



Whitepaper da AWS

Soluções de streaming de dados na AWS com o Amazon Kinesis



Soluções de streaming de dados na AWS com o Amazon Kinesis:

Whitepaper da AWS

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

As marcas comerciais e o visual comercial da Amazon não podem ser usados em conexão com nenhum produto ou serviço que não seja da Amazon, nem de qualquer maneira que possa causar confusão entre os clientes ou que deprecie ou desacredite a Amazon. Todas as outras marcas comerciais que não pertencem à Amazon pertencem a seus respectivos proprietários, que podem ou não ser afiliados, conectados ou patrocinados pela Amazon.

Table of Contents

Resumo	1
Resumo	1
Introdução	2
Cenários de aplicações em tempo real e quase em tempo real	2
Diferença entre processamento em lote e de fluxos	3
Desafios de processamento de streaming	3
Soluções de streaming de dados: exemplos	5
Cenário 1: oferta de Internet com base na localização	5
Amazon Kinesis Data Streams	5
Processar fluxos de dados com AWS Lambda	7
Resumo	8
Cenário 2: dados quase em tempo real para equipes de segurança	8
Amazon Kinesis Data Firehose	9
Resumo	15
Cenário 3: preparar dados de clickstream para processos de insights de dados	15
AWS Glue e streaming do AWS Glue	16
Amazon DynamoDB	18
Endpoints de serviço do Amazon SageMaker e do Amazon SageMaker	18
Inferir insights de dados em tempo real	19
Resumo	19
Cenário 4: detecção e notificações de anomalias em tempo real dos sensores do dispositivo	20
Amazon Kinesis Data Analytics	21
Aplicações Amazon Kinesis Data Analytics for Apache Flink	22
Cenário 5: monitoramento de dados de telemetria em tempo real com o Apache Kafka	24
Amazon Managed Streaming for Apache Kafka (Amazon MSK)	25
Migrar para o Amazon MSK	27
Conclusão e colaboradores	31
Conclusão	31
Colaboradores	31
Revisões do documento	32

Soluções de streaming de dados na AWS

Data de publicação: 1º de setembro de 2021 ([Revisões do documento](#))

Resumo

Engenheiros de dados, analistas de dados e desenvolvedores de big data estão procurando evoluir suas análises de lote para tempo real, para que suas empresas possam aprender sobre o que seus clientes, aplicações e produtos estão fazendo agora e reagir prontamente. Este whitepaper aborda a evolução das análises do lote até o tempo real. Ele descreve como serviços como o [Amazon Kinesis Data Streams](#), o [Amazon Kinesis Data Firehose](#), o [Amazon EMR](#), o [Amazon Kinesis Data Analytics](#) e o [Amazon Managed Streaming for Apache Kafka](#) (Amazon MSK) e outros serviços podem ser usados para implementar aplicações em tempo real e fornecem padrões de design comuns usando esses serviços.

Introdução

Atualmente, as empresas recebem dados em grande escala e velocidade devido ao crescimento explosivo das origens de dados que geram fluxos de dados continuamente. Quer se trate de dados de log de servidores de aplicações, dados de fluxo de cliques de sites e aplicativos móveis ou dados de telemetria de dispositivos de Internet das Coisas (IoT), tudo contém informações que podem ajudar você a aprender sobre o que seus clientes, aplicações e produtos estão fazendo agora.

Ter a capacidade de processar e analisar esses dados em tempo real é essencial para monitorar continuamente suas aplicações a fim de garantir alto tempo de atividade do serviço, bem como para personalizar ofertas promocionais e recomendações de produtos. O processamento em tempo real e quase em tempo real também pode tornar outros casos de uso comuns, como análise de sites e machine learning, mais precisos e acionáveis, disponibilizando dados para essas aplicações em segundos ou minutos, em vez de horas ou dias.

Cenários de aplicações em tempo real e quase em tempo real

Você pode usar serviços de dados de streaming para aplicações em tempo real e quase em tempo real, como monitoramento de aplicações, detecção de fraudes e tabelas de classificação ao vivo. Casos de uso em tempo real exigem latências de ponta a ponta em milissegundos, desde a ingestão até o processamento, até a emissão dos resultados para armazenamentos de dados de destino e outros sistemas. Por exemplo, a Netflix usa o [Amazon Kinesis Data Streams](#) para monitorar as comunicações entre todas as suas aplicações, detectando e corrigindo problemas com rapidez e garantindo um serviço com alto tempo de atividade e disponibilidade aos seus clientes. Embora o caso de uso mais comumente aplicável seja o monitoramento de performance de aplicações, há um número crescente de aplicações em tempo real em tecnologia de anúncios, jogos e IoT que se enquadram nessa categoria.

Casos de uso comuns quase em tempo real incluem análises em armazenamentos de dados para ciência de dados e machine learning (ML). Você pode usar soluções de streaming de dados para carregar continuamente dados em tempo real em seus data lakes. Além disso, é possível atualizar modelos de ML com maior frequência assim que novos dados são disponibilizados, garantindo a precisão e a confiabilidade dos resultados. Por exemplo, a Zillow usa o Kinesis Data Streams para coletar dados de registros públicos e listagens de serviços de listagem múltipla (MLS) e, depois, fornecer aos compradores e vendedores de imóveis as estimativas de valor residencial mais atualizadas quase em tempo real. A ZipRecruiter usa o [Amazon MSK](#) para os pipelines de registro

em log de eventos, que são os componentes essenciais de infraestrutura responsáveis por coletar, armazenar e processar continuamente mais de seis bilhões de eventos por dia no marketplace de ofertas de trabalho ZipRecruiter.

Diferença entre processamento em lote e de fluxos

É necessário ter ferramentas para coletar, preparar e processar dados de streaming em tempo real diferentes daquelas usadas tradicionalmente para análise em lote. Com a análise tradicional, você coleta os dados, carrega-os periodicamente em um banco de dados e os analisa horas, dias ou semanas depois. A análise de dados em tempo real exige uma abordagem diferente. As aplicações de processamento de fluxos processam dados continuamente em tempo real, mesmo antes de serem armazenados. Os dados de streaming podem chegar em um ritmo acelerado, e os volumes de dados podem aumentar e diminuir a qualquer momento. As plataformas de processamento de dados de streaming precisam ser capazes de lidar com a velocidade e a variabilidade dos dados recebidos e processá-los à medida que chegam, geralmente milhões a centenas de milhões de eventos por hora.

Desafios de processamento de streaming

O processamento de dados em tempo real à medida que eles chegam pode permitir que você tome decisões com muito mais rapidez do que é possível com as tecnologias tradicionais de análise de dados. No entanto, criar e operar seus próprios pipelines de dados de streaming personalizados é complicado e consome muitos recursos:

- É necessário criar um sistema que possa, de forma econômica, coletar, preparar e transmitir dados provenientes de milhares de origens de dados simultaneamente.
- Você precisa ajustar os recursos de armazenamento e computação para que os dados sejam agrupados e transmitidos de forma eficiente para obter a máxima taxa de transferência e baixa latência.
- É necessário implantar e gerenciar uma frota de servidores para escalar o sistema a fim de que você possa lidar com as velocidades variadas de dados que serão lançados nele.


A atualização de versão é um processo complexo e caro. Depois de criar essa plataforma, você precisa monitorar o sistema e recuperá-lo de qualquer falha de servidor ou rede, atualizando o processamento de dados do ponto apropriado no fluxo, sem criar dados duplicados. Você também precisa de uma equipe dedicada para o gerenciamento de infraestrutura. Tudo isso exige um tempo

valioso e dinheiro e, no final das contas, a maioria das empresas nunca chega lá, devendo contentar-se com o status quo e operar seus negócios com informações de horas ou dias.

Soluções de streaming de dados: exemplos

Cenário 1: oferta de Internet com base na localização

A empresa InternetProvider fornece serviços de Internet com uma variedade de opções de largura de banda para usuários em todo o mundo. Quando um usuário se cadastra na Internet, a empresa InternetProvider fornece a ele diferentes opções de largura de banda com base na localização geográfica. Devido a esses requisitos, a empresa InternetProvider implementou o Amazon Kinesis Data Streams para consumir detalhes e localização do usuário. Os detalhes do usuário e a localização são enriquecidos com diferentes opções de largura de banda antes da publicação de volta na aplicação. O [AWS Lambda](#) permite esse enriquecimento em tempo real.



Processar fluxos de dados com o AWS Lambda

Amazon Kinesis Data Streams

O [Amazon Kinesis Data Streams](#) permite que você crie aplicações personalizadas em tempo real usando frameworks populares de processamento de fluxos e carregue dados de streaming em vários armazenamentos de dados diferentes. Um fluxo do Kinesis pode ser configurado para receber continuamente eventos de centenas de milhares de produtores de dados entregues a partir de fontes como fluxos de cliques em sites, sensores de IoT, feeds de mídia social e logs de aplicações. Em milissegundos, os dados ficam disponíveis para serem lidos e processados pela sua aplicação.

Ao implementar uma solução com o Kinesis Data Streams, você cria aplicações de processamento de dados personalizadas conhecidas como aplicações do Kinesis Data Streams. Uma aplicação típica do Kinesis Data Streams lê dados de um fluxo do Kinesis como registros de dados.

Os dados colocados no Kinesis Data Streams têm a garantia de ser altamente disponíveis e elásticos, além de estarem disponíveis em milissegundos. É possível adicionar continuamente vários tipos de dados como clickstreams, logs de aplicações e mídia social a um fluxo do Kinesis de

centenas de milhares de fontes. Em segundos, os dados estarão disponíveis para suas [aplicações do Kinesis](#) para leitura e processamento por meio do fluxo.

O Amazon Kinesis Data Streams é um serviço de dados de streaming totalmente gerenciado. Ele gerencia infraestrutura, armazenamento, redes e configuração necessários para transmitir seus dados no nível da sua taxa de transferência de dados.

Enviar dados ao Amazon Kinesis Data Streams

Há várias maneiras de enviar dados ao Kinesis Data Streams, oferecendo flexibilidade nos designs de suas soluções.

- Você pode escrever código usando um dos [AWS SDKs](#) que são compatíveis com várias linguagens populares.
- É possível usar o [Amazon Kinesis Agent](#), uma ferramenta para enviar dados ao Kinesis Data Streams.

A [Amazon Kinesis Producer Library](#) (KPL) simplifica o desenvolvimento de aplicações do produtor, permitindo que os desenvolvedores obtenham alta taxa de transferência de gravação para um ou mais Kinesis Data Streams.

A KPL é uma biblioteca fácil de usar e altamente configurável que você instala em seus hosts. Ela atua como um intermediário entre o código da sua aplicação de produtor e as ações da API do Kinesis Streams. Para obter mais informações sobre a KPL e sua capacidade de produzir eventos de forma síncrona e assíncrona com exemplos de código, consulte [Gravar no Kinesis Data Streams usando a KPL](#).

Existem duas operações diferentes na API do Kinesis Data Streams que adicionam dados a um fluxo: PutRecords e PutRecord. A operação PutRecords envia vários registros ao seu fluxo por solicitação HTTP, enquanto PutRecord envia um registro por solicitação HTTP. Para obter maior taxa de transferência para a maioria das aplicações, use PutRecords.

Para obter mais informações sobre essas APIs, consulte [Adicionar dados a um fluxo](#). Os detalhes de cada operação de API podem ser encontrados na [Referência de API do Amazon Kinesis Data Streams](#).

Processar dados no Amazon Kinesis Data Streams

Para ler e processar dados dos fluxos do Kinesis, você precisa criar uma aplicação de consumidor. Existem várias maneiras de criar consumidores para o Kinesis Data Streams. Algumas dessas

abordagens incluem o uso do [Amazon Kinesis Data Analytics](#) para analisar dados de streaming com o uso da KCL, utilizando o [AWS Lambda](#), [AWS Glue trabalhos de ETL de streaming](#) e o uso direto da API do Kinesis Data Streams.

As aplicações de consumidor para o Kinesis Data Streams podem ser desenvolvidas com o uso da KCL, que ajuda você a consumir e processar dados do Kinesis Data Streams. A KCL se encarrega de muitas das tarefas complexas associadas à computação distribuída, como balanceamento de carga em várias instâncias, resposta a falhas de instância, definição de pontos de verificação de registros processados e reação à reestilhaçamento. A KCL permite que você se concentre em escrever a lógica de processamento de registro. Para obter mais informações sobre como criar sua própria aplicação de KCL, consulte [Usar a biblioteca de cliente do Kinesis](#).

Você pode assinar funções do Lambda para ler automaticamente lotes de registros do fluxo do Kinesis e processá-los se os registros forem detectados no fluxo. O AWS Lambda pesquisa periodicamente o fluxo (uma vez por segundo) em busca de novos registros e, ao detectar novos registros, invoca a função do Lambda transmitindo os novos registros como parâmetros. A função do Lambda só é executada quando novos registros são detectados. É possível mapear uma função do Lambda para um consumidor de taxa de transferência compartilhada (iterador padrão)

Você pode criar um consumidor que use um recurso chamado [distribuição avançada](#) quando você precisa de uma taxa de transferência dedicada que não rivalize com outros consumidores que estejam recebendo dados do fluxo. Esse recurso permite que consumidores recebam registros de um fluxo com taxa de transferência de até 2 MB de dados por segundo por estilhaço.

Na maioria dos casos, é necessário usar o Kinesis Data Analytics, a KCL, o AWS Glue ou o AWS Lambda para processar dados de um fluxo. No entanto, se preferir, você pode criar uma aplicação de consumidor desde o início usando a API do Kinesis Data Streams. A API do Kinesis Data Streams fornece os métodos `GetShardIterator` e `GetRecords` para recuperar dados de um fluxo.

Nesse modelo de extração, seu código extrai dados diretamente dos estilhaços do fluxo. Para obter mais informações sobre como criar sua própria aplicação de consumidor usando a API, consulte [Desenvolver consumidores personalizados com taxa de transferência compartilhada usando o AWS SDK for Java](#). Detalhes sobre a API podem ser encontrados na [Referência de API do Amazon Kinesis Data Streams](#).

Processar fluxos de dados com AWS Lambda

O [AWS Lambda](#) permite executar código sem provisionar ou gerenciar servidores. Com o Lambda, é possível executar código para praticamente qualquer tipo de aplicação ou serviço de back-end

sem nenhuma administração. Faça upload do seu código e o Lambda se encarregará de tudo que for necessário para executar e fazer o ajuste de escala de seu código com alta disponibilidade. Você pode configurar seu código para que ele seja acionado automaticamente por meio de outros serviços da AWS ou chamá-lo diretamente usando qualquer aplicativo móvel ou da web.

O AWS Lambda integra-se nativamente com o Amazon Kinesis Data Streams. As complexidades de pesquisa, ponto de verificação e tratamento de erros são abstraídas quando você usa essa integração nativa. Isso permite que o código de função do Lambda se concentre no processamento da lógica de negócios.

É possível mapear uma função do Lambda para um consumidor de taxa de transferência compartilhada (iterador padrão) ou para um consumidor de taxa de transferência dedicada com distribuição avançada. Com um iterador padrão, o Lambda sonda cada estilhaço no fluxo do Kinesis em busca de registros que usem o protocolo HTTP. Para minimizar a latência e maximizar a taxa de transferência de leitura, é possível criar um consumidor de fluxo de dados com distribuição avançada. Os consumidores de fluxo nessa arquitetura obtêm uma conexão dedicada a cada estilhaço sem competir com outras aplicações que estejam lendo no mesmo fluxo. O Amazon Kinesis Data Streams envia registros ao Lambda por HTTP/2.

Por padrão, o AWS Lambda invoca sua função assim que os registros estão disponíveis no fluxo. Para armazenar em buffer os registros para cenários de lote, você pode implementar uma janela de lote por até cinco minutos na fonte do evento. Se a sua função retornar um erro, o Lambda tentará executar novamente o lote até que o processamento seja bem-sucedido ou os dados expirem.

Resumo

A empresa InternetProvider utilizou o Amazon Kinesis Data Streams para transmitir detalhes e localização do usuário. O fluxo de registro foi consumido pelo AWS Lambda para enriquecer os dados com opções de largura de banda armazenadas na biblioteca da função. Após o enriquecimento, o AWS Lambda publicou as opções de largura de banda de volta para a aplicação. O Amazon Kinesis Data Streams e o AWS Lambda administraram o provisionamento e o gerenciamento de servidores, permitindo que a empresa InternetProvider se concentrasse mais no desenvolvimento de aplicações de negócios.


Cenário 2: dados quase em tempo real para equipes de segurança

A empresa ABC2Badge fornece sensores e crachás para eventos corporativos ou em grande escala, como o [AWS re:Invent](#). Os usuários se cadastram no evento e recebem crachás exclusivos

que os sensores captam em todo o campus. Conforme os usuários passam por um sensor, suas informações anonimizadas são registradas em um banco de dados relacional.

Em um próximo evento, devido ao alto volume de participantes, a equipe de segurança do evento solicitou que a ABC2Badge coletasse dados para as áreas mais concentradas do campus a cada 15 minutos. Isso dará à equipe de segurança tempo suficiente para reagir e dispersar o pessoal de segurança de forma proporcional às áreas concentradas. Considerando-se esse novo requisito da equipe de segurança e a inexperiência na criação de uma solução de streaming, para processar dados quase em tempo real, a ABC2Badge está procurando uma solução simples, mas escalável e confiável.

Sua solução atual de data warehouse é o [Amazon Redshift](#). Ao analisar os recursos dos serviços do Amazon Kinesis, eles perceberam que o Amazon Kinesis Data Firehose pode receber um fluxo de registros de dados, agrupá-los com base no tamanho do buffer e/ou intervalo de tempo e inseri-los no Amazon Redshift. Eles criaram um fluxo de entrega do Kinesis Data Firehose e o configuraram para copiar dados em suas tabelas do Amazon Redshift a cada cinco minutos. Como parte dessa nova solução, eles usaram o agente do Amazon Kinesis nos servidores. A cada cinco minutos, o Kinesis Data Firehose carrega dados no Amazon Redshift, onde a equipe de business intelligence (BI) pode realizar sua análise e enviar os dados à equipe de segurança a cada 15 minutos.



Nova solução usando o Amazon Kinesis Data Firehose

Amazon Kinesis Data Firehose

O [Amazon Kinesis Data Firehose](#) é o modo mais fácil de carregar dados de streaming na AWS. Ele pode capturar, transformar e carregar dados de streaming no [Amazon Kinesis Data Analytics](#), no [Amazon Simple Storage Service](#) (Amazon S3), no [Amazon Redshift](#), [Amazon OpenSearch Service](#) (OpenSearch Service) e no [Splunk](#). Além disso, o Kinesis Data Firehose pode carregar dados de

streaming em qualquer endpoint HTTP personalizado ou endpoints HTTP pertencentes a [provedores de serviços terceiros](#) compatíveis.

O Kinesis Data Firehose viabiliza análises quase em tempo real com ferramentas e painéis de business intelligence que você já usa no momento. Trata-se de um serviço sem servidor totalmente gerenciado que escala automaticamente para corresponder à taxa de transferência dos dados e exige administração contínua. O Kinesis Data Firehose pode separar em lotes, compactar e criptografar os dados antes de carregá-los, o que minimiza o volume de armazenamento usado no destino e aumenta a segurança. Ele também pode transformar os dados da fonte com o uso do AWS Lambda e entregar os dados transformados aos destinos. Você configura os produtores de dados para enviar dados ao Kinesis Data Firehose, e ele os entrega automaticamente ao destino especificado.

Enviar dados para um fluxo de entrega do Firehose

Para enviar dados para o fluxo de entrega, existem várias opções. A AWS oferece SDKs para muitas linguagens de programação populares, sendo que cada uma fornece APIs para o [Amazon Kinesis Data Firehose](#). A AWS tem um utilitário para ajudar a enviar dados ao seu fluxo de entrega. O Kinesis Data Firehose foi integrado a outros serviços da AWS para enviar dados diretamente desses serviços ao fluxo de entrega.

Usar o Amazon Kinesis Agent

O [Amazon Kinesis Agent](#) é uma aplicação de software independente que monitora continuamente um conjunto de arquivos de log para que novos dados sejam enviados ao fluxo de entrega. O agente lida automaticamente com a rotação de arquivos, pontos de verificação, novas tentativas em caso de falhas e emite métricas do [Amazon CloudWatch](#) para monitoramento e solução de problemas do fluxo de entrega. Configurações adicionais, como pré-processamento de dados, monitoramento de vários diretórios de arquivos e gravação em vários fluxos de entrega, podem ser aplicadas ao agente.

O agente pode ser instalado em servidores baseados em Linux ou Windows, como servidores web, servidores de log e servidores de banco de dados. Depois que o agente estiver instalado, bastará especificar os arquivos de log que ele monitorará e o fluxo de entrega para o qual ele fará os envios. O agente enviará novos dados de forma durável e confiável para o fluxo de entrega.

Usar a API com o AWS SDK e os serviços da AWS como fonte

A API do Kinesis Data Firehose oferece duas operações para enviar dados para o fluxo de entrega. O PutRecord envia um registro de dados em uma chamada. O PutRecordBatch pode enviar

vários registros de dados em uma chamada e pode atingir maior taxa de transferência por produtor. Em cada método, é necessário especificar o nome do fluxo de entrega e o registro de dados, ou matriz de registros de dados, ao usar esse método. Para obter mais informações e código de exemplo para as operações da API do Kinesis Data Firehose, consulte [Gravar em um fluxo de entrega do Firehose usando o AWS SDK](#).

O Kinesis Data Firehose também é executado com o [Kinesis Data Firehose](#), o [CloudWatch Logs](#), o [CloudWatch Events](#), o [Amazon Simple Notification Service](#) (Amazon SNS), o [Amazon API Gateway](#) e o [AWS IoT](#). É possível enviar fluxos de dados, logs, eventos e dados de IoT de maneira escalável e confiável diretamente para um destino do Kinesis Data Firehose.

Processar dados antes da entrega ao destino

Em alguns cenários, é recomendável transformar ou aprimorar seus dados de streaming antes que eles sejam entregues ao destino. Por exemplo, os produtores de dados podem enviar texto não estruturado em cada registro de dados, e você precisa transformá-lo em JSON antes de entregá-lo ao [OpenSearch Service](#). Ou talvez você queira converter os dados JSON em um formato de arquivo em colunas, como o [Apache Parquet](#) ou o [Apache ORC](#), antes de armazenar os dados no [Amazon S3](#).

O Kinesis Data Firehose tem capacidade de [conversão de formato](#) de dados integrada. Com isso, você pode converter facilmente seus fluxos de dados JSON em formatos de arquivo Apache Parquet ou Apache ORC.

Fluxo de transformação de dados

Para habilitar [transformações de dados](#) de streaming, o Kinesis Data Firehose usa uma função do Lambda criada por você para transformar seus dados. O Kinesis Data Firehose armazena os dados recebidos em um tamanho de buffer especificado para a função e, depois, chama a função do Lambda especificada de forma assíncrona. Os dados transformados são enviados do Lambda ao Kinesis Data Firehose, e o Kinesis Data Firehose entrega os dados ao destino.

Conversão de formato de dados

Você também pode habilitar a [conversão de formato de dados](#) do Kinesis Data Firehose, que converterá seu fluxo de dados JSON em Apache Parquet ou Apache ORC. Esse recurso só pode converter JSON em Apache Parquet ou Apache ORC. Se você tiver dados em CSV, poderá transformá-los em JSON com o uso de uma função do Lambda e, depois, aplicar a conversão do formato de dados.

Entrega de dados

Como um fluxo de entrega quase em tempo real, o Kinesis Data Firehose armazena os dados recebidos em buffer. Depois que os limites de buffer do fluxo de entrega forem atingidos, seus dados serão entregues ao destino configurado. Há algumas diferenças na forma como o Kinesis Data Firehose [entrega dados para cada destino](#) que serão analisadas nas próximas seções deste artigo.

Amazon S3

O [Amazon S3](#) é um armazenamento de objetos com uma interface de web service simples para armazenar e recuperar qualquer quantidade de dados, de qualquer parte da Web. Ele foi projetado para oferecer uma resiliência de 99,999999999% e escalar para mais de 1 trilhão de objetos em todo o mundo.

Entrega de dados para o Amazon S3

Para a entrega de dados para o Amazon S3, o Kinesis Data Firehose concatena vários registros de entrada com base na configuração de buffer do fluxo de entrega e os entrega ao Amazon S3 como um objeto do S3. A frequência de entrega de dados para o S3 é determinada pelo tamanho do buffer do S3 (1 MB a 128 MB) ou pelo intervalo do buffer (60 segundos a 900 segundos), o que ocorrer primeiro.

A entrega de dados para o bucket do S3 pode apresentar falha por vários motivos. Por exemplo, o bucket pode não existir mais ou a função do [AWS Identity and Access Management](#) (IAM) https://docs.aws.amazon.com/IAM/latest/UserGuide/id_roles.html que o Kinesis Data Firehose assume pode não ter acesso ao bucket. Nessas condições, o Kinesis Data Firehose continua executando novas tentativas por até 24 horas até que a entrega seja bem-sucedida. O tempo máximo de armazenamento de dados do Kinesis Data Firehose é de 24 horas. Se a entrega de dados apresentar falha por mais de 24 horas, os dados serão perdidos.

Amazon Redshift


O [Amazon Redshift](#) é um data warehouse rápido e totalmente gerenciado que torna simples e econômica a análise de todos os seus dados usando ferramentas SQL padrão e ferramentas de BI que você já tem. O serviço permite executar consultas complexas de análise em petabytes de dados estruturados, usando otimização de consultas sofisticada, armazenamento em colunas em discos locais de alta performance e execução paralela massiva de consultas.

Entrega de dados para o Amazon Redshift

Para a entrega de dados ao Amazon Redshift, o Kinesis Data Firehose primeiro entrega os dados recebidos ao bucket do S3 no formato descrito anteriormente. Depois, o Kinesis Data Firehose emite um comando COPY do Amazon Redshift para carregar os dados do bucket do S3 para o cluster do Amazon Redshift.

A frequência das operações COPY de dados do S3 para o Amazon Redshift é determinada de acordo com a velocidade com a qual o cluster do Amazon Redshift consegue finalizar o comando COPY. Para um destino do Amazon Redshift, você pode especificar uma duração de repetição (0 a 7.200 segundos) ao criar um fluxo de entrega para lidar com falhas de entrega de dados. O Kinesis Data Firehose faz novas tentativas pelo período especificado e ignorará esse lote específico de objetos do S3 se não for bem-sucedido. As informações dos objetos ignorados são entregues ao bucket do S3 como um arquivo manifesto na pasta errors/, que você pode usar para alocação manual.

Veja a seguir um diagrama de arquitetura do fluxo de dados do Kinesis Data Firehose para o Amazon Redshift. Embora esse fluxo de dados seja exclusivo do Amazon Redshift, o Kinesis Data Firehose segue padrões semelhantes para os outros destinos.



Fluxo de dados do Kinesis Data Firehose para o Amazon Redshift

Amazon OpenSearch Service (OpenSearch Service)

[OpenSearch Service](#) é um serviço totalmente gerenciado que fornece as APIs fáceis de usar do OpenSearch e recursos em tempo real, além da disponibilidade, da escalabilidade e da segurança exigidas pelas workloads de produção. O OpenSearch Service facilita a implantação, a operação e a escala do OpenSearch para análise de logs, pesquisa de texto completo e monitoramento de aplicações.

Entrega de dados ao OpenSearch Service

Para entrega de dados ao OpenSearch Service, o Kinesis Data Firehose armazena os registros recebidos em buffer com base na configuração de armazenamento em buffer do fluxo de entrega e, depois, gera uma solicitação em massa do OpenSearch para indexar vários registros no cluster do OpenSearch. A frequência de entrega de dados ao OpenSearch Service é determinada pelos valores de tamanho do buffer do OpenSearch (1 MB a 100 MB) e do intervalo de buffer (60 segundos a 900 segundos), o que ocorrer primeiro.

No destino do OpenSearch Service, você pode especificar uma duração de nova tentativa (0 a 7.200 segundos) ao criar um fluxo de entrega. O Kinesis Data Firehose executa novas tentativas pelo período especificado e, depois, ignora essa solicitação de índice específica. Os documentos ignorados são entregues ao bucket do S3 na pasta `elasticsearch_failed/`, que você pode usar para alocação manual.

O Amazon Kinesis Data Firehose pode alternar o índice do OpenSearch Service com base em uma duração. Dependendo da opção de rotação escolhida (`NoRotation`, `OneHour`, `OneDay`, `OneWeek` ou `OneMonth`), o Kinesis Data Firehose anexa uma parte do carimbo de data/hora de chegada no Tempo Universal Coordenado (UTC) ao nome de índice especificado.

Endpoint HTTP personalizado ou provedor de serviços de terceiros compatível

O Kinesis Data Firehose pode enviar dados para endpoints HTTP personalizados ou provedores terceiros compatíveis, como Datadog, Dynatrace, LogicMonitor, MongoDB, New Relic, Splunk e Sumo Logic.

Endpoint HTTP personalizado ou provedor de serviços de terceiros compatível

Para que o Kinesis Data Firehose forneça dados com êxito a endpoints HTTP personalizados, esses endpoints devem aceitar solicitações e enviar respostas usando determinados formatos de solicitação e resposta do Kinesis Data Firehose.

Ao fornecer dados a um endpoint HTTP de propriedade de um provedor de serviços terceiro compatível, você pode usar o serviço AWS Lambda integrado para criar uma função com o objetivo de transformar o(s) registro(s) de entrada no formato esperado pela integração do provedor de serviços.

Para a frequência de entrega de dados, cada provedor de serviços tem um tamanho de buffer recomendado. Trabalhe com seu provedor de serviços para obter mais informações sobre o tamanho

recomendado do buffer. Para o tratamento de falhas na entrega de dados, o Kinesis Data Firehose estabelece uma conexão com o endpoint HTTP primeiro aguardando uma resposta do destino. O Kinesis Data Firehose continua estabelecendo conexão até que a duração da nova tentativa expire. Depois, o Kinesis Data Firehose considera isso uma falha de entrega e faz backup dos dados no bucket do S3.

Resumo

O Kinesis Data Firehose pode entregar persistentemente seus dados de streaming a um destino compatível. É uma solução totalmente gerenciada, que requer pouco ou nenhum desenvolvimento. Para a empresa ABC2Badge, o uso do Kinesis Data Firehose foi uma escolha natural. Eles já estavam usando o Amazon Redshift como sua solução de data warehouse. Como suas origens de dados faziam gravações contínuas em logs de transações, conseguiram utilizar o Amazon Kinesis Agent para fazer streaming desses dados sem escrever nenhum código adicional. Agora que a empresa ABC2Badge criou um fluxo de registros de sensores e está recebendo esses registros por meio do Kinesis Data Firehose, eles podem usar isso como base para o caso de uso da equipe de segurança.

Cenário 3: preparar dados de clickstream para processos de insights de dados

A Fast Sneakers é uma boutique de moda com foco em tênis modernos. O preço de qualquer par de sapatos pode subir ou descer dependendo do estoque e das tendências, por exemplo, qual celebridade ou estrela do esporte foi vista usando um tênis de marca na TV na noite passada. É importante que a Fast Sneakers acompanhe e analise essas tendências para maximizar sua receita.

A Fast Sneakers não quer introduzir sobrecarga adicional no projeto com nova infraestrutura para manter. Eles querem ter a capacidade de dividir o desenvolvimento com as partes apropriadas e que os engenheiros de dados possam se concentrar na transformação de dados e os cientistas de dados possam trabalhar em sua funcionalidade de ML de forma independente.

Para reagir de forma rápida e ajustar automaticamente os preços de acordo com a demanda, a Fast Sneakers transmite eventos significativos (como dados de compras e cliques em áreas de interesse), transformando e aumentando os dados do evento e alimentando-os em um modelo de ML. Seu modelo de ML é capaz de determinar se um ajuste de preço é necessário. Isso permite que a Fast Sneakers modifique automaticamente seus preços para maximizar o lucro de seus produtos.



Ajustes de preços em tempo real da Fast Sneakers

Este diagrama de arquitetura mostra a solução de streaming em tempo real que a Fast Sneakers criou utilizando o Kinesis Data Streams, o AWS Glue e o DynamoDB Streams. Ao aproveitar esses serviços, eles têm uma solução elástica e confiável, sem a necessidade de perder tempo configurando e mantendo a infraestrutura de suporte. Eles podem dedicar seu tempo ao que agrega valor para sua empresa, concentrando-se em um trabalho de extração, transformação e carga (ETL) de streaming e seu modelo de machine learning.

Para entender melhor a arquitetura e as tecnologias usadas em sua workload, veja alguns detalhes dos serviços usados.

AWS Glue e streaming do AWS Glue

[AWS Glue](#) é um serviço ETL totalmente gerenciado que você pode usar para catalogar seus dados, limpá-los, enriquecê-los e movê-los de forma confiável entre armazenamentos de dados. Com o AWS Glue, é possível reduzir significativamente o custo, a complexidade e o tempo gasto na criação de trabalhos de ETL. O AWS Glue não tem servidor, portanto, não há infraestrutura para configurar ou gerenciar. Você paga apenas pelos recursos consumidos durante a execução dos trabalhos.

Ao utilizar o AWS Glue, você pode criar uma aplicação de consumidor com um [trabalho ETL de streaming do AWS Glue](#). Dessa forma, você pode utilizar o Apache Spark e outros módulos baseados no Spark para consumir e processar seus dados de eventos. A próxima seção deste documento aborda mais detalhadamente esse cenário.

AWS Glue Data Catalog

O [AWS Glue Data Catalog](#) contém referências aos dados que são usados como fontes e destinos de seus trabalhos de ETL no AWS Glue. O AWS Glue Data Catalog é um índice para as métricas de localização, esquema e tempo de execução dos seus dados. Use as informações no Catálogo de dados para criar e monitorar seus trabalhos de ETL. As informações no Catálogo de dados são armazenadas como tabelas de metadados, em que cada tabela especifica um único armazenamento de dados. Ao configurar um rastreador, você pode avaliar automaticamente vários tipos de armazenamentos de dados, incluindo armazenamentos conectados do DynamoDB, do S3 e do Java Database Connectivity (JDBC), extrair metadados e esquemas e, depois, criar definições de tabela no AWS Glue Data Catalog.

Para trabalhar com o Amazon Kinesis Data Streams em trabalhos de ETL de streaming do AWS Glue, é uma prática recomendada definir seu fluxo em uma tabela em um banco de dados AWS Glue Data Catalog. Você define uma tabela originária do fluxo com o fluxo do Kinesis, um dos muitos formatos compatíveis (CSV, JSON, ORC, Parquet, Avro ou um formato de cliente com Grok). É possível inserir manualmente um esquema ou deixar essa etapa para o trabalho do AWS Glue determinar durante o tempo de execução do trabalho.

Trabalho de ETL de streaming do AWS Glue

O [AWS Glue](#) executa seus trabalhos de ETL em um ambiente sem servidor Apache Spark. O AWS Glue executa esses trabalhos em recursos virtuais que ele provisiona e gerencia na sua própria conta de serviço. Além de poder executar trabalhos baseados no Apache Spark, o AWS Glue fornece um nível adicional de funcionalidade além do Spark com o [DynamicFrames](#).

O DynamicFrames são tabelas distribuídas que são compatíveis com dados aninhados, como estruturas e matrizes. Cada registro é autodescritivo, projetado para flexibilidade de esquema com dados semiestruturados. Um registro em um DynamicFrame contém os dados e o esquema que descreve os dados. Tanto o Apache Spark DataFrames quanto o DynamicFrames são compatíveis com seus scripts ETL, e você pode convertê-los livremente. O DynamicFrames fornece um conjunto de transformações avançadas para limpeza de dados e ETL.

Ao usar o Spark Streaming em seu trabalho do AWS Glue, você pode criar trabalhos de ETL de streaming que são executados continuamente e consumir dados de fontes de streaming, como o Amazon Kinesis Data Streams, o Apache Kafka e o Amazon MSK. Os trabalhos podem limpar, mesclar e transformar os dados e, depois, carregar os resultados em armazenamentos, incluindo armazenamentos de dados do Amazon S3, do Amazon DynamoDB ou do JDBC.

Por padrão, o AWS Glue processa e grava dados em janelas de 100 segundos. Isso permite que os dados sejam processados de forma eficiente e que as agregações sejam realizadas em dados que chegam mais tarde do que o esperado. Você pode configurar o tamanho da janela ajustando-a para acomodar a velocidade da resposta em comparação com a precisão da sua agregação. Os trabalhos de streaming do AWS Glue usam pontos de verificação para rastrear os dados lidos do Kinesis Data Stream. Para obter uma demonstração da criação de um trabalho de ETL de streaming no AWS Glue, consulte [Adicionar trabalhos de ETL de streaming ao AWS Glue](#)

Amazon DynamoDB

O [Amazon DynamoDB](#) é um banco de dados de chave-valor e documentos que oferece performance abaixo de 10 milissegundos em qualquer escala. É um banco de dados totalmente gerenciado, multirregional, multiativo e durável com segurança, backup e restauração integrados e armazenamento em cache na memória para aplicações em escala de Internet. O DynamoDB pode processar mais de 10 trilhões de solicitações por dia e comportar picos de mais de 20 milhões de solicitações por segundo.

Captura de dados de alteração do DynamoDB Streams

Um [fluxo do DynamoDB](#) é um fluxo ordenado de informações sobre alterações em itens de uma tabela do DynamoDB. Quando você ativa um fluxo em uma tabela, o DynamoDB captura informações sobre todas as modificações em itens de dados na tabela. O DynamoDB é executado no AWS Lambda para que você possa criar acionadores, ou seja, partes de código que respondem automaticamente a eventos no DynamoDB Streams. Com os acionadores, você pode criar aplicações que reagem às modificações de dados em tabelas do DynamoDB.

Quando um fluxo é habilitado em uma tabela, você pode associar o [Nome de recurso da Amazon](#) (ARN) do fluxo a uma função do Lambda criada por você. Imediatamente após um item da tabela ser modificado, um novo registro é exibido no fluxo da tabela. O AWS Lambda faz uma sondagem no fluxo e invoca a função do Lambda de forma síncrona ao detectar novos registros de fluxo.

Endpoints de serviço do Amazon SageMaker e do Amazon SageMaker

O [Amazon SageMaker](#) é uma plataforma totalmente gerenciada que permite que desenvolvedores e cientistas de dados criem, treinem e implantem modelos de ML rapidamente e em qualquer escala. O SageMaker inclui módulos que podem ser usados em conjunto ou de forma independente para criar, treinar e implantar modelos de ML. Com os [endpoints de serviço do Amazon SageMaker](#), você pode criar um endpoint hospedado gerenciado para inferência em tempo real com um modelo implantado desenvolvido dentro ou fora do Amazon SageMaker.

Ao utilizar o AWS SDK, você pode invocar um endpoint do SageMaker transmitindo informações de tipo de conteúdo junto com o conteúdo e, depois, receber previsões em tempo real com base nos dados transmitidos. Isso permite que você mantenha o design e o desenvolvimento de seus modelos de ML separados do código que executa ações nos resultados inferidos.

Isso permite que os cientistas de dados se concentrem no ML e os desenvolvedores que estão usando o modelo de ML se concentrem na forma como o usam no código. Para obter mais informações sobre como invocar um endpoint no SageMaker, consulte [InvokeEndpoint na Referência de API do Amazon SageMaker](#).

Inferir insights de dados em tempo real

O diagrama de arquitetura anterior mostra que a aplicação web existente da Fast Sneakers adicionou um Kinesis Data Stream contendo eventos de clickstream, que fornece dados de tráfego e eventos do site. O catálogo de produtos, que contém informações como categorização, atributos do produto e preços, e a tabela de pedidos, que tem dados como itens pedidos, faturamento, remessa, etc., são tabelas separadas do DynamoDB. A fonte do fluxo de dados e as tabelas apropriadas do DynamoDB têm seus metadados e esquemas definidos no AWS Glue Data Catalog a serem usados pelo trabalho de ETL de streaming do AWS Glue.

Ao utilizar o Apache Spark, o streaming do Spark e o DynamicFrames em seu trabalho de ETL de streaming do AWS Glue, a Fast Sneakers consegue extrair dados de qualquer fluxo de dados e transformá-los mesclando dados das tabelas de produtos e pedidos. Com os dados hidratados da transformação, os conjuntos de dados dos quais obter resultados de inferência são enviados para uma tabela do DynamoDB.

O fluxo do DynamoDB para a tabela aciona uma função do Lambda para cada novo registro gravado. A função do Lambda envia os registros transformados anteriormente a um endpoint do SageMaker com o AWS SDK para inferir quais ajustes de preço são necessários para um produto, se for o caso. Se o modelo de ML identificar que um ajuste no preço é necessário, a função do Lambda gravará a alteração de preço no produto na tabela do catálogo do DynamoDB.

Resumo


O Amazon Kinesis Data Streams facilita a coleta, o processo e a análise de dados de streaming em tempo real, permitindo que você obtenha insights oportunos e reaja rapidamente às novas informações. Combinado com o serviço de integração de dados do AWS Glue sem servidor, você pode criar aplicações de streaming de eventos em tempo real que preparam e combinam dados para ML.

Como o Kinesis Data Streams e os serviços do AWS Glue são totalmente gerenciados, a AWS elimina o esforço indiferenciado de gerenciar a infraestrutura da sua plataforma de big data, permitindo que você se concentre na geração de insights de dados com base nos seus dados.

A Fast Sneakers pode utilizar o processamento de eventos em tempo real e o ML para permitir que seu site faça ajustes de preços em tempo real totalmente automatizados, para maximizar o estoque de produtos. Isso traz o máximo valor para seus negócios, evitando a necessidade de criar e manter uma plataforma de big data.

Cenário 4: detecção e notificações de anomalias em tempo real dos sensores do dispositivo

A empresa ABC4Logistics transporta produtos petrolíferos altamente inflamáveis, como gasolina, propano líquido (GLP) e nafta do porto para várias cidades. Existem centenas de veículos que possuem vários sensores instalados para monitorar fatores como localização, temperatura do motor, temperatura dentro do contêiner, velocidade de condução, localização do estacionamento, condições da estrada, etc. Um dos requisitos da ABC4Logistics é monitorar as temperaturas do motor e do contêiner em tempo real e alertar o motorista e a equipe de monitoramento da frota em caso de qualquer anomalia. Para detectar essas condições e gerar alertas em tempo real, a ABC4Logistics implementou na AWS a arquitetura a seguir.



Arquitetura de detecção de anomalias e notificações em tempo real de sensores de dispositivos da ABC4Logistics

Os dados dos sensores de dispositivos são ingeridos pelo AWS IoT Gateway, no qual o mecanismo de [regras de AWS IoT](#) disponibilizará os dados de streaming no Amazon Kinesis Data Streams. Usando o Kinesis Data Analytics, a ABC4Logistics pode realizar a análise em tempo real dos dados de streaming no Kinesis Data Streams.

Usando o Kinesis Data Analytics, a ABC4Logistics pode detectar se as leituras de temperatura dos sensores se desviam das leituras normais durante um período de dez segundos e ingerir o registro em outra instância do Kinesis Data Streams, identificando os registros anômalos. Depois, o Amazon Kinesis Data Streams invoca funções do Lambda, que podem enviar alertas ao motorista e à equipe de monitoramento da frota por meio do Amazon SNS.

Os dados no Kinesis Data Streams também são enviados para o Amazon Kinesis Data Firehose. O Amazon Kinesis Data Firehose mantém esses dados no Amazon S3, permitindo que a ABC4Logistics realize análises em lote ou quase em tempo real nos dados do sensor. A ABC4Logistics usa o [Amazon Athena](#) para consultar dados no S3 e o [Amazon QuickSight](#) para visualizações. Para retenção de dados de longo prazo, a política de [ciclo de vida do S3](#) é usada para arquivar dados no [Amazon S3 Glacier](#).

Os componentes importantes dessa arquitetura são detalhados a seguir.

Amazon Kinesis Data Analytics

O [Amazon Kinesis Data Analytics](#) permite transformar e analisar dados de streaming e responder a anomalias em tempo real. É um serviço sem servidor na AWS, o que significa que o Kinesis Data Analytics se encarrega do provisionamento e escala elasticamente a infraestrutura para lidar com qualquer taxa de transferência de dados. Isso elimina todo o esforço indiferenciado de configurar e gerenciar a infraestrutura de streaming e permite que você dedique mais tempo à criação de aplicações de streaming.

Com o Amazon Kinesis Data Analytics, é possível consultar dados de streaming de forma interativa usando várias opções, incluindo SQL padrão, aplicações Apache Flink em Java, Python e Scala, e criar aplicações Apache Beam usando Java para analisar fluxos de dados.

Essas opções oferecem a flexibilidade de usar uma abordagem específica, dependendo do nível de complexidade da aplicação de streaming e do suporte à fonte/destino. A seção a seguir discute a opção Kinesis Data Analytics for Flink Applications.


Aplicações Amazon Kinesis Data Analytics for Apache Flink

O [Apache Flink](#) é uma framework popular de código aberto e um mecanismo de processamento distribuído para cálculos com estado em [fluxos de dados ilimitados e limitados](#). O Apache Flink foi projetado para realizar cálculos na velocidade da memória e em escala com suporte para a semântica do tipo exatamente uma vez (exactly-once). As aplicações baseadas no Apache Flink ajudam a obter baixa latência com alta taxa de transferência de maneira tolerante a falhas.

Com o [Amazon Kinesis Data Analytics for Apache Flink](#), você pode criar e executar código em fontes de streaming para executar análises de séries temporais, alimentar painéis em tempo real e criar métricas em tempo real sem gerenciar o complexo ambiente distribuído do Apache Flink. É possível usar os recursos de programação de alto nível do Flink da mesma forma que os usa ao hospedar a infraestrutura do Flink.

O Kinesis Data Analytics for Apache Flink permite criar aplicações em Java, Scala, Python ou SQL para processar e analisar dados de streaming. Uma aplicação típica do Flink lê os dados do fluxo de entrada, do local ou da origem de dados, transforma/filtra ou une dados usando operadores ou funções e armazena os dados no fluxo de saída ou no local de dados ou no coletor.

O diagrama de arquitetura a seguir mostra algumas das fontes e coletores compatíveis com a aplicação Kinesis Data Analytics Flink. Além dos conectores pré-agrupados para fonte/coletor, você também pode utilizar conectores personalizados para uma variedade de outras fontes/coletores para aplicações Flink no Kinesis Data Analytics.



Aplicação Apache Flink no Kinesis Data Analytics para processamento de fluxos em tempo real

Os desenvolvedores podem usar seu IDE preferido para desenvolver aplicações do Flink e implantá-las no Kinesis Data Analytics a partir de ferramentas [AWS Management Console](#) ou DevOps.

Amazon Kinesis Data Analytics Studio

Como parte do serviço Kinesis Data Analytics, o [Kinesis Data Analytics Studio](#) está disponível para que os clientes consultem fluxos de dados interativamente em tempo real e criem e executem facilmente aplicações de processamento de fluxos usando SQL, Python e Scala. Os cadernos Studio são equipados com o [Apache Zeppelin](#).

Usando o [caderno Studio](#), você tem a capacidade de desenvolver o código da aplicação Flink em um ambiente de caderno, visualizar os resultados do seu código em tempo real e visualizá-lo em seu caderno. Você pode criar um caderno Studio com tecnologia Apache Zeppelin e Apache Flink com um único clique no console do Kinesis Data Streams e do Amazon MSK, ou iniciá-lo no console do Kinesis Data Analytics.

Depois de desenvolver o código iterativamente como parte do Kinesis Data Analytics Studio, você poderá implantar um caderno como uma aplicação de análise de dados do Kinesis para ser executada no modo de streaming continuamente, lendo dados de suas fontes, gravando em seus destinos, mantendo o estado da aplicação de longa execução escalando automaticamente com base na taxa de transferência de seus fluxos de origem. Anteriormente, os clientes usavam o [Kinesis Data Analytics for SQL Applications](#) para essa análise interativa de dados de streaming em tempo real na AWS.

O Kinesis Data Analytics for SQL ainda está disponível, mas para novos projetos, a AWS recomenda que você use o novo [Kinesis Data Analytics Studio](#). O Kinesis Data Analytics Studio combina facilidade de uso com recursos analíticos avançados, permitindo que você crie aplicações sofisticadas de processamento de fluxos em minutos.

Para tornar a aplicação Kinesis Data Analytics Flink tolerante a falhas, você pode usar pontos de verificação e snapshots, conforme descrito em [Implementar tolerância a falhas no Kinesis Data Analytics for Apache Flink](#).

As aplicações Kinesis Data Analytics Flink são úteis para criar aplicações complexas de análise de streaming, como aplicações com [semântica do tipo exatamente uma vez](#) de processamento de dados, recursos de ponto de verificação e processamento de dados de origens de dados, como Kinesis Data Streams, Kinesis Data Firehose, Amazon MSK, Rabbit MQ e Apache Cassandra, incluindo conectores personalizados.

Depois de processar dados de streaming na aplicação Flink, você pode manter os dados em vários coletores ou destinos, como Amazon Kinesis Data Streams, Amazon Kinesis Data Firehose, Amazon DynamoDB, Amazon OpenSearch Service, Amazon Timestream, Amazon S3, etc. A aplicação Kinesis Data Analytics Flink também oferece garantias de performance abaixo de um segundo.

Aplicações Apache Beam para Kinesis Data Analytics

O [Apache Beam](#) é um modelo de programação para processamento de dados de streaming. O Apache Beam fornece uma camada de API portátil para criar pipelines sofisticados de processamento paralelo de dados que podem ser executados em uma diversidade de mecanismos ou executores como Flink, Spark Streaming, Apache Samza, etc.

É possível usar a framework do Apache Beam com sua aplicação do Kinesis Data Analytics para processar dados de streaming. As aplicações do Kinesis Data Analytics que usam o Apache Beam usam o [Apache Flink Runner](#) para executar pipelines do Beam.

Resumo

Ao usar os serviços de streaming do AWS Amazon Kinesis Data Streams, do Amazon Kinesis Data Analytics e do Amazon Kinesis Data Firehose,


A ABC4Logistics pode detectar padrões anômalos nas leituras de temperatura e notificar o motorista e a equipe de gerenciamento de frota em tempo real, evitando acidentes graves, como avaria completa do veículo ou incêndio.

Cenário 5: monitoramento de dados de telemetria em tempo real com o Apache Kafka

A ABC1Cabs é uma empresa de serviços de reserva de táxi on-line. Todas as cabines têm dispositivos IoT que coletam dados de telemetria dos veículos. Atualmente, a ABC1Cabs está executando clusters do Apache Kafka projetados para consumo de eventos em tempo real, reunindo métricas de integridade do sistema, rastreamento de atividades e alimentando os dados na plataforma Apache Spark Streaming criada em um cluster do Hadoop on-premises.

A ABC1Cabs usa o OpenSearch Dashboards para métricas de negócios, depuração, alertas e criação de outros painéis. Eles estão interessados no Amazon MSK, no Amazon EMR com Spark Streaming e no OpenSearch Service com OpenSearch Dashboards. Seu requisito é reduzir a sobrecarga administrativa da manutenção de clusters do Apache Kafka e do Hadoop, ao mesmo

tempo em que usam softwares e APIs de código aberto conhecidos para orquestrar o pipeline de dados. O diagrama de arquitetura a seguir mostra a solução deles na AWS.



Processamento em tempo real com o Amazon MSK e o processamento de fluxos usando o Apache Spark Streaming no Amazon EMR e Amazon OpenSearch Service com o OpenSearch Dashboards

Os dispositivos IoT das cabines coletam dados de telemetria e os enviam para um hub de origem. O hub de origem está configurado para enviar dados em tempo real para o Amazon MSK. Usando as APIs da biblioteca de produtores do Apache Kafka, o Amazon MSK é configurado para transmitir os dados em um cluster do Amazon EMR. O cluster do Amazon EMR tem um cliente Kafka e o Spark Streaming instalados para poder consumir e processar os fluxos de dados.

O Spark Streaming tem conectores de coletor que podem gravar dados diretamente em índices definidos do Elasticsearch. Os clusters do Elasticsearch com o OpenSearch Dashboards podem ser usados para métricas e painéis. O Amazon MSK, o Amazon EMR com Spark Streaming e o OpenSearch Service com OpenSearch Dashboards são todos serviços gerenciados, nos quais a AWS gerencia o esforço indiferenciado do gerenciamento de infraestrutura de diferentes clusters, o que permite que você crie sua aplicação usando software de código aberto familiar com poucos cliques. A próxima seção analisa mais de perto esses serviços.

Amazon Managed Streaming for Apache Kafka (Amazon MSK)

O Apache Kafka é uma plataforma de código aberto que permite aos clientes capturar dados de streaming, como eventos de clickstream, transações, eventos de IoT e logs de aplicações e máquinas. Com essas informações, é possível desenvolver aplicações que executam análises em tempo real, executam transformações contínuas e distribuem esses dados para data lakes e bancos de dados em tempo real.

Você pode usar o Kafka como um armazenamento de dados de streaming para dissociar aplicações do produtor e dos consumidores e permitir a transferência confiável de dados entre os dois componentes. Embora o Kafka seja uma plataforma popular de transmissão de dados e mensagens corporativas, pode ser difícil configurar, dimensionar e gerenciar na produção.

O Amazon MSK encarrega-se dessas tarefas de gerenciamento e facilita a instalação, a configuração e a execução do Kafka, juntamente com o Apache Zookeeper, em um ambiente que segue as práticas recomendadas de alta disponibilidade e segurança. Você ainda pode usar as operações do plano de controle e as operações do plano de dados do Kafka para gerenciar a produção e o consumo de dados.

Como o Amazon MSK executa e gerencia o Apache Kafka de código aberto, ele facilita a migração e a execução de aplicações Apache Kafka existentes na AWS sem precisar fazer alterações no código da aplicação.

Escalabilidade

O Amazon MSK oferece operações de escalabilidade para que o usuário possa escalar o cluster ativamente durante sua execução. Ao criar um cluster do Amazon MSK, você pode especificar o tipo de instância dos agentes na execução do cluster. É possível começar com alguns agentes em um cluster do Amazon MSK. Depois, usando o AWS Management Console ou a AWS CLI, você pode escalar até centenas de agentes por cluster.

Como alternativa, é possível escalar os clusters alterando o tamanho ou a família dos agentes Apache Kafka. Alterar o tamanho ou a família dos seus agentes oferece a você a flexibilidade de ajustar a capacidade computacional dos clusters do Amazon MSK para as mudanças em suas workloads. Use a [Planilha de dimensionamento e definição de preço do Amazon MSK](#) (download de arquivo) para determinar o número correto de agentes para o cluster do Amazon MSK. Essa planilha fornece uma estimativa para dimensionar um cluster do Amazon MSK e os custos associados do Amazon MSK comparados a um cluster do Apache Kafka semelhante, autogerenciado e baseado no EC2.

Depois de criar o cluster do Amazon MSK, você pode aumentar a quantidade de armazenamento do EBS por agente, com exceção da diminuição do armazenamento. Os volumes de armazenamento permanecem disponíveis durante essa operação de expansão. Ele oferece dois tipos de operações de dimensionamento: autoescalabilidade e escalabilidade manual.

O Amazon MSK é compatível com a expansão automática do armazenamento do seu cluster em resposta ao aumento do uso utilizando políticas do Application Auto Scaling. Sua política de autoescalabilidade define a utilização de disco de destino e a capacidade máxima de escalabilidade.

O limite de utilização de armazenamento ajuda o Amazon MSK a acionar uma operação de autoescalabilidade. Para aumentar o armazenamento usando a escalabilidade manual, aguarde até que o cluster esteja no estado ACTIVE. A escalabilidade de armazenamento tem um período

de desaquecimento de pelo menos seis horas entre os eventos. Embora a operação disponibilize armazenamento adicional imediatamente, o serviço realiza otimizações no cluster que podem levar até 24 horas ou mais.

A duração dessas otimizações é proporcional ao tamanho do armazenamento. Além disso, também oferece replicação de várias zonas de disponibilidade em uma região da AWS para fornecer alta disponibilidade.

Configuração

O Amazon MSK fornece uma configuração padrão para agentes, tópicos e nós Apache Zookeeper. Você também pode criar configurações personalizadas e usá-las para criar clusters do Amazon MSK ou atualizar clusters existentes. Quando você cria um cluster do MSK sem especificar uma configuração personalizada do Amazon MSK, o Amazon MSK cria e usa uma configuração padrão. Para obter uma lista desses valores padrão, consulte [Configuração do Apache Kafka](#).

Para fins de monitoramento, o Amazon MSK reúne métricas do Apache Kafka e as envia ao Amazon CloudWatch, onde você pode visualizá-las. As métricas configuradas para os fluxos são coletadas e enviadas automaticamente ao CloudWatch. O monitoramento do atraso do consumidor permite identificar consumidores lentos ou estagnados que não estão acompanhando os dados mais recentes disponíveis em um tópico. Quando necessário, você pode tomar medidas corretivas, como escalar ou reiniciar esses consumidores.

Migrar para o Amazon MSK

A migração da estrutura on-premises para o Amazon MSK pode ser obtida por um dos métodos a seguir.

- **MirrorMaker2.0:** o MirrorMaker2.0 (MM2) MM2 é um mecanismo de replicação de dados de vários clusters baseado na framework do Apache Kafka Connect. O MM2 é uma combinação de um conector de fonte do Apache Kafka e um conector coletor. É possível usar um único cluster do MM2 para migrar dados entre vários clusters. O MM2 detecta automaticamente novos tópicos e partições, além de garantir que as configurações de tópico sejam sincronizadas entre clusters. O MM2 é compatível com a migrações de ACLs, configurações de tópicos e conversão de deslocamento. Para obter mais detalhes relacionados à migração, consulte [Migrar clusters com o uso do MirrorMaker do Apache Kafka](#). O MM2 é usado automaticamente para casos de uso relacionados à replicação de configurações de tópicos e conversão de deslocamento.
- **Apache Flink:** o MM2 é compatível com a semântica do tipo exatamente uma vez. Os registros podem ser duplicados para o destino e espera-se que os consumidores sejam idempotentes para

lidar com registros duplicados. Em cenários de exatamente uma vez, a semântica é necessária para que os clientes possam usar o Apache Flink. Ele fornece uma alternativa para obter uma semântica do tipo exatamente uma vez.

O Apache Flink também pode ser usado para cenários em que os dados exigem ações de mapeamento ou transformação antes do envio ao cluster de destino. O Apache Flink fornece conectores para o Apache Kafka com fontes e coletores que podem ler dados de um cluster do Apache Kafka e gravar em outro. O Apache Flink pode ser executado na AWS iniciando um [cluster do Amazon EMR](#) ou executando o Apache Flink como uma aplicação usando o [Amazon Kinesis Data Analytics](#).

- AWS Lambda: com suporte para o Apache Kafka como fonte de eventos para [AWS Lambda](#), os clientes agora podem consumir mensagens de um tópico por meio de uma função do Lambda. O serviço AWS Lambda pesquisa internamente novos registros ou mensagens da fonte do evento e, depois, chama de forma síncrona a função do Lambda de destino para consumir essas mensagens. O Lambda lê as mensagens em lotes e fornece os lotes de mensagens para sua função na carga útil do evento para processamento. As mensagens consumidas podem ser transformadas e/ou gravadas diretamente no cluster do Amazon MSK de destino.


Amazon EMR com Spark Streaming

O [Amazon EMR](#) é uma plataforma de cluster gerenciada que simplifica a execução de frameworks de big data, como o [Apache Hadoop](#) e o [Apache Spark](#) na AWS para processar e analisar grandes quantidades de dados.

O Amazon EMR fornece os recursos do Spark e pode ser usado para iniciar o streaming do Spark para consumir dados do Kafka. O Spark Streaming é uma extensão da API principal do Spark que permite o processamento escalável, de alta taxa de transferência e tolerante a falhas de fluxos de dados ao vivo.

É possível criar um cluster do Amazon EMR usando o [AWS Command Line Interface](#) (AWS CLI) ou o [AWS Management Console](#) e selecionar Spark e Zeppelin em configurações avançadas ao criar o cluster. Conforme mostrado no diagrama de arquitetura a seguir, os dados podem ser ingeridos de várias fontes, como Apache Kafka e Kinesis Data Streams, e podem ser processados usando algoritmos complexos expressos com funções de alto nível, como map, reduce, join e window. Para obter mais informações, consulte [Transformações em DStreams](#).

Os dados processados podem ser enviados para sistemas de arquivos, bancos de dados e painéis dinâmicos.



Fluxo de streaming em tempo real do Apache Kafka para o ecossistema Hadoop

Por padrão, o Apache Spark Streaming tem um modelo de execução de microlote. No entanto, desde que o Spark 2.3 foi lançado, o Apache introduziu um novo modo de processamento de baixa latência chamado Processamento contínuo, que pode atingir latências de ponta a ponta tão baixas quanto um milissegundo com garantias de pelo menos uma vez.

Sem alterar as operações Dataset/DataFrames em suas consultas, você pode escolher o modo com base nos requisitos da sua aplicação. Alguns dos benefícios do Spark Streaming são:

- Ele traz a [API integrada à linguagem](#) do Apache Spark para o processamento de streaming, permitindo que você escreva trabalhos de streaming da mesma forma que escreve trabalhos em lote.
- É compatível com Java, Scala e Python.
- Ele pode recuperar o trabalho perdido e o estado do operador (como janelas deslizantes) predefinidos, sem nenhum código adicional de sua parte.
- Ao ser executado no Spark, o Spark Streaming permite reutilizar o mesmo código para processamento em lote, unir fluxos com dados históricos ou executar consultas ad hoc no estado do fluxo e criar aplicações interativas avançadas, não apenas análises.
- Depois que o fluxo de dados é processado com o Spark Streaming, o OpenSearch Sink Connector pode ser usado para gravar dados no cluster do OpenSearch Service e, por sua vez, o OpenSearch Service com o OpenSearch Dashboards pode ser usado como camada de consumo.

Amazon OpenSearch Service com OpenSearch Dashboards

O [OpenSearch Service](#) é um serviço gerenciado que facilita a implantação, a operação e o escala de clusters do OpenSearch na Nuvem AWS. O OpenSearch é um conhecido mecanismo de pesquisa e

análise de código aberto para casos de uso, como análise de log, monitoramento de aplicações em tempo real e análise de clickstream.

O [OpenSearch Dashboards](#) é uma ferramenta de visualização e exploração de dados usada para log e análise de séries temporais, monitoramento de aplicações e casos de uso de inteligência operacional. Ele oferece recursos avançados e fáceis de usar, como histogramas, grafos de linhas, grafos de pizza, mapas de calor e suporte geoespacial integrado.

O OpenSearch Dashboards fornece uma forte integração com o [OpenSearch](#), um mecanismo de análise e pesquisa popular, o que torna o OpenSearch Dashboards a escolha padrão para visualizar dados armazenados em OpenSearch. O OpenSearch Service fornece uma instalação do OpenSearch Dashboards com todos os domínios do OpenSearch Service. Você pode encontrar um link para o OpenSearch Dashboards no painel do seu domínio no console do OpenSearch Service.

Resumo

Com o Apache Kafka oferecido como um serviço gerenciado na AWS, é possível se concentrar no consumo em vez de gerenciar a coordenação entre os agentes, o que geralmente requer um entendimento detalhado do Apache Kafka. Recursos como alta disponibilidade, escalabilidade de agentes e controle de acesso granular são gerenciados pela plataforma Amazon MSK.

A ABC1Cabs utilizou esses serviços para criar aplicações de produção sem precisar de experiência em gerenciamento de infraestrutura. Eles puderam se concentrar na camada de processamento para consumir dados do Amazon MSK e se propagar ainda mais para a camada de visualização.

O Spark Streaming no Amazon EMR pode ajudar na análise em tempo real de dados de streaming e na publicação no [OpenSearch Dashboards](#) no Amazon OpenSearch Service para a camada de visualização.

Conclusão e colaboradores

Conclusão

Este documento analisou vários cenários de fluxos de trabalho de streaming. Nesses cenários, o processamento de dados de streaming forneceu às empresas de exemplo a capacidade de adicionar novos recursos e funcionalidades.

Ao analisar os dados à medida que são criados, você obterá insights sobre o que sua empresa está fazendo agora. Os serviços de streaming da AWS permitem que você se concentre em sua aplicação para tomar decisões de negócios urgentes em vez de implantar e gerenciar a infraestrutura

Colaboradores

- Amalia Rabinovitch, arquiteta de soluções sênior da AWS
- Priyanka Chaudhary, arquiteta de dados e data lake da AWS
- Zohair Nasimi, arquiteto de soluções da AWS
- Rob Kuhr, arquiteto de soluções da AWS
- Ejaz Sayyed, arquiteto de soluções sênior de parceiros da AWS
- Allan MacInnis, arquiteto de soluções da AWS
- Chander Matrubhutam, gerente de marketing de produto da AWS

Revisões do documento

Para ser notificado sobre atualizações deste whitepaper, inscreva-se no RSS feed.

update-history-change

update-history-description

update-history-date

[Atualizado](#)

Atualizado quanto à precisão
técnica

1º de setembro de 2021

[Publicação inicial](#)

Primeira publicação do
whitepaper

1º de julho de 2017