleteApplicationInputProcessingConfiguration</u>Aktion entfernt eine Konfiguration zur Eingabeverarbeitung aus einer Managed Service for Apache Flink-Anwendung:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 4,
    "InputId": "2.1"
}
```

DeleteApplicationOutput

Der folgende Beispiel-Anforderungscode für die <u>DeleteApplicationOutput</u>Aktion entfernt eine Anwendungsausgabe aus einer Managed Service for Apache Flink-Anwendung:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 4,
    "OutputId": "4.1"
}
```

DeleteApplicationReferenceDataSource

Der folgende Beispiel-Anforderungscode für die <u>DeleteApplicationReferenceDataSource</u>Aktion entfernt eine Anwendungsreferenzdatenquelle aus einer Managed Service for Apache Flink-Anwendung:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 5,
    "ReferenceId": "5.1"
}
```

DeleteApplicationSnapshot

Der folgende Beispiel-Anforderungscode für die <u>DeleteApplicationSnapshot</u>Aktion löscht einen Snapshot des Anwendungsstatus:

{
 "ApplicationName": "MyApplication",
 "SnapshotCreationTimestamp": 12345678912,
 "SnapshotName": "MySnapshot"
}

DeleteApplicationVpcConfiguration

Der folgende Beispiel-Anforderungscode für die <u>DeleteApplicationVpcConfiguration</u>-Aktion entfernt eine bestehende VPC-Konfiguration aus einer Anwendung:

```
{
    "ApplicationName": "MyApplication",
    "CurrentApplicationVersionId": 9,
    "VpcConfigurationId": "1.1"
}
```

DescribeApplication

Der folgende Beispiel-Anforderungscode für die <u>DescribeApplication</u>Aktion gibt Details zu einer Managed Service for Apache Flink-Anwendung zurück:

{"ApplicationName": "MyApplication"}

DescribeApplicationSnapshot

Der folgende Beispiel-Anforderungscode für die <u>DescribeApplicationSnapshot</u>Aktion gibt Details über einen Snapshot des Anwendungsstatus zurück:

```
"ApplicationName": "MyApplication",
"SnapshotName": "MySnapshot"
```

{

}

DiscoverInputSchema

Der folgende Beispiel-Anforderungscode für die <u>DiscoverInputSchema</u>Aktion generiert ein Schema aus einer Streaming-Quelle:

```
{
   "InputProcessingConfiguration": {
      "InputLambdaProcessor": {
         "ResourceARN": "arn:aws:lambda:us-
east-1:012345678901:function:MyLambdaFunction"
      }
   },
   "InputStartingPositionConfiguration": {
      "InputStartingPosition": "NOW"
   },
   "ResourceARN": "arn:aws:kinesis:us-east-1:012345678901:stream/ExampleInputStream",
   "S3Configuration": {
      "BucketARN": "string",
      "FileKey": "string"
   },
   "ServiceExecutionRole": "string"
}
```

Der folgende Beispiel-Anforderungscode für die <u>DiscoverInputSchema</u>Aktion generiert ein Schema aus einer Referenzquelle:

```
{
    "S3Configuration": {
        "BucketARN": "arn:aws:s3:::amzn-s3-demo-bucket",
        "FileKey": "TickerReference.csv"
    },
    "ServiceExecutionRole": "arn:aws:iam::123456789123:role/myrole"
}
```

ListApplications

Der folgende Beispiel-Anforderungscode für die ListApplicationsAktion gibt eine Liste der Managed Service for Apache Flink-Anwendungen in Ihrem Konto zurück:

```
{
    "ExclusiveStartApplicationName": "MyApplication",
    "Limit": 50
}
```

ListApplicationSnapshots

Der folgende Beispiel-Anforderungscode für die <u>ListApplicationSnapshots</u>Aktion gibt eine Liste von Snapshots des Anwendungsstatus zurück:

```
{"ApplicationName": "MyApplication",
    "Limit": 50,
    "NextToken": "aBcDeFgHiJkLmNoPqRsTuVwXyZ0123"
}
```

StartApplication

Der folgende Beispiel-Anforderungscode für die <u>StartApplication</u>Aktion startet eine Managed Service for Apache Flink-Anwendung und lädt den Anwendungsstatus aus dem letzten Snapshot (falls vorhanden):

```
{
    "ApplicationName": "MyApplication",
    "RunConfiguration": {
        "ApplicationRestoreConfiguration": {
            "ApplicationRestoreType": "RESTORE_FROM_LATEST_SNAPSHOT"
            }
      }
}
```

StopApplication

Der folgende Beispiel-Anforderungscode für die Aktion <u>API_STopApplication</u> beendet eine Managed Service for Apache Flink-Anwendung:

```
{"ApplicationName": "MyApplication"}
```

UpdateApplication

Der folgende Beispiel-Anforderungscode für die <u>UpdateApplication</u>Aktion aktualisiert eine Managed Service for Apache Flink-Anwendung, um den Speicherort des Anwendungscodes zu ändern:

Managed Service für Apache Flink API-Referenz

Informationen zu dem APIs , was Managed Service für Apache Flink bereitstellt, finden Sie unter Managed Service for Apache Flink API-Referenz.

Dieser Inhalt wurde in die Release-Versionen verschoben. Siehe Release-Versionen.