



Guia de desenvolvimento do Amazon EMR no EKS

Amazon EMR



Amazon EMR: Guia de desenvolvimento do Amazon EMR no EKS

Copyright © 2026 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

As marcas comerciais e imagens de marcas da Amazon não podem ser usadas no contexto de nenhum produto ou serviço que não seja da Amazon, nem de qualquer maneira que possa gerar confusão entre os clientes ou que deprecie ou desprestige a Amazon. Todas as outras marcas comerciais que não são propriedade da Amazon pertencem aos respectivos proprietários, os quais podem ou não ser afiliados, estar conectados ou ser patrocinados pela Amazon.

Table of Contents

O que é o Amazon EMR no EKS?	1
Arquitetura do Amazon EMR no EKS	2
Noções básicas de conceitos e terminologia do Amazon EMR no EKS	3
Namespace do Kubernetes	3
Cluster virtual	4
Execução de trabalho	4
Contêineres do Amazon EMR	4
O que acontece quando você envia trabalhos para um cluster virtual do Amazon EMR no EKS	5
Conceitos básicos do Amazon EMR no EKS	7
Execução de uma aplicação do Spark	8
Práticas recomendadas	14
Segurança	14
Envio de trabalho para o Pyspark	14
Armazenamento	14
Integração com o metastore	15
Depuração	15
Solução de problemas do Amazon EMR no EKS	15
Posicionamento de nó	15
desempenho	15
Otimização de custos	16
Usando AWS Outposts	16
Personalização de imagens do Docker	17
Como personalizar imagens do Docker	17
Pré-requisitos	18
Etapa 1: recuperar uma imagem base do Amazon Elastic Container Registry (Amazon ECR)	18
Etapa 2: personalizar uma imagem base	19
Etapa 3: (opcional, mas recomendada) validar uma imagem personalizada	20
Etapa 4: publicar uma imagem personalizada	22
Etapa 5: enviar uma workload do Spark no Amazon EMR usando uma imagem personalizada	23
Personalização de imagens do Docker para endpoints interativos	25
Trabalho com imagens de múltiplas arquiteturas	27

Detalhes sobre como selecionar um URI de imagem base	29
Contas de registro do Amazon ECR	30
Considerações para personalizar imagens	31
Execução de trabalhos do Flink	33
Operador do Kubernetes para Flink	33
Configurar	34
Instalar o operador Flink Kubernetes	35
Execução de uma aplicação do Flink	37
Permissões do perfil de segurança para executar uma aplicação do Flink	41
Desinstalação do operador	44
Kubernetes nativo do Flink	44
Configurar	44
Introdução	45
Requisitos de segurança	48
Personalização de imagens do Docker para o Flink e o FluentD	49
Pré-requisitos	49
Recuperar uma imagem base do Amazon Elastic Container Registry	49
Personalização de uma imagem base	50
Como publicar a imagem personalizada	51
Como enviar uma workload	51
Monitoramento	52
Uso do Amazon Managed Service for Prometheus	52
Uso da interface do usuário do Flink	54
Uso da configuração de monitoramento	55
Como o Flink oferece suporte à alta disponibilidade e resiliência do trabalho	61
Uso da alta disponibilidade	61
Otimização dos tempos de reinicialização	67
Desativação tranquila	74
Uso do Autoscaler	77
Ajuste automático dos parâmetros do escalador automático	79
Manutenção e solução de problemas para trabalhos do Flink no Amazon EMR no EKS	89
Manutenção de aplicações do Flink	89
Solução de problemas	90
Versões compatíveis	94
Execução de trabalhos do Spark	96
StartJobRun	97

Configurar	97
Envio de uma execução de trabalho com StartJobRun	126
Uso da classificação de envio de trabalho	128
Usar a classificação de padrões do contêiner do Amazon EMR	135
Operador do Spark	138
Configurar	138
Introdução	139
Autoescalabilidade vertical	143
Desinstalar	148
Usar a configuração de monitoramento para monitorar o Spark	149
Segurança	156
spark-submit	167
Configurar	168
Introdução	169
Segurança	170
Apache Livy	175
Configurar	176
Introdução	177
Execução de uma aplicação do Spark	182
Desinstalação	184
Segurança	184
Propriedades de instalação	194
Solução de erros comuns de formato de variável de ambiente	200
Gerenciamento de execuções de trabalhos	201
Gerenciamento com a CLI	202
Execução de scripts do Spark SQL	208
Estados de execução de trabalho	211
Visualização de trabalhos no console	212
Erros comuns na execução de trabalhos	212
Uso de modelos de trabalho	218
Criação e uso de um modelo de trabalho para iniciar uma execução de trabalho	219
Definição de parâmetros de modelos de trabalhos	221
Controle do acesso aos modelos de trabalhos	223
Uso de modelos de pod	225
Cenários comuns	225
Habilitação de modelos de pod com o Amazon EMR no EKS	227

Campos do modelo de pod	229
Considerações sobre contêineres sidecar	232
Uso de políticas de repetição	234
Definição de uma política de repetição	234
Recuperação de um status da política	237
Monitoramento do trabalho	238
Descoberta de logs de drivers	238
Uso da alternância de log de eventos do Spark	238
Uso da alternância de log do contêiner do Spark	239
Uso da escalabilidade automática vertical	242
Configurar	242
Introdução	245
Configuração	247
Monitoramento das recomendações	253
Desinstalação	255
Execução de workloads interativas	256
Visão geral dos endpoints interativos	256
Pré-requisitos para os endpoints interativos	258
AWS CLI	259
eksctl	259
Cluster Amazon EKS	259
Concessão de acesso ao cluster	260
Ativação de perfis do IAM para contas de serviço	260
Criação de um perfil de execução de trabalho do IAM	260
Concessão de acesso para os usuários	260
Registro do cluster do Amazon EKS com o Amazon EMR	261
Load Balancer Controller	261
Criação de um endpoint interativo	261
Criação de um endpoint interativo	261
Especificação de parâmetros personalizados	262
.....	263
Parâmetros para um endpoint interativo	264
Definição de configurações para endpoints interativos	265
Monitorar trabalhos Spark	266
Modelos de pod personalizados	267
Implantação de um pod do JEG em um grupo de nós	268

Opções de configuração do JEG	272
Modificando parâmetros PySpark	272
Imagem de kernel personalizada	273
Monitoramento de endpoints interativos	275
Exemplos	277
Uso de cadernos Jupyter de hospedagem própria	278
Criar um grupo de segurança	279
Criação de um endpoint interativo	279
Obtenção do URL do servidor de gateway	280
Obtenção do token de autenticação	280
Implantação de um caderno	281
Limpeza	286
Como obter informações sobre endpoints interativos com comandos da CLI	287
.....	287
Listagem de endpoints interativos	288
Exclusão de um endpoint interativo	290
Upload dos dados	291
Pré-requisitos	291
Introdução	291
Monitorar trabalhos	294
Monitore trabalhos com a Amazon CloudWatch Events	294
Automatize o Amazon EMR no EKS com eventos CloudWatch	295
Exemplo: configuração de uma regra que invoque o Lambda	296
Monitore o driver pod do trabalho com uma política de repetição usando o Amazon Events CloudWatch	297
Gerenciamento de clusters virtuais	298
Criação de um cluster virtual	298
Listagem de clusters virtuais	300
Descrição de um cluster virtual	300
Exclusão de um cluster virtual	300
Estados de um cluster virtual	300
Tutoriais	301
Uso do Delta Lake	301
Uso do Iceberg	302
Configurações de sessão do Spark para integração de catálogo	303
Usando PyFlink	304

Usando AWS Glue com Flink	305
Uso do Apache Hudi	308
Envio de um trabalho do Apache Hudi	308
Uso do RAPIDS para Spark	312
Uso do Spark no Redshift	316
Iniciar uma aplicação do Spark	317
Autenticação no Amazon Redshift	318
Leitura e gravação para o Amazon Redshift	320
Considerações	322
Uso do Volcano	323
Visão geral do	323
Instalação	324
Envio: operador do Spark	325
Envio: spark-submit	327
Usando YuniKorn	328
Visão geral do	328
Crie seu cluster do	328
Instalar YuniKorn	331
Envio: operador do Spark	331
Envio: spark-submit	334
Segurança	14
Práticas recomendadas	338
Aplicação do princípio de privilégio mínimo	338
Listagem de controle de acesso para endpoints	338
Obtenção das atualizações de segurança mais recentes para as imagens personalizadas ..	339
Limitação do acesso à credencial do pod	339
Isolamento de código de uma aplicação não confiável	339
Permissões de controle de acesso por perfil (RBAC)	339
Restrição do acesso às credenciais do perfil do IAM ou do perfil de instância do grupo de nós	340
Proteção de dados	341
Criptografia em repouso	342
Criptografia em trânsito	344
Gerenciamento de Identidade e Acesso	345
Público	346
Autenticação com identidades	346

Gerenciar o acesso usando políticas	347
Como o Amazon EMR no EKS funciona com o IAM	349
Uso de perfis vinculadas ao serviço	354
Políticas gerenciadas para o Amazon EMR no EKS	358
Uso de perfis de execução de trabalho com o Amazon EMR no EKS	360
Exemplos de políticas baseadas em identidade	362
Políticas para controle de acesso baseado em etiquetas	365
Solução de problemas	369
Usando o Amazon EMR no EKS com Lake Formation AWS	371
Como o Amazon EMR no EKS funciona com AWS o Lake Formation	372
Habilitar o Lake Formation com o Amazon EMR no EKS	373
Considerações e limitações	382
Solução de problemas	384
Registro em log e monitoramento	386
Criptografia de logs	387
CloudTrail troncos	390
Concessão de Acesso do S3	393
Visão geral do	393
Executar um cluster	394
Considerações	395
Validação de conformidade	395
Resiliência	396
Segurança da infraestrutura	396
Análise de configuração e vulnerabilidade	396
Endpoints da VPC de interface	397
Criação de uma política de endpoint da VPC para o Amazon EMR no EKS	398
Acesso entre contas	401
Pré-requisitos	401
Como acessar um bucket do Amazon S3 ou uma tabela do DynamoDB entre contas	401
Marcar recursos	407
Conceitos Básicos de Tags	407
Marcar seus recursos com tag	408
Restrições de tag	409
Trabalhe com tags usando o AWS CLI e o Amazon EMR na API EKS	410
Solução de problemas	15
Falhas em trabalhos que usam PVC	411

Verificação	411
Patch	412
Aplicação manual de patches	416
Falhas de escalabilidade automática vertical	418
Erro 403 Forbidden	418
Namespace não encontrado	418
Erro de credenciais do Docker	419
Falhas em operadores do Spark	419
Falha na instalação do chart do Helm	419
Exceção FileSystem sem suporte	420
Cotas e endpoints de serviço	422
Service endpoints	422
Cotas de serviço	425
Visualizar cotas e solicitar aumentos de cotas	426
Versões de liberação	427
Versões 7.12.0	428
Versões	428
Notas da versão	430
Alterações e recursos	432
emr-7.12.0-mais recente	432
emr-7.12.0-20251111	432
emr-7.12.0-flink-latest	433
emr-7.12.0-flink-20251111	433
Versões 7.11.0	433
Versões	433
Notas da versão	435
Alterações e recursos	436
emr-7.11.0-mais recente	437
emr-7.11.0-20251020	437
emr-7.11.0-flink-latest	437
emr-7.11.0-flink-20251020	438
Versões 7.10.0	438
Versões	438
Notas da versão	440
Alterações e recursos	441
emr-7.10.0-mais recente	442

emr-7.10.0-20250801	442
emr-7.10.0-flink-latest	442
emr-7.10.0-flink-20250801	442
Versões 7.9.0	443
Versões	443
Notas da versão	444
Alterações	446
emr-7.9.0-mais recente	446
emr-7.9.0-20250425	446
emr-7.9.0-flink-latest	447
emr-7.9.0-flink-20250425	447
Versões 7.8.0	447
Versões	447
Notas da versão	449
Alterações	450
emr-7.8.0-mais recente	451
emr-7.8.0-20250228	451
emr-7.8.0-flink-mais recente	451
emr-7.8.0-flink-20250228	452
Versões 7.7.0	452
Versões	452
Notas da versão	454
Alterações	455
emr-7.7.0-mais recente	455
emr-7.7.0-20250131	456
emr-7.7.0-flink-latest	456
emr-7.7.0-flink-20250131	456
Versões 7.6.0	456
Versões	457
Notas da versão	458
Recursos	460
Alterações	460
emr-7.6.0-mais recente	460
emr-7.6.0-20241213	460
emr-7.6.0-flink-latest	461
emr-7.6.0-flink-20241213	461

Versões 7.5.0	461
Versões	461
Notas da versão	462
Versões 7.4.0	462
Versões	462
Notas da versão	462
Versões 7.3.0	463
Versões	463
Notas da versão	464
Recursos	466
Alterações	466
emr-7.3.0-latest	467
emr-7.3.0-20240920	467
emr-7.3.0-flink-latest	467
emr-7.3.0-flink-29240920	467
Versões 7.2.0	468
Versões	468
Notas da versão	469
Recursos	471
emr-7.2.0-latest	472
emr-7.2.0-20240610	472
emr-7.2.0-flink-latest	472
emr-7.2.0-flink-20240610	472
Versões 7.1.0	473
Versões	473
Notas da versão	475
Recursos	476
emr-7.1.0-latest	476
emr-7.1.0-20240321	477
emr-7.1.0-flink-latest	477
emr-7.1.0-flink-20240321	477
Versões 7.0.0	477
Versões	478
Notas da versão	479
Recursos	481
Alterações	481

emr-7.0.0-latest	481
emr-7.0.0-2024321	482
emr-7.0.0-20231211	482
emr-7.0.0-flink-latest	482
emr-7.0.0-flink-2024321	482
emr-7.0.0-flink-20231211	483
Versões 6.15.0	483
Versões	483
Notas da versão	485
Recursos	486
emr-6.15.0-latest	487
emr-6.15.0-20240105	487
emr-6.15.0-20231109	487
emr-6.15.0-flink-latest	487
emr-6.15.0-flink-20240105	488
emr-6.15.0-flink-20231109	488
Versões 6.14.0	488
Versões	488
Notas da versão	490
Recursos	491
emr-6.14.0-latest	491
emr-6.14.0-20231005	491
Versões 6.13.0	492
Versões	492
Notas da versão	493
Recursos	495
emr-6.13.0-latest	495
emr-6.13.0-20230814	495
Versões 6.12.0	496
Versões	496
Notas da versão	497
Recursos	498
emr-6.12.0-latest	498
emr-6.12.0-20240321	499
emr-6.12.0-20230701	499
Versões 6.11.0	499

Versões	499
Notas da versão	500
Recursos	501
emr-6.11.0-latest	502
emr-6.11.0-20230905	502
emr-6.11.0-20230509	502
Versões 6.10.0	503
emr-6.10.0-latest	505
emr-6.10.0-20230905	506
emr-6.10.0-20230624	506
emr-6.10.0-20230421	506
emr-6.10.0-20230403	506
emr-6.10.0-20230220	507
Versões 6.9.0	507
emr-6.9.0-latest	510
emr-6.9.0-20230905	510
emr-6.9.0-20230624	510
emr-6.9.0-20221108	511
Versões 6.8.0	511
emr-6.8.0-latest	515
emr-6.8.0-20230905	515
emr-6.8.0-20230624	515
emr-6.8.0-20221219	516
emr-6.8.0-20220802	516
Versões 6.7.0	516
emr-6.7.0-latest	518
emr-6.7.0-20240321	518
emr-6.7.0-20230624	519
emr-6.7.0-20221219	519
emr-6.7.0-20220630	519
Versões 6.6.0	519
emr-6.6.0-latest	521
emr-6.6.0-20240321	521
emr-6.6.0-20230624	521
emr-6.6.0-20221219	522
emr-6.6.0-20220411	522

Versões 6.5.0	522
emr-6.5.0-latest	523
emr-6.5.0-20240321	524
emr-6.5.0-20221219	524
emr-6.5.0-20220802	524
emr-6.5.0-20211119	524
Versões 6.4.0	525
emr-6.4.0-latest	526
emr-6.4.0-20240321	526
emr-6.4.0-20221219	527
emr-6.4.0-20210830	527
Versões 6.3.0	527
emr-6.3.0-latest	528
emr-6.3.0-20240321	529
emr-6.3.0-20220802	529
emr-6.3.0-20211008	529
emr-6.3.0-20210802	529
emr-6.3.0-20210429	530
Versões 6.2.0	530
emr-6.2.0-latest	531
emr-6.2.0-20240321	532
emr-6.2.0-20220802	532
emr-6.2.0-20211008	532
emr-6.2.0-20210802	532
emr-6.2.0-20210615	533
emr-6.2.0-20210129	533
emr-6.2.0-20201218	533
emr-6.2.0-20201201	533
Versões 5.36.0	534
emr-5.36.0-latest	535
emr-5.36.0-20240321	535
emr-5.36.0-20221219	536
emr-5.36.0-20220620	536
emr-5.36.0-20220525	536
Versões 5.35.0	536
emr-5.35.0-latest	538

emr-5.35.0-20240321	538
emr-5.35.0-20221219	538
emr-5.35.0-20220802	538
emr-5.35.0-20220307	539
Versões 5.34	539
emr-5.34.0-latest	540
emr-5.34.0-20240321	540
emr-5.34.0-20220802	541
emr-5.34.0-20211208	541
Versões 5.33.0	541
emr-5.33.0-latest	543
emr-5.33.0-20240321	543
emr-5.33.0-20221219	543
emr-5.33.0-20220802	543
emr-5.33.0-20211008	544
emr-5.33.0-20210802	544
emr-5.33.0-20210615	544
emr-5.33.0-20210323	544
Versões 5.32.0	545
emr-5.32.0-latest	546
emr-5.32.0-20240321	546
emr-5.32.0-20220802	547
emr-5.32.0-20211008	547
emr-5.32.0-20210802	547
emr-5.32.0-20210615	547
emr-5.32.0-20210129	548
emr-5.32.0-20201218	548
emr-5.32.0-20201201	548
Histórico do documento	549
.....	dlii

O que é o Amazon EMR no EKS?


O Amazon EMR no EKS oferece uma opção de implantação para o Amazon EMR que permite executar estruturas de big data de código aberto no Amazon Elastic Kubernetes Service (Amazon EKS). Com essa opção de implantação, você pode se concentrar na execução de workloads de analytics enquanto o Amazon EMR no EKS cria, configura e gerencia contêineres para aplicações de código aberto.

Se você já usa o Amazon EMR, agora poderá executar aplicações baseadas no Amazon EMR com outros tipos de aplicações no mesmo cluster do Amazon EKS. Esta opção de implantação também melhora a utilização de recursos e simplifica o gerenciamento da infraestrutura em diversas zonas de disponibilidade. Se você já executa estruturas de big data no Amazon EKS, poderá usar o Amazon EMR para automatizar o provisionamento e o gerenciamento, e executar o Apache Spark mais rapidamente.

O Amazon EMR no EKS possibilita que sua equipe colabore com mais eficiência e processe grandes quantidades de dados com mais facilidade e economia:

- Você pode executar aplicações em um grupo comum de recursos sem a necessidade de provisionar infraestrutura. Você pode usar o [Amazon EMR Studio](#) e o AWS SDK ou AWS CLI desenvolver, enviar e diagnosticar aplicativos de análise executados em clusters EKS. É possível executar trabalhos programados no Amazon EMR no EKS usando o Apache Airflow autogerenciado ou o Amazon Managed Workflows for Apache Airflow (MWAA).
- As equipes de infraestrutura podem gerenciar centralmente uma plataforma de computação comum para consolidar as workloads do Amazon EMR com outras aplicações baseadas em contêiner. Você pode simplificar o gerenciamento da infraestrutura com ferramentas comuns do Amazon EKS e aproveitar um cluster compartilhado para workloads que precisam de versões diferentes de estruturas de código aberto. Também é possível reduzir a sobrecarga operacional com o gerenciamento automatizado de cluster do Kubernetes e com a aplicação de patches para o sistema operacional. Com a Amazon EC2 e AWS Fargate, você pode habilitar vários recursos computacionais para atender aos requisitos operacionais, financeiros ou de desempenho.

O diagrama a seguir mostra os dois diferentes modelos de implantação do Amazon EMR.



Tópicos


- [Arquitetura do Amazon EMR no EKS](#)
- [Noções básicas de conceitos e terminologia do Amazon EMR no EKS](#)
- [O que acontece quando você envia trabalhos para um cluster virtual do Amazon EMR no EKS](#)

Arquitetura do Amazon EMR no EKS

O Amazon EMR no EKS realiza um acoplamento fraco das aplicações à infraestrutura na qual elas são executadas. Cada camada de infraestrutura fornece orquestração para a camada subsequente. Ao enviar um trabalho para o Amazon EMR, a definição do trabalho contém todos os parâmetros específicos da aplicação. O Amazon EMR usa esses parâmetros para instruir o Amazon EKS sobre quais pods e contêineres implantar. O Amazon EKS então coloca on-line os recursos de computação da Amazon EC2 e AWS Fargate necessários para executar o trabalho.

Com esse acoplamento fraco de serviços, você pode executar simultaneamente múltiplos trabalhos isolados com segurança. Também é possível realizar uma avaliação comparativa do mesmo trabalho com diferentes back-ends de computação ou distribuir o trabalho em diversas zonas de disponibilidade para melhorar a disponibilidade.

O diagrama a seguir ilustra como o Amazon EMR no EKS funciona com AWS outros serviços.



Noções básicas de conceitos e terminologia do Amazon EMR no EKS

O Amazon EMR no EKS oferece uma opção de implantação para o Amazon EMR que permite executar estruturas de big data de código aberto no Amazon Elastic Kubernetes Service (Amazon EKS). Este tópico fornece contexto sobre algumas das terminologias comuns para isso, incluindo namespaces, clusters virtuais e execuções de trabalhos, que são unidades de trabalho enviadas para processamento.

Namespace do Kubernetes

O Amazon EKS usa namespaces do Kubernetes para dividir os recursos de cluster entre diversos usuários e aplicações. Esses namespaces são a base para ambientes multilocatários. Um namespace Kubernetes pode ter a Amazon EC2 ou AWS Fargate o provedor de computação. Essa flexibilidade oferece diferentes opções de performance e de custos para a execução de seus trabalhos.

Cluster virtual

Um cluster virtual corresponde a um namespace do Kubernetes no qual o Amazon EMR está registrado. O Amazon EMR usa clusters virtuais para executar trabalhos e hospedar endpoints. Diversos clusters virtuais podem ser apoiados pelo mesmo cluster físico. No entanto, cada cluster virtual é mapeado para um namespace em um cluster do EKS. Os clusters virtuais não criam quaisquer recursos ativos que contribuam para o seu faturamento ou que requeiram gerenciamento do ciclo de vida de forma externa ao serviço.

Execução de trabalho

A execução de um trabalho é uma unidade de trabalho, como um Spark jar, PySpark script ou consulta SparkSQL, que você envia para o Amazon EMR no EKS. Um trabalho pode ter várias execuções de trabalhos. Ao enviar uma execução de trabalho, você inclui as seguintes informações:

- Um cluster virtual no qual o trabalho deve ser executado.
- Um nome do trabalho para a identificação do trabalho.
- O perfil de execução, que é um perfil do IAM com escopo definido que executa o trabalho e permite especificar quais recursos podem ser acessados pelo trabalho.
- O rótulo de versão do Amazon EMR que especifica a versão das aplicações de código aberto a serem usadas.
- Os artefatos a serem usados ao enviar seu trabalho, como os parâmetros spark-submit.

Por padrão, os logs são carregados no servidor de histórico do Spark e podem ser acessados do Console de gerenciamento da AWS. Você também pode enviar registros de eventos, registros de execução e métricas para o Amazon S3 e a Amazon CloudWatch.

Contêineres do Amazon EMR

Os contêineres do Amazon EMR correspondem ao [nome da API do Amazon EMR no EKS](#). O prefixo `emr-containers` é usado nos seguintes cenários:

- É o prefixo nos comandos da CLI para o Amazon EMR no EKS. Por exemplo, `.aws emr-containers start-job-run`
- É o prefixo antes das ações de política do IAM para o Amazon EMR no EKS. Por exemplo, `"Action": [ "emr-containers:StartJobRun"]` Para obter mais informações, consulte [Ações de políticas para o Amazon EMR no EKS](#).


- É o prefixo usado nos endpoints de serviço do Amazon EMR no EKS. Por exemplo, `.emr-containers.us-east-1.amazonaws.com`. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

O que acontece quando você envia trabalhos para um cluster virtual do Amazon EMR no EKS

O registro do Amazon EMR com um namespace do Kubernetes no Amazon EKS cria um cluster virtual. O Amazon EMR passará a poder executar workloads de analytics nesse namespace. Quando você usa o Amazon EMR no EKS para enviar trabalhos do Spark ao cluster virtual, o Amazon EMR no EKS solicita que o programador do Kubernetes no Amazon EKS programe pods.

As seguintes etapas e o diagrama abaixo ilustram o fluxo de trabalho do Amazon EMR no EKS:

- Uso de um cluster existente do Amazon EKS ou criação um cluster ao usar o utilitário de linha de comando [eksctl](#) ou o console do Amazon EKS.
- Criação de um cluster virtual ao registrar o Amazon EMR com um namespace em um cluster do EKS.
- Envie seu trabalho para o cluster virtual usando o AWS CLI ou SDK.



Para cada trabalho executado, o Amazon EMR no EKS cria um contêiner com uma imagem base do Amazon Linux 2, o Apache Spark e as dependências associadas. Cada execução de trabalho ocorre em um pod que faz download do contêiner e começa a executá-lo. O pod é encerrado após o término do trabalho. Se a imagem de contêiner tiver sido implantada anteriormente no nó, uma imagem em

cache será usada e o download será ignorado. Os contêineres sidecar, como encaminhadores de log ou de métricas, podem ser implantados no pod. Após o término do trabalho, você ainda poderá depurá-lo usando a interface do usuário da aplicação do Spark no console do Amazon EMR.

Conceitos básicos do Amazon EMR no EKS

Este tópico ajuda você a começar a usar o Amazon EMR no EKS ao implantar uma aplicação do Spark em um cluster virtual. Inclui etapas para configurar as permissões corretas e iniciar um trabalho. Antes de começar, siga as etapas em [Configuração do Amazon EMR no EKS](#). Isso ajuda você a obter ferramentas como a AWS CLI configurada antes de criar seu cluster virtual. Para outros modelos que podem ajudar você a começar, consulte nosso [Guia de práticas recomendadas de contêineres do EMR](#) em. GitHub

Você precisará das seguintes informações para as etapas de configuração:

- O ID do cluster virtual para o cluster do Amazon EKS e o namespace do Kubernetes registrado no Amazon EMR.

Important

Ao criar um cluster do EKS, certifique-se de usar m5.xlarge como tipo de instância ou qualquer outro tipo de instância com CPU e memória superiores. Usar um tipo de instância com CPU ou memória inferior ao m5.xlarge, pode levar à falha do trabalho devido à insuficiência de recursos disponíveis no cluster.

- O nome do perfil do IAM usado para a execução do trabalho.
- O rótulo de versão da versão do Amazon EMR (por exemplo, emr-6.4.0-latest).
- As metas de destino para o registro em log e o monitoramento:
 - Nome do grupo de CloudWatch log da Amazon e prefixo do fluxo de registros
 - A localização do Amazon S3 para armazenar logs de eventos e de contêineres.

Important

As tarefas do Amazon EMR no EKS usam a Amazon CloudWatch e o Amazon S3 como destinos para monitoramento e registro. Você pode monitorar o progresso do trabalho e solucionar falhas ao visualizar os logs de trabalho enviados para esses destinos. Para ativar o registro em log, a política do IAM associada ao perfil do IAM para a execução do trabalho deve ter as permissões necessárias para acessar os recursos das metas. Se a política do IAM não tiver as permissões necessárias, você deverá seguir as etapas descritas em [Atualização da política de confiança do perfil de execução de trabalho](#) [Configurar uma](#)

[execução de trabalho para usar registros do Amazon S3 e Configurar uma execução de trabalho para CloudWatch usar registros antes de executar](#) esse exemplo de trabalho.

Execução de uma aplicação do Spark

Siga as etapas a seguir para executar uma aplicação simples do Spark no Amazon EMR no EKS. O arquivo da aplicação `entryPoint` para a aplicação em Python do Spark está localizado em `s3://REGION.elasticmapreduce/emr-containers/samples/wordcount/scripts/wordcount.py`. **REGION** é a região na qual seu cluster virtual Amazon EMR no EKS reside, como `us-east-1`.

1. Atualize a política do IAM para o perfil de execução de trabalho com as permissões necessárias, conforme demonstram as instruções de política a seguir.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "ReadFromLoggingAndInputScriptBuckets",
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::*.elasticmapreduce",
        "arn:aws:s3:::*.elasticmapreduce/*",
        "arn:aws:s3:::amzn-s3-demo-bucket",
        "arn:aws:s3:::amzn-s3-demo-bucket/*",
        "arn:aws:s3:::amzn-s3-demo-bucket-b",
        "arn:aws:s3:::amzn-s3-demo-bucket-b/*"
      ]
    },
    {
      "Sid": "WriteToLoggingAndOutputDataBuckets",
      "Effect": "Allow",
      "Action": [
```



```

        "s3:PutObject",
        "s3:DeleteObject"
    ],
    "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket/*",
        "arn:aws:s3:::amzn-s3-demo-bucket-b/*"
    ]
},
{
    "Sid": "DescribeAndCreateCloudwatchLogStream",
    "Effect": "Allow",
    "Action": [
        "logs:CreateLogStream",
        "logs:DescribeLogGroups",
        "logs:DescribeLogStreams"
    ],
    "Resource": [
        "arn:aws:logs:*:*:*"
    ]
},
{
    "Sid": "WriteToCloudwatchLogs",
    "Effect": "Allow",
    "Action": [
        "logs:PutLogEvents"
    ],
    "Resource": [
        "arn:aws:logs:*:*:log-group:my_log_group_name:log-
stream:my_log_stream_prefix/*"
    ]
}
]
}

```

- A primeira instrução `ReadFromLoggingAndInputScriptBuckets` nesta política concede acesso para `ListBucket` e `GetObject`s aos seguintes buckets do Amazon S3:
 - *REGION*.elasticmapreduce: o bucket em que o arquivo da aplicação `entryPoint` está localizado.
 - *amzn-s3-demo-destination-bucket*- um bucket que você define para seus dados de saída.

- *amzn-s3-demo-logging-bucket* - um bucket que você define para seus dados de registro.
 - A segunda instrução `WriteToLoggingAndOutputDataBuckets` nesta política concede ao trabalho as permissões para gravar dados em seus buckets de saída e de registro em log, respectivamente.
 - A terceira declaração `DescribeAndCreateCloudwatchLogStream` concede ao trabalho permissões para descrever e criar Amazon CloudWatch Logs.
 - A quarta declaração `WriteToCloudwatchLogs` concede permissões para gravar registros em um grupo de CloudWatch registros da Amazon chamado *my_log_group_name* em um fluxo de registros chamado *my_log_stream_prefix*.
2. Para executar uma aplicação em Python do Spark, use o comando apresentado a seguir. Substitua todos os *red italicized* valores substituíveis por valores apropriados. *REGION* É a região na qual seu cluster virtual Amazon EMR no EKS reside, como. *us-east-1*

```
aws emr-containers start-job-run \
--virtual-cluster-id cluster_id \
--name sample-job-name \
--execution-role-arn execution-role-arn \
--release-label emr-6.4.0-latest \
--job-driver '{
  "sparkSubmitJobDriver": {
    "entryPoint": "s3://REGION.elasticmapreduce/emr-containers/samples/wordcount/
scripts/wordcount.py",
    "entryPointArguments": ["s3://amzn-s3-demo-destination-bucket/
wordcount_output"],
    "sparkSubmitParameters": "--conf spark.executor.instances=2 --
conf spark.executor.memory=2G --conf spark.executor.cores=2 --conf
spark.driver.cores=1"
  }
}' \
--configuration-overrides '{
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "my_log_group_name",
      "logStreamNamePrefix": "my_log_stream_prefix"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://amzn-s3-demo-logging-bucket"
    }
  }
}
```

```
}'
```

Os dados de saída deste trabalho estarão disponíveis em `s3://amzn-s3-demo-destination-bucket/wordcount_output`.

Você também pode criar um arquivo JSON com parâmetros especificados para sua execução de trabalho. Em seguida, execute o comando `start-job-run` com um caminho para o arquivo JSON. Para obter mais informações, consulte [Envio de uma execução de trabalho com StartJobRun](#). Para obter mais detalhes sobre como configurar parâmetros de execução de trabalho, consulte [Opções para a configuração de uma execução de trabalho](#).

3. Para executar uma aplicação em SQL do Spark, use o comando apresentado a seguir. Substitua todos *red italicized* os valores pelos valores apropriados. *REGION* É a região na qual seu cluster virtual Amazon EMR no EKS reside, como. *us-east-1*

```
aws emr-containers start-job-run \
--virtual-cluster-id cluster_id \
--name sample-job-name \
--execution-role-arn execution-role-arn \
--release-label emr-6.7.0-latest \
--job-driver '{
  "sparkSqlJobDriver": {
    "entryPoint": "s3://query-file.sql",
    "sparkSqlParameters": "--conf spark.executor.instances=2 --
conf spark.executor.memory=2G --conf spark.executor.cores=2 --conf
spark.driver.cores=1"
  }
}' \
--configuration-overrides '{
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "my_log_group_name",
      "logStreamNamePrefix": "my_log_stream_prefix"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://amzn-s3-demo-logging-bucket"
    }
  }
}'
```

Um arquivo de consulta SQL de exemplo é mostrado abaixo. Você deve ter um armazenamento de arquivos externo, como o S3, no qual os dados das tabelas são armazenados.

```
CREATE DATABASE demo;
CREATE EXTERNAL TABLE IF NOT EXISTS demo.amazonreview( marketplace string,
  customer_id string, review_id string, product_id string, product_parent string,
  product_title string, star_rating integer, helpful_votes integer, total_votes
  integer, vine string, verified_purchase string, review_headline string,
  review_body string, review_date date, year integer) STORED AS PARQUET LOCATION
  's3://URI to parquet files';
SELECT count(*) FROM demo.amazonreview;
SELECT count(*) FROM demo.amazonreview WHERE star_rating = 3;
```

A saída desse trabalho estará disponível nos registros de stdout do driver no S3 ou CloudWatch, dependendo do `monitoringConfiguration` que estiver configurado.

4. Você também pode criar um arquivo JSON com parâmetros especificados para sua execução de trabalho. Em seguida, execute o comando `start-job-run` com um caminho para o arquivo JSON. Para obter mais informações, consulte [Envio de uma execução de trabalho](#). Para obter mais detalhes sobre como configurar parâmetros de execução de trabalho, consulte [Opções para a configuração de uma execução de trabalho](#).

Para monitorar o progresso do trabalho ou para depurar falhas, você pode inspecionar os logs enviados para o Amazon S3 CloudWatch , Logs ou ambos. Consulte o caminho do log no Amazon S3 em [Configurar uma execução de trabalho para usar registros do S3 e para os registros](#) do Cloudwatch em [Configurar uma execução de trabalho](#) para usar registros. CloudWatch Para ver os registros no CloudWatch Logs, siga as instruções abaixo.

- Abra o CloudWatch console em <https://console.aws.amazon.com/cloudwatch/>.
- No painel de navegação, selecione Logs. Em seguida, escolha Grupos de logs.
- Escolha o grupo de logs do Amazon EMR no EKS e, em seguida, visualize os eventos de log carregados.

CloudWatch > CloudWatch Logs > Log groups > /emr-containers/jobs > [Switch to the original interface.](#)

Log events ☐ View as text [Actions](#) [Create Metric Filter](#)

[Clear](#) [1m](#) [30m](#) [1h](#) [12h](#) [Custom](#) [⌵](#) [⌵](#)

▶	Timestamp	Message
		No older events at this moment. Retry
▶	2020-03-10T14:27:35.713678563Z	{"message": "PI is roughly 3.1427357136785683", "time": "2020-03-10T14:27:35.713678563Z"}
		No newer events at this moment. Auto retry paused. Resume

Important

Os trabalhos têm uma [política de repetição padrão configurada](#). Para obter informações sobre como modificar ou desabilitar a configuração, consulte [Uso de políticas de repetição de trabalho](#).

Links para o Amazon EMR nos guias de melhores práticas do EKS sobre GitHub

Desenvolvemos o [Guia de práticas recomendadas do Amazon EMR no EKS](#) com a colaboração da comunidade de código aberto para que fosse possível iterar rapidamente e fornecer recomendações sobre aspectos de criação e execução de um cluster virtual. Recomendamos usar o [Guia de práticas recomendadas do Amazon EMR no EKS](#) para as seções. Escolha os links em cada seção para acessar o GitHub site.

Segurança

Note

Para obter mais informações sobre segurança com o Amazon EMR no EKS, consulte [Práticas recomendadas de segurança para o Amazon EMR no EKS](#).

[Práticas recomendadas de criptografia](#): descreve como usar a criptografia para dados em repouso e em trânsito.

O [gerenciamento da segurança da rede](#) descreve como configurar grupos de segurança para pods do Amazon EMR no EKS ao se conectar a fontes de dados hospedadas em Serviços da AWS , como o Amazon RDS e o Amazon Redshift.

[Usando o gerenciador de AWS segredos para armazenar segredos](#).

Envio de trabalho para o Pyspark

[Envio de trabalho para o Pyspark](#): especifica diferentes tipos de empacotamentos para as aplicações do PySpark usando formatos de empacotamento como zip, egg, wheel e pex.

Armazenamento

[Uso de volumes do EBS](#): descreve como usar o provisionamento estático e dinâmico para trabalhos que precisam de volumes do EBS.

[Usando volumes do Amazon FSx for Luster](#): como usar o provisionamento estático e dinâmico para trabalhos que precisam de volumes do Amazon FSx for Luster.

[Uso de volumes de armazenamento de instância](#): descreve como usar volumes de armazenamento de instância para o processamento de trabalhos.

Integração com o metastore

[Uso do Hive Metastore](#): oferece diferentes maneiras de usar o Hive Metastore.

[Usando o AWS Glue](#): oferece maneiras diferentes de configurar o catálogo do AWS Glue.

Depuração

[Uso da depuração do Spark](#): descreve como alterar o nível de log.

[Conexão com a interface do usuário do Spark no pod do driver](#).

[Como usar o servidor de histórico do Spark de hospedagem própria com o Amazon EMR no EKS](#).

Solução de problemas do Amazon EMR no EKS

[Solução de problemas](#).

Posicionamento de nó

[Uso de seletores de nó do Kubernetes](#) para single-az e outros casos de uso.

[Uso do posicionamento de nó do Fargate](#).

desempenho

[Uso da alocação dinâmica de recursos \(DRA\)](#).

[Práticas recomendadas do EKS](#) para o plug-in Container Network Interface (CNI) da Amazon VPC, o Cluster Autoscaler e o CoreDNS.

Otimização de custos

[Usando instâncias spot](#): melhores práticas de instâncias EC2 spot da Amazon e como usar o recurso de desativação de nós do Spark.

Usando AWS Outposts

[Executando o Amazon EMR no EKS usando AWS Outposts](#)

Personalização de imagens do Docker para o Amazon EMR no EKS

É possível usar imagens do Docker personalizadas com o Amazon EMR no EKS. A personalização da imagem de runtime do Amazon EMR no EKS oferece os seguintes benefícios:

- Empacotamento das dependências e do ambiente de runtime da aplicação em um único contêiner imutável que promove a portabilidade e simplifica o gerenciamento de dependências para cada workload.
- Instalação e configuração de pacotes otimizados para as workloads. Esses pacotes podem não estar amplamente disponíveis na distribuição pública dos runtimes do Amazon EMR.
- Integração do Amazon EMR no EKS aos processos atuais de criação, teste e implantação estabelecidos em sua organização, incluindo desenvolvimento e testes locais.
- Aplicação dos processos de segurança estabelecidos, como a verificação de imagens, que atendem aos requisitos de conformidade e governança da sua organização.

Tópicos

- [Como personalizar imagens do Docker](#)
- [Detalhes sobre como selecionar um URI de imagem base](#)
- [Considerações para personalizar imagens](#)

Como personalizar imagens do Docker

Siga as etapas a seguir para personalizar as imagens do Docker para o Amazon EMR no EKS. As etapas mostram como obter uma imagem base, personalizá-la e publicá-la e enviar uma workload usando a imagem.

- [Pré-requisitos](#)
- [Etapa 1: recuperar uma imagem base do Amazon Elastic Container Registry \(Amazon ECR\)](#)
- [Etapa 2: personalizar uma imagem base](#)
- [Etapa 3: \(opcional, mas recomendada\) validar uma imagem personalizada](#)
- [Etapa 4: publicar uma imagem personalizada](#)
- [Etapa 5: enviar uma workload do Spark no Amazon EMR usando uma imagem personalizada](#)

Note

Outras opções que você pode considerar ao personalizar imagens do Docker são a personalização para endpoints interativos, feita para garantir que tenha as dependências necessárias, ou o uso de imagens de contêiner com várias arquiteturas:

- [Personalização de imagens do Docker para endpoints interativos](#)
- [Trabalho com imagens de múltiplas arquiteturas](#)

Pré-requisitos

- Conclua as etapas em [Configuração do Amazon EMR no EKS](#) para o Amazon EMR no EKS.
- Instale o Docker em seu ambiente. Para obter mais informações, consulte [Get Docker](#).

Etapa 1: recuperar uma imagem base do Amazon Elastic Container Registry (Amazon ECR)

A imagem base contém o runtime do Amazon EMR e os conectores usados para acessar outros serviços da AWS. Para a versão 6.9.0 e posteriores do Amazon EMR, você pode obter as imagens base na galeria pública do Amazon ECR. Navegue pela galeria para encontrar o link da imagem e extraia-a para seu Workspace local. Por exemplo, para a versão 7.12.0 do Amazon EMR, o `docker pull` comando a seguir fornece a última imagem base padrão. Você pode substituir `emr-7.12.0:latest` por `emr-7.12.0-spark-rapids:latest` para recuperar a imagem que tem o acelerador RAPIDS da Nvidia. Você também pode substituir `emr-7.12.0:latest` por `emr-7.12.0-java11:latest` para recuperar a imagem com o runtime do Java 11.

```
docker pull public.ecr.aws/emr-on-eks/spark/emr-7.12.0:latest
```

Se você deseja recuperar a imagem base para uma versão 6.9.0 ou para versões anteriores do Amazon EMR, ou se preferir recuperá-la de contas de registro do Amazon ECR em cada região, use as seguintes etapas:

1. Escolha um URI de imagem base. O URI de imagem segue este formato, *ECR-registry-account*.dkr.ecr.*Region*.amazonaws.com/spark/*container-image-tag*, como demonstra o exemplo a seguir.

```
895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.6.0:latest
```

Para escolher uma imagem base em sua região, consulte [Detalhes sobre como selecionar um URI de imagem base](#).

2. Faça login no repositório do Amazon ECR no qual a imagem base está armazenada. Substitua `895885662937` e `us-west-2` pela conta de registro do Amazon ECR e pela AWS região que você selecionou.

```
aws ecr get-login-password --region us-west-2 | docker login --username AWS --password-stdin 895885662937.dkr.ecr.us-west-2.amazonaws.com
```

3. Extraia a imagem base para seu Workspace local. `emr-6.6.0:latest` Substitua pela tag de imagem do contêiner que você selecionou.

```
docker pull 895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.6.0:latest
```

Etapa 2: personalizar uma imagem base

Siga as etapas a seguir para personalizar a imagem base extraída do Amazon ECR.

1. Crie um novo Dockerfile em seu Workspace local.
2. Edite o Dockerfile que você acabou de criar e adicione o conteúdo a seguir. Este Dockerfile usa a imagem de contêiner que você extraiu de `895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.6.0:latest`.

```
FROM 895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.6.0:latest
USER root
### Add customization commands here ###
USER hadoop:hadoop
```

3. Adicione comandos no Dockerfile para personalizar a imagem base. Por exemplo, adicione um comando para instalar bibliotecas Python, como demonstra o Dockerfile a seguir.

```
FROM 895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.6.0:latest
USER root
RUN pip3 install --upgrade boto3 pandas numpy // For python 3
USER hadoop:hadoop
```

4. No mesmo diretório em que o `Dockerfile` foi criado, execute o comando apresentado a seguir para criar a imagem do Docker. Forneça um nome para a imagem do Docker, por exemplo, `emr6.6_custom`.

```
docker build -t emr6.6_custom .
```

Etapa 3: (opcional, mas recomendada) validar uma imagem personalizada

Recomendamos testar a compatibilidade da sua imagem personalizada antes de publicá-la. Você pode usar a [CLI de imagem personalizada do Amazon EMR no EKS](#) para verificar se sua imagem tem as estruturas de arquivos necessárias e as configurações corretas para a execução no Amazon EMR no EKS.

Note

A CLI de imagem personalizada do Amazon EMR no EKS não pode confirmar se sua imagem está isenta de erros. Tenha cuidado ao remover dependências das imagens base.

Siga as etapas apresentadas a seguir para validar a imagem personalizada.

1. Faça download e instale a CLI de imagem personalizada do Amazon EMR no EKS. Para obter mais informações, consulte [Amazon EMR on EKS custom image CLI Installation Guide](#).
2. Execute o comando apresentado a seguir para testar a instalação.

```
emr-on-eks-custom-image --version
```

Confira a seguir um exemplo da saída.

```
Amazon EMR on EKS Custom Image CLI  
Version: x.xx
```

3. Execute o comando apresentado a seguir para validar a imagem personalizada.

```
emr-on-eks-custom-image validate-image -i image_name -r release_version [-  
t image_type]
```

- `-i` especifica o URI da imagem local que precisa ser validado. Pode ser o URI da imagem, qualquer nome ou etiqueta que você definiu para a imagem.
- `-r` especifica a versão de liberação exata para a imagem base, por exemplo, `emr-6.6.0-latest`.
- `-t` especifica o tipo de imagem. Se for uma imagem do Spark, insira `spark`. O valor padrão é `spark`. A versão atual da CLI de imagem personalizada do Amazon EMR no EKS oferece suporte somente para imagens de runtime do Spark.

Se você executar o comando com êxito e a imagem personalizada atender a todas as configurações e estruturas de arquivos necessárias, a saída retornada exibirá os resultados de todos os testes, como demonstra o exemplo a seguir.

```
Amazon EMR on EKS Custom Image Test
Version: x.xx
... Checking if docker cli is installed
... Checking Image Manifest
[INFO] Image ID: xxx
[INFO] Created On: 2021-05-17T20:50:07.986662904Z
[INFO] Default User Set to hadoop:hadoop : PASS
[INFO] Working Directory Set to /home/hadoop : PASS
[INFO] Entrypoint Set to /usr/bin/entrypoint.sh : PASS
[INFO] SPARK_HOME is set with value: /usr/lib/spark : PASS
[INFO] JAVA_HOME is set with value: /etc/alternatives/jre : PASS
[INFO] File Structure Test for spark-jars in /usr/lib/spark/jars: PASS
[INFO] File Structure Test for hadoop-files in /usr/lib/hadoop: PASS
[INFO] File Structure Test for hadoop-jars in /usr/lib/hadoop/lib: PASS
[INFO] File Structure Test for bin-files in /usr/bin: PASS
... Start Running Sample Spark Job
[INFO] Sample Spark Job Test with local:///usr/lib/spark/examples/jars/spark-
examples.jar : PASS
-----
Overall Custom Image Validation Succeeded.
-----
```

Se a imagem personalizada não atender às configurações ou estruturas de arquivos necessárias, você obterá mensagens de erro. A saída retornada fornece informações sobre configurações ou estruturas de arquivos incorretas.

Etapa 4: publicar uma imagem personalizada

Publique a nova imagem do Docker no registro do Amazon ECR.

1. Execute o comando apresentado a seguir para criar um repositório do Amazon ECR para o armazenamento da imagem do Docker. Forneça um nome para seu repositório, por exemplo, `emr6.6_custom_repo`. Substitua `us-west-2` pela sua região.

```
aws ecr create-repository \  
  --repository-name emr6.6_custom_repo \  
  --image-scanning-configuration scanOnPush=true \  
  --region us-west-2
```

Para obter mais informações, consulte [Criar um repositório](#) no Guia do usuário do Amazon ECR.

2. Execute o comando apresentado a seguir para realizar a autenticação em seu registro padrão.

```
aws ecr get-login-password --region us-west-2 | docker login --username AWS --  
password-stdin aws_account_id.dkr.ecr.us-west-2.amazonaws.com
```

Para obter mais informações, consulte [Autenticar-se no registro padrão](#) no Guia do usuário do Amazon ECR.

3. Faça a marcação e publique uma imagem no repositório do Amazon ECR que você criou.

Marque a imagem.

```
docker tag emr6.6_custom aws_account_id.dkr.ecr.us-  
west-2.amazonaws.com/emr6.6_custom_repo
```

Envie a imagem.

```
docker push aws_account_id.dkr.ecr.us-west-2.amazonaws.com/emr6.6_custom_repo
```

Para obter mais informações, consulte [Enviar uma imagem ao Amazon ECR](#) no Guia do usuário do Amazon ECR.

Etapa 5: enviar uma workload do Spark no Amazon EMR usando uma imagem personalizada

Depois que uma imagem personalizada for criada e publicada, será possível enviar um trabalho do Amazon EMR no EKS usando uma imagem personalizada.

Primeiro, crie um start-job-run-request arquivo.json e especifique o `spark.kubernetes.container.image` parâmetro para referenciar a imagem personalizada, como demonstra o exemplo de arquivo JSON a seguir.

Note

Você pode usar o esquema `local://` para se referir aos arquivos disponíveis na imagem personalizada, conforme mostrado com o argumento `entryPoint` no trecho de código JSON abaixo. Você também pode usar o esquema `local://` para se referir às dependências da aplicação. Todos os arquivos e as dependências referenciados usando o esquema `local://` já devem estar presentes no caminho especificado na imagem personalizada.

```
{
  "name": "spark-custom-image",
  "virtualClusterId": "virtual-cluster-id",
  "executionRoleArn": "execution-role-arn",
  "releaseLabel": "emr-6.6.0-latest",
  "jobDriver": {
    "sparkSubmitJobDriver": {
      "entryPoint": "local:///usr/lib/spark/examples/jars/spark-examples.jar",
      "entryPointArguments": [
        "10"
      ],
      "sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi --conf spark.kubernetes.container.image=123456789012.dkr.ecr.us-west-2.amazonaws.com/emr6.6_custom_repo"
    }
  }
}
```

Você também pode fazer referência à imagem personalizada com propriedades `applicationConfiguration`, como demonstra o exemplo a seguir.

```
{
  "name": "spark-custom-image",
  "virtualClusterId": "virtual-cluster-id",
  "executionRoleArn": "execution-role-arn",
  "releaseLabel": "emr-6.6.0-latest",
  "jobDriver": {
    "sparkSubmitJobDriver": {
      "entryPoint": "local:///usr/lib/spark/examples/jars/spark-examples.jar",
      "entryPointArguments": [
        "10"
      ],
      "sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi"
    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "spark-defaults",
        "properties": {
          "spark.kubernetes.container.image": "123456789012.dkr.ecr.us-west-2.amazonaws.com/emr6.6_custom_repo"
        }
      }
    ]
  }
}
```

Em seguida, execute o comando `start-job-run` para enviar o trabalho.

```
aws emr-containers start-job-run --cli-input-json file:///./start-job-run-request.json
```

Nos exemplos de JSON acima, *emr-6.6.0-latest* substitua pela sua versão de lançamento do Amazon EMR. Recomendamos fortemente usar a versão de liberação `-latest` para garantir que a versão selecionada contenha as atualizações de segurança mais recentes. Para obter mais informações sobre as versões de liberação do Amazon EMR e suas etiquetas de imagem, consulte [Detalhes sobre como selecionar um URI de imagem base](#).

Note

É possível usar `spark.kubernetes.driver.container.image` e `spark.kubernetes.executor.container.image` para especificar uma imagem diferente para pods de drivers e de executores.

Personalização de imagens do Docker para endpoints interativos

Você também pode personalizar as imagens do Docker para endpoints interativos com a finalidade de executar imagens base de kernel personalizadas. Isso ajuda a garantir que você tenha as dependências necessárias ao executar workloads interativas do EMR Studio.

1. Siga as [etapas 1 a 4](#) descritas acima para personalizar uma imagem do Docker. Para versões 6.9.0 e posteriores do Amazon EMR, é possível obter o URI da imagem base na galeria pública do Amazon ECR. Para versões anteriores ao Amazon EMR 6.9.0, você pode obter a imagem nas contas de registro do Amazon ECR em cada Região da AWS, e a única diferença é o URI da imagem base em seu Dockerfile. O URI da imagem base segue o formato:

```
ECR-registry-account.dkr.ecr.Region.amazonaws.com/notebook-spark/container-image-tag
```

Você precisa usar `notebook-spark` no URI da imagem base, em vez de `spark`. A imagem base contém o runtime do Spark e os kernels do caderno que são executados com ele. Para obter mais informações sobre como selecionar as regiões e as etiquetas de imagem de contêiner, consulte [Detalhes sobre como selecionar um URI de imagem base](#).

Note

Atualmente, somente substituições de imagens básicas são suportadas e a introdução de kernels completamente novos de outros tipos além dos fornecidos pelas imagens AWS básicas não é suportada.

2. Crie um endpoint interativo que possa ser usado com a imagem personalizada.

Primeiro, crie um arquivo JSON chamado `custom-image-managed-endpoint.json` com o conteúdo apresentado a seguir.

```
{
  "name": "endpoint-name",
  "virtualClusterId": "virtual-cluster-id",
  "type": "JUPYTER_ENTERPRISE_GATEWAY",
  "releaseLabel": "emr-6.6.0-latest",
  "executionRoleArn": "execution-role-arn",
  "certificateArn": "certificate-arn",
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "jupyter-kernel-overrides",
        "configurations": [
          {
            "classification": "python3",
            "properties": {
              "container-image": "123456789012.dkr.ecr.us-
west-2.amazonaws.com/custom-notebook-python:latest"
            }
          },
          {
            "classification": "spark-python-kubernetes",
            "properties": {
              "container-image": "123456789012.dkr.ecr.us-
west-2.amazonaws.com/custom-notebook-spark:latest"
            }
          }
        ]
      }
    ]
  }
}
```

Em seguida, crie um endpoint interativo usando as configurações especificadas no arquivo JSON, como demonstra o exemplo a seguir.

```
aws emr-containers create-managed-endpoint --cli-input-json custom-image-managed-
endpoint.json
```

Para obter mais informações, consulte [Criação de um endpoint interativo para o cluster virtual](#).

3. Conecte-se ao endpoint interativo usando o EMR Studio. Para obter mais informações, consulte [Connecting from Studio](#).

Trabalho com imagens de múltiplas arquiteturas

O Amazon EMR no EKS oferece suporte a imagens de contêiner de múltiplas arquiteturas para o Amazon Elastic Container Registry (Amazon ECR). Para obter mais informações, consulte [Introducing multi-architecture container images for Amazon ECR](#).

As imagens personalizadas do Amazon EMR no EKS oferecem suporte tanto para instâncias EC2 AWS baseadas em Graviton quanto para instâncias EC2. non-Graviton-based As imagens baseadas em Graviton são armazenadas nos mesmos repositórios de imagens no Amazon ECR que as imagens. non-Graviton-based

Por exemplo, para inspecionar a lista de manifestos do Docker para imagens 6.6.0, execute o comando a seguir.

```
docker manifest inspect 895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.6.0:latest
```

Confira a saída a seguir. A arquitetura arm64 é para instâncias baseadas no Graviton. A arquitetura amd64 é para instâncias não baseadas no Graviton.

```
{
  "schemaVersion": 2,
  "mediaType": "application/vnd.docker.distribution.manifest.list.v2+json",
  "manifests": [
    {
      "mediaType": "application/vnd.docker.distribution.manifest.v2+json",
      "size": 1805,
      "digest":
"xxx123:6b971cb47d11011ab3d45fff925e9442914b4977ae0f9fbcdcf5cfa99a7593f0",
      "platform": {
        "architecture": "arm64",
        "os": "linux"
      }
    },
    {
      "mediaType": "application/vnd.docker.distribution.manifest.v2+json",
      "size": 1805,
```

```
    "digest":  
    "xxx123:6f2375582c9c57fa9838c1d3a626f1b4fc281e287d2963a72dfe0bd81117e52f",  
    "platform": {  
        "architecture": "amd64",  
        "os": "linux"  
    }  
  }  
]  
}
```

Execute as seguintes etapas para criar imagens de múltiplas arquiteturas:

1. Crie um Dockerfile com o conteúdo apresentado a seguir para que você possa extrair a imagem arm64.

```
FROM --platform=arm64 895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/  
emr-6.6.0:latest  
USER root  
  
RUN pip3 install boto3 // install customizations here  
USER hadoop:hadoop
```

2. Siga as instruções em [Introducing multi-architecture container images for Amazon ECR](#) para desenvolver uma imagem com múltiplas arquiteturas.

 Note

Você deve criar imagens arm64 em instâncias arm64. De forma semelhante, você deve criar imagens amd64 em instâncias amd64.

Também é possível desenvolver imagens com múltiplas arquiteturas sem a necessidade de criar cada tipo de instância específico com o comando `buildx` do Docker. Para obter mais informações, consulte [Leverage multi-CPU architecture support](#).

3. Após criar uma imagem com múltiplas arquiteturas, você poderá enviar um trabalho com o mesmo parâmetro `spark.kubernetes.container.image` e direcioná-lo para a imagem. Em um cluster heterogêneo com instâncias AWS baseadas em Graviton e non-Graviton-based EC2, a instância determina a imagem correta da arquitetura com base na arquitetura da instância que extrai a imagem.

Detalhes sobre como selecionar um URI de imagem base

Note

Para versões 6.9.0 e posteriores do Amazon EMR, é possível recuperar a imagem base da galeria pública do Amazon ECR, portanto, não é necessário criar o URI da imagem base conforme as instruções nesta página. Para encontrar a etiqueta da imagem de contêiner para sua imagem base, consulte a [página de notas de versão](#) da versão correspondente do Amazon EMR no EKS.

As imagens base do Docker que você pode selecionar são armazenadas no Amazon Elastic Container Registry (Amazon ECR). O URI da imagem segue este formato: *ECR-registry-account.dkr.ecr.Region.amazonaws.com/spark/container-image-tag*, como demonstra o seguinte exemplo a seguir.

```
895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-7.12.0:latest
```

O URI da imagem para endpoints interativos segue este formato: *ECR-registry-account.dkr.ecr.Region.amazonaws.com/notebook-spark/container-image-tag*, como demonstra o exemplo a seguir. Você precisa usar notebook-spark no URI da imagem base, em vez de spark.

```
895885662937.dkr.ecr.us-west-2.amazonaws.com/notebook-spark/emr-7.12.0:latest
```

De forma semelhante, para imagens python3 que não sejam do Spark para endpoints interativos, o URI da imagem é *ECR-registry-account.dkr.ecr.Region.amazonaws.com/notebook-python/container-image-tag*. O seguinte URI de exemplo está formatado corretamente:

```
895885662937.dkr.ecr.us-west-2.amazonaws.com/notebook-python/emr-7.12.0:latest
```

Para encontrar a etiqueta da imagem de contêiner para sua imagem base, consulte a [página de notas de versão](#) da versão correspondente do Amazon EMR no EKS.

Contas de registro do Amazon ECR por região

Para evitar a alta latência da rede, extraia uma imagem base da imagem mais próxima Região da AWS. Selecione a conta de registro do Amazon ECR que corresponde à região da qual você extrairá a imagem com base na tabela a seguir.

Regiões	Contas de registro do Amazon ECR	
ap-east-1	736135916053	
ap-northeast-1	059004520145	
ap-northeast-2	996579266876	
ap-northeast-3	705689932349	
ap-southeast-3	946962994502	
ap-south-1	235914868574	
ap-south-2	691480105545	
ap-southeast-1	671219180197	
ap-southeast-2	038297999601	
ca-central-1	351826393999	
eu-central-1	107292555468	
eu-central-2	314408114945	
eu-north-1	830386416364	
eu-west-1	483788554619	
eu-west-2	118780647275	
eu-west-3	307523725174	

Regiões	Contas de registro do Amazon ECR	
eu-south-1	238014973495	
eu-south-2	350796622945	
il-central-1	395734710648	
me-south-1	008085056818	
me-central-1	818935616732	
sa-east-1	052806832358	
us-gov-west-1	299385240661	
us-gov-east-1	299393998622	
us-east-1	755674844232	
us-east-2	711395599931	
us-west-1	608033475327	
us-west-2	895885662937	
af-south-1	358491847878	
cn-north-1	068337069695	
cn-northwest-1	068420816659	

Considerações para personalizar imagens

Ao personalizar imagens do Docker, é possível escolher o runtime exato para seu trabalho em um nível granular. Considere estas práticas recomendadas ao usar esse recurso. Isso inclui considerações sobre segurança, configuração e montagem de uma imagem:

- A segurança é uma responsabilidade compartilhada entre você AWS e você. Você é responsável pela aplicação de patches de segurança nos binários adicionados à imagem. Siga as [Práticas recomendadas de segurança para o Amazon EMR no EKS](#), especialmente o que é colocado em [Obtenção das atualizações de segurança mais recentes para as imagens personalizadas](#) e [Aplicação do princípio de privilégio mínimo](#).
- Ao personalizar uma imagem base, você deve alterar o usuário do Docker para `hadoop:hadoop` com a finalidade de que os trabalhos não sejam executados com o usuário raiz.
- O Amazon EMR no EKS monta arquivos sobre as configurações para as imagens, como o `spark-defaults.conf`, no runtime. Para substituir esses arquivos de configuração, recomendamos usar o parâmetro `applicationOverrides` durante o envio do trabalho e não modificar diretamente os arquivos na imagem personalizada.
- O Amazon EMR no EKS monta determinadas pastas no runtime. Quaisquer modificações feitas nessas pastas não estarão disponíveis no contêiner. Se você deseja adicionar uma aplicação ou suas dependências para as imagens personalizadas, recomendamos escolher um diretório que não faça parte dos seguintes caminhos definidos previamente:
 - `/var/log/fluentd`
 - `/var/log/spark/user`
 - `/var/log/spark/apps`
 - `/mnt`
 - `/tmp`
 - `/home/hadoop`
- Você pode fazer upload de sua imagem personalizada para qualquer repositório compatível com Docker, como o Amazon ECR, o Docker Hub ou um repositório empresarial privado. Para obter mais informações sobre como configurar a autenticação de cluster do Amazon EKS com o repositório do Docker selecionado, consulte [Pull an Image from a Private Registry](#).

Execução de trabalhos do Flink com o Amazon EMR no EKS

As versões 6.13.0 e superiores do Amazon EMR oferecem suporte ao Amazon EMR no EKS com o Apache Flink ou ao operador do Kubernetes para Flink, como um modelo de envio de trabalhos para o Amazon EMR no EKS. Com o Amazon EMR no EKS com o Apache Flink, você pode implantar e gerenciar aplicações do Flink com o runtime da versão do Amazon EMR em seus próprios clusters do Amazon EKS. Depois de implantar o operador do Kubernetes para Flink em seu cluster do Amazon EKS, você poderá enviar aplicações do Flink diretamente com o operador. O operador gerencia o ciclo de vida das aplicações do Flink.

Tópicos

- [Configuração e uso do operador do Kubernetes do Flink](#)
- [Uso do Kubernetes nativo do Flink](#)
- [Personalização de imagens do Docker para o Flink e o FluentD](#)
- [Monitoramento do operador do Kubernetes para Flink e dos trabalhos do Flink](#)
- [Como o Flink oferece suporte à alta disponibilidade e resiliência do trabalho](#)
- [Uso do Autoscaler para aplicações do Flink](#)
- [Manutenção e solução de problemas para trabalhos do Flink no Amazon EMR no EKS](#)
- [Versões compatíveis para Amazon EMR no EKS com Apache Flink](#)

Configuração e uso do operador do Kubernetes do Flink

As páginas apresentadas a seguir descrevem como configurar e usar o operador do Kubernetes para Flink com a finalidade de executar trabalhos do Flink com o Amazon EMR no EKS. Os tópicos disponíveis incluem pré-requisitos obrigatórios, como configurar seu ambiente e executar uma aplicação do Flink no Amazon EMR no EKS.

Tópicos

- [Configuração do operador do Kubernetes para Flink para o Amazon EMR no EKS](#)
- [Desinstalação do operador do Kubernetes do Flink no Amazon EMR no EKS](#)
- [Execução de uma aplicação do Flink](#)
- [Permissões do perfil de segurança para executar uma aplicação do Flink](#)

- [Desinstalação do operador do Kubernetes para Flink para o Amazon EMR no EKS](#)

Configuração do operador do Kubernetes para Flink para o Amazon EMR no EKS

Conclua as tarefas apresentadas a seguir para se preparar antes de instalar o operador do Kubernetes para Flink no Amazon EKS. Se você já se inscreveu na Amazon Web Services (AWS) e usou o Amazon EKS, está com quase tudo pronto para usar o Amazon EMR no EKS. Conclua as tarefas apresentadas a seguir para se preparar para usar o operador do Flink no Amazon EKS. Se você já completou algum dos pré-requisitos, pode ignorá-los e passar para os próximos.

- [Instale ou atualize para a versão mais recente do AWS CLI](#) — Se você já instalou o AWS CLI, confirme se você tem a versão mais recente.
- [Instale kubectl e eksctl](#): o eksctl é uma ferramenta de linha de comando usada para se comunicar com o Amazon EKS.
- [Instale o Helm](#): o gerenciador de pacotes Helm para o Kubernetes ajuda a instalar e gerenciar aplicações em seu cluster do Kubernetes.
- [Comece a usar o Amazon EKS \(eksctl\)](#): siga as etapas para criar um cluster do Kubernetes com nós no Amazon EKS.
- [Escolha um rótulo de lançamento do Amazon EMR](#) (versão 6.13.0 ou superiores): o operador do Kubernetes do Flink é compatível com as versões 6.13.0 e superiores do Amazon EMR.
- [Habilite perfis do IAM para contas de serviço \(IRSA\) no cluster do Amazon EKS](#).
- [Crie um perfil de execução de trabalho](#).
- [Atualize a política de confiança do perfil de execução de trabalho](#).
- Crie um perfil de execução de operador. Esta etapa é opcional. É possível usar o mesmo perfil para trabalhos e operadores do Flink. Se desejar ter um perfil do IAM diferente para o operador, você poderá criar um perfil separado.
- Atualize a política de confiança do perfil de execução do operador. Você deve adicionar explicitamente uma entrada de política de confiança para os perfis que deseja usar para a conta de serviço do operador do Kubernetes para Flink no Amazon EMR. Você pode seguir este formato de exemplo:

JSON

```
{
```

```
"Version": "2012-10-17",
"Statement": [
  {
    "Effect": "Allow",
    "Action": [
      "sts:AssumeRoleWithWebIdentity"
    ],
    "Resource": [
      "*"
    ],
    "Condition": {
      "StringLike": {
        "aws:userid": "system:serviceaccount:emr:emr-containers-sa-flink-
operator"
      }
    },
    "Sid": "AllowSTSAssumerolewithwebidentity"
  }
]
```

Desinstalação do operador do Kubernetes do Flink no Amazon EMR no EKS

Este tópico ajuda você a começar a usar o operador do Kubernetes do Flink no Amazon EKS ao preparar uma implantação do Flink.

Como instalar o operador do Kubernetes

Use as etapas a seguir para instalar o operador do Kubernetes para Apache Flink.

1. Caso ainda não tenha feito, conclua as etapas em [the section called “Configurar”](#).
2. Instale o *cert-manager* (uma vez por cluster do Amazon EKS) para permitir a adição do componente webhook.

```
kubectl apply -f https://github.com/cert-manager/cert-manager/releases/download/
v1.12.0/cert-manager.yaml
```

3. Instale o chart do Helm.

```
export VERSION=7.12.0 # The Amazon EMR release version
```

```
export NAMESPACE=The Kubernetes namespace to deploy the operator

helm install flink-kubernetes-operator \
oci://public.ecr.aws/emr-on-eks/flink-kubernetes-operator \
--version $VERSION \
--namespace $NAMESPACE
```

Resultado do exemplo:

```
NAME: flink-kubernetes-operator
LAST DEPLOYED: Tue May 31 17:38:56 2022
NAMESPACE: $NAMESPACE
STATUS: deployed
REVISION: 1
TEST SUITE: None
```

4. Aguarde a conclusão da implantação e verifique a instalação do chart.

```
kubectl wait deployment flink-kubernetes-operator --namespace $NAMESPACE --for
condition=Available=True --timeout=30s
```

5. Você deverá visualizar a mensagem a seguir quando a implantação for concluída.

```
deployment.apps/flink-kubernetes-operator condition met
```

6. Use o comando apresentado a seguir para visualizar o operador implantado.

```
helm list --namespace $NAMESPACE
```

O exemplo a seguir mostra um exemplo de saída, em que a versão da aplicação `x.y.z-amzn-n` corresponderia à versão do operador do Flink para seu Amazon EMR na versão EKS. Para obter mais informações, consulte [Versões compatíveis para Amazon EMR no EKS com Apache Flink](#).

NAME	STATUS	CHART	NAMESPACE	REVISION	UPDATED	APP VERSION
flink-kubernetes-operator			\$NAMESPACE	1	2023-02-22 16:43:45	24148
-0500 EST	deployed	flink-kubernetes-operator-emr-7.12.0				x.y.z-amzn-n

Faça upgrade do operador Kubernetes

Para fazer upgrade para a versão do operador Flink, siga estas etapas:

1. Desinstale o antigo `flink-kubernetes-operator`: `helm uninstall flink-kubernetes-operator -n <NAMESPACE>`.
2. Exclua o CRD (já que o helm não exclui automaticamente o CRD antigo): `kubectl delete crd flinkdeployments.flink.apache.org flinksessionjobs.flink.apache.org`.
3. Reinstale `flink-kubernetes-operator` com a versão mais recente.

Execução de uma aplicação do Flink

Com as versões 6.13.0 e superiores do Amazon EMR, você pode executar uma aplicação do Flink usando o operador do Kubernetes para Flink no modo Aplicação do Amazon EMR no EKS. Com as versões 6.15.0 e superiores do Amazon EMR, você também pode executar uma aplicação do Flink no modo Sessão. Esta página descreve ambos os métodos para executar uma aplicação do Flink com o Amazon EMR no EKS.

Note

Você deve ter um bucket do Amazon S3 criado para armazenar os metadados de alta disponibilidade ao enviar o trabalho do Flink. Se não desejar esse atributo, você poderá desativá-lo. Por padrão, ele é habilitado.

Pré-requisito: antes de executar uma aplicação do Flink com o operador do Kubernetes para Flink, conclua as etapas em [the section called “Configurar”](#) e [the section called “Como instalar o operador do Kubernetes”](#).

Application mode

Com as versões 6.13.0 e superiores do Amazon EMR, você pode executar uma aplicação do Flink usando o operador do Kubernetes para Flink no modo Aplicação do Amazon EMR no EKS.

1. Crie um arquivo `basic-example-app-cluster.yaml` de definição `FlinkDeployment` como no exemplo a seguir. Se você ativou e usou um dos [opt-in Regiões da AWS](#), certifique-se de descomentar e configurar a configuração. `fs.s3a.endpoint.region`

```

apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: basic-example-app-cluster
spec:
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
    #fs.s3a.endpoint.region: OPT_IN_AWS_REGION_NAME
    state.checkpoints.dir: CHECKPOINT_S3_STORAGE_PATH
    state.savepoints.dir: SAVEPOINT_S3_STORAGE_PATH
  flinkVersion: v1_17
  executionRoleArn: JOB_EXECUTION_ROLE_ARN
  emrReleaseLabel: "emr-6.13.0-flink-latest" # 6.13 or higher
  jobManager:
    storageDir: HIGH_AVAILABILITY_STORAGE_PATH
    resource:
      memory: "2048m"
      cpu: 1
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
  job:
    # if you have your job jar in S3 bucket you can use that path as well
    jarURI: local:///opt/flink/examples/streaming/StateMachineExample.jar
    parallelism: 2
    upgradeMode: savepoint
    savepointTriggerNonce: 0
  monitoringConfiguration:
    cloudWatchMonitoringConfiguration:
      logGroupName: LOG_GROUP_NAME

```

- Envie a implantação do Flink com o comando apresentado a seguir. Isso também criará um objeto FlinkDeployment chamado basic-example-app-cluster.

```
kubectl create -f basic-example-app-cluster.yaml -n <NAMESPACE>
```

- Acesse a interface do usuário do Flink.

```
kubectl port-forward deployments/basic-example-app-cluster 8081 -n NAMESPACE
```

4. Abra `localhost:8081` para visualizar os trabalhos do Flink localmente.
5. Limpe o trabalho. Lembre-se de limpar os artefatos do S3 que foram criados para esse trabalho, como pontos de verificação, alta disponibilidade, metadados de pontos de salvamento e registros. CloudWatch

Para obter mais informações sobre o envio de inscrições para o Flink por meio do operador Flink Kubernetes, consulte exemplos de operadores do [Flink Kubernetes](#) na pasta em. `apache/flink-kubernetes-operator` GitHub

Session mode

Com as versões 6.15.0 e superiores do Amazon EMR, você pode executar uma aplicação do Flink usando o operador do Kubernetes para Flink no modo Sessão no Amazon EMR no EKS.

1. Crie um arquivo de definição `FlinkDeployment` chamado `basic-example-app-cluster.yaml` como no exemplo a seguir. Se você ativou e usou um dos [opt-in Regiões da AWS](#), certifique-se de descomentar e configurar a configuração. `fs.s3a.endpoint.region`

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: basic-example-session-cluster
spec:
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
    #fs.s3a.endpoint.region: OPT_IN_AWS_REGION_NAME
    state.checkpoints.dir: CHECKPOINT_S3_STORAGE_PATH
    state.savepoints.dir: SAVEPOINT_S3_STORAGE_PATH
  flinkVersion: v1_17
  executionRoleArn: JOB_EXECUTION_ROLE_ARN
  emrReleaseLabel: "emr-6.15.0-flink-latest"
  jobManager:
    storageDir: HIGH_AVAILABILITY_S3_STORAGE_PATH
    resource:
      memory: "2048m"
      cpu: 1
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
```

```
monitoringConfiguration:
  s3MonitoringConfiguration:
    logUri:
  cloudWatchMonitoringConfiguration:
    logGroupName: LOG_GROUP_NAME
```

- Envie a implantação do Flink com o comando apresentado a seguir. Isso também criará um objeto FlinkDeployment chamado basic-example-session-cluster.

```
kubectl create -f basic-example-app-cluster.yaml -n NAMESPACE
```

- Use o seguinte comando para confirmar se o cluster da sessão LIFECYCLE é STABLE:

```
kubectl get flinkdeployments.flink.apache.org basic-example-session-cluster -n NAMESPACE
```

A saída deve ser semelhante ao seguinte exemplo:

NAME	JOB STATUS	LIFECYCLE STATE
basic-example-session-cluster		STABLE

- Crie um arquivo basic-session-job.yaml de recursos de definição personalizado do FlinkSessionJob com o seguinte conteúdo de exemplo:

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkSessionJob
metadata:
  name: basic-session-job
spec:
  deploymentName: basic-session-deployment
  job:
    # If you have your job jar in an S3 bucket you can use that path.
    # To use jar in S3 bucket, set
    # OPERATOR_EXECUTION_ROLE_ARN (--set emrContainers.operatorExecutionRoleArn=
    $OPERATOR_EXECUTION_ROLE_ARN)
    # when you install Spark operator
    jarURI: https://repo1.maven.org/maven2/org/apache/flink/flink-examples-
    streaming_2.12/1.16.1/flink-examples-streaming_2.12-1.16.1-TopSpeedWindowing.jar
    parallelism: 2
    upgradeMode: stateless
```


- Envie o trabalho de sessão do Flink com o comando apresentado a seguir. Isso criará um objeto do FlinkSessionJob `basic-session-job`.

```
kubectl apply -f basic-session-job.yaml -n $NAMESPACE
```

- Use o seguinte comando para confirmar se o cluster da sessão LIFECYCLE é STABLE e o JOB STATUS é RUNNING:

```
kubectl get flinkdeployments.flink.apache.org basic-example-session-cluster -n NAMESPACE
```

A saída deve ser semelhante ao seguinte exemplo:

NAME	JOB STATUS	LIFECYCLE STATE
basic-example-session-cluster	RUNNING	STABLE

- Acesse a interface do usuário do Flink.

```
kubectl port-forward deployments/basic-example-session-cluster 8081 -n NAMESPACE
```

- Abra `localhost:8081` para visualizar os trabalhos do Flink localmente.
- Limpe o trabalho. Lembre-se de limpar os artefatos do S3 que foram criados para esse trabalho, como pontos de verificação, alta disponibilidade, metadados de pontos de salvamento e registros. CloudWatch

Permissões do perfil de segurança para executar uma aplicação do Flink

Este tópico descreve os perfis de segurança para implantar e executar uma aplicação do Flink. Há dois perfis necessários para gerenciar uma implantação e criar e gerenciar trabalhos: o perfil de operador e o perfil de trabalho. Este tópico os apresenta e lista as permissões.

Controle de acesso baseado em perfis

Para implantar o operador e executar os trabalhos do Flink, é necessário criar dois perfis do Kubernetes: um perfil de operador e um perfil de trabalho. Por padrão, o Amazon EMR cria os dois perfis ao instalar o operador.

Perfil de operador

Usamos a função de operador para gerenciar `flinkdeployments` a criação e o JobManager gerenciamento de cada tarefa do Flink e de outros recursos, como serviços.

O nome padrão do perfil de operador é `emr-containers-sa-flink-operator` e ele requer as permissões apresentadas a seguir.

```
rules:
- apiGroups:
  - ""
  resources:
  - pods
  - services
  - events
  - configmaps
  - secrets
  - serviceaccounts
  verbs:
  - '*'
- apiGroups:
  - rbac.authorization.k8s.io
  resources:
  - roles
  - rolebindings
  verbs:
  - '*'
- apiGroups:
  - apps
  resources:
  - deployments
  - deployments/finalizers
  - replicasets
  verbs:
  - '*'
- apiGroups:
  - extensions
  resources:
  - deployments
  - ingresses
  verbs:
  - '*'
- apiGroups:
```

```
- flink.apache.org
resources:
- flinkdeployments
- flinkdeployments/status
- flinksessionjobs
- flinksessionjobs/status
verbs:
- '*'

- apiGroups:
- networking.k8s.io
resources:
- ingresses
verbs:
- '*'

- apiGroups:
- coordination.k8s.io
resources:
- leases
verbs:
- '*'
```

Perfil de trabalho

JobManager Ele usa a função de trabalho para criar e gerenciar TaskManagers e ConfigMaps para cada trabalho.

```
rules:
- apiGroups:
- ""
resources:
- pods
- configmaps
verbs:
- '*'

- apiGroups:
- apps
resources:
- deployments
- deployments/finalizers
verbs:
- '*'
```

Desinstalação do operador do Kubernetes para Flink para o Amazon EMR no EKS

Siga estas etapas para desinstalar o operador do Kubernetes para Flink.

1. Exclua o operador.

```
helm uninstall flink-kubernetes-operator -n <NAMESPACE>
```

2. Exclua os recursos do Kubernetes que o Helm não desinstala.

```
kubectl delete serviceaccounts, roles, rolebindings -l emr-  
containers.amazonaws.com/component=flink.operator --namespace <namespace>  
kubectl delete crd flinkdeployments.flink.apache.org  
flinksessionjobs.flink.apache.org
```

3. (Opcional) Exclua o cert-manager.

```
kubectl delete -f https://github.com/jetstack/cert-manager/releases/download/  
v1.12.0/cert-manager.yaml
```

Uso do Kubernetes nativo do Flink

As versões 6.13.0 e superiores do Amazon EMR oferecem suporte ao Kubernetes nativo para Flink como uma ferramenta de linha de comando que você pode usar para enviar e executar aplicações do Flink para um cluster do Amazon EMR no EKS.

Tópicos

- [Configuração do Kubernetes nativo para Flink para o Amazon EMR no EKS](#)
- [Conceitos básicos do Kubernetes nativo para Flink para o Amazon EMR no EKS](#)
- [Requisitos de segurança da conta JobManager de serviço Flink para Kubernetes nativo](#)

Configuração do Kubernetes nativo para Flink para o Amazon EMR no EKS

Conclua as tarefas apresentadas a seguir para se preparar antes de executar uma aplicação com a CLI do Flink no Amazon EMR no EKS. Se você já se inscreveu na Amazon Web Services (AWS)

e usou o Amazon EKS, está com quase tudo pronto para usar o Amazon EMR no EKS. Se você já completou algum dos pré-requisitos, pode ignorá-los e passar para os próximos.

- [Instale ou atualize para a versão mais recente do AWS CLI](#) — Se você já instalou o AWS CLI, confirme se você tem a versão mais recente.
- [Comece a usar o Amazon EKS \(eksctl\)](#): siga as etapas para criar um cluster do Kubernetes com nós no Amazon EKS.
- [Selecione um URI de imagem base do Amazon EMR](#) (versão 6.13.0 ou superiores): o comando do Kubernetes para Flink é compatível com as versões 6.13.0 e superiores do Amazon EMR.
- Confirme se a conta JobManager de serviço tem as permissões apropriadas para criar e assistir TaskManager pods. Para obter mais informações, consulte [Requisitos de segurança da conta JobManager de serviço do Flink para o Kubernetes nativo](#).
- Configure seu [perfil de credenciais locais da AWS](#).
- [Crie ou atualize um arquivo kubeconfig para um cluster do Amazon EKS](#) no qual você deseja executar as aplicações do Flink.

Conceitos básicos do Kubernetes nativo para Flink para o Amazon EMR no EKS

Essas etapas mostram como configurar, definir uma conta de serviço e executar uma aplicação do Flink. O Kubernetes nativo para Flink é usado na implantação do Flink em um cluster do Kubernetes em execução.

Como configurar e executar uma aplicação do Flink

As versões 6.13.0 e posteriores do Amazon EMR oferecem suporte ao Kubernetes nativo para Flink para a execução de aplicações do Flink em um cluster do Amazon EKS. Para executar uma aplicação do Flink, siga estas etapas:

1. Antes de executar uma aplicação do Flink com o comando do Kubernetes nativo para Flink, conclua as etapas em [the section called “Configurar”](#).
2. [Download e instalação do Flink](#).
3. Defina os valores para as variáveis de ambiente a seguir.

```
#Export the FLINK_HOME environment variable to your local installation of Flink
export FLINK_HOME=/usr/local/bin/flink #Will vary depending on your installation
```

```
export NAMESPACE=flink
export CLUSTER_ID=flink-application-cluster
export IMAGE=<123456789012.dkr.ecr.sample-Região da AWS-.amazonaws.com/flink/
emr-6.13.0-flink:latest>
export FLINK_SERVICE_ACCOUNT=emr-containers-sa-flink
export FLINK_CLUSTER_ROLE_BINDING=emr-containers-crb-flink
```

4. Crie uma conta de serviço para gerenciar os recursos do Kubernetes.

```
kubectl create serviceaccount $FLINK_SERVICE_ACCOUNT -n $NAMESPACE
kubectl create clusterrolebinding $FLINK_CLUSTER_ROLE_BINDING --clusterrole=edit --
serviceaccount=$NAMESPACE:$FLINK_SERVICE_ACCOUNT
```

5. Execute o comando run-application da CLI.

```
$FLINK_HOME/bin/flink run-application \
  --target kubernetes-application \
  -Dkubernetes.namespace=$NAMESPACE \
  -Dkubernetes.cluster-id=$CLUSTER_ID \
  -Dkubernetes.container.image.ref=$IMAGE \
  -Dkubernetes.service-account=$FLINK_SERVICE_ACCOUNT \
  local:///opt/flink/examples/streaming/Iteration.jar
2022-12-29 21:13:06,947 INFO  org.apache.flink.kubernetes.utils.KubernetesUtils
    [] - Kubernetes deployment requires a fixed port. Configuration
blob.server.port will be set to 6124
2022-12-29 21:13:06,948 INFO  org.apache.flink.kubernetes.utils.KubernetesUtils
    [] - Kubernetes deployment requires a fixed port. Configuration
taskmanager.rpc.port will be set to 6122
2022-12-29 21:13:07,861 WARN
org.apache.flink.kubernetes.KubernetesClusterDescriptor    [] - Please note that
Flink client operations(e.g. cancel, list, stop, savepoint, etc.) won't work from
outside the Kubernetes cluster since 'kubernetes.rest-service.exposed.type' has
been set to ClusterIP.
2022-12-29 21:13:07,868 INFO
org.apache.flink.kubernetes.KubernetesClusterDescriptor    [] - Create flink
application cluster flink-application-cluster successfully, JobManager Web
Interface: http://flink-application-cluster-rest.flink:8081
```

6. Examine os recursos do Kubernetes criados.

```
kubectl get all -n <namespace>
NAME READY STATUS RESTARTS AGE
```

```
pod/flink-application-cluster-546687cb47-w2p2z 1/1 Running 0 3m37s
pod/flink-application-cluster-taskmanager-1-1 1/1 Running 0 3m24s
```

```
NAME TYPE CLUSTER-IP EXTERNAL-IP PORT(S) AGE
service/flink-application-cluster ClusterIP None <none> 6123/TCP,6124/TCP 3m38s
service/flink-application-cluster-rest ClusterIP 10.100.132.158 <none> 8081/TCP
3m38s
```


```
NAME READY UP-TO-DATE AVAILABLE AGE
deployment.apps/flink-application-cluster 1/1 1 1 3m38s
```

```
NAME DESIRED CURRENT READY AGE
replicaset.apps/flink-application-cluster-546687cb47 1 1 1 3m38s
```

7. Encaminhe a porta para 8081.

```
kubectl port-forward service/flink-application-cluster-rest 8081 -n <namespace>
Forwarding from 127.0.0.1:8081 -> 8081
```

8. Acesse localmente a interface do usuário do Flink.



9. Exclua a aplicação do Flink.

```
kubectl delete deployment.apps/flink-application-cluster -n <namespace>
deployment.apps "flink-application-cluster" deleted
```

Para obter mais informações sobre o envio de aplicações para o Flink, consulte [Native Kubernetes](#) na documentação do Apache Flink.

Requisitos de segurança da conta JobManager de serviço Flink para Kubernetes nativo

O JobManager pod Flink usa uma conta de serviço do Kubernetes para acessar o servidor da API Kubernetes para criar e assistir pods. TaskManager A conta JobManager de serviço deve ter as permissões apropriadas para create/delete TaskManager os pods e permitir que o TaskManager líder do ConfigMaps to watch recupere o endereço de JobManager e ResourceManager no seu cluster.

As regras apresentadas a seguir se aplicam a esta conta de serviço.

```
rules:
- apiGroups:
  - ""
  resources:
  - pods
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - services
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - configmaps
  verbs:
  - "*"
- apiGroups:
  - "apps"
  resources:
  - deployments
  verbs:
  - "*"

```


Personalização de imagens do Docker para o Flink e o FluentD

Siga as etapas a seguir para personalizar as imagens do Docker para o Amazon EMR no EKS com imagens do Apache Flink ou do FluentD. Isso inclui orientação técnica para obter uma imagem base, personalizá-la, publicá-la e enviar uma workload.

Tópicos

- [Pré-requisitos](#)
- [Etapa 1: recuperar uma imagem base do Amazon Elastic Container Registry](#)
- [Etapa 2: personalizar uma imagem base](#)
- [Etapa 3: publicar uma imagem personalizada](#)
- [Etapa 4: enviar uma workload do Flink no Amazon EMR usando uma imagem personalizada](#)

Pré-requisitos

Antes de personalizar a imagem do Docker, certifique-se de ter atendido aos seguintes pré-requisitos:

- Concluir as etapas em [Setting up the Flink Kubernetes operator for Amazon EMR on EKS](#).
- Instalar o Docker em seu ambiente. Para obter mais informações, consulte [Get Docker](#).

Etapa 1: recuperar uma imagem base do Amazon Elastic Container Registry

A imagem base contém o runtime do Amazon EMR e os conectores necessários para acessar outros Serviços da AWS. Se estiver usando o Amazon EMR no EKS com a versão 6.14.0 ou posterior do Flink, você pode obter as imagens base na galeria pública do Amazon ECR. Navegue pela galeria para encontrar o link da imagem e extraia-a para seu Workspace local. Por exemplo, para a versão 6.14.0 do Amazon EMR, o comando `docker pull` a seguir retorna a imagem base padrão mais recente. Substitua `emr-6.14.0:latest` pela versão de lançamento desejada.

```
docker pull public.ecr.aws/emr-on-eks/flink/emr-6.14.0-flink:latest
```

Estes são os links para a imagem da galeria do Flink e a imagem da galeria do FluentD:

- [emr-on-eks/flink/emr-6.14.0-flink](#)
- [emr-on-eks/fluente/emr-6.14.0 \(](#)

Etapa 2: personalizar uma imagem base

As etapas a seguir descrevem como personalizar a imagem base extraída do Amazon ECR.

1. Crie um novo Dockerfile em seu Workspace local.
2. Edite o Dockerfile e adicione o conteúdo a seguir. Este Dockerfile usa a imagem de contêiner que você extraiu de `public.ecr.aws/emr-on-eks/flink/emr-7.12.0-flink:latest`.

```
FROM public.ecr.aws/emr-on-eks/flink/emr-7.12.0-flink:latest
USER root
### Add customization commands here ###
USER hadoop:hadoop
```

Use a configuração a seguir se estiver utilizando o Fluentd.

```
FROM public.ecr.aws/emr-on-eks/fluentsd/emr-7.12.0:latest
USER root
### Add customization commands here ###
USER hadoop:hadoop
```

3. Adicione comandos no Dockerfile para personalizar a imagem base. O comando a seguir demonstra como instalar bibliotecas Python.

```
FROM public.ecr.aws/emr-on-eks/flink/emr-7.12.0-flink:latest
USER root
RUN pip3 install --upgrade boto3 pandas numpy // For python 3
USER hadoop:hadoop
```

4. No mesmo diretório em que o DockerFile foi criado, execute o comando a seguir para criar a imagem do Docker. O campo que você fornece após o sinalizador `-t` é o nome personalizado da imagem.

```
docker build -t <YOUR_ACCOUNT_ID>.dkr.ecr.<YOUR_ECR_REGION>.amazonaws.com/
<ECR_REPO>:<ECR_TAG>
```

Etapa 3: publicar uma imagem personalizada

Agora você pode publicar a nova imagem do Docker no Amazon ECR Registry.

1. Execute o comando a seguir para criar um repositório do Amazon ECR e armazenar a imagem do Docker. Forneça um nome para o repositório, como `emr_custom_repo`. Para obter mais informações, consulte [Create a repository](#) no Guia do usuário do Amazon Elastic Container Registry.

```
aws ecr create-repository \
  --repository-name emr_custom_repo \
  --image-scanning-configuration scanOnPush=true \
  --region <AWS_REGION>
```

2. Execute o comando apresentado a seguir para realizar a autenticação em seu registro padrão. Para obter mais informações, consulte [Authenticate to your default registry](#) no Guia do usuário do Amazon Elastic Container Registry.

```
aws ecr get-login-password --region <AWS_REGION> | docker login --username AWS --
password-stdin <AWS_ACCOUNT_ID>.dkr.ecr.<YOUR_ECR_REGION>.amazonaws.com
```

3. Envie a imagem. Para obter mais informações, consulte [Push an image to Amazon ECR](#) no Guia do usuário do Amazon Elastic Container Registry.

```
docker push <YOUR_ACCOUNT_ID>.dkr.ecr.<YOUR_ECR_REGION>.amazonaws.com/
<ECR_REPO>:<ECR_TAG>
```

Etapa 4: enviar uma workload do Flink no Amazon EMR usando uma imagem personalizada

Faça as alterações a seguir na especificação `FlinkDeployment` para usar uma imagem personalizada. Para fazer isso, insira sua própria imagem na linha `spec.image` da especificação de implantação.

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: basic-example
spec:
```

```
flinkVersion: v1_18
image: <YOUR_ACCOUNT_ID>.dkr.ecr.<YOUR_ECR_REGION>.amazonaws.com/
<ECR_REPO>:<ECR_TAG>
imagePullPolicy: Always
flinkConfiguration:
    taskmanager.numberOfTaskSlots: "1"
```

Para usar uma imagem personalizada no trabalho do FluentD, insira sua própria imagem na linha `monitoringConfiguration.image` da especificação de implantação.

```
monitoringConfiguration:
    image: <YOUR_ACCOUNT_ID>.dkr.ecr.<YOUR_ECR_REGION>.amazonaws.com/
    <ECR_REPO>:<ECR_TAG>
    cloudWatchMonitoringConfiguration:
        logGroupName: flink-log-group
        logStreamNamePrefix: custom-fluentd
```

Monitoramento do operador do Kubernetes para Flink e dos trabalhos do Flink

Esta seção descreve diversas maneiras para monitorar trabalhos do Flink com o Amazon EMR no EKS. Isso inclui a integração do Flink com o Amazon Managed Service for Prometheus, o uso do Flink Web Dashboard, que fornece o status e as métricas do trabalho, ou o uso de uma configuração de monitoramento para enviar dados de log ao Amazon S3 e ao Amazon CloudWatch.

Tópicos

- [Uso do Amazon Managed Service para Prometheus no monitoramento de trabalhos do Flink](#)
- [Uso da interface do usuário do Flink para monitorar trabalhos do Flink](#)
- [Uso da configuração de monitoramento para monitorar o operador do Kubernetes do Flink e os trabalhos do Flink](#)

Uso do Amazon Managed Service para Prometheus no monitoramento de trabalhos do Flink

Você pode integrar o Apache Flink ao Amazon Managed Service for Prometheus (portal de gerenciamento). O Amazon Managed Service for Prometheus oferece suporte à ingestão de métricas de servidores do Amazon Managed Service for Prometheus em clusters em execução no Amazon

EKS. O Amazon Managed Service for Prometheus funciona em conjunto com um servidor do Prometheus que já está em execução no cluster do Amazon EKS. A execução da integração do Amazon Managed Service for Prometheus com o operador do Flink do Amazon EMR implantará e configurará automaticamente um servidor do Prometheus para a integração com o Amazon Managed Service for Prometheus.

1. [Crie um Workspace do Amazon Managed Service for Prometheus](#). Este Workspace serve como um endpoint de ingestão. Você precisará do URL de gravação remota posteriormente.
2. Configure perfis do IAM para as contas de serviço.

Para esse método de integração, use perfis do IAM para as contas de serviço no cluster do Amazon EKS em que o servidor do Prometheus está em execução. Esses perfis também são chamados de perfis de serviço.

Se você ainda não tiver os perfis, [configure perfis de serviço para a ingestão de métricas de clusters do Amazon EKS](#).

Antes de continuar, crie um perfil do IAM chamado `amp-iamproxy-ingest-role`.

3. Instale o operador do Flink do Amazon EMR com o Amazon Managed Service for Prometheus.

Agora que você tem um Workspace do Amazon Managed Service for Prometheus, um perfil do IAM dedicado para o Amazon Managed Service for Prometheus e as permissões necessárias, é possível instalar o operador do Flink do Amazon EMR.

Criar um arquivo `enable-amp.yaml` Esse arquivo permite usar uma configuração personalizada para substituir as configurações do Amazon Managed Service for Prometheus. Use seus próprios perfis.

```
kube-prometheus-stack:
  prometheus:
    serviceAccount:
      create: true
      name: "amp-iamproxy-ingest-service-account"
      annotations:
        eks.amazonaws.com/role-arn: "arn:aws:iam::<AWS_ACCOUNT_ID>:role/amp-iamproxy-ingest-role"
      remoteWrite:
        - url: <AMAZON_MANAGED_PROMETHEUS_REMOTE_WRITE_URL>
      sigv4:
        region: <AWS_REGION>
```

```
queueConfig:
  maxSamplesPerSend: 1000
  maxShards: 200
  capacity: 2500
```

Use o comando `Helm Install --set` para transferir as substituições para o chart `flink-kubernetes-operator`.

```
helm upgrade -n <namespace> flink-kubernetes-operator \
oci://public.ecr.aws/emr-on-eks/flink-kubernetes-operator \
--set prometheus.enabled=true
-f enable-amp.yaml
```

Esse comando instala automaticamente um relator do Prometheus no operador na porta 9999. Qualquer `FlinkDeployment` futura também expõe uma porta para `metrics` em 9249.

- As métricas do operador do Flink aparecem no Prometheus sob o rótulo `flink_k8soperator_`.
- As métricas Task Manager do Flink aparecem no Prometheus sob o rótulo `flink_taskmanager_`.
- As métricas Job Manager do Flink aparecem no Prometheus sob o rótulo `flink_jobmanager_`.

Uso da interface do usuário do Flink para monitorar trabalhos do Flink

Para monitorar a integridade e a performance de uma aplicação do Flink em execução, use o painel Web do Flink. Esse painel fornece informações sobre o status do trabalho, o número TaskManagers e as métricas e registros do trabalho. Ele também permite visualizar e modificar a configuração do trabalho do Flink e interagir com o cluster do Flink para enviar ou cancelar trabalhos.

Para acessar o painel Web do Flink para uma aplicação do Flink em execução no Kubernetes:

1. Use o `kubectl port-forward` comando para encaminhar uma porta local para a porta na qual o Flink Web Dashboard está sendo executado nos pods do TaskManager aplicativo Flink. Por padrão, esta porta é 8081. `deployment-name` Substitua pelo nome da implantação do aplicativo Flink acima.

```
kubectl get deployments -n namespace
```

Resultado do exemplo:

```
kubectl get deployments -n flink-namespace
```


NAME	READY	UP-TO-DATE	AVAILABLE	AGE
basic-example	1/1	1	1	11m
flink-kubernetes-operator	1/1	1	1	21h

```
kubectl port-forward deployments/deployment-name 8081 -n namespace
```

- Se você quiser usar uma porta diferente localmente, use o parâmetro: `8081`*local-port*.

```
kubectl port-forward -n flink deployments/basic-example 8080:8081
```

- Em um navegador da Web, vá até `http://localhost:8081` (ou `http://localhost:local-port`, se você usou uma porta local personalizada) para acessar o painel Web do Flink. Esse painel mostra informações sobre o aplicativo Flink em execução, como o status do trabalho, o número e as métricas e registros do trabalho. TaskManagers



Uso da configuração de monitoramento para monitorar o operador do Kubernetes do Flink e os trabalhos do Flink

A configuração de monitoramento permite que você configure facilmente o arquivamento de registros do seu aplicativo Flink e dos registros do operador no S3 and/or CloudWatch (você pode escolher

um ou ambos). Isso adiciona um sidecar FluentD aos JobManager seus pods TaskManager e, posteriormente, encaminha os registros desses componentes para os coletores configurados.

Note

Você deve configurar perfis do IAM para a conta de serviço do seu operador do Flink e seu trabalho do Flink (contas de serviço) para poder usar esse recurso, pois ele requer interação com outros Serviços da AWS. Você deve configurar isso usando IRSA em [Configuração do operador do Kubernetes para Flink para o Amazon EMR no EKS](#).

Logs da aplicação do Flink

Você pode definir essa configuração da maneira apresentada a seguir.

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: basic-example
spec:
  image: FLINK IMAGE TAG
  imagePullPolicy: Always
  flinkVersion: v1_17
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
  executionRoleArn: JOB EXECUTION ROLE
  jobManager:
    resource:
      memory: "2048m"
      cpu: 1
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
  job:
    jarURI: local:///opt/flink/examples/streaming/StateMachineExample.jar
  monitoringConfiguration:
    s3MonitoringConfiguration:
      logUri: S3 BUCKET
    cloudWatchMonitoringConfiguration:
      logGroupName: LOG GROUP NAME
      logStreamNamePrefix: LOG GROUP STREAM PREFIX
```



```
sidecarResources:
  limits:
    cpuLimit: 500m
    memoryLimit: 250Mi
  containerLogRotationConfiguration:
    rotationSize: 2GB
    maxFilesToKeep: 10
```

A seguir, são apresentadas as opções de configuração.

- `s3MonitoringConfiguration`: a chave de configuração para configurar o encaminhamento para o S3.
- `logUri` (obrigatório): o caminho do bucket do S3 em que você deseja armazenar seus logs.
- O caminho no S3 depois que os logs forem carregados será semelhante ao apresentado a seguir.
- Nenhuma alternância de log habilitada:

```
s3://${logUri}/${POD_NAME}/STDOUT or STDERR.gz
```

- A alternância de log está habilitada. Você pode usar um arquivo rotacionado e um arquivo atual (um que não tenha carimbo de data).

```
s3://${logUri}/${POD_NAME}/STDOUT or STDERR.gz
```

O formato a seguir é um número incremental.

```
s3://${logUri}/${POD_NAME}/stdout_YYYYMMDD_index.gz
```

- As permissões do IAM apresentadas a seguir são obrigatórias para usar este encaminhador.

```
{
  "Effect": "Allow",
  "Action": [
    "s3:PutObject"
  ],
  "Resource": [
    "${S3_BUCKET_URI}/*",
    "${S3_BUCKET_URI}"
  ]
}
```

- `cloudWatchMonitoringConfiguration`— chave de configuração para a qual configurar o encaminhamento. CloudWatch
- `logGroupName`(obrigatório) — nome do grupo de CloudWatch registros para o qual você deseja enviar registros (cria automaticamente o grupo se ele não existir).
- `logStreamNamePrefix` (opcional): o nome do fluxo de logs para o qual você deseja enviar os logs. O valor padrão é uma string vazia. O formato é o seguinte:

```
${logStreamNamePrefix}/${POD_NAME}/STDOUT or STDERR
```

- As permissões do IAM apresentadas a seguir são obrigatórias para usar este encaminhador.

```
{
  "Effect": "Allow",
  "Action": [
    "logs:CreateLogStream",
    "logs:CreateLogGroup",
    "logs:PutLogEvents"
  ],
  "Resource": [
    "arn:aws:logs:REGION:ACCOUNT-ID:log-group:{YOUR_LOG_GROUP_NAME}:*",
    "arn:aws:logs:REGION:ACCOUNT-ID:log-group:{YOUR_LOG_GROUP_NAME}"
  ]
}
```

- `sideCarResources` (opcional): a chave de configuração para definir limites de recursos no contêiner sidecar do Fluent Bit iniciado.
- `memoryLimit` (opcional): o valor padrão é 512 Mi. Ajuste de acordo com suas necessidades.
- `cpuLimit` (opcional): esta opção não tem um padrão. Ajuste de acordo com suas necessidades.
- `containerLogRotationConfiguration` (opcional): controla o comportamento de alternância de log do contêiner. Ele é habilitado por padrão.
- `rotationSize` (obrigatório): especifica o tamanho do arquivo para a alternância de log. O intervalo de valores possíveis é de 2 KB a 2 GB. A parcela numérica da unidade do parâmetro `rotationSize` é transferida como um número inteiro. Como não há suporte para valores decimais, você pode especificar um tamanho de rotação de 1,5 GB, por exemplo, com o valor 1.500 MB. O padrão é 2 GB.

- `maxFilesToKeep` (obrigatório): especifica o número máximo de arquivos a serem retidos no contêiner após a alternância ter ocorrido. O valor mínimo é de 1 e o valor máximo é de 50. O padrão é 10.

Logs do operador do Flink

Também podemos habilitar o arquivamento de logs para o operador ao usar as opções apresentadas a seguir no arquivo `values.yaml` da instalação do chart do Helm. Você pode ativar o S3 ou ambos. CloudWatch

```
monitoringConfiguration:
  s3MonitoringConfiguration:
    logUri: "S3-BUCKET"
    totalFileSize: "1G"
    uploadTimeout: "1m"
  cloudWatchMonitoringConfiguration:
    logGroupName: "flink-log-group"
    logStreamNamePrefix: "example-job-prefix-test-2"
  sidecarResources:
    limits:
      cpuLimit: 1
      memoryLimit: 800Mi
    memoryBufferLimit: 700M
```

A seguir, estão apresentadas as opções de configuração disponíveis em `monitoringConfiguration`.

- `s3MonitoringConfiguration`: defina esta opção para realizar o arquivamento no S3.
- `logUri` (obrigatório): o caminho do bucket do S3 em que você deseja armazenar seus logs.
- A seguir, estão apresentados os formatos de como os caminhos do bucket do S3 podem parecer depois que os logs são carregados.
- Nenhuma alternância de log habilitada.

```
s3://{logUri}/{POD NAME}/OPERATOR or WEBHOOK/STDOUT or STDERR.gz
```

- A alternância de log está habilitada. Você pode usar um arquivo rotacionado e um arquivo atual (um que não tenha carimbo de data).

```
s3://${logUri}/${POD_NAME}/OPERATOR or WEBHOOK/STDOUT or STDERR.gz
```

O índice de formato a seguir é um número incremental.

```
s3://${logUri}/${POD_NAME}/OPERATOR or WEBHOOK/stdout_YYYYMMDD_index.gz
```

- `cloudWatchMonitoringConfiguration`— a chave de configuração para a qual configurar o encaminhamento. CloudWatch
- `logGroupName` (obrigatório) — nome do grupo de CloudWatch registros para o qual você deseja enviar registros. O grupo é criado automaticamente, se não existir.
- `logStreamNamePrefix` (opcional): o nome do fluxo de logs para o qual você deseja enviar os logs. O valor padrão é uma string vazia. O formato em CloudWatch é o seguinte:

```
${logStreamNamePrefix}/${POD_NAME}/STDOUT or STDERR
```

- `sidecarResources` (opcional): a chave de configuração para definir limites de recursos no contêiner sidecar do Fluent Bit iniciado.
 - `memoryLimit` (opcional): o limite de memória. Ajuste de acordo com suas necessidades. O padrão é de 512Mi.
 - `cpuLimit`: o limite de CPU. Ajuste de acordo com suas necessidades. Nenhum valor padrão.
- `containerLogRotationConfiguration` (opcional): controla o comportamento de alternância de log do contêiner. Ele é habilitado por padrão.
 - `rotationSize` (obrigatório): especifica o tamanho do arquivo para a alternância de log. O intervalo de valores possíveis é de 2 KB a 2 GB. A parcela numérica da unidade do parâmetro `rotationSize` é transferida como um número inteiro. Como não há suporte para valores decimais, você pode especificar um tamanho de rotação de 1,5 GB, por exemplo, com o valor 1.500 MB. O padrão é 2 GB.
 - `maxFilesToKeep` (obrigatório): especifica o número máximo de arquivos a serem retidos no contêiner após a alternância ter ocorrido. O valor mínimo é de 1 e o valor máximo é de 50. O padrão é 10.

Como o Flink oferece suporte à alta disponibilidade e resiliência do trabalho

As seções a seguir descrevem como o Flink torna os trabalhos mais confiáveis e altamente disponíveis. Ele faz isso por meio de capacidades integradas, como a alta disponibilidade do Flink e vários recursos de recuperação, caso ocorram falhas.

Tópicos

- [Uso da alta disponibilidade \(HA\) para operadores e aplicações do Flink](#)
- [Otimização dos tempos de reinicialização de trabalhos do Flink para operações de recuperação e ajuste de escala de tarefas com o Amazon EMR no EKS](#)
- [Desativação tranquila de instâncias spot com Flink no Amazon EMR no EKS](#)

Uso da alta disponibilidade (HA) para operadores e aplicações do Flink

Este tópico mostra como configurar a alta disponibilidade e descreve como ela funciona em alguns casos de uso diferentes. Isso inclui o uso do gerenciador de trabalhos e do Kubernetes nativo para Flink.

Alta disponibilidade do operador do Flink

Habilitamos a alta disponibilidade do operador do Flink para que possamos fazer failover para um operador do Flink em espera a fim de minimizar o tempo de inatividade no loop de controle do operador se ocorrerem falhas. A alta disponibilidade é habilitada por padrão e o número padrão de réplicas iniciais para o operador é dois. É possível configurar o campo de réplicas em seu arquivo `values.yaml` para o chart do Helm.

Os seguintes campos são personalizáveis:

- `replicas` (opcional, o padrão é dois): definir esse número como maior que um cria outros operadores em espera e permite uma recuperação mais rápida do trabalho.
- `highAvailabilityEnabled` (opcional, o padrão é “true”): controla se você deseja habilitar a HA. Especificar esse parâmetro como “true” habilita o suporte à implantação multi-AZ e define os parâmetros `flink-conf.yaml` corretos.

Você pode desativar a HA para seu operador ao definir a configuração apresentada a seguir em seu arquivo `values.yaml`.

```
...
imagePullSecrets: []

replicas: 1

# set this to false if you don't want HA
highAvailabilityEnabled: false
...
```

Implantação multi-AZ

Criamos os pods do operador em várias zonas de disponibilidade. Esta é uma restrição leve, e seus pods do operador serão programados na mesma AZ, se você não tiver recursos suficientes em uma AZ diferente.

Determinação da réplica líder

Se o HA estiver habilitado, as réplicas usarão uma concessão para determinar qual delas JMs é a líder e usarão uma locação K8s para a eleição do líder. Você pode descrever a concessão e consultar o campo `.Spec.Holder Identity` para determinar o líder atual.

```
kubectl describe lease <Helm Install Release Name>-<NAMESPACE>-lease -n <NAMESPACE> |
grep "Holder Identity"
```

Interação entre o Flink e o S3

Configuração de credenciais de acesso

Certifique-se de ter configurado o IRSA com as permissões do IAM apropriadas para acessar o bucket do S3.

Busca por trabalhos em JARs do modo de aplicação do S3

O operador do Flink também oferece suporte à busca de aplicações do S3 em JARs. Você acabou de fornecer a localização S3 para o JARuri em sua `FlinkDeployment` especificação.

Você também pode usar esse recurso para baixar outros artefatos, como PyFlink scripts. O script do Python resultante é descartado no caminho `/opt/flink/usr/lib/`.

O exemplo a seguir demonstra como usar esse recurso para um PyFlink trabalho. Observe os campos `jarURI` e `args`.

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: python-example
spec:
  image: <YOUR CUSTOM PYFLINK IMAGE>
  emrReleaseLabel: "emr-6.12.0-flink-latest"
  flinkVersion: v1_16
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "1"
  serviceAccount: flink
  jobManager:
    highAvailabilityEnabled: false
    replicas: 1
    resource:
      memory: "2048m"
      cpu: 1
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
  job:
    jarURI: "s3://<S3-BUCKET>/scripts/pyflink.py" # Note, this will trigger the
    artifact download process
    entryClass: "org.apache.flink.client.python.PythonDriver"
    args: ["-pyclientexec", "/usr/local/bin/python3", "-py", "/opt/flink/usrlib/
    pyflink.py"]
    parallelism: 1
    upgradeMode: stateless
```

Conectores do S3 para Flink

O Flink vem com dois conectores do S3 (listados abaixo). As seções a seguir debatem sobre o momento de usar cada conector.

Ponto de verificação: conector do S3 para Presto

- Defina o esquema do S3 como `s3p://`.

- O conector recomendado a ser usado como ponto de verificação para o s3. Para obter mais informações, consulte [S3-specific](#) na documentação do Apache Flink.

Exemplo de FlinkDeployment especificação:

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: basic-example
spec:
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
    state.checkpoints.dir: s3p://<BUCKET-NAME>/flink-checkpoint/
```

Leitura e gravação no S3: conector Hadoop S3

- Defina o esquema do S3 como `s3://` ou `(s3a://)`.
- O conector recomendado para a leitura e a gravação de arquivos do S3 (somente um conector do S3 que implementa a [interface Flink Filesystem](#)).
- Por padrão, definimos `fs.s3a.aws.credentials.provider` no arquivo `flink-conf.yaml`, que é `com.amazonaws.auth.WebIdentityTokenCredentialsProvider`. Se você substituir completamente o `flink-conf` padrão e estiver interagindo com o S3, certifique-se de usar este provedor.

Exemplo de FlinkDeployment especificação

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: basic-example
spec:
  job:
    jarURI: local:///opt/flink/examples/streaming/WordCount.jar
    args: [ "--input", "s3a://<INPUT BUCKET>/PATH", "--output", "s3a://<OUTPUT BUCKET>/PATH" ]
    parallelism: 2
    upgradeMode: stateless
```


JobManager do Flink

A alta disponibilidade (HA) para implantações do Flink permite que os trabalhos continuem progredindo mesmo que um erro transitório seja encontrado e você falhe. JobManager Com a HA habilitada, os trabalhos serão reiniciados, mas a partir do último ponto de verificação com êxito. Sem o HA ativado, o Kubernetes reiniciará o seu JobManager, mas seu trabalho começará como um novo trabalho e perderá o progresso. Depois de configurar o HA, podemos pedir ao Kubernetes que armazene os metadados de HA em um armazenamento persistente para referência no caso de uma falha transitória no JobManager e, em seguida, retome nossos trabalhos a partir do último ponto de verificação bem-sucedido.

A HA é habilitada, por padrão, para os trabalhos do Flink (a contagem de réplicas é definida como dois, o que exigirá que você forneça um local de armazenamento do S3 para que os metadados de HA persistam).

Configurações de HA

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: basic-example
spec:
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
  executionRoleArn: "<JOB EXECUTION ROLE ARN>"
  emrReleaseLabel: "emr-6.13.0-flink-latest"
  jobManager:
    resource:
      memory: "2048m"
      cpu: 1
    replicas: 2
    highAvailabilityEnabled: true
    storageDir: "s3://<S3 PERSISTENT STORAGE DIR>"
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
```

A seguir estão as descrições das configurações de HA apresentadas acima no Job Manager (definidas em `.spec.jobManager`):

- `highAvailabilityEnabled` (opcional, o padrão é `"true"`): defina como `false` se você não deseja que a HA seja habilitada e não quiser usar as configurações de HA fornecidas. Você ainda pode manipular o campo `"réplicas"` para configurar manualmente a HA.
- `replicas` (opcional, o padrão é 2): definir esse número como maior que 1 cria outro modo de espera `JobManagers` e permite uma recuperação mais rápida do seu trabalho. Se você desabilitar a HA, deverá definir a contagem de réplicas como um ou continuará recebendo erros de validação (somente uma réplica tem suporte se a HA não estiver habilitada).
- `storageDir` (obrigatório): por usar a contagem de réplicas como dois, por padrão, é necessário fornecer um `storageDir` persistente. No momento, este campo aceita somente caminhos do S3 como local de armazenamento.

Localidade de pod

Se você habilitar o HA, também tentaremos colocar pods na mesma AZ, o que leva a um melhor desempenho (latência de rede reduzida ao ter pods no mesmo). Este é um processo de melhor esforço, ou seja, se você não tiver recursos suficientes na AZ em que a maioria dos seus pods está programada, os pods restantes ainda serão programados, mas poderão acabar em um nó externo a esta AZ.

Determinação da réplica líder

Se o HA estiver habilitado, as réplicas usarão uma concessão para determinar qual delas JMs é a líder e usam um K8s Configmap como armazenamento de dados para armazenar esses metadados. Se quiser determinar o líder, você pode consultar o conteúdo do Configmap e a chave `org.apache.flink.k8s.leader.restserver` nos dados para encontrar o pod do K8s com o endereço IP. Você também pode usar os comandos bash apresentados a seguir.

```
ip=$(kubectl get configmap -n <NAMESPACE> <JOB-NAME>-cluster-config-map -o json | jq -r ".data[\"org.apache.flink.k8s.leader.restserver\"]" | awk -F: '{print $2}' | awk -F '/' '{print $3}')
kubectl get pods -n NAMESPACE -o json | jq -r ".items[] | select(.status.podIP == \"$ip\") | .metadata.name"
```

Trabalho do Flink: Kubernetes nativo

As versões 6.13.0 e superiores do Amazon EMR oferecem suporte ao Kubernetes nativo para Flink para a execução de aplicações do Flink no modo de alta disponibilidade em um cluster do Amazon EKS.

 Note

Você deve ter um bucket do Amazon S3 criado para armazenar os metadados de alta disponibilidade ao enviar o trabalho do Flink. Se não desejar esse atributo, você poderá desativá-lo. Por padrão, ele é habilitado.

Para ativar o recurso de alta disponibilidade do Flink, forneça os parâmetros do Flink descritos a seguir ao [executar o comando da CLI `run-application`](#). Os parâmetros são definidos abaixo do exemplo.

```
-Dhigh-availability.type=kubernetes \  
-Dhigh-availability.storageDir=S3://DOC-EXAMPLE-STORAGE-BUCKET \  
-  
Dfs.s3a.aws.credentials.provider="com.amazonaws.auth.WebIdentityTokenCredentialsProvider"  
\  
-Dkubernetes.jobmanager.replicas=3 \  
-Dkubernetes.cluster-id=example-cluster
```

- **Dhigh-availability.storageDir**: o bucket do Amazon S3 onde você deseja armazenar os metadados de alta disponibilidade para o trabalho.

Dkubernetes.jobmanager.replicas: o número de pods do gerenciador de trabalhos a serem criados como um número inteiro maior que 1.

Dkubernetes.cluster-id: um ID exclusivo que identifica o cluster do Flink.

Otimização dos tempos de reinicialização de trabalhos do Flink para operações de recuperação e ajuste de escala de tarefas com o Amazon EMR no EKS

Quando uma tarefa falha ou ocorre uma operação de ajuste de escala, o Flink tenta reexecutar a tarefa com base no último ponto de verificação concluído. O processo de reinicialização pode levar um minuto ou mais para ser executado, dependendo do tamanho do estado do ponto de verificação e do número de tarefas paralelas. Durante o período de reinicialização, as tarefas de backlog podem se acumular para o trabalho. No entanto, existem algumas maneiras de o Flink otimizar a velocidade de recuperação e reinicialização dos gráficos de execução para melhorar a estabilidade do trabalho.

Esta página descreve algumas maneiras que o Flink no Amazon EMR pode usar para melhorar o tempo de reinício de trabalhos durante as operações de recuperação ou ajuste de escala de tarefas em instâncias spot. As instâncias spot são capacidades computacionais não utilizadas que estão disponíveis com desconto. Elas têm comportamentos únicos, incluindo interrupções ocasionais, por isso é importante entender como o Amazon EMR no EKS lida com elas e como o Amazon EMR no EKS realiza a desativação e a reinicialização do trabalho.

Tópicos

- [Recuperação local de tarefas](#)
- [Recuperação local de tarefas por meio da montagem de volume do Amazon EBS](#)
- [Ponto de verificação incremental genérico baseado em logs](#)
- [Recuperação refinada](#)
- [Mecanismo de reinício combinado no agendador adaptável](#)

Recuperação local de tarefas

Note

A recuperação local de tarefas é compatível com o Flink nas versões 6.14.0 e superiores do Amazon EMR no EKS.

Com os pontos de verificação do Flink, cada tarefa produz um snapshot do próprio estado que o Flink grava em um armazenamento distribuído, como o Amazon S3. Em casos de recuperação, as tarefas restauram o estado no armazenamento distribuído. O armazenamento distribuído oferece tolerância a falhas e pode redistribuir o estado durante o reajuste de escala por ser acessível a todos os nós.

No entanto, um armazenamento distribuído remoto também tem uma desvantagem: todas as tarefas devem ler seu estado de um local remoto na rede. Isso pode resultar em tempos de recuperação longos para estados grandes durante operações de recuperação ou ajuste de escala de tarefas.

Esse problema de tempo de recuperação longo é resolvido pela recuperação local de tarefas. As tarefas gravam seu estado no ponto de verificação em um armazenamento secundário local para a tarefa, como em um disco local. Elas também armazenam seu estado no armazenamento principal, ou no Amazon S3, no nosso caso. Durante a recuperação, o agendador programa as tarefas no

mesmo gerenciador de tarefas em que elas foram executadas anteriormente, para que possam se recuperar do armazenamento de estado local em vez de ler do armazenamento de estado remoto. Para obter mais informações, consulte [Task-Local Recovery](#) na Documentação do Apache Flink.

Nossos testes de benchmark com exemplos de trabalhos mostraram que o tempo de recuperação foi reduzido de minutos para alguns segundos com a recuperação local da tarefa ativada.

Para habilitar a recuperação local de tarefas, defina as configurações a seguir no seu arquivo `flink-conf.yaml`. Especifique o valor do intervalo do ponto de verificação em milissegundos.

```
state.backend.local-recovery: true
state.backend: hasmap or rocksdb
state.checkpoints.dir: s3://STORAGE-BUCKET-PATH/checkpoint
execution.checkpointing.interval: 15000
```

Recuperação local de tarefas por meio da montagem de volume do Amazon EBS

Note

A recuperação local de tarefas por meio do Amazon EBS é compatível com o Flink nas versões 6.15.0 e superiores do Amazon EMR no EKS.

Com o Flink para Amazon EMR no EKS, você pode provisionar automaticamente os volumes do Amazon EBS nos pods do TaskManager para a recuperação local de tarefas. A montagem de sobreposição padrão vem com um volume de 10 GB, o que é suficiente para trabalhos com um estado inferior. Trabalhos com estados grandes podem habilitar a opção de montagem automática de volume do EBS. Os pods do TaskManager são criados e montados automaticamente durante a criação do pod e removidos durante a exclusão do pod.

Use as etapas a seguir para habilitar a montagem automática de volume do EBS para o Flink no Amazon EMR no EKS.

1. Exporte os valores das seguintes variáveis que você usará nas próximas etapas:

```
export AWS_REGION=aa-example-1
export FLINK_EKS_CLUSTER_NAME=my-cluster
export AWS_ACCOUNT_ID=111122223333
```

2. Crie ou atualize um arquivo kubeconfig YAML para o cluster.

```
aws eks update-kubeconfig --name $FLINK_EKS_CLUSTER_NAME --region $AWS_REGION
```

3. Crie uma conta de serviço do IAM para o driver de interface de armazenamento de contêiner (CSI) do Amazon EBS no cluster do Amazon EKS.

```
eksctl create iamserviceaccount \  
  --name ebs-csi-controller-sa \  
  --namespace kube-system \  
  --region $AWS_REGION \  
  --cluster $FLINK_EKS_CLUSTER_NAME \  
  --role-name TLR_${AWS_REGION}_${FLINK_EKS_CLUSTER_NAME} \  
  --role-only \  
  --attach-policy-arn arn:aws:iam::aws:policy/service-role/  
AmazonEBSCSIDriverPolicy \  
  --approve
```

4. Crie o driver CSI do Amazon EBS com o seguinte comando:

```
eksctl create addon \  
  --name aws-ebs-csi-driver \  
  --region $AWS_REGION \  
  --cluster $FLINK_EKS_CLUSTER_NAME \  
  --service-account-role-arn arn:aws:iam::${AWS_ACCOUNT_ID}:role/TLR_  
${AWS_REGION}_${FLINK_EKS_CLUSTER_NAME}
```

5. Crie a classe de armazenamento do Amazon EBS com o seguinte comando:

```
cat # EOF # storage-class.yaml  
apiVersion: storage.k8s.io/v1  
kind: StorageClass  
metadata:  
  name: ebs-sc  
provisioner: ebs.csi.aws.com  
volumeBindingMode: WaitForFirstConsumer  
EOF
```

Depois, aplique a classe:

```
kubectl apply -f storage-class.yaml
```

6. O Helm instala o operador do Kubernetes para Flink do Amazon EMR com opções para criar uma conta de serviço. Isso cria o `emr-containers-sa-flink` para ser usado na implantação do Flink.

```
helm install flink-kubernetes-operator flink-kubernetes-operator/ \
  --set jobServiceAccount.create=true \
  --set rbac.jobRole.create=true \
  --set rbac.jobRoleBinding.create=true
```

7. Para enviar o trabalho do Flink e habilitar o provisionamento automático de volumes do EBS para a recuperação local de tarefas, defina as configurações a seguir no seu arquivo `flink-conf.yaml`. Ajuste o limite de tamanho para o tamanho do estado do trabalho. Defina `serviceAccount` como `emr-containers-sa-flink`. Especifique o valor do intervalo do ponto de verificação em milissegundos. Omita o `executionRoleArn`.

```
flinkConfiguration:
  task.local-recovery.ebs.enable: true
  kubernetes.taskmanager.local-recovery.persistentVolumeClaim.sizeLimit: 10Gi
  state.checkpoints.dir: s3://BUCKET-PATH/checkpoint
  state.backend.local-recovery: true
  state.backend: hasmap or rocksdb
  state.backend.incremental: "true"
  execution.checkpointing.interval: 15000
  serviceAccount: emr-containers-sa-flink
```

Quando estiver tudo pronto para excluir o plug-in do driver CSI do Amazon EBS, use os seguintes comandos:

```
# Detach Attached Policy
aws iam detach-role-policy --role-name TLR_${AWS_REGION}_${FLINK_EKS_CLUSTER_NAME}
--policy-arn arn:aws:iam::aws:policy/service-role/AmazonEBSCSIDriverPolicy
# Delete the created Role
aws iam delete-role --role-name TLR_${AWS_REGION}_${FLINK_EKS_CLUSTER_NAME}
# Delete the created service account
eksctl delete iamserviceaccount --name ebs-csi-controller-sa --namespace kube-system
--cluster $FLINK_EKS_CLUSTER_NAME --region $AWS_REGION
# Delete Addon
eksctl delete addon --name aws-ebs-csi-driver --cluster $FLINK_EKS_CLUSTER_NAME --
region $AWS_REGION
# Delete the EBS storage class
```

```
kubectl delete -f storage-class.yaml
```

Ponto de verificação incremental genérico baseado em logs

Note

O ponto de verificação incremental genérico baseado em logs é compatível com o Flink para as versões 6.14.0 e superiores do Amazon EMR no EKS.

O recurso de ponto de verificação incremental genérico baseado em logs foi adicionado ao Flink 1.16 para melhorar a velocidade dos pontos de verificação. Um intervalo de ponto de verificação mais rápido costuma resultar em uma redução do trabalho de recuperação porque menos eventos precisam ser reprocessados após a recuperação. Para obter mais informações, consulte [Improving speed and stability of checkpointing with generic log-based incremental checkpoints](#) no blog do Apache Flink.

Com exemplos de trabalhos, nossos testes de comparação mostraram que o tempo do ponto de verificação foi reduzido de minutos para alguns segundos com o ponto de verificação incremental genérico baseado em logs.

Para habilitar os pontos de verificação incrementais genéricos baseados em logs, defina as configurações a seguir no seu arquivo `flink-conf.yaml`. Especifique o valor do intervalo do ponto de verificação em milissegundos.

```
state.backend.changelog.enabled: true
state.backend.changelog.storage: filesystem
dstl.dfs.base-path: s3://bucket-path/changelog
state.backend.local-recovery: true
state.backend: rocksdb
state.checkpoints.dir: s3://bucket-path/checkpoint
execution.checkpointing.interval: 15000
```

Recuperação refinada

Note

O suporte de recuperação refinada para o agendador padrão é compatível com o Flink nas versões 6.14.0 e superiores do Amazon EMR no EKS. O suporte de recuperação refinada

no agendador adaptável está disponível com o Flink nas versões 6.15.0 e superiores do Amazon EMR no EKS.

Quando uma tarefa falha durante a execução, o Flink redefine todo o gráfico de execução e aciona a reexecução completa com base no último ponto de verificação concluído. Isso é mais caro do que apenas reexecutar as tarefas que falharam. A recuperação refinada reinicia somente o componente conectado ao pipeline da tarefa que falhou. No exemplo a seguir, o gráfico do trabalho tem cinco vértices (de A a E). É feito o pipeline de todas as conexões entre os vértices com distribuição pontual, e o `parallelism.default` do trabalho é definido como 2.

```
A # B # C # D # E
```

Neste exemplo, há um total de dez tarefas em execução. O primeiro pipeline (de a1 a e1) é executado em um TaskManager (TM1) e o segundo pipeline (de a2 a e2) é executado em outro TaskManager (TM2).

```
a1 # b1 # c1 # d1 # e1  
a2 # b2 # c2 # d2 # e2
```

Há dois componentes conectados por pipeline: a1 # e1 e a2 # e2. Se TM1 ou TM2 falhar, a falha afetará somente as cinco tarefas no pipeline em que TaskManager estava em execução. A estratégia de reinicialização só inicia o componente do pipeline afetado.

A recuperação refinada funciona somente com trabalhos perfeitamente paralelos do Flink. Não é compatível com operações de `keyBy()` ou `redistribute()`. Para obter mais informações, consulte [FLIP-1: Fine Grained Recovery from Task Failures](#) no projeto Jira Flink Improvement Proposal.

Para habilitar a recuperação refinada, defina as configurações a seguir no seu arquivo `flink-conf.yaml`.

```
jobmanager.execution.failover-strategy: region  
restart-strategy: exponential-delay or fixed-delay
```

Mecanismo de reinício combinado no agendador adaptável

Note

O mecanismo de reinicialização combinado no agendador adaptável é compatível com o Flink nas versões 6.15.0 e superiores do Amazon EMR no EKS.

O agendador adaptável pode ajustar o paralelismo do trabalho com base nos slots disponíveis. Ele reduz automaticamente o paralelismo se não houver slots suficientes disponíveis para atender ao paralelismo do trabalho configurado. Se novos slots ficarem disponíveis, o trabalho aumentará a escala verticalmente mais uma vez para o paralelismo do trabalho configurado. Um agendador adaptável evita o tempo de inatividade no trabalho quando não há recursos suficientes disponíveis. Esse é o agendador compatível com o escalador automático do Flink. Recomendamos o agendador adaptável com o Flink no Amazon EMR por esses motivos. No entanto, os agendadores adaptáveis podem fazer várias reinicializações em um curto período; uma reinicialização para cada novo recurso adicionado. Isso pode levar a uma queda na performance do trabalho.

Com o Amazon EMR 6.15.0 e versões superiores, o Flink tem um mecanismo de reinício combinado no agendador adaptável que abre uma janela de reinicialização quando o primeiro recurso é adicionado e aguarda pelo intervalo configurado da janela do padrão de um minuto. Ele executa uma única reinicialização quando há recursos suficientes disponíveis para executar o trabalho com o paralelismo configurado ou quando o intervalo expira.

Com os exemplos de trabalhos, nossos testes de comparação mostraram que esse recurso processa 10% a mais dos registros do que o comportamento padrão ao usar o agendador adaptável e o escalador automático do Flink.

Para habilitar o mecanismo de reinício combinado, defina as configurações a seguir no seu arquivo `flink-conf.yaml`.

```
jobmanager.adaptive-scheduler.combined-restart.enabled: true
jobmanager.adaptive-scheduler.combined-restart.window-interval: 1m
```

Desativação tranquila de instâncias spot com Flink no Amazon EMR no EKS

O Flink com o Amazon EMR no EKS pode melhorar o tempo de reinicialização de trabalhos durante as operações de recuperação e ajuste de escala de tarefas.

Visão geral do

As versões 6.15.0 e superiores do Amazon EMR no EKS oferecem suporte à desativação tranquila de gerenciadores de tarefas em instâncias spot no Amazon EMR no EKS com o Flink para Apache. Como parte desse recurso, o Amazon EMR no EKS com o Flink fornece as funcionalidades a seguir.

- **Just-in-time ponto de verificação** — As tarefas de streaming do Flink podem responder à interrupção da Instância Spot, realizar o ponto de verificação just-in-time (JIT) das tarefas em execução e impedir o agendamento de tarefas adicionais nessas Instâncias Spot. O ponto de verificação de JIT é compatível com agendadores padrão e adaptáveis.
- **Mecanismo de reinicialização combinado**: um mecanismo de reinicialização combinado faz a melhor tentativa de reiniciar o trabalho depois que ele atinge o paralelismo de recursos de destino ou o final da janela configurada atual. Isso também evita reinicializações consecutivas de trabalhos que podem ser causadas por vários encerramentos de instâncias spot. O mecanismo de reinicialização combinado está disponível somente com o agendador adaptável.

Esses recursos fornecem os seguintes benefícios:

- Você pode aproveitar as instâncias spot para executar gerenciadores de tarefas e reduzir os gastos com clusters.
- O aprimoramento de liveness do gerenciador de tarefas da instância spot resulta em maior resiliência e agendamento de trabalhos mais eficiente.
- Seus trabalhos do Flink terão mais tempo de atividade porque haverá menos reinicializações após o encerramento da instância spot.

Como funciona a desativação normal

Considere o seguinte exemplo: você provisiona um cluster do Amazon EMR no EKS executando o Flink para Apache e especifica nós sob demanda para o gerenciador de trabalhos e nós de instância spot para o gerenciador de tarefas. Dois minutos antes do encerramento, o gerenciador de tarefas recebe um aviso de interrupção.

Nesse cenário, o gerenciador de trabalhos manipularia o sinal de interrupção da instância spot, bloquearia o agendamento de tarefas adicionais na instância spot e iniciaria o ponto de verificação de JIT do trabalho de streaming.

Em seguida, o gerenciador de trabalhos reiniciaria o gráfico do trabalho somente depois que houvesse disponibilidade suficiente de novos recursos para satisfazer o paralelismo atual de trabalhos na janela atual do intervalo de reinicialização. O intervalo da janela de reinicialização é decidido com base na duração da substituição da instância spot, na criação de novos pods do gerenciador de tarefas e no registro no gerenciador de trabalhos.

Pré-requisitos

Para usar a desativação normal, crie e execute um trabalho de streaming em um cluster do Amazon EMR no EKS executando o Apache Flink. Habilite o agendador adaptável e os gerenciadores de tarefas agendados em, pelo menos, uma instância spot, conforme mostrado no exemplo a seguir. Você deve usar nós sob demanda para o gerenciador de trabalhos e pode usar nós sob demanda para os gerenciadores de tarefas, desde que também haja pelo menos uma instância spot.

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: deployment_name
spec:
  flinkVersion: v1_17
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
    cluster.taskmanager.graceful-decommission.enabled: "true"
    execution.checkpointing.interval: "240s"
    jobmanager.adaptive-scheduler.combined-restart.enabled: "true"
    jobmanager.adaptive-scheduler.combined-restart.window-interval : "1m"
  serviceAccount: flink
  jobManager:
    resource:
      memory: "2048m"
      cpu: 1
    nodeSelector:
      'eks.amazonaws.com/capacityType': 'ON_DEMAND'
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
    nodeSelector:
      'eks.amazonaws.com/capacityType': 'SPOT'
  job:
    jarURI: flink_job_jar_path
```

Configuração

Esta seção aborda a maioria das configurações que você pode especificar para as suas necessidades de desativação.

Chave	Description	Valor padrão	Valores aceitos
<code>cluster.taskmanager.graceful-decommission.enabled</code>	Habilita a desativação tranquila do gerenciador de tarefas.	<code>true</code>	<code>true</code> , <code>false</code>
<code>jobmanager.adaptive-scheduler.combined-restart.enabled</code>	Habilita o mecanismo de reinicialização combinado no agendador adaptável.	<code>false</code>	<code>true</code> , <code>false</code>
<code>jobmanager.adaptive-scheduler.combined-restart.window-interval</code>	O intervalo combinado da janela de reinicialização para efetuar reinicializações mescladas do trabalho. Um número inteiro sem uma unidade é interpretado como milissegundos.	<code>1m</code>	Exemplos: <code>30</code> , <code>60s</code> , <code>3m</code> , <code>1h</code>

Uso do Autoscaler para aplicações do Flink

O Autoscaler do operador pode ajudar a aliviar a contrapressão ao coletar métricas de trabalhos do Flink e ajustar automaticamente o paralelismo em nível de vértice do trabalho. Confira o seguinte exemplo de como a configuração pode se parecer:

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
```

```
metadata:
  ...
spec:
  ...
  flinkVersion: v1_18
  flinkConfiguration:
    job.autoscaler.enabled: "true"
    job.autoscaler.stabilization.interval: 1m
    job.autoscaler.metrics.window: 5m
    job.autoscaler.target.utilization: "0.6"
    job.autoscaler.target.utilization.boundary: "0.2"
    job.autoscaler.restart.time: 2m
    job.autoscaler.catch-up.duration: 5m
    pipeline.max-parallelism: "720"
  ...
```

Essa configuração usa valores padrão para a versão mais recente do Amazon EMR. Se você usar outras versões, é possível que tenha valores diferentes.

Note

A partir do Amazon EMR 7.2.0, você não precisa incluir o prefixo `kubernetes.operator` na sua configuração. Se você usa a versão 7.1.0 ou inferior, deve usar o prefixo antes de cada configuração. Por exemplo, você deve especificar `kubernetes.operator.job.autoscaler.scaling.enabled`.

A seguir, são apresentadas as opções de configuração para o Autoscaler.

- `job.autoscaler.scaling.enabled`: especifica se a execução do ajuste de escala de vértices deve ser habilitada pelo escalador automático. O padrão é `true`. Se você desabilitar essa configuração, o escalador automático coletará apenas métricas e avaliará o paralelismo sugerido para cada vértice, mas não atualizará os trabalhos.
- `job.autoscaler.stabilization.interval`: o período de estabilização no qual nenhuma nova escalabilidade será executada. O padrão é de cinco minutos.
- `job.autoscaler.metrics.window`: o tamanho da janela de agregação de métricas de escalabilidade. Quanto mais ampla for a janela, mais harmoniosa e estável ela será, mas o Autoscaler pode demorar mais para reagir a alterações repentinas de carga. O padrão é de 15 minutos. Recomendamos que você experimente usando um valor entre 3 e 60 minutos.

- `job.autoscaler.target.utilization`: a utilização desejada para o vértice para fornecer uma performance de trabalho estável e algum buffer para flutuações de carga. O padrão é 0.7 atingir 70% utilization/load para os vértices do trabalho.
- `job.autoscaler.target.utilization.boundary`: o limite da utilização desejada para o vértice, que serve como buffer extra para evitar uma escalabilidade imediata em flutuações de carga. O padrão é 0.3, o que significa que é permitido um desvio de 30% da utilização desejada antes do acionamento de uma ação de ajuste de escala.
- `ob.autoscaler.restart.time`: o tempo esperado para reiniciar a aplicação. O padrão é de cinco minutos.
- `job.autoscaler.catch-up.duration`: o tempo esperado para a recuperação, ou seja, o processamento total de qualquer backlog após a conclusão de uma operação de escalabilidade. O padrão é de cinco minutos. Ao reduzir a duração da recuperação, é necessário que o Autoscaler reserve uma capacidade extra para as ações de escalabilidade.
- `pipeline.max-parallelism`: o paralelismo máximo que o Autoscaler pode usar. O Autoscaler ignora esse limite se ele for maior que o paralelismo máximo configurado na configuração do Flink ou diretamente em cada operador. O padrão é -1. Observe que o Autoscaler calcula o paralelismo como um divisor do número de paralelismo máximo, portanto, é recomendado escolher configurações de paralelismo máximo com muitos divisores em vez de confiar nos padrões fornecidos pelo Flink. Recomendamos usar múltiplos de 60 para esta configuração, por exemplo, 120, 180, 240, 360, 720 etc.

Para obter uma página de referência de configurações mais detalhada, consulte [Autoscaler Configuration](#).

Ajuste automático dos parâmetros do escalador automático

Esta seção descreve o comportamento de ajuste automático para várias versões do Amazon EMR. Ela também detalha as diferentes configurações de ajuste de escala automático.

Note

O Amazon EMR 7.2.0 e versões posteriores usam a configuração de código aberto `job.autoscaler.restart.time-tracking.enabled` para habilitar a estimativa do tempo de redimensionamento. A estimativa do tempo de redimensionamento tem a mesma funcionalidade do ajuste automático do Amazon EMR, então você não precisa atribuir manualmente valores empíricos ao horário de reinicialização.

Você ainda pode usar o ajuste automático do Amazon EMR se estiver utilizando o Amazon EMR 7.1.0 ou inferior.

7.2.0 and higher

O Amazon EMR 7.2.0 e versões posteriores medem o tempo real de reinicialização necessário para aplicar decisões de ajuste de escala automático. Nas versões 7.1.0 e inferiores, você precisava usar a configuração `job.autoscaler.restart.time` para configurar manualmente o tempo máximo estimado de reinicialização. Ao usar a configuração `job.autoscaler.restart.time-tracking.enabled`, você só precisa inserir um horário de reinicialização para o primeiro ajuste de escala. Depois, o operador registra o tempo real de reinicialização e o usará para ajustes de escala subsequentes.

Para habilitar esse rastreamento, use o seguinte comando:

```
job.autoscaler.restart.time-tracking.enabled: true
```

A seguir estão as configurações relacionadas para a estimativa do tempo de redimensionamento.

Configuração	Obrigatório	Padrão	Description
<code>job.autoscaler.restart.time-tracking.enabled</code>	Não	Falso	Indica se o escalador automático do Flink deve ajustar automaticamente as configurações ao longo do tempo para otimizar as decisões de escalabilidade. Observe que o escalador automático só pode ajustar automaticamente o parâmetro <code>restart.time</code> do escalador automático.
<code>job.autoscaler.restart.time</code>	Não	5 minutos	O tempo de reinicialização esperado que o Amazon EMR no EKS usa até que o operador possa determina

Configuração	Obrigatório	Padrão	Description
			r o tempo real de reinicialização com base nos ajustes de escala anteriores.
job.autoscaler.restart.time-tracking.limit	Não	15 minutos	O tempo máximo de reinicialização observado quando <code>job.autoscaler.restart.time-tracking.enabled</code> está definido como <code>true</code> .

Confira este exemplo de especificação de implantação que você pode usar para testar a estimativa do tempo de redimensionamento:

```

apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: autoscaling-example
spec:
  flinkVersion: v1_18
  flinkConfiguration:

    # Autoscaler parameters
    job.autoscaler.enabled: "true"
    job.autoscaler.scaling.enabled: "true"
    job.autoscaler.stabilization.interval: "5s"
    job.autoscaler.metrics.window: "1m"

    job.autoscaler.restart.time-tracking.enabled: "true"
    job.autoscaler.restart.time: "2m"
    job.autoscaler.restart.time-tracking.limit: "10m"

    jobmanager.scheduler: adaptive
    taskmanager.numberOfTaskSlots: "1"
    pipeline.max-parallelism: "12"

  executionRoleArn: <JOB ARN>
  emrReleaseLabel: emr-7.12.0-flink-latest
  jobManager:

```

```

highAvailabilityEnabled: false
storageDir: s3://<s3_bucket>/flink/autoscaling/ha/
replicas: 1
resource:
  memory: "1024m"
  cpu: 0.5
taskManager:
  resource:
    memory: "1024m"
    cpu: 0.5
job:
  jarURI: s3://<s3_bucket>/some-job-with-back-pressure
  parallelism: 1
  upgradeMode: stateless

```

Para simular a contrapressão, use a especificação de implantação a seguir.

```

job:
  jarURI: s3://<s3_bucket>/pyflink-script.py
  entryClass: "org.apache.flink.client.python.PythonDriver"
  args: ["-py", "/opt/flink/usrlib/pyflink-script.py"]
  parallelism: 1
  upgradeMode: stateless

```

Faça upload do script Python a seguir no bucket do S3.

```

import logging
import sys
import time
import random

from pyflink.datastream import StreamExecutionEnvironment
from pyflink.table import StreamTableEnvironment

TABLE_NAME="orders"
QUERY=f"""
CREATE TABLE {TABLE_NAME} (
  id INT,
  order_time AS CURRENT_TIMESTAMP,
  WATERMARK FOR order_time AS order_time - INTERVAL '5' SECONDS
)
WITH (
  'connector' = 'datagen',

```

```

    'rows-per-second'='10',
    'fields.id.kind'='random',
    'fields.id.min'='1',
    'fields.id.max'='100'
);
"""

def create_backpressure(i):
    time.sleep(2)
    return i

def autoscaling_demo():
    env = StreamExecutionEnvironment.get_execution_environment()
    t_env = StreamTableEnvironment.create(env)
    t_env.execute_sql(QUERY)
    res_table = t_env.from_path(TABLE_NAME)

    stream = t_env.to_data_stream(res_table) \
        .shuffle().map(lambda x: create_backpressure(x)) \
        .print()
    env.execute("Autoscaling demo")

if __name__ == '__main__':
    logging.basicConfig(stream=sys.stdout, level=logging.INFO, format="%(message)s")
    autoscaling_demo()

```

Para verificar se a estimativa do tempo de redimensionamento está funcionando, confira se o registro em log em nível de DEBUG do operador do Flink está habilitado. O exemplo abaixo demonstra como atualizar o arquivo `values.yaml` do chart do Helm. Em seguida, reinstale o chart do Helm atualizado e execute o trabalho do Flink novamente.

```

log4j-operator.properties: |+
# Flink Operator Logging Overrides
rootLogger.level = DEBUG

```

Obtenha o nome do pod líder.

```

ip=$(kubectl get configmap -n $NAMESPACE <job-name>-cluster-config-map -o json | jq
-r ".data[\"org.apache.flink.k8s.leader.restserver\"]" | awk -F: '{print $2}' | awk
-F '/' '{print $3}')

```

```
kubectl get pods -n $NAMESPACE -o json | jq -r ".items[] | select(.status.podIP == \"$ip\") | .metadata.name"
```

Execute o comando a seguir para obter o tempo real de reinicialização usado nas avaliações de métricas.

```
kubectl logs <FLINK-OPERATOR-POD-NAME> -c flink-kubernetes-operator -n <OPERATOR-NAMESPACE> -f | grep "Restart time used in scaling summary computation"
```

Você deve ver logs semelhantes aos mostrados a seguir. Observe que somente o primeiro ajuste de escala usa `job.autoscaler.restart.time`. Os ajustes de escala subsequentes usam o tempo de reinicialização observado.

```
2024-05-16 17:17:32,590 o.a.f.a.ScalingExecutor [DEBUG][default/autoscaler-example] Restart time used in scaling summary computation: PT2M
2024-05-16 17:19:03,787 o.a.f.a.ScalingExecutor [DEBUG][default/autoscaler-example] Restart time used in scaling summary computation: PT14S
2024-05-16 17:19:18,976 o.a.f.a.ScalingExecutor [DEBUG][default/autoscaler-example] Restart time used in scaling summary computation: PT14S
2024-05-16 17:20:50,283 o.a.f.a.ScalingExecutor [DEBUG][default/autoscaler-example] Restart time used in scaling summary computation: PT14S
2024-05-16 17:22:21,691 o.a.f.a.ScalingExecutor [DEBUG][default/autoscaler-example] Restart time used in scaling summary computation: PT14S
```

7.0.0 and 7.1.0

O escalador automático integrado do Flink e de código aberto usa várias métricas para tomar as melhores decisões de ajuste de escala. No entanto, os valores padrão que ele usa para seus cálculos devem ser aplicáveis à maioria das workloads e podem não ser ideais para um determinado trabalho. O recurso de ajuste automático adicionado à versão do Amazon EMR no EKS do operador do Flink analisa as tendências históricas observadas em métricas específicas capturadas e, em seguida, tenta calcular o valor mais adequado para o trabalho em questão.

Configuração	Obrigatório	Padrão	Description
kubernetes.operator.job.autoscaler.autotune.enable	Não	Falso	Indica se o escalador automático do Flink deve ajustar automaticamente as configurações ao longo

Configuração	Obrigatório	Padrão	Description
			do tempo para otimizar as decisões de escalabilidade do escalador automático. Atualmente, o escalador automático só pode ajustar automaticamente seu parâmetro <code>restart.time</code> .
<code>kubernetes.operator.job.autoscaler.autotune.metrics.history.max.count</code>	Não	3	Indica quantas métricas históricas do Amazon EMR no EKS o escalador automático mantém no mapa de configuração de métricas do Amazon EMR no EKS.
<code>kubernetes.operator.job.autoscaler.autotune.metrics.restart.count</code>	Não	3	Indica quantas reinicializações o escalador automático executa antes de começar a calcular o tempo médio de reinicialização de um determinado trabalho.

Para habilitar o ajuste automático, você deve concluir as seguintes etapas:

- Defina `kubernetes.operator.job.autoscaler.autotune.enable`: como `true`
- Defina `metrics.job.status.enable`: como `TOTAL_TIME`
- Seguir a configuração em [Using Autoscaler for Flink applications](#) para habilitar o ajuste de escala automático.

Confira a seguir um exemplo de especificação de implantação que você pode usar para experimentar o ajuste automático.

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
```

```

name: autoscaling-example
spec:
  flinkVersion: v1_18
  flinkConfiguration:

    # Autotuning parameters
    kubernetes.operator.job.autoscaler.autotune.enable: "true"
    kubernetes.operator.job.autoscaler.autotune.metrics.history.max.count: "2"
    kubernetes.operator.job.autoscaler.autotune.metrics.restart.count: "1"
    metrics.job.status.enable: TOTAL_TIME

    # Autoscaler parameters
    kubernetes.operator.job.autoscaler.enabled: "true"
    kubernetes.operator.job.autoscaler.scaling.enabled: "true"
    kubernetes.operator.job.autoscaler.stabilization.interval: "5s"
    kubernetes.operator.job.autoscaler.metrics.window: "1m"

    jobmanager.scheduler: adaptive

    taskmanager.numberOfTaskSlots: "1"
    state.savepoints.dir: s3://<S3_bucket>/autoscaling/savepoint/
    state.checkpoints.dir: s3://<S3_bucket>/flink/autoscaling/checkpoint/
    pipeline.max-parallelism: "4"

  executionRoleArn: <JOB ARN>
  emrReleaseLabel: emr-6.14.0-flink-latest
  jobManager:
    highAvailabilityEnabled: true
    storageDir: s3://<S3_bucket>/flink/autoscaling/ha/
    replicas: 1
    resource:
      memory: "1024m"
      cpu: 0.5
  taskManager:
    resource:
      memory: "1024m"
      cpu: 0.5
  job:
    jarURI: s3://<S3_bucket>/some-job-with-back-pressure
    parallelism: 1
    upgradeMode: last-state

```

Para simular a contrapressão, use a especificação de implantação a seguir.

```
job:
  jarURI: s3://<S3_bucket>/pyflink-script.py
  entryClass: "org.apache.flink.client.python.PythonDriver"
  args: ["-py", "/opt/flink/usrlib/pyflink-script.py"]
  parallelism: 1
  upgradeMode: last-state
```

Faça upload do script Python a seguir no bucket do S3.

```
import logging
import sys
import time
import random

from pyflink.datastream import StreamExecutionEnvironment
from pyflink.table import StreamTableEnvironment

TABLE_NAME="orders"
QUERY=f"""
CREATE TABLE {TABLE_NAME} (
  id INT,
  order_time AS CURRENT_TIMESTAMP,
  WATERMARK FOR order_time AS order_time - INTERVAL '5' SECONDS
)
WITH (
  'connector' = 'datagen',
  'rows-per-second'='10',
  'fields.id.kind'='random',
  'fields.id.min'='1',
  'fields.id.max'='100'
);
"""

def create_backpressure(i):
    time.sleep(2)
    return i

def autoscaling_demo():
    env = StreamExecutionEnvironment.get_execution_environment()
    t_env = StreamTableEnvironment.create(env)
    t_env.execute_sql(QUERY)
    res_table = t_env.from_path(TABLE_NAME)
```

```

stream = t_env.to_data_stream(res_table) \
    .shuffle().map(lambda x: create_backpressure(x))\
    .print()
env.execute("Autoscaling demo")

if __name__ == '__main__':
    logging.basicConfig(stream=sys.stdout, level=logging.INFO, format="%(message)s")
    autoscaling_demo()

```

Para verificar se o escalador automático está funcionando, use os comandos a seguir. Observe que você deve usar as informações do seu próprio pod líder no operador do Flink.

Primeiro, obtenha o nome do seu pod líder.

```

ip=$(kubectl get configmap -n $NAMESPACE <job-name>-cluster-config-map -o json | jq
-r ".data[\"org.apache.flink.k8s.leader.restserver\"]" | awk -F: '{print $2}' | awk
-F '/' '{print $3}')

kubectl get pods -n $NAMESPACE -o json | jq -r ".items[] | select(.status.podIP ==
\"$ip\") | .metadata.name"

```

Depois de ter o nome do pod líder, será possível executar o comando a seguir.

```

kubectl logs -n $NAMESPACE -c flink-kubernetes-operator --follow <YOUR-FLINK-
OPERATOR-POD-NAME> | grep -E 'EmrEks|autotun|calculating|restart|autoscaler'

```

Você deve ver logs semelhantes aos mostrados a seguir.

```

[m[33m2023-09-13 20:10:35,941[m [36mc.a.c.f.k.o.a.EmrEksMetricsAutotuner[m
[36m[DEBUG][flink/autoscaling-example] Using the latest
Emr Eks Metric for calculating restart.time for autotuning:
EmrEksMetrics(restartMetric=RestartMetric(restartingTime=65, numRestarts=1))

[m[33m2023-09-13 20:10:35,941[m [36mc.a.c.f.k.o.a.EmrEksMetricsAutotuner[m
[32m[INFO ][flink/autoscaling-example] Calculated average restart.time metric via
autotuning to be: PT0.065S

```


Manutenção e solução de problemas para trabalhos do Flink no Amazon EMR no EKS

As seções a seguir descrevem como manter seus trabalhos de execução prolongada do Flink e fornecem orientações sobre como solucionar alguns problemas comuns em trabalhos do Flink.

Manutenção de aplicações do Flink

Tópicos

- [Modos de atualização](#)

As aplicações do Flink costumam ser projetadas para execuções por longos períodos, como semanas, meses ou até anos. Como acontece com todos os serviços de execução prolongada, as aplicações de streaming do Flink precisam de manutenção. Isso inclui correções de erros, melhorias e migração para um cluster do Flink de uma versão mais recente.

Quando o arquivo spec muda para os recursos `FlinkDeployment` e `FlinkSessionJob`, você precisa atualizar a aplicação em execução. Para isso, o operador interrompe o trabalho em execução (a menos que já esteja suspenso) e o reimplanta com o arquivo spec mais recente e, em aplicações com estado, o estado da execução anterior.

Os usuários controlam como gerenciar o estado quando aplicações com estado param e são restauradas com a configuração `upgradeMode` do `JobSpec`.

Modos de atualização

Introdução opcional

Sem estado

Atualizações de aplicações sem estado começando do estado vazio.

Último estado

Atualizações rápidas em qualquer estado da aplicação (mesmo em trabalhos com falha) não exigem um trabalho íntegro, pois sempre usam o ponto de verificação bem-sucedido mais recente. A recuperação manual pode ser necessária se os metadados de HA forem perdidos. Para limitar o tempo em que o trabalho pode efetuar fallback ao escolher o ponto de verificação mais recente, você pode configurar `kubernetes.operator.job.upgrade.last-`

`state.max.allowed.checkpoint.age`. Se o ponto de verificação for mais antigo que o valor configurado, um ponto de salvamento será usado para trabalhos íntegros. Isso não é compatível com o modo Sessão.

Ponto de salvamento

Use o ponto de salvamento para atualização, fornecendo máxima segurança e possibilidade de servir como ponto. `backup/fork` O ponto de salvamento será criado durante o processo de atualização. Observe que o trabalho do Flink precisa estar em execução para permitir que o ponto de salvamento seja criado. Se o trabalho não estiver íntegro, o último ponto de verificação será usado (a menos que `kubernetes.operator.job.upgrade`). `last-state-fallback.enabled` está definido como `false`). Se o ponto de verificação mais recente não estiver disponível, a atualização do trabalho falhará.

Solução de problemas

Esta seção descreve como solucionar problemas com o Amazon EMR no EKS. Para obter informações sobre como solucionar problemas gerais com o Amazon EMR, consulte [Troubleshoot a cluster](#) no Guia de gerenciamento do Amazon EMR.

- [Solução de problemas de trabalhos que usam PersistentVolumeClaims \(PVC\)](#)
- [Solução de problemas de escalabilidade automática vertical do Amazon EMR no EKS](#)
- [Solução de problemas do operador do Spark do Amazon EMR no EKS](#)

Solução de problemas do Apache Flink para Amazon EMR no EKS

Mapeamento de recursos não encontrado ao instalar o chart do Helm

Você pode encontrar a mensagem de erro apresentada a seguir ao instalar o chart do Helm.

```
Error: INSTALLATION FAILED: pulling from host 1234567890.dkr.ecr.us-west-2.amazonaws.com failed with status code [manifests 6.13.0]: 403 Forbidden Error:
INSTALLATION FAILED: unable to build kubernetes objects from release manifest:
[resource mapping not found for name: "flink-operator-serving-cert" namespace: "<the namespace to install your operator>" from "": no matches for kind "Certificate" in version "cert-manager.io/v1"]
```

```
ensure CRDs are installed first, resource mapping not found for name: "flink-operator-selfsigned-issuer" namespace: "<the namespace to install your operator>" " from "": no matches for kind "Issuer" in version "cert-manager.io/v1"
```

```
ensure CRDs are installed first].
```

Para resolver esse erro, instale o cert-manager para habilitar a adição do componente webhook. Você deve instalar o cert-manager em cada cluster do Amazon EKS que usa.

```
kubectl apply -f https://github.com/cert-manager/cert-manager/releases/download/v1.12.0
```

AWS service (Serviço da AWS) erro de acesso negado

Se você ver um erro `access denied`, confirme se o perfil do IAM para `operatorExecutionRoleArn` no arquivo `values.yaml` do chart do Helm tem as permissões corretas. Além disso, certifique-se de que o perfil do IAM em `executionRoleArn` na sua especificação de `FlinkDeployment` tenha as permissões corretas.

FlinkDeployment está preso

Se seu `FlinkDeployment` ficar em um estado preso, use as etapas a seguir para forçar a exclusão da implantação:

1. Edite a execução da implantação.

```
kubectl edit -n Flink Namespace flinkdeployments/App Name
```

2. Remova este finalizador.

```
finalizers:  
  - flinkdeployments.flink.apache.org/finalizer
```

3. Exclua a implantação.

```
kubectl delete -n Flink Namespace flinkdeployments/App Name
```

AWSBadRequestException problema s3a ao executar um aplicativo Flink em um opt-in Região da AWS

Se você executar um aplicativo Flink em um [opt-in Região da AWS](#), poderá ver os seguintes erros:

```
Caused by: org.apache.hadoop.fs.s3a.AWSBadRequestException: getFileStatus on
```

```
s3://flink.txt: com.amazonaws.services.s3.model.AmazonS3Exception: Bad Request
(Service: Amazon S3; Status Code: 400; Error Code: 400 Bad Request; Request ID:
ABCDEFGHIJKL; S3 Extended Request ID:
ABCDEFGHIJKLMNQP=; Proxy: null), S3 Extended Request ID: ABCDEFGHIJKLMNQP=:400 Bad
Request: Bad Request
(Service: Amazon S3; Status Code: 400; Error Code: 400 Bad Request; Request ID:
ABCDEFGHIJKL; S3 Extended Request ID: ABCDEFGHIJKLMNQP=; Proxy: null)
```

```
Caused by: org.apache.hadoop.fs.s3a.AWSBadRequestException: getS3Region on flink-
application: software.amazon.awssdk.services.s3.model.S3Exception: null
(Service: S3, Status Code: 400, Request ID: ABCDEFGHIJKLMNQP, Extended Request ID:
ABCDEFGHIJKLMNQPQRST==):null: null
(Service: S3, Status Code: 400, Request ID: ABCDEFGHIJKLMNQP, Extended Request ID:
AHl42uDNaTUF0us/5IIVNvSakBcMjMCH7dd37ky0vE6jhABCDEFGHIJKLMNQPQRST==)
```

Para corrigir esses erros, use a configuração a seguir no arquivo `FlinkDeployment` de definição.

```
spec:
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
    fs.s3a.endpoint.region: OPT_IN_AWS_REGION_NAME
```

Também recomendamos que você use o provedor de SDKv2 credenciais:

```
fs.s3a.aws.credentials.provider:
  software.amazon.awssdk.auth.credentials.WebIdentityTokenFileCredentialsProvider
```

Se você quiser usar o provedor de SDKv1 credenciais, certifique-se de que seu SDK seja compatível com sua região de inscrição. Para obter mais informações, consulte o [aws-sdk-java GitHub repositório](#).

Se você obtiver o erro `S3 AWSBadRequestException` ao executar instruções SQL do Flink em uma região de ingresso, certifique-se de definir a configuração `fs.s3a.endpoint.region`: *OPT_IN_AWS_REGION_NAME* na especificação de configuração do Flink.

`S3A AWSBad RequestException` ao executar um trabalho de sessão do Flink em regiões CN

Nas versões 6.15.0 à 7.2.0 do Amazon EMR, você pode encontrar as mensagens de erro a seguir ao executar um trabalho de sessão do Flink nas regiões da China. Estes incluem China (Pequim) e China (Ningxia):

Error:

```
{
  "type": "org.apache.flink.kubernetes.operator.exception.ReconciliationException",
  "message": "on
    getFileStatus on s3://ABCDPath:
software.amazon.awssdk.services.s3.model.S3Exception: null (Service: S3, Status Code:
400, Request ID: ABCDEFGH, Extended Request ID:
  ABCDEFGH:null: null (Service: S3, Status Code: 400, Request ID:
ABCDEFGH, Extended Request ID: ABCDEFGH", "additionalMetadata": {}, "throwableList":

[{"type": "org.apache.hadoop.fs.s3a.AWSBadRequestException", "message": "getFileStatus on
s3://ABCDPath: software.amazon.awssdk.services.s3.model.S3Exception:
  null (Service: S3, Status Code: 400, Request ID: ABCDEFGH, Extended
Request ID: ABCDEFGH:null: null (Service: S3, Status Code: 400, Request ID: ABCDEFGH,
  Extended Request ID: ABCDEFGH", "additionalMetadata": {}},
{"type": "software.amazon.awssdk.services.s3.model.S3Exception", "message": "null
  (Service: S3, Status Code: 400,
    Request ID: ABCDEFGH, Extended Request ID:
  ABCDEFGH", "additionalMetadata": {}}}]}
```

Esse problema é conhecido. A equipe está trabalhando na correção dos operadores do Flink em todas essas versões de lançamento. No entanto, antes de concluirmos o patch, para corrigir esse erro, você precisa baixar o chart do Helm do operador do Flink, descompactá-lo (extrair o arquivo compactado) e fazer alterações na configuração do chart do Helm.

As etapas específicas são as seguintes:

1. Altere, especificamente, os diretórios da sua pasta local do chart do Helm e execute a linha de comando a seguir para extrair o chart do Helm e descompactá-lo (extraí-lo).

```
helm pull oci://public.ecr.aws/emr-on-eks/flink-kubernetes-operator \
--version $VERSION \
--namespace $NAMESPACE
```

```
tar -zxvf flink-kubernetes-operator-$VERSION.tgz
```

2. Vá até a pasta do chart do Helm e encontre o arquivo `templates/flink-operator.yaml`.
3. Localize `flink-operator-config ConfigMap` e adicione a seguinte `fs.s3a.endpoint.region` configuração no `flink-conf.yaml`. Por exemplo:

```
{{- if .Values.defaultConfiguration.create }}
apiVersion: v1
```

```
kind: ConfigMap
metadata:
  name: flink-operator-config
  namespace: {{ .Release.Namespace }}
  labels:
    {{- include "flink-operator.labels" . | nindent 4 }}
data:
  flink-conf.yaml: |+
    fs.s3a.endpoint.region: {{ .Values.emrContainers.awsRegion }}
```

4. Instale o chart do Helm local e execute o trabalho.

Versões compatíveis para Amazon EMR no EKS com Apache Flink

O Apache Flink está disponível com as versões do Amazon EMR no EKS apresentadas a seguir. Para obter informações sobre todas as versões disponíveis, consulte [Versões do Amazon EMR no EKS](#).

Rótulo da versão	Java	Flink	Operador do Flink
emr-7.2.0-flink-latest	17	1.18.1	-
emr-7.2.0-flink-k8s-operator-latest	11	-	1.8.0
emr-7.1.0-flink-latest	17	1.18.1	-
emr-7.1.0-flink-k8s-operator-latest	11	-	1.6.1
emr-7.0.0-flink-latest	11	1.18.0	-
emr-7.0.0-flink-k8s-operator-latest	11	-	1.6.1
emr-6.15.0-flink-latest	11	1.17.1	-
emr-6.15.0-flink-k8s-operator-latest	11	-	1.6.0
emr-6.14.0-flink-latest	11	1.17.1	-
emr-6.14.0-flink-k8s-operator-latest	11	-	1.6.0

Rótulo da versão	Java	Flink	Operador do Flink
emr-6.13.0-flink-latest	11	1.17.0	-
emr-6.13.0-flink-k8s-operator-latest	11	-	1.5.0

Execução de trabalhos do Spark com o Amazon EMR no EKS

A execução de um trabalho é uma unidade de trabalho, como um Spark jar, PySpark script ou consulta SparkSQL, que você envia para o Amazon EMR no EKS. Este tópico fornece uma visão geral do gerenciamento de execuções de trabalhos usando o AWS CLI, da visualização de execuções de trabalhos usando o console do Amazon EMR e da solução de problemas comuns de execução de trabalhos.

Observe que você não pode executar trabalhos do IPv6 Spark no Amazon EMR no EKS

Note

Antes de enviar uma execução de trabalho com o Amazon EMR no EKS, você deve concluir as etapas em [Configuração do Amazon EMR no EKS](#).

Tópicos

- [Execução de trabalhos do Spark com StartJobRun](#)
- [Execução de trabalhos do Spark com o operador do Spark](#)
- [Execução de trabalhos do Spark com spark-submit](#)
- [Uso do Apache Livy com o Amazon EMR no EKS](#)
- [Gerenciamento de execuções de trabalhos do Amazon EMR no EKS](#)
- [Uso de modelos de trabalho](#)
- [Uso de modelos de pod](#)
- [Uso de políticas de repetição de trabalho](#)
- [Uso da alternância de log de eventos do Spark](#)
- [Uso da alternância de log do contêiner do Spark](#)
- [Uso da escalabilidade automática vertical com trabalhos do Spark no Amazon EMR](#)

Execução de trabalhos do Spark com **StartJobRun**

Esta seção inclui etapas detalhadas de configuração para preparar seu ambiente para executar trabalhos do Spark e, em seguida, fornece step-by-step instruções para enviar um trabalho executado com parâmetros especificados.

Tópicos

- [Configuração do Amazon EMR no EKS](#)
- [Envio de uma execução de trabalho com StartJobRun](#)
- [Uso da classificação de envio de trabalho](#)
- [Usar a classificação de padrões do contêiner do Amazon EMR](#)

Configuração do Amazon EMR no EKS

Conclua as tarefas apresentadas a seguir para se preparar para usar o Amazon EMR no EKS. Se você já se inscreveu na Amazon Web Services (AWS) e usa o Amazon EKS, está com quase tudo pronto para usar o Amazon EMR no EKS. Ignore qualquer tarefa que já tenha concluído.

Note

Você também pode acompanhar o [Amazon EMR on EKS Workshop](#) para configurar todos os recursos obrigatórios para executar trabalhos do Spark no Amazon EMR no EKS. O workshop também fornece automação usando CloudFormation modelos para criar os recursos necessários para você começar. Para outros modelos e melhores práticas, consulte nosso [Guia de práticas recomendadas de contêineres do EMR](#) em GitHub

1. [Instale ou atualize para a versão mais recente do AWS CLI](#)
2. [Configuração do kubectl e eksctl](#)
3. [Conceitos básicos do Amazon EKS: eksctl](#)
4. [Habilite o acesso ao cluster para o Amazon EMR no EKS](#)
5. [Habilitar perfis do IAM para o cluster do EKS](#)
6. [Concessão de acesso ao Amazon EMR no EKS para os usuários](#)
7. [Registro do cluster do Amazon EKS com o Amazon EMR](#)

Habilitação do acesso ao cluster para o Amazon EMR no EKS

As seções a seguir mostram algumas maneiras de habilitar o acesso ao cluster. A primeira é usando o gerenciamento de acesso ao cluster (CAM) do Amazon EKS e a segunda mostra como executar etapas manuais para habilitar o acesso ao cluster.

Como habilitar o acesso ao cluster usando a entrada de acesso do EKS (recomendado)

Note

O `aws-auth` ConfigMap está obsoleto. [O método recomendado para gerenciar o acesso ao Kubernetes APIs é o Access Entries.](#)

O Amazon EMR é integrado ao [gerenciamento de acesso ao cluster \(CAM\) do Amazon EKS](#), para que você possa automatizar a configuração das políticas AuthN e AuthZ necessárias para executar trabalhos Spark do Amazon EMR em namespaces de clusters do Amazon EKS. Quando você cria um cluster virtual usando um namespace de cluster do Amazon EKS, o Amazon EMR configura automaticamente todas as permissões necessárias, para que você não precise adicionar nenhuma etapa extra aos fluxos de trabalho atuais.

Note

A integração do Amazon EMR com o CAM do Amazon EKS é compatível somente com novos clusters virtuais do Amazon EMR no EKS. Não é possível migrar clusters virtuais existentes para usar essa integração.

Pré-requisitos

- Verifique se você está executando a versão 2.15.3 ou superior do AWS CLI
- O cluster do Amazon EKS deve estar na versão 1.23 ou posterior.

Configuração

Para configurar a integração entre o Amazon EMR e as operações de AccessEntry API do Amazon EKS, certifique-se de ter concluído os seguintes itens:

- Verifique se `authenticationMode` do cluster do Amazon EKS está configurado como `API_AND_CONFIG_MAP`.

```
aws eks describe-cluster --name <eks-cluster-name>
```

Se ainda não estiver, defina `authenticationMode` como `API_AND_CONFIG_MAP`.

```
aws eks update-cluster-config
  --name <eks-cluster-name>
  --access-config authenticationMode=API_AND_CONFIG_MAP
```

Para obter mais informações sobre modos de autenticação, consulte [Cluster authentication modes](#).

- Certifique-se de que o [perfil do IAM](#) que você está usando para executar `CreateVirtualCluster` e as operações da API `DeleteVirtualCluster` também tenha as seguintes permissões:

```
{
  "Effect": "Allow",
  "Action": [
    "eks:CreateAccessEntry"
  ],
  "Resource":
    "arn:<AWS_PARTITION>:eks:<AWS_REGION>:<AWS_ACCOUNT_ID>:cluster/<EKS_CLUSTER_NAME>"
},
{
  "Effect": "Allow",
  "Action": [
    "eks:DescribeAccessEntry",
    "eks>DeleteAccessEntry",
    "eks>ListAssociatedAccessPolicies",
    "eks:AssociateAccessPolicy",
    "eks:DisassociateAccessPolicy"
  ],
  "Resource": "arn:<AWS_PARTITION>:eks:<AWS_REGION>:<AWS_ACCOUNT_ID>:access-entry/
<EKS_CLUSTER_NAME>/role/<AWS_ACCOUNT_ID>/AWSServiceRoleForAmazonEMRContainers/*"
}
```

Conceitos e terminologia

A seguir está uma lista de terminologias e conceitos relacionados ao CAM do Amazon EKS.

- Cluster virtual (VC): representação lógica do namespace criado no Amazon EKS. É um link 1:1 para um namespace de cluster do Amazon EKS. Você pode usá-lo para executar workloads do Amazon EMR em um cluster do Amazon EKS dentro do namespace especificado.
- Namespace: mecanismo para isolar grupos de recursos em um único cluster do EKS.
- Política de acesso: permissões que concedem acesso e ações a um perfil do IAM em um cluster do EKS.
- Entrada de acesso: uma entrada criada com um ARN de perfil. Você pode vincular a entrada de acesso a uma política de acesso para atribuir permissões específicas no cluster do Amazon EKS.
- Cluster virtual integrado de entrada de acesso do EKS: o cluster virtual criado usando [operações de API de entrada de acesso](#) do Amazon EKS.

Como habilitar o acesso ao cluster usando **aws-auth**

Você deve permitir o acesso do Amazon EMR no EKS a um namespace específico em seu cluster ao executar as seguintes ações: criar um perfil do Kubernetes, associar o perfil a um usuário do Kubernetes e mapear o usuário do Kubernetes com o perfil vinculado ao serviço [AWSServiceRoleForAmazonEMRContainers](#). Essas ações são automatizadas em `eksctl` quando o comando de mapeamento de identidade do IAM é usado com `emr-containers` como nome do serviço. Você pode executar essas operações facilmente ao usar o comando apresentado a seguir.

```
eksctl create iamidentitymapping \  
  --cluster my_eks_cluster \  
  --namespace kubernetes_namespace \  
  --service-name "emr-containers"
```

my_eks_cluster Substitua pelo nome do seu cluster Amazon EKS e *kubernetes_namespace* substitua pelo namespace Kubernetes criado para executar cargas de trabalho do Amazon EMR.

Important

Você deve fazer o download do `eksctl` mais recente usando a etapa anterior [Configuração do kubectl e eksctl](#) para usar esta funcionalidade.

Etapas manuais para habilitar o acesso ao cluster para o Amazon EMR no EKS

Você também pode usar as etapas manuais apresentadas a seguir para habilitar o acesso ao cluster para o Amazon EMR no EKS.

1. Crie um perfil do Kubernetes em um namespace específico

Amazon EKS 1.22 - 1.29

Com o Amazon EKS, versões 1.22 a 1.29, execute o comando a seguir para criar um perfil do Kubernetes em um namespace específico. Esse perfil concede as permissões de RBAC obrigatórias ao Amazon EMR no EKS.

```
namespace=my-namespace
cat - >>EOF | kubectl apply -f - >>namespace "${namespace}"
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  name: emr-containers
  namespace: ${namespace}
rules:
  - apiGroups: [""]
    resources: ["namespaces"]
    verbs: ["get"]
  - apiGroups: [""]
    resources: ["serviceaccounts", "services", "configmaps", "events", "pods",
"pods/log"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletcollection", "annotate", "patch", "label"]
  - apiGroups: [""]
    resources: ["secrets"]
    verbs: ["create", "patch", "delete", "watch"]
  - apiGroups: ["apps"]
    resources: ["statefulsets", "deployments"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"annotate", "patch", "label"]
  - apiGroups: ["batch"]
    resources: ["jobs"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"annotate", "patch", "label"]
  - apiGroups: ["extensions", "networking.k8s.io"]
    resources: ["ingresses"]
```

```

    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"annotate", "patch", "label"]
  - apiGroups: ["rbac.authorization.k8s.io"]
    resources: ["roles", "rolebindings"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
  - apiGroups: [""]
    resources: ["persistentvolumeclaims"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
EOF

```

Amazon EKS 1.21 and below

Com o Amazon EKS, versões 1.21 e anteriores, execute o comando a seguir para criar um perfil do Kubernetes em um namespace específico. Esse perfil concede as permissões de RBAC obrigatórias ao Amazon EMR no EKS.

```

namespace=my-namespace
cat - >>EOF | kubectl apply -f - >>namespace "${namespace}"
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  name: emr-containers
  namespace: ${namespace}
rules:
  - apiGroups: [""]
    resources: ["namespaces"]
    verbs: ["get"]
  - apiGroups: [""]
    resources: ["serviceaccounts", "services", "configmaps", "events", "pods",
"pods/log"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
  - apiGroups: [""]
    resources: ["secrets"]
    verbs: ["create", "patch", "delete", "watch"]
  - apiGroups: ["apps"]
    resources: ["statefulsets", "deployments"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"annotate", "patch", "label"]
  - apiGroups: ["batch"]

```

```

resources: ["jobs"]
verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"annotate", "patch", "label"]
- apiGroups: ["extensions"]
resources: ["ingresses"]
verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"annotate", "patch", "label"]
- apiGroups: ["rbac.authorization.k8s.io"]
resources: ["roles", "rolebindings"]
verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
- apiGroups: [""]
resources: ["persistentvolumeclaims"]
verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
EOF

```

2. Crie uma associação de perfil do Kubernetes com escopo definido para o namespace

Execute o comando apresentado a seguir para criar uma associação de perfil do Kubernetes no namespace especificado. Essa associação de perfil concede as permissões definidas no perfil criado na etapa anterior a um usuário chamado `emr-containers`. Esse usuário identifica [perfis vinculados ao serviço para o Amazon EMR no EKS](#) e, dessa forma, permite que o Amazon EMR no EKS execute ações conforme definido pelo perfil criado.

```

namespace=my-namespace

cat - <<EOF | kubectl apply -f - --namespace "${namespace}"
apiVersion: rbac.authorization.k8s.io/v1
kind: RoleBinding
metadata:
  name: emr-containers
  namespace: ${namespace}
subjects:
- kind: User
  name: emr-containers
  apiGroup: rbac.authorization.k8s.io
roleRef:
  kind: Role
  name: emr-containers
  apiGroup: rbac.authorization.k8s.io

```

EOF

3. Atualize mapa de configuração **aws-auth** do Kubernetes

Você pode usar uma das opções apresentadas a seguir para mapear o perfil vinculado ao serviço do Amazon EMR no EKS com o usuário `emr-containers` que foi associado ao perfil do Kubernetes na etapa anterior.

Opção 1: usar o **eksctl**

Execute o comando `eksctl` apresentado a seguir para mapear o perfil vinculado ao serviço do Amazon EMR no EKS com o usuário `emr-containers`.

```
eksctl create iamidentitymapping \
  --cluster my-cluster-name \
  --arn "arn:aws:iam::my-account-id:role/AWSServiceRoleForAmazonEMRContainers" \
  --username emr-containers
```

Opção 2: sem usar o `eksctl`

1. Execute o comando apresentado a seguir para abrir o mapa de configuração `aws-auth` no editor de texto.

```
kubectl edit -n kube-system configmap/aws-auth
```

Note

Se você receber um erro `informandoError from server (NotFound): configmaps "aws-auth" not found`, consulte as etapas em [Adicionar funções de usuário](#) no Guia do usuário do Amazon EKS para aplicar o estoque ConfigMap.

2. Adicione detalhes do perfil vinculado ao serviço do Amazon EMR no EKS à seção `mapRoles` do ConfigMap, em `data`. Adicione essa seção se ela ainda não existir no arquivo. A seção `mapRoles` atualizada em dados deve ser semelhante ao exemplo a seguir.

```
apiVersion: v1
data:
  mapRoles: |
    - rolearn: arn:aws:iam::<your-account-id>:role/
      AWSServiceRoleForAmazonEMRContainers
```



```
username: emr-containers
- ... <other previously existing role entries, if there's any>.
```

3. Salve o arquivo e saia do seu editor de texto.

Habilitar perfis do IAM para o cluster do EKS

Os tópicos a seguir detalham as opções para habilitar perfis do IAM.

Tópicos

- [Opção 1: habilitar a Identidade de Pods do EKS no cluster do EKS](#)
- [Opção 2: habilitar perfis do IAM para contas de serviço \(IRSA\) no cluster do EKS](#)

Opção 1: habilitar a Identidade de Pods do EKS no cluster do EKS

As associações de Identidade de Pods do Amazon EKS permitem gerenciar credenciais para suas aplicações de forma semelhante a como os perfis de instância do Amazon EC2 fornecem credenciais para instâncias do Amazon EC2. A Identidade de Pods do Amazon EKS fornece credenciais para suas workloads com uma API EKS Auth adicional e um pod de atendente executado em cada nó.

O Amazon EMR no EKS começa a oferecer suporte à identidade de pod do EKS desde o lançamento do emr-7.3.0 para o modelo de envio. StartJobRun

Para obter mais informações sobre identidades de pods do EKS, consulte [Como funciona a Identidade de Pods do EKS](#).

Por que trabalhar com Identidades de pods do EKS?

Como parte da configuração do EMR, o perfil de execução de tarefas precisa estabelecer limites de confiança entre o perfil do IAM e contas de serviço em um namespace específico (de clusters virtuais do EMR). Com o IRSA, isso foi alcançado através da atualização da política de confiança do Perfil de execução de trabalho do EMR. No entanto, devido ao limite rígido de 4096 caracteres no comprimento da política de confiança do IAM, havia uma restrição para compartilhar um único perfil do IAM de execução de trabalho em um máximo de doze (12) clusters do EKS.

Com o suporte do EMR para identidades de pods, o limite de confiança entre as funções do IAM e as contas de serviço agora está sendo gerenciado pela equipe do EKS por meio da associação da identidade do pod do EKS. APIs

Note

A fronteira de segurança para identidade de pods do EKS ainda está no nível da conta de serviço, e não no nível do pod.

Considerações sobre Identidade de Pods

Para obter informações sobre as Limitações de identidade de pods, consulte [Considerações sobre Identidade de pods do EKS](#).

Preparar a identidade de pods do EKS no cluster do EKS

Verifique se a permissão necessária existe em NodeInstanceRole

O perfil de nó NodeInstanceRole precisa de permissão o agente realizar a ação AssumeRoleForPodIdentity na API de autenticação do EKS. Você pode adicionar o seguinte à [Amazon EKSWorker NodePolicy](#), que é definida no Guia do usuário do Amazon EKS, ou usar uma política personalizada.

Se seu cluster EKS foi criado com a versão eksctl superior a 0.181.0, a Amazon, incluindo a AssumeRoleForPodIdentity permissão necessária EKSWorkerNodePolicy, será anexada automaticamente à função de nó. Se a permissão não estiver presente, adicione manualmente a seguinte permissão à Amazon, EKSWorker NodePolicy que permite assumir uma função para a identidade do pod. Essa permissão é necessária pelo agente de identidade de pods do EKS para recuperar credenciais para pods.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "eks-auth:AssumeRoleForPodIdentity"
      ],
      "Resource": [
        "*"
      ],
    },
  ],
}
```

```
        "Sid": "AllowEKSAUTHAssumeroleforpodidentity"  
      }  
    ]  
  }  
}
```

Criar complemento do agente de identidade do pod do EKS

Use o comando a seguir para criar o complemento Agente de identidade de pods do EKS com a versão mais recente:

```
aws eks create-addon --cluster-name cluster-name --addon-name eks-pod-identity-agent  
  
kubectl get pods -n kube-system | grep 'eks-pod-identity-agent'
```

Use as etapas a seguir para criar o complemento Agente de identidade de pods do EKS no console do Amazon EKS:

1. Abra o console do Amazon EKS: [Console do Amazon EKS](#).
2. No painel de navegação esquerdo, selecione Clusters e depois o nome do cluster para o qual você deseja configurar o complemento do atendente de Identidade de Pods do EKS.
3. Escolha a guia Add-ons (Complementos).
4. Escolha Obter mais complementos.
5. Selecione a caixa no canto superior direito da caixa do complemento do atendente de Identidade de Pods do EKS e escolha Editar.
6. Na página Configurar complementos selecionados, selecione qualquer versão na lista suspensa Versão.
7. (Opcional) Expanda Configurações opcionais para inserir configurações adicionais. Por exemplo, é possível indicar um local alternativo para a imagem do contêiner e ImagePullSecrets. O esquema JSON com chaves aceitas é mostrado no Esquema de configuração do complemento.

Insira as chaves e os valores de configuração em Valores de configuração.

8. Escolha Próximo.
9. Confirme se os pods do agente estão em execução no seu cluster por meio da CLI.

```
kubectl get pods -n kube-system | grep 'eks-pod-identity-agent'
```

Veja a seguir um exemplo de saída:

NAME	READY	STATUS	RESTARTS	AGE
eks-pod-identity-agent-gmqp7	1/1	Running	1 (24h ago)	24h
eks-pod-identity-agent-prnsh	1/1	Running	1 (24h ago)	24h

Isso configura um novo DaemonSet no kube-system namespace. O Amazon EKS Pod Identity Agent, executado em cada nó do EKS, usa a [AssumeRoleForPodIdentity](#) ação para recuperar credenciais temporárias da API EKS Auth. Essas credenciais são então disponibilizadas para AWS SDKs que você execute dentro de seus contêineres.

Para obter mais informações, verifique o pré-requisito no documento público: [Configurar o Agente de identidade de pods do EKS](#).

Criar um perfil de execução de trabalho

Criar ou atualizar o perfil de execução de trabalhos que permite a Identidade de Pods do EKS

Para executar workloads no Amazon EMR no EKS, você precisa criar um perfil do IAM. Referimo-nos a esse perfil como perfil de execução de trabalho nesta documentação. Para obter mais informações sobre como criar o perfil do IAM, consulte [Criação de perfis do IAM](#) no Guia do usuário.

Além disso, você deve criar uma política do IAM que especifique as permissões necessárias para o perfil de execução de trabalho e, em seguida, anexar essa política ao perfil para habilitar a Identidade de Pods do EKS.

Por exemplo, você tem o seguinte perfil de execução de trabalho. Para obter mais informações, consulte [Criar um perfil de execução de trabalho](#).

```
arn:aws:iam::111122223333:role/PodIdentityJobExecutionRole
```

Important

O Amazon EMR no EKS cria contas de serviço do Kubernetes automaticamente, com base no nome do perfil de execução de trabalho. Certifique-se de que o nome do perfil não seja muito longo, pois seu trabalho poderá falhar se a combinação de `cluster_name`, `pod_name`, `service_account_name` e exceder o limite de comprimento.

Configuração do perfil de execução de trabalho: certifique-se de que o perfil de execução de trabalho seja criado com a permissão de confiança abaixo para a Identidade de Pods do EKS. Para atualizar um perfil de execução de trabalho existente, configure-o para confiar na seguinte entidade principal de serviço do EKS como uma permissão adicional na política de confiança. Essa permissão de confiança pode coexistir com as políticas de confiança do IRSA existentes.

```
cat >trust-relationship.json <<EOF
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AllowEksAuthToAssumeRoleForPodIdentity",
      "Effect": "Allow",
      "Principal": {
        "Service": "pods.eks.amazonaws.com"
      },
      "Action": [
        "sts:AssumeRole",
        "sts:TagSession"
      ]
    }
  ]
}
EOF
```

Permissão do usuário: os usuários necessitam da permissão `iam:PassRole` para executar chamadas de API `StartJobRun` ou enviar trabalhos. Essa permissão permite que os usuários passem o perfil de execução de trabalho ao EMR no EKS. Os administradores de trabalhos devem ter a permissão por padrão.

Abaixo está a permissão necessária para um usuário:

```
{
  "Effect": "Allow",
  "Action": "iam:PassRole",
  "Resource": "arn:aws:iam::111122223333:role/PodIdentityJobExecutionRole",
  "Condition": {
    "StringEquals": {
      "iam:PassedToService": "pods.eks.amazonaws.com"
    }
  }
}
```

```
}
```

Para restringir ainda mais o acesso do usuário a clusters EKS específicos, adicione o filtro de `AssociatedResourceArn` atributos à política do IAM. Limita a atribuição de perfis a clusters do EKS autorizados, reforçando os controles de segurança no nível dos recursos.

```
"Condition": {
  "ArnLike": {
    "iam:AssociatedResourceARN": [
      "arn:aws:eks:us-west-2:111122223333:cluster/*"
    ]
  }
}
```

Configurar associações de identidade de pods do EKS

Pré-requisito

Certifique-se de que a identidade do IAM que cria a associação de identidade de pods, como um usuário administrador do EKS, tenha a permissão `eks:CreatePodIdentityAssociation` e `iam:PassRole`.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "eks:CreatePodIdentityAssociation"
      ],
      "Resource": [
        "arn:aws:eks:*:*:cluster/*"
      ],
      "Sid": "AllowEKSCreatepodidentityassociation"
    },
    {
      "Effect": "Allow",
      "Action": [
        "iam:PassRole"
      ],
      "Resource": [
```

```
    "arn:aws:iam::*:role/*"
  ],
  "Condition": {
    "StringEquals": {
      "iam:PassedToService": "pods.eks.amazonaws.com"
    }
  },
  "Sid": "AllowIAMPassrole"
}
]
```

Criar associações para o perfil e a conta de serviço do EMR

Create EMR role associations through the AWS CLI

Quando você envia um trabalho para um namespace do Kubernetes, um administrador deve criar associações entre o perfil de execução do trabalho e a identidade da conta de serviço gerenciada do EMR. Observe que a conta de serviço gerenciado do EMR é criada automaticamente no envio do trabalho, com escopo definido para o namespace no qual o trabalho é enviado.

Com a versão 2.24.0 AWS CLI (acima), execute o comando a seguir para criar associações de função com a identidade do pod.

Execute o seguinte comando para criar associações de perfil com a identidade do pod:

```
aws emr-containers create-role-associations \
  --cluster-name mycluster \
  --namespace mynamespace \
  --role-name JobExecutionRoleIRSAv2
```

Observação:

- Cada cluster pode ter um limite de 1.000 associações. Para cada mapeamento de perfil de execução de trabalho - namespace, será necessário três associados para os pods de remetente, driver e executor de trabalho.
- Você só pode associar funções que estejam na mesma AWS conta do cluster. É possível delegar o acesso de outra conta ao perfil nessa conta configurada por você para o EKS Pod Identities usar. Para ver um tutorial sobre delegação de acesso `AssumeRole`, consulte o [tutorial do IAM: Delegar acesso entre AWS contas usando funções do IAM](#).

Create EMR role associations through Amazon EKS

O EMR cria uma conta de serviço com um determinado padrão de nomenclatura quando um trabalho é enviado. Para fazer associações manuais ou integrar esse fluxo de trabalho ao AWS SDK, siga estas etapas:

Nome da conta de serviço do constructo:

```
emr-containers-sa-spark-%(SPARK_ROLE)s-%(AWS_ACCOUNT_ID)s-
%(BASE36_ENCODED_ROLE_NAME)s
```

Os exemplos abaixo criam uma associação de função para um exemplo de função de execução de Job `JobExecutionRoleIRSAv2`.

Exemplos de associações de perfis:

```
RoleName: JobExecutionRoleIRSAv2
Base36EncodingOfRoleName: 2eum5fah1jc1kwyjc19ikdhdkdegh1n26vbe
```

Exemplo de comando CLI:

```
# setup for the client service account (used by job runner pod)
# emr-containers-sa-spark-client-111122223333-2eum5fah1jc1kwyjc19ikdhdkdegh1n26vbe
aws eks create-pod-identity-association --cluster-name mycluster
--role-arn arn:aws:iam::111122223333:role/JobExecutionRoleIRSAv2
--namespace mynamespace --service-account emr-containers-sa-spark-
client-111122223333-2eum5fah1jc1kwyjc19ikdhdkdegh1n26vbe

# driver service account
# emr-containers-sa-spark-driver-111122223333-2eum5fah1jc1kwyjc19ikdhdkdegh1n26vbe

aws eks create-pod-identity-association --cluster-name mycluster
--role-arn arn:aws:iam::111122223333:role/JobExecutionRoleIRSAv2
--namespace mynamespace --service-account emr-containers-sa-spark-
driver-111122223333-2eum5fah1jc1kwyjc19ikdhdkdegh1n26vbe

# executor service account
# emr-containers-sa-spark-executor-111122223333-2eum5fah1jc1kwyjc19ikdhdkdegh1n26vbe
aws eks create-pod-identity-association --cluster-name mycluster
--role-arn arn:aws:iam::111122223333:role/JobExecutionRoleIRSAv2
--namespace mynamespace --service-account emr-containers-sa-spark-
executor-111122223333-2eum5fah1jc1kwyjc19ikdhdkdegh1n26vbe
```


Depois de concluir todas as etapas necessárias para a Identidade de Pods do EKS, você pode pular as etapas a seguir para a configuração do IRSA:

- [Ativar funções do IAM para contas de serviço \(IRSA\) no cluster EKS](#)
- [Crie uma função de execução de tarefas](#)
- [Atualize a política de confiança da função de execução do trabalho](#)

É possível avançar diretamente para a etapa seguinte: [Conceder aos usuários acesso ao Amazon EMR no EKS](#)

Excluir associações de perfil

Sempre que você excluir um cluster virtual ou um perfil de execução de trabalho e não quiser mais conceder acesso ao EMR às suas contas de serviço, você deverá excluir as associações do perfil. Isso ocorre porque o EKS permite associações com recursos inexistentes (namespace e conta de serviço). O Amazon EMR no EKS recomenda excluir as associações se o namespace for excluído ou se o perfil não estiver mais em uso, para liberar espaço para outras associações.

Note

As associações persistentes podem afetar sua capacidade de escalar se você não as excluir, pois o EKS tem limitações no número de associações que você pode criar (limite flexível: 1000 associações por cluster). Você pode listar as associações de identidades de pods em um determinado namespace para verificar se há alguma associação remanescente que precisa ser limpa:

```
aws eks list-pod-identity-associations --cluster-name mycluster --namespace mynamespace
```

Com a AWS CLI (versão 2.24.0 ou superior), execute o seguinte comando `emr-containers` para excluir as associações de função do EMR:

```
aws emr-containers delete-role-associations \  
  --cluster-name mycluster \  
  --namespace mynamespace \  
  --role-name JobExecutionRoleIRSAv2
```

Migrar automaticamente o IRSA existente para a Identidade de Pods

Você pode usar a ferramenta eksctl para migrar perfis do IAM existentes para contas de serviço (IRSA) para associações de identidade de pods:

```
eksctl utils migrate-to-pod-identity \  
  --cluster mycluster \  
  --remove-oidc-provider-trust-relationship \  
  --approve
```

A execução do comando sem o sinalizador `--approve` produzirá apenas um plano que reflete as etapas da migração, e nenhuma migração real ocorrerá.

Solução de problemas

Meu trabalho falhou com `NoClassDefinitionFound` ou com `ClassNotFound` exceção do provedor de credenciais, ou falhou em obter o provedor de credenciais.

A Identidade de Pods do EKS usa o Provedor de credenciais de contêiner para recuperar as credenciais necessárias. Se você especificou um provedor de credenciais personalizado, verifique se ele está funcionando corretamente. Como alternativa, verifique se você está usando uma versão correta do AWS SDK compatível com o EKS Pod Identity. Para obter mais informações, consulte [Conceitos básicos do Amazon EKS](#).

O trabalho falhou com o erro “Falha na recuperação de credenciais devido ao limite de tamanho [x]” mostrado no eks-pod-identity-agent registro.

O EMR no EKS cria contas de serviço do Kubernetes com base no nome do perfil de execução do trabalho. Se o nome do perfil for muito longo, o EKS Auth não conseguirá recuperar as credenciais porque a combinação de `cluster_name`, `pod_name` e `service_account_name` excede o limite de comprimento. Identifique qual componente está ocupando mais espaço e ajuste o tamanho de acordo.

O trabalho falhou com o erro “Failed to Retrieve Credentials xxx” exibido no eks-pod-identity registro.

Uma possível causa desse problema pode ser que o cluster EKS esteja configurado em sub-redes privadas sem ser configurado corretamente PrivateLink para o cluster. Verifique se seu cluster está em uma rede privada e configure AWS PrivateLink para resolver o problema. Para obter instruções detalhadas, consulte [Comece a usar o Amazon EKS](#).

Opção 2: habilitar perfis do IAM para contas de serviço (IRSA) no cluster do EKS

O recurso de perfis do IAM para contas de serviço está disponível nas versões 1.14 e posteriores do Amazon EKS e para clusters do EKS atualizados para as versões 1.13 ou posteriores ou após 3 de setembro de 2019. Para usar esse recurso, é possível atualizar os clusters do EKS existentes para a versão 1.14 ou posterior. Para obter mais informações, consulte [Atualizar uma versão do Kubernetes do cluster do Amazon EKS](#).

Se o seu cluster oferecer suporte para perfis do IAM para contas de serviço, ele terá um URL do emissor [OpenID Connect](#) associado a ele. Você pode visualizar essa URL no console do Amazon EKS ou usar o AWS CLI comando a seguir para recuperá-la.

Important

Você deve usar a versão mais recente do AWS CLI para receber a saída adequada desse comando.

```
aws eks describe-cluster --name cluster_name --query "cluster.identity.oidc.issuer" --output text
```

A saída esperada é semelhante à apresentada a seguir.

```
https://oidc.eks.<region-code>.amazonaws.com/id/EXAMPLED539D4633E53DE1B716D3041E
```

Para usar perfis do IAM para contas de serviço em seu cluster, é necessário criar um provedor de identidades OIDC usando o [eksctl](#) ou o [Console de gerenciamento da AWS](#).

Para criar um provedor de identidade OIDC do IAM para o cluster com o **eksctl**

Verifique a versão do **eksctl** com o comando a seguir. Este procedimento pressupõe que você instalou o **eksctl** e que a versão do **eksctl** seja 0.32.0 ou posterior.

```
eksctl version
```

Para obter mais informações sobre como instalar ou atualizar o **eksctl**, consulte [Instalar ou atualizar o eksctl](#).

Crie o provedor de identidade OIDC para o cluster com o seguinte comando. Substitua *cluster_name* pelos seus próprios valores.

```
eksctl utils associate-iam-oidc-provider --cluster cluster_name --approve
```

Para criar um provedor de identidade IAM OIDC para seu cluster com o Console de gerenciamento da AWS

Recupere a URL do emissor do OIDC na descrição do console Amazon EKS do seu cluster ou use o comando a seguir. AWS CLI

Use o comando apresentado a seguir para recuperar o URL do emissor OIDC da AWS CLI.

```
aws eks describe-cluster --name <cluster_name> --query "cluster.identity.oidc.issuer"
--output text
```

Use as etapas apresentadas a seguir para recuperar o URL do emissor OIDC do console do Amazon EKS.

1. Abra o console do IAM em <https://console.aws.amazon.com/iam/>.
2. No painel de navegação, escolha Provedores de identidade e, em seguida, selecione Criar provedor.
 1. Para Tipo de provedor, escolha Escolher um tipo de provedor e escolha OpenID Connect.
 2. Em Provider URL (URL do provedor), cole o URL emissor OIDC do cluster.
 3. Para Público, digite sts.amazonaws.com e escolha Próxima etapa.
3. Verifique se as informações do provedor estão corretas e escolha Create (Criar) para criar seu provedor de identidade.

Criação de um perfil de execução de trabalho

Para executar workloads no Amazon EMR no EKS, você precisa criar um perfil do IAM. Referimo-nos a esse perfil como perfil de execução de trabalho nesta documentação. Para obter mais informações sobre como criar perfis do IAM, consulte [Criação de perfis do IAM](#) no Guia do usuário do IAM.

Você também deve criar uma política do IAM que especifique as permissões para o perfil de execução de trabalho e, em seguida, anexar a política do IAM ao perfil de execução de trabalho.

A política a seguir para a função de execução do trabalho permite acesso a destinos de recursos, Amazon S3 e. CloudWatch Essas permissões são necessárias para monitorar trabalhos e acessar logs. Para seguir o mesmo processo usando o AWS CLI:

Crie o perfil do IAM para execução do trabalho: vamos criar o perfil que o EMR usará para a execução do trabalho. Essa é o perfil que os trabalhos do EMR assumirão quando forem executados no EKS.

```
cat <<EoF > ~/environment/emr-trust-policy.json
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Service": "elasticmapreduce.amazonaws.com"
      },
      "Action": "sts:AssumeRole"
    }
  ]
}
EoF

aws iam create-role --role-name EMRContainers-JobExecutionRole --assume-role-policy-
document file://~/environment/emr-trust-policy.json
```

Em seguida, precisamos anexar as políticas do IAM necessárias ao perfil para que ele possa gravar logs no S3 e no cloudwatch.

```
cat <<EoF > ~/environment/EMRContainers-JobExecutionRole.json
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": "arn:aws:s3:::amzn-s3-demo-bucket"
    },
    {
      "Effect": "Allow",
      "Action": [
        "logs:PutLogEvents",

```

```

        "logs:CreateLogStream",
        "logs:DescribeLogGroups",
        "logs:DescribeLogStreams"
    ],
    "Resource": [
        "arn:aws:logs:*:*:*"
    ]
}
]
}
EoF
aws iam put-role-policy --role-name EMRContainers-JobExecutionRole --policy-name
EMR-Containers-Job-Execution --policy-document file://~/environment/EMRContainers-
JobExecutionRole.json

```

Note

O acesso deve ter um escopo adequado e não ser concedido a todos os objetos do S3 no perfil de execução de trabalho.

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket"
      ],
      "Sid": "AllowS3Putobject"
    },
    {
      "Effect": "Allow",
      "Action": [

```

```
        "logs:PutLogEvents",
        "logs:CreateLogStream",
        "logs:DescribeLogGroups",
        "logs:DescribeLogStreams"
    ],
    "Resource": [
        "arn:aws:logs:*:*:*"
    ],
    "Sid": "AllowLOGSPutlogevents"
  }
]
```

Para obter mais informações, consulte [Usando funções de execução de trabalho](#), [Configurar uma execução de trabalho para usar registros do S3](#) e [Configurar uma execução de trabalho para usar CloudWatch registros](#).

Atualização da política de confiança do perfil de execução de trabalho

Ao usar perfis do IAM para contas de serviço (IRSA) com a finalidade de executar trabalhos em um namespace do Kubernetes, um administrador deve criar uma relação de confiança entre o perfil de execução de trabalho e a identidade da conta de serviço gerenciado do EMR. A relação de confiança pode ser criada ao atualizar a política de confiança do perfil de execução de trabalho. Observe que a conta de serviço gerenciado do EMR é criada automaticamente no envio do trabalho, com escopo definido para o namespace no qual o trabalho é enviado.

Execute o comando apresentado a seguir para atualizar a política de confiança.

```
aws emr-containers update-role-trust-policy \
  --cluster-name cluster \
  --namespace namespace \
  --role-name iam_role_name_for_job_execution
```

Para obter mais informações, consulte [Uso de perfis de execução de trabalho com o Amazon EMR no EKS](#).

Important

O operador que executa o comando acima deve ter estas permissões:
eks:DescribeCluster, iam:GetRole e iam:UpdateAssumeRolePolicy.

Concessão de acesso ao Amazon EMR no EKS para os usuários

Para as ações executadas no Amazon EMR no EKS, uma permissão do IAM correspondente para essa ação é necessária. Você deve criar uma política do IAM que permita executar ações do Amazon EMR no EKS e anexá-la ao perfil ou ao usuário do IAM que você usa.

Este tópico fornece etapas para a criação de uma nova política e para o anexo dela a um usuário. Ele também abrange as permissões básicas necessárias para configurar o ambiente do Amazon EMR no EKS. Recomendamos redefinir as permissões para recursos específicos sempre que possível com base nas suas necessidades de negócios.

Criação de uma nova política do IAM e anexo dela a um usuário no console do IAM

Crie uma nova política do IAM

1. Faça login no Console de gerenciamento da AWS e abra o console do IAM em <https://console.aws.amazon.com/iam/>.
2. No painel de navegação esquerdo do console do IAM, escolha Políticas.
3. Na página Políticas (Políticas), escolha Create Policy (Criar política).
4. Na janela Criar política, navegue até a guia Editar JSON. Crie um documento de política com uma ou mais instruções JSON, conforme mostrado nos exemplos que seguem este procedimento. Em seguida, escolha Analisar política.
5. Na tela Review Policy (Revisar política), insira o Policy Name (Nome da política), por exemplo, AmazonEMR0nEKSPolicy. Insira uma descrição opcional e, em seguida, escolha Criar política.

Anexe a política a um usuário ou a um perfil

1. Faça login no Console de gerenciamento da AWS e abra o console do IAM em <https://console.aws.amazon.com/iam/>.
2. No painel de navegação, selecione Políticas.
3. Na lista de políticas, marque a caixa de seleção ao lado da política criada na seção anterior. Você pode usar o menu Filtro e a caixa de pesquisa para filtrar a lista de políticas.
4. Selecione Ações da política e escolha Anexar.
5. Escolha o usuário ou o perfil ao qual a política será anexada. Você pode usar o menu Filter (Filtro) e a caixa de pesquisa para filtrar a lista de entidades principais. Após escolher o usuário ou o perfil ao qual a política será anexada, selecione Anexar política.

Permissões para o gerenciamento de clusters virtuais

Para gerenciar clusters virtuais em sua AWS conta, crie uma política do IAM com as seguintes permissões. Essas permissões permitem que você crie, liste, descreva e exclua clusters virtuais em sua AWS conta.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "iam:CreateServiceLinkedRole"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringLike": {
          "iam:AWSServiceName": "emr-containers.amazonaws.com"
        }
      },
      "Sid": "AllowIAMCreateservicelinkedrole"
    },
    {
      "Effect": "Allow",
      "Action": [
        "emr-containers:CreateVirtualCluster",
        "emr-containers:ListVirtualClusters",
        "emr-containers:DescribeVirtualCluster",
        "emr-containers>DeleteVirtualCluster"
      ],
      "Resource": [
        "*"
      ],
      "Sid": "AllowEMRCONTAINERSCreatevirtualcluster"
    }
  ]
}
```

O Amazon EMR é integrado ao gerenciamento de acesso ao cluster (CAM) do Amazon EKS, para que você possa automatizar a configuração das políticas AuthN e AuthZ necessárias para executar trabalhos Spark do Amazon EMR em namespaces de clusters do Amazon EKS. Para fazer isso, você deve ter as seguintes permissões:

```
{
  "Effect": "Allow",
  "Action": [
    "eks:CreateAccessEntry"
  ],
  "Resource":
    "arn:<AWS_PARTITION>:eks:<AWS_REGION>:<AWS_ACCOUNT_ID>:cluster/<EKS_CLUSTER_NAME>"
},
{
  "Effect": "Allow",
  "Action": [
    "eks:DescribeAccessEntry",
    "eks>DeleteAccessEntry",
    "eks:ListAssociatedAccessPolicies",
    "eks:AssociateAccessPolicy",
    "eks:DisassociateAccessPolicy"
  ],
  "Resource": "arn:<AWS_PARTITION>:eks:<AWS_REGION>:<AWS_ACCOUNT_ID>:access-
entry/<EKS_CLUSTER_NAME>/role/<AWS_ACCOUNT_ID>/AWSServiceRoleForAmazonEMRContainers/*"
}
```

Para obter mais informações, consulte [Automate enabling cluster access for Amazon EMR on EKS](#).

Quando a `CreateVirtualCluster` operação é invocada pela primeira vez a partir de uma AWS conta, você também precisa das `CreateServiceLinkedRole` permissões para criar a função vinculada ao serviço para o Amazon EMR no EKS. Para obter mais informações, consulte [Uso de perfis vinculados ao serviço para o Amazon EMR no EKS](#).

Permissões para o envio de trabalhos

Para enviar trabalhos nos clusters virtuais da sua AWS conta, crie uma política do IAM com as seguintes permissões. Essas permissões permitem iniciar, listar, descrever e cancelar execuções de trabalhos para todos os clusters virtuais em sua conta. Você deve considerar adicionar permissões para listar ou descrever clusters virtuais, o que permite verificar o estado do cluster virtual antes de enviar trabalhos.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "emr-containers:StartJobRun",
        "emr-containers:ListJobRuns",
        "emr-containers:DescribeJobRun",
        "emr-containers:CancelJobRun"
      ],
      "Resource": [
        "*"
      ],
      "Sid": "AllowEMRCONTAINERSStartjobrun"
    }
  ]
}
```

Permissões para a depuração e o monitoramento

Para obter acesso aos registros enviados para o Amazon S3 e CloudWatch, ou para visualizar os registros de eventos do aplicativo no console do Amazon EMR, crie uma política do IAM com as seguintes permissões. Recomendamos redefinir as permissões para recursos específicos sempre que possível com base nas suas necessidades de negócios.

 Important

Se você não criou um bucket do Amazon S3, será necessário adicionar a permissão `s3:CreateBucket` à instrução de política. Se você não criou um grupo de logs, será necessário adicionar `logs:CreateLogGroup` à instrução de política.

JSON

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

```
"Statement": [
  {
    "Effect": "Allow",
    "Action": [
      "emr-containers:DescribeJobRun",
      "elasticmapreduce:CreatePersistentAppUI",
      "elasticmapreduce:DescribePersistentAppUI",
      "elasticmapreduce:GetPersistentAppUIPresignedURL"
    ],
    "Resource": [
      "*"
    ],
    "Sid": "AllowEMRCONTAINERSDescribejobrun"
  },
  {
    "Effect": "Allow",
    "Action": [
      "s3:GetObject",
      "s3:ListBucket"
    ],
    "Resource": [
      "*"
    ],
    "Sid": "AllowS3Getobject"
  },
  {
    "Effect": "Allow",
    "Action": [
      "logs:Get*",
      "logs:DescribeLogGroups",
      "logs:DescribeLogStreams"
    ],
    "Resource": [
      "*"
    ],
    "Sid": "AllowLOGSGet"
  }
]
```

Para obter mais informações sobre como configurar uma execução de trabalho para enviar registros para o Amazon S3 CloudWatch, consulte [Configurar uma execução de trabalho para usar registros do S3 e Configurar uma execução de trabalho para usar registros](#). CloudWatch

Registro do cluster do Amazon EKS com o Amazon EMR

Registrar o cluster é a etapa final obrigatória para configurar o Amazon EMR no EKS para executar workloads.

Use o comando apresentado a seguir para criar um cluster virtual com um nome de sua escolha para o cluster e para o namespace do Amazon EKS configurados nas etapas anteriores.

Note

Cada cluster virtual deve ter um nome exclusivo em todos os clusters do EKS. Se dois clusters virtuais tiverem o mesmo nome, o processo de implantação falhará mesmo que os dois clusters virtuais pertençam a clusters do EKS diferentes.

```
aws emr-containers create-virtual-cluster \  
--name virtual_cluster_name \  
--container-provider '{  
  "id": "cluster_name",  
  "type": "EKS",  
  "info": {  
    "eksInfo": {  
      "namespace": "namespace_name"  
    }  
  }  
'
```

Como alternativa, você pode criar um arquivo JSON que inclua os parâmetros obrigatórios para o cluster virtual e, em seguida, executar o comando `create-virtual-cluster` com o caminho para o arquivo JSON. Para obter mais informações, consulte [Gerenciamento de clusters virtuais](#).

Note

Para validar a criação com êxito de um cluster virtual, visualize o status dos clusters virtuais ao usar a operação `list-virtual-clusters` ou acessar a página Clusters virtuais no console do Amazon EMR.

Envio de uma execução de trabalho com **StartJobRun**

Enviar uma execução de trabalho com um arquivo JSON com parâmetros especificados

1. Crie um arquivo `start-job-run-request.json` e especifique os parâmetros obrigatórios para a execução de trabalho, como demonstrado pelo arquivo JSON de exemplo a seguir. Para obter mais informações sobre os parâmetros, consulte [Opções para a configuração de uma execução de trabalho](#).

```
{
  "name": "myjob",
  "virtualClusterId": "123456",
  "executionRoleArn": "iam_role_name_for_job_execution",
  "releaseLabel": "emr-6.2.0-latest",
  "jobDriver": {
    "sparkSubmitJobDriver": {
      "entryPoint": "entryPoint_location",
      "entryPointArguments": ["argument1", "argument2", ...],
      "sparkSubmitParameters": "--class <main_class> --conf
spark.executor.instances=2 --conf spark.executor.memory=2G --conf
spark.executor.cores=2 --conf spark.driver.cores=1"
    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "spark-defaults",
        "properties": {
          "spark.driver.memory": "2G"
        }
      }
    ]
  },
  "monitoringConfiguration": {
    "persistentAppUI": "ENABLED",
```

```

    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "my_log_group",
      "logStreamNamePrefix": "log_stream_prefix"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://my_s3_log_location"
    }
  }
}

```

2. Use o comando `start-job-run` com um caminho para o arquivo `start-job-run-request.json` armazenado localmente.

```

aws emr-containers start-job-run \
--cli-input-json file:///./start-job-run-request.json

```

Iniciar uma execução de trabalho usando o comando **start-job-run**

1. Forneça todos os parâmetros especificados no comando `StartJobRun`, como demonstrado pelo exemplo a seguir.

```

aws emr-containers start-job-run \
--virtual-cluster-id 123456 \
--name myjob \
--execution-role-arn execution-role-arn \
--release-label emr-6.2.0-latest \
--job-driver '{"sparkSubmitJobDriver": {"entryPoint": "entryPoint_location",
"entryPointArguments": ["argument1", "argument2", ...], "sparkSubmitParameters":
"--class <main_class> --conf spark.executor.instances=2 --conf
spark.executor.memory=2G --conf spark.executor.cores=2 --conf
spark.driver.cores=1"}}' \
--configuration-overrides '{"applicationConfiguration": [{"classification":
"spark-defaults", "properties": {"spark.driver.memory": "2G"}},
"monitoringConfiguration": {"cloudWatchMonitoringConfiguration":
{"logGroupName": "log_group_name", "logStreamNamePrefix": "log_stream_prefix"},
"persistentAppUI": "ENABLED", "s3MonitoringConfiguration": {"logUri":
"s3://my_s3_log_location" }}}'

```

2. Para o Spark SQL, forneça todos os parâmetros especificados no comando `StartJobRun`, como demonstrado pelo exemplo a seguir.

```
aws emr-containers start-job-run \
--virtual-cluster-id 123456 \
--name myjob \
--execution-role-arn execution-role-arn \
--release-label emr-6.7.0-latest \
--job-driver '{"sparkSqlJobDriver": {"entryPoint": "entryPoint_location",
"sparkSqlParameters": "--conf spark.executor.instances=2 --conf
spark.executor.memory=2G --conf spark.executor.cores=2 --conf
spark.driver.cores=1"}}' \
--configuration-overrides '{"applicationConfiguration": [{"classification":
"spark-defaults", "properties": {"spark.driver.memory": "2G"}}],
"monitoringConfiguration": {"cloudWatchMonitoringConfiguration":
{"logGroupName": "log_group_name", "logStreamNamePrefix": "log_stream_prefix"},
"persistentAppUI": "ENABLED", "s3MonitoringConfiguration": {"logUri":
"s3://my_s3_log_location" }}}
```

Uso da classificação de envio de trabalho

Visão geral do

A solicitação `StartJobRun` do Amazon EMR no EKS cria um pod de envio de trabalho (também conhecido como pod job-runner) para gerar o driver do Spark. Você pode usar a `emr-job-submitter` classificação para configurar seletores de nós, adicionar tolerâncias, personalizar o registro e fazer outras modificações no pod remetente do trabalho.

As seguintes configurações estão disponíveis na classificação `emr-job-submitter`:

`jobsubmitter.node.selector.[selectorKey]`

É adicionado ao seletor de nós do pod remetente do trabalho, com a chave `selectorKey` e o valor como valor de configuração. Por exemplo, você pode `jobsubmitter.node.selector.identifier` definir como `myIdentifier` e o pod remetente do trabalho terá um seletor de nós com uma chave `identifier` e um valor. `myIdentifier` Isso pode ser usado para especificar em quais nós o pod remetente do trabalho pode ser colocado. Para adicionar diversas chaves seletoras de nós, defina diversas configurações com esse prefixo.

jobsubmitter.label.[*labelKey*]

Adiciona aos rótulos do pod remetente do trabalho, com a chave *labelKey* e o valor como valor de configuração. Para adicionar vários rótulos, defina várias configurações com esse prefixo.

jobsubmitter.annotation.[*annotationKey*]

Adiciona às anotações do pod remetente do trabalho, com a chave *annotationKey* e o valor como valor de configuração. Para adicionar várias anotações, defina várias configurações com esse prefixo.

jobsubmitter.node.toleration.[*tolerationKey*]

Adiciona [tolerâncias](#) ao pod do remetente do trabalho. Por padrão, não há tolerâncias adicionadas ao pod. A chave da tolerância será *tolerationKey* e o valor da tolerância será o valor da configuração. Se o valor da configuração for definido como uma string não vazia, o operador será `Equals`. Se o valor da configuração estiver definido como "", o operador será `Exists`.

jobsubmitter.node.toleration.[*tolerationKey*].[*effect*]

Adiciona um efeito de tolerância ao prefixo *tolerationKey*. Esse campo é obrigatório ao adicionar tolerâncias. Os valores permitidos para o campo de efeito são `NoExecuteNoSchedule`, `PreferNoSchedule` e.

jobsubmitter.node.toleration.[*tolerationKey*].[*tolerationSeconds*]

Adiciona `tolerationSeconds` ao prefixo *tolerationKey*. Campo opcional. Aplicável somente quando o efeito é `NoExecute`.

jobsubmitter.scheduler.name

Define um `SchedulerName` personalizado para o pod remetente do trabalho.

jobsubmitter.logging

Ativa ou desativa o registro no pod remetente do trabalho. Quando isso é definido como, `DISABLED` o contêiner de registro é removido do pod remetente do trabalho, o que desativará qualquer registro desse pod especificado no `monitoringConfiguration`, como `s3MonitoringConfiguration` ou `cloudWatchMonitoringConfiguration`. Quando essa configuração não está definida ou está definida com qualquer outro valor, o login no pod remetente do trabalho é ativado.

jobsubmitter.logging.image

Define uma imagem personalizada a ser usada para o contêiner de registro em log no pod remetente do trabalho.

jobsubmitter.logging.request.cores

Define um valor personalizado para o número CPUs, em unidades de CPU, do contêiner de registro no pod remetente do trabalho. Por padrão, ela é definida como 100m.

jobsubmitter.logging.request.memory

Define um valor personalizado para a quantidade de memória, em bytes, para o contêiner de log no pod do remetente do trabalho. Por padrão, ela é definida como 200Mi. Um mebibyte é uma unidade de medida semelhante a um megabyte.

jobsubmitter.container.image

Define uma imagem personalizada para o contêiner do pod remetente do job-runner trabalho.

jobsubmitter.container.image.pullPolicy

Define os [imagePullPolicy](#) contêineres do pod remetente do trabalho para os contêineres.

Recomendamos colocar pods de remetentes de trabalhos em instâncias sob demanda. A colocação de pods remetentes de trabalhos em instâncias spot pode resultar em uma falha no trabalho se a instância em que o pod remetente de trabalho é executado estiver sujeita a uma interrupção da instância spot. Você também pode [colocar o pod remetente do trabalho em uma única zona de disponibilidade ou usar qualquer rótulo do Kubernetes aplicado aos nós](#).

Exemplos de classificação de envio de trabalho

Nesta seção

- [Solicitação StartJobRun com nó sob demanda estabelecido para o pod de envio de trabalho](#)
- [StartJobRunsolicitação com posicionamento de nó Single-AZ e posicionamento do tipo de instância Amazon EC2 para o pod remetente do trabalho](#)
- [StartJobRunsolicitação com rótulos, anotações e um agendador personalizado para o pod remetente do trabalho](#)
- [StartJobRunsolicitação com uma tolerância aplicada ao pod remetente do trabalho com chavededicated, valor graviton_machinesNoExecute, efeito e a de 60 segundos tolerationSeconds](#)
- [StartJobRunsolicitação com registro desativado para o pod remetente do trabalho](#)

- [StartJobRunsolicitação com imagem de contêiner de registro personalizada, CPU e memória para o pod remetente do trabalho](#)
- [StartJobRunsolicitação com uma imagem personalizada do contêiner do remetente do trabalho e política de pull](#)

Solicitação **StartJobRun** com nó sob demanda estabelecido para o pod de envio de trabalho

```
cat >spark-python-in-s3-nodeselector-job-submitter.json << EOF
{
  "name": "spark-python-in-s3-nodeselector",
  "virtualClusterId": "virtual-cluster-id",
  "executionRoleArn": "execution-role-arn",
  "releaseLabel": "emr-6.11.0-latest",
  "jobDriver": {
    "sparkSubmitJobDriver": {
      "entryPoint": "s3://S3-prefix/trip-count.py",
      "sparkSubmitParameters": "--conf spark.driver.cores=5 --conf
spark.executor.memory=20G --conf spark.driver.memory=15G --conf
spark.executor.cores=6"
    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "spark-defaults",
        "properties": {
          "spark.dynamicAllocation.enabled": "false"
        }
      },
      {
        "classification": "emr-job-submitter",
        "properties": {
          "jobsubmitter.node.selector.eks.amazonaws.com/capacityType": "ON_DEMAND"
        }
      }
    ],
    "monitoringConfiguration": {
      "cloudWatchMonitoringConfiguration": {
        "logGroupName": "/emr-containers/jobs",
        "logStreamNamePrefix": "demo"
      },
      "s3MonitoringConfiguration": {
```

```

        "logUri": "s3://joblogs"
    }
}
}
EOF
aws emr-containers start-job-run --cli-input-json file:///spark-python-in-s3-
nodeselector-job-submitter.json

```

StartJobRunsolicitação com posicionamento de nó Single-AZ e posicionamento do tipo de instância Amazon EC2 para o pod remetente do trabalho

```

"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-job-submitter",
      "properties": {
        "jobsubmitter.node.selector.topology.kubernetes.io/zone": "Availability Zone",
        "jobsubmitter.node.selector.node.kubernetes.io/instance-type": "m5.4xlarge"
      }
    }
  ]
}

```

StartJobRunsolicitação com rótulos, anotações e um agendador personalizado para o pod remetente do trabalho

```

"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-job-submitter",
      "properties": {
        "jobsubmitter.label.label1": "value1",
        "jobsubmitter.label.label2": "value2",
        "jobsubmitter.annotation.ann1": "value1",
        "jobsubmitter.annotation.ann2": "value2",
        "jobsubmitter.scheduler.name": "custom-scheduler"
      }
    }
  ]
}

```

StartJobRunssolicitação com uma tolerância aplicada ao pod remetente do trabalho com **chavededicated**, valor **graviton_machinesNoExecute**, efeito e a de 60 segundos **tolerationSeconds**

```
"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-job-submitter",
      "properties": {
        "jobsubmitter.node.toleration.dedicated": "graviton_machines",
        "jobsubmitter.node.toleration.dedicated.effect": "NoExecute",
        "jobsubmitter.node.toleration.dedicated.tolerationSeconds": "60"
      }
    }
  ]
}
```

StartJobRunssolicitação com registro desativado para o pod remetente do trabalho

```
"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-job-submitter",
      "properties": {
        "jobsubmitter.logging": "DISABLED"
      }
    }
  ],
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "/emr-containers/jobs",
      "logStreamNamePrefix": "demo"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://joblogs"
    }
  }
}
```

StartJobRunsolicitação com imagem de contêiner de registro personalizada, CPU e memória para o pod remetente do trabalho

```
"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-job-submitter",
      "properties": {
        "jobsubmitter.logging.image": "YOUR_ECR_IMAGE_URL",
        "jobsubmitter.logging.request.memory": "200Mi",
        "jobsubmitter.logging.request.cores": "0.5"
      }
    }
  ],
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "/emr-containers/jobs",
      "logStreamNamePrefix": "demo"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://joblogs"
    }
  }
}
```

StartJobRunsolicitação com uma imagem personalizada do contêiner do remetente do trabalho e política de pull

```
"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-job-submitter",
      "properties": {
        "jobsubmitter.container.image": "123456789012.dkr.ecr.us-west-2.amazonaws.com/emr6.11_custom_repo",
        "jobsubmitter.container.image.pullPolicy": "kubernetes pull policy"
      }
    }
  ]
}
```

Usar a classificação de padrões do contêiner do Amazon EMR

Visão geral do

As seguintes configurações estão disponíveis na classificação `emr-containers-defaults`:

`job-start-timeout`

Por padrão, um trabalho atingirá o tempo limite se não puder ser iniciado e esperar no estado SUBMITTED por 15 minutos. Essa configuração altera o número de segundos de espera antes da expiração da tarefa.

`executor.logging`

Ativa ou desativa o registro nos pods do executor. Quando isso é definido como, DISABLED o contêiner de registro é removido dos pods do executor, o que desativará qualquer registro desses pods especificados no `monitoringConfiguration`, como `s3MonitoringConfiguration` ou `cloudWatchMonitoringConfiguration`. Quando essa configuração não está definida ou está definida com qualquer outro valor, o registro nos pods do executor é ativado.

`logging.image`

Define uma imagem personalizada a ser utilizada para o contêiner de registro em log nos pods do driver e do executor.

`logging.request.cores`

Define um valor personalizado para o número CPUs, em unidades de CPU, do contêiner de registro nos pods do driver e do executor. Isso não é definido por padrão.

`logging.request.memory`

Define um valor personalizado para a quantidade de memória, em bytes, para o contêiner de registro em log nos pods do driver e do executor. Por padrão, ela é definida como 512Mi. Um mebibyte é uma unidade de medida semelhante a um megabyte.

Exemplos de classificação de envio de trabalho

Nesta seção

- [Solicitação StartJobRun com tempo limite de trabalho personalizado](#)
- [StartJobRunsolicitação com registro desativado para pods de executores](#)

- [StartJobRunsolicitação com imagem de contêiner de registro personalizada, CPU e memória para os pods de driver e executor](#)

Solicitação **StartJobRun** com tempo limite de trabalho personalizado

```
{
  "name": "spark-python",
  "virtualClusterId": "virtual-cluster-id",
  "executionRoleArn": "execution-role-arn",
  "releaseLabel": "emr-6.11.0-latest",
  "jobDriver": {
    "sparkSubmitJobDriver": {
      "entryPoint": "s3://S3-prefix/trip-count.py"
    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "emr-containers-defaults",
        "properties": {
          "job-start-timeout": "1800"
        }
      }
    ],
    "monitoringConfiguration": {
      "cloudWatchMonitoringConfiguration": {
        "logGroupName": "/emr-containers/jobs",
        "logStreamNamePrefix": "demo"
      },
      "s3MonitoringConfiguration": {
        "logUri": "s3://joblogs"
      }
    }
  }
}
```

StartJobRunsolicitação com registro desativado para pods de executores

```
"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-containers-defaults",
```



```

    "properties": {
      "executor.logging": "DISABLED"
    }
  ],
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "/emr-containers/jobs",
      "logStreamNamePrefix": "demo"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://joblogs"
    }
  }
}

```

StartJobRunssolicitação com imagem de contêiner de registro personalizada, CPU e memória para os pods de driver e executor

```

"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "emr-containers-defaults",
      "properties": {
        "logging.image": "YOUR_ECR_IMAGE_URL",
        "logging.request.memory": "200Mi",
        "logging.request.cores": "0.5"
      }
    }
  ],
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "/emr-containers/jobs",
      "logStreamNamePrefix": "demo"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://joblogs"
    }
  }
}

```

Execução de trabalhos do Spark com o operador do Spark

As versões 6.10.0 e superiores do Amazon EMR oferecem suporte ao operador do Kubernetes para Apache Spark, ou ao operador do Spark, como um modelo de envio de trabalho para o Amazon EMR no EKS. Com o operador do Spark, você pode implantar e gerenciar aplicações do Spark com o runtime da versão do Amazon EMR em seus próprios clusters do Amazon EKS. Após implantar o operador do Spark no cluster do Amazon EKS, você poderá enviar aplicações do Spark diretamente ao operador. O operador gerencia o ciclo de vida das aplicações do Spark.

Note

O Amazon EMR calcula preços no Amazon EKS com base no consumo de memória e vCPU. Esse cálculo se aplica aos pods de drivers e de executores. Esse cálculo começa quando você baixa a imagem da aplicação do Amazon EMR até que o pod do Amazon EKS seja encerrado e arredondado para o segundo mais próximo.

Tópicos

- [Configuração do operador do Spark para o Amazon EMR no EKS](#)
- [Conceitos básicos do operador do Spark para o Amazon EMR no EKS](#)
- [Uso do ajuste de escala automático vertical com o operador do Spark para Amazon EMR no EKS](#)
- [Desinstalação do operador do Spark para o Amazon EMR no EKS](#)
- [Usar a configuração de monitoramento para monitorar o operador Spark Kubernetes e os trabalhos Spark](#)
- [Segurança e o operador do Spark com o Amazon EMR no EKS](#)

Configuração do operador do Spark para o Amazon EMR no EKS

Conclua as tarefas apresentadas a seguir para se preparar antes de instalar o operador do Spark no Amazon EKS. Se você já se inscreveu na Amazon Web Services (AWS) e usou o Amazon EKS, está com quase tudo pronto para usar o Amazon EMR no EKS. Conclua as tarefas apresentadas a seguir para se preparar para usar o operador do Spark no Amazon EKS. Se você já completou algum dos pré-requisitos, pode ignorá-los e passar para os próximos.

- [Instale ou atualize para a versão mais recente do AWS CLI](#) — Se você já instalou o AWS CLI, confirme se você tem a versão mais recente.

- [Instale o kubectl e o eksctl](#) : o eksctl é uma ferramenta de linha de comando que você usa para se comunicar com o Amazon EKS.
- [Instale o Helm](#): o gerenciador de pacotes Helm para o Kubernetes ajuda a instalar e gerenciar aplicações em seu cluster do Kubernetes.
- [Comece a usar o Amazon EKS \(eksctl\)](#): siga as etapas para criar um cluster do Kubernetes com nós no Amazon EKS.
- [Selecione um URI de imagem base do Amazon EMR](#) (versão 6.10.0 ou superiores): o operador do Spark é compatível com as versões 6.10.0 e superiores do Amazon EMR.

Conceitos básicos do operador do Spark para o Amazon EMR no EKS

Este tópico ajuda você a começar a usar o operador do Spark no Amazon EKS ao implantar uma aplicação do Spark e uma aplicação programada do Spark.

Instalação do operador do Spark

Use as etapas apresentadas a seguir para instalar o operador do Kubernetes para Apache Spark.

1. Caso ainda não tenha feito, conclua as etapas em [Configuração do operador do Spark para o Amazon EMR no EKS](#).
2. Autentique seu cliente Helm no registro do Amazon ECR. No comando a seguir, substitua *region-id* os valores pelos seus preferidos Região da AWS e pelo *ECR-registry-account* valor correspondente para a Região na [Contas de registro do Amazon ECR por região](#) página.

```
aws ecr get-login-password \
--region region-id | helm registry login \
--username AWS \
--password-stdin ECR-registry-account.dkr.ecr.region-id.amazonaws.com
```

3. Instale o operador do Spark com o comando apresentado a seguir.

Para o parâmetro `--version` do chart do Helm, use o rótulo de versão do Amazon EMR com o prefixo `emr-` e o sufixo de data removidos. Por exemplo, com a versão `emr-6.12.0-java17-latest`, especifique `6.12.0-java17`. O exemplo com o comando apresentado a seguir usa a versão `emr-7.12.0-latest`, portanto, especifica `7.12.0` para o chart do Helm `--version`.

```
helm install spark-operator-demo \
oci://895885662937.dkr.ecr.region-id.amazonaws.com/spark-operator \
```

```
--set emrContainers.awsRegion=region-id \  
--version 7.12.0 \  
--namespace spark-operator \  
--create-namespace
```

Por padrão, o comando cria uma conta de serviço `emr-containers-sa-spark-operator` para o operador do Spark. Para usar uma conta de serviço diferente, forneça o argumento `serviceAccounts.sparkoperator.name`. Por exemplo:

```
--set serviceAccounts.sparkoperator.name my-service-account-for-spark-operator
```

Para [usar o escalonamento automático vertical com o operador Spark](#), adicione a seguinte linha ao comando de instalação para permitir webhooks para o operador:

```
--set webhook.enable=true
```

4. Verifique se você instalou o chart do Helm com o comando `helm list`:

```
helm list --namespace spark-operator -o yaml
```

O comando `helm list` deve retornar as informações da versão do chart do Helm recém-implantado:

```
app_version: v1beta2-1.3.8-3.1.1  
chart: spark-operator-7.12.0  
name: spark-operator-demo  
namespace: spark-operator  
revision: "1"  
status: deployed  
updated: 2023-03-14 18:20:02.721638196 +0000 UTC
```

5. Conclua a instalação com quaisquer opções adicionais necessárias. Para obter mais informações, consulte a [spark-on-k8s-operator](#) documentação em GitHub

Execução de uma aplicação do Spark

O operador do Spark é compatível com o Amazon EMR 6.10.0 ou com versões superiores. Ao instalar o operador do Spark, ele cria a conta de serviço `emr-containers-sa-spark` para executar aplicações do Spark por padrão. Use as etapas apresentadas a seguir para executar

uma aplicação do Spark com o operador do Spark no Amazon EMR no EKS 6.10.0 ou em versões superiores.

1. Antes de executar uma aplicação do Spark com o operador do Spark, conclua as etapas em [Configuração do operador do Spark para o Amazon EMR no EKS](#) e [Instalação do operador do Spark](#).
2. Crie um arquivo de definição SparkApplication `spark-pi.yaml` com o seguinte conteúdo de exemplo:

```
apiVersion: "sparkoperator.k8s.io/v1beta2"
kind: SparkApplication
metadata:
  name: spark-pi
  namespace: spark-operator
spec:
  type: Scala
  mode: cluster
  image: "895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.10.0:latest"
  imagePullPolicy: Always
  mainClass: org.apache.spark.examples.SparkPi
  mainApplicationFile: "local:///usr/lib/spark/examples/jars/spark-examples.jar"
  sparkVersion: "3.3.1"
  restartPolicy:
    type: Never
  volumes:
    - name: "test-volume"
      hostPath:
        path: "/tmp"
        type: Directory
  driver:
    cores: 1
    coreLimit: "1200m"
    memory: "512m"
    labels:
      version: 3.3.1
    serviceAccount: emr-containers-sa-spark
    volumeMounts:
      - name: "test-volume"
        mountPath: "/tmp"
  executor:
    cores: 1
    instances: 1
```

```
memory: "512m"
labels:
  version: 3.3.1
volumeMounts:
  - name: "test-volume"
    mountPath: "/tmp"
```

3. Agora, envie a aplicação do Spark com o comando apresentado a seguir. Isso também criará um objeto SparkApplication chamado spark-pi:

```
kubectl apply -f spark-pi.yaml
```

4. Verifique os eventos do objeto SparkApplication com o seguinte comando:

```
kubectl describe sparkapplication spark-pi --namespace spark-operator
```

Para obter mais informações sobre como enviar inscrições para o Spark por meio do operador do Spark, consulte [Usando um SparkApplication na spark-on-k8s-operator documentação](#) sobre. GitHub

Uso do Amazon S3 para armazenamento

Para usar o Amazon S3 como opção de armazenamento de arquivos, adicione as configurações a seguir ao arquivo YAML.

```
hadoopConf:
# EMRFS filesystem
  fs.s3.customAWSCredentialsProvider:
    com.amazonaws.auth.WebIdentityTokenCredentialsProvider
  fs.s3.impl: com.amazon.ws.emr.hadoop.fs.EmrFileSystem
  fs.AbstractFileSystem.s3.impl: org.apache.hadoop.fs.s3.EMRFSDelegate
  fs.s3.buffer.dir: /mnt/s3
  fs.s3.getObject.initialSocketTimeoutMilliseconds: "2000"
  mapreduce.fileoutputcommitter.algorithm.version.emr_internal_use_only.EmrFileSystem:
    "2"
  mapreduce.fileoutputcommitter.cleanup-
failures.ignored.emr_internal_use_only.EmrFileSystem: "true"
sparkConf:
# Required for EMR Runtime
  spark.driver.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/hadoop-
aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/share/aws/
```

```

emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/security/conf:/
usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-glue-datacatalog-
spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-serde.jar:/usr/share/aws/
sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/hadoop/extrajars/*
spark.driver.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-lzo/lib/
native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/native
spark.executor.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/hadoop-
aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/share/aws/
emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/security/conf:/
usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-glue-datacatalog-
spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-serde.jar:/usr/share/aws/
sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/hadoop/extrajars/*
spark.executor.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-lzo/lib/
native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/native

```

Se você usa o Amazon EMR nas versões 7.2.0 e superiores, as configurações são incluídas por padrão. Nesse caso, você pode definir o caminho do arquivo como `s3://<bucket_name>/<file_path>` em vez de `local://<file_path>` no arquivo YAML da aplicação do Spark.

Em seguida, envie a aplicação do Spark normalmente.

Uso do ajuste de escala automático vertical com o operador do Spark para Amazon EMR no EKS

A partir do Amazon EMR 7.0, você pode usar o ajuste de escala automático vertical do Amazon EMR no EKS para simplificar o gerenciamento de recursos. Ela ajusta automaticamente os recursos de memória e de CPU para se adaptar às necessidades da workload fornecida para aplicações do Spark no Amazon EMR. Para obter mais informações, consulte [Uso da escalabilidade automática vertical com trabalhos do Spark no Amazon EMR](#).

Esta seção descreve como configurar o operador Spark para usar o ajuste de escala automático vertical.

Pré-requisitos

Antes de configurar o monitoramento, certifique-se de concluir as seguintes tarefas de configuração:

- Siga as etapas em [Configuração do operador do Spark para o Amazon EMR no EKS](#).
- (opcional) Se você instalou anteriormente uma versão mais antiga do operador Spark, exclua o SparkApplication/ScheduledSparkApplication CRD.

```
kubectl delete crd sparkApplication
kubectl delete crd scheduledSparkApplication
```

- Siga as etapas em [Instalação do operador do Spark](#). Na etapa 3, adicione a seguinte linha ao comando de instalação para permitir webhooks para o operador:

```
--set webhook.enable=true
```

- Siga as etapas em [Configuração da escalabilidade automática vertical para o Amazon EMR no EKS](#).
- Dê acesso aos arquivos na localização do Amazon S3:

- Anote sua conta de serviço do driver e do operador com o JobExecutionRole que tem as permissões do S3.

```
kubectl annotate serviceaccount -n spark-operator emr-containers-sa-spark
eks.amazonaws.com/role-arn=JobExecutionRole
kubectl annotate serviceaccount -n spark-operator emr-containers-sa-spark-
operator eks.amazonaws.com/role-arn=JobExecutionRole
```

- Atualize a política de confiança do perfil de execução de trabalho nesse namespace.

```
aws emr-containers update-role-trust-policy \
--cluster-name cluster \
--namespace ${Namespace} \
--role-name iam_role_name_for_job_execution
```

- Edite a política de confiança do perfil do IAM do perfil de execução de trabalhos e atualize a serviceaccount de emr-containers-sa-spark-**-*-xxxx* para emr-containers-sa-***.

```
{
  "Effect": "Allow",
  "Principal": {
    "Federated": "OIDC-provider"
  },
  "Action": "sts:AssumeRoleWithWebIdentity",
  "Condition": {
    "StringLike": {
      "OIDC": "system:serviceaccount:${Namespace}:emr-containers-sa-*"
    }
  }
}
```



```

    }
  }
}

```

4. Se estiver usando o Amazon S3 como armazenamento de arquivos, adicione os padrões a seguir ao arquivo YAML.

```

hadoopConf:
# EMRFS filesystem
  fs.s3.customAWSCredentialsProvider:
com.amazonaws.auth.WebIdentityTokenCredentialsProvider
  fs.s3.impl: com.amazon.ws.emr.hadoop.fs.EmrFileSystem
  fs.AbstractFileSystem.s3.impl: org.apache.hadoop.fs.s3.EMRFSDelegate
  fs.s3.buffer.dir: /mnt/s3
  fs.s3.getObject.initialSocketTimeoutMilliseconds: "2000"

mapreduce.fileoutputcommitter.algorithm.version.emr_internal_use_only.EmrFileSystem:
"2"
  mapreduce.fileoutputcommitter.cleanup-
failures.ignored.emr_internal_use_only.EmrFileSystem: "true"
sparkConf:
# Required for EMR Runtime
  spark.driver.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/hadoop-
aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/share/
aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/
security/conf:/usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-
glue-datacatalog-spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-
serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/
hadoop/extrajars/*
  spark.driver.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-lzo/
lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/
native
  spark.executor.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/
hadoop-aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/
share/aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/
security/conf:/usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-
glue-datacatalog-spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-
serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/
hadoop/extrajars/*
  spark.executor.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-
lzo/lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/
native

```

Execute um trabalho com ajuste de escala automático vertical no operador do Spark

Antes de executar uma aplicação do Spark com o operador do Spark, conclua as etapas em [Pré-requisitos](#).

Para usar o ajuste de escala automático vertical com o operador do Spark, adicione a seguinte configuração ao driver da especificação da aplicação do Spark para ativar o ajuste de escala automático vertical:

```
dynamicSizing:
  mode: Off
  signature: "my-signature"
```

Essa configuração permite o ajuste de escala automático vertical e é uma configuração de assinatura obrigatória que permite escolher uma assinatura para o trabalho.

Para obter mais informações sobre as configurações e os valores dos parâmetros, consulte [Configuring vertical autoscaling for Amazon EMR on EKS](#). Por padrão, seu trabalho é enviado com a opção somente monitoramento no modo Desativado para a escalabilidade automática vertical. Esse estado de monitoramento permite calcular e visualizar recomendações de recursos sem realizar a escalabilidade automática. Para obter mais informações, consulte [Vertical autoscaling modes](#).

O exemplo a seguir mostra um arquivo de definição SparkApplication chamado `spark-pi.yaml` com as configurações necessárias para usar ajuste de escala automático vertical.

```
apiVersion: "sparkoperator.k8s.io/v1beta2"
kind: SparkApplication
metadata:
  name: spark-pi
  namespace: spark-operator
spec:
  type: Scala
  mode: cluster
  image: "895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-7.12.0:latest"
  imagePullPolicy: Always
  mainClass: org.apache.spark.examples.SparkPi
  mainApplicationFile: "local:///usr/lib/spark/examples/jars/spark-examples.jar"
  sparkVersion: "3.4.1"
  dynamicSizing:
    mode: Off
    signature: "my-signature"
  restartPolicy:
```

```
  type: Never
volumes:
  - name: "test-volume"
    hostPath:
      path: "/tmp"
      type: Directory
driver:
  cores: 1
  coreLimit: "1200m"
  memory: "512m"
  labels:
    version: 3.4.1
  serviceAccount: emr-containers-sa-spark
  volumeMounts:
    - name: "test-volume"
      mountPath: "/tmp"
executor:
  cores: 1
  instances: 1
  memory: "512m"
  labels:
    version: 3.4.1
  volumeMounts:
    - name: "test-volume"
      mountPath: "/tmp"
```

Agora, envie a aplicação do Spark com o comando apresentado a seguir. Isso também criará um objeto `SparkApplication` chamado `spark-pi`:

```
kubectl apply -f spark-pi.yaml
```

Para obter mais informações sobre como enviar inscrições para o Spark por meio do operador do Spark, consulte [Usando um SparkApplication na spark-on-k8s-operator documentação](#) sobre. GitHub

Verificação de funcionalidade da escalabilidade automática vertical

Para verificar se a escalabilidade automática vertical está funcionando corretamente para o trabalho enviado, use `kubectl` para obter o recurso personalizado `verticalpodautoscaler` e visualizar suas recomendações de escalabilidade.

```
kubectl get verticalpodautoscalers --all-namespaces \
```

```
-l=emr-containers.amazonaws.com/dynamic.sizing.signature=my-signature
```

A saída desta consulta deve ser semelhante à seguinte:

NAMESPACE	NAME	MODE		
CPU	MEM	PROVIDED	AGE	
spark-operator	ds-p73j6mkosvc4xeb3gr7x4xol2bfcw5evqimzqojrlysvj3giozuq-vpa	Off		
580026651	True	15m		

Se a saída não for semelhante ou tiver um código de erro, consulte [Solução de problemas de escalabilidade automática vertical do Amazon EMR no EKS](#) para obter passos que ajudam a resolver o problema.

Para remover pods e aplicações, execute o seguinte comando:

```
kubectl delete sparkapplication spark-pi
```

Desinstalação do operador do Spark para o Amazon EMR no EKS

Use as etapas apresentadas a seguir para desinstalar o operador do Spark.

1. Exclua o operador do Spark usando o namespace correto. Para este exemplo, o namespace é spark-operator-demo.

```
helm uninstall spark-operator-demo -n spark-operator
```

2. Exclua a conta de serviço do operador do Spark:

```
kubectl delete sa emr-containers-sa-spark-operator -n spark-operator
```

3. Exclua o operador do Spark CustomResourceDefinitions (CRDs):

```
kubectl delete crd sparkapplications.sparkoperator.k8s.io
kubectl delete crd scheduledsparkapplications.sparkoperator.k8s.io
```

Usar a configuração de monitoramento para monitorar o operador Spark Kubernetes e os trabalhos Spark

A configuração de monitoramento permite configurar facilmente o arquivamento de logs da sua aplicação Spark e logs do operador no Amazon S3 ou no Amazon CloudWatch. Você pode escolher um ou os dois. Isso adiciona um sidecar do agente de log ao seu pod do operador Spark, driver e pods executores e, subsequentemente, encaminha os logs desses componentes para seus coletores configurados.

Pré-requisitos

Antes de configurar o monitoramento, certifique-se de concluir as seguintes tarefas de configuração:

1. (Opcional) Se você instalou anteriormente uma versão mais antiga do operador Spark, exclua o SparkApplicationScheduledSparkApplication/CRD.

```
kubectl delete crd scheduledsparkapplications.sparkoperator.k8s.io
kubectl delete crd sparkapplications.sparkoperator.k8s.io
```

2. Crie uma função de operador/job execução no IAM se você ainda não tiver uma.
3. Execute o comando a seguir para atualizar a política de confiança da função de operador/job execução que você acabou de criar:

```
aws emr-containers update-role-trust-policy \
--cluster-name cluster \
--namespace namespace \
--role-name iam_role_name_for_operator/job_execution_role
```

4. Edite a política de confiança da função do IAM da sua função de operador/job execução da seguinte forma:

```
{
  "Effect": "Allow",
  "Principal": {
    "Federated": "${OIDC-provider}"
  },
  "Action": "sts:AssumeRoleWithWebIdentity",
  "Condition": {
    "StringLike": {
```

```

        "OIDC_PROVIDER:sub": "system:serviceaccount:${Namespace}:emr-
containers-sa-*"
      }
    }
  }
}

```

5. Crie uma política `monitoringConfiguration` no IAM com as seguintes permissões:

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:DescribeLogStreams",
        "logs:CreateLogStream",
        "logs:CreateLogGroup",
        "logs:PutLogEvents"
      ],
      "Resource": [
        "arn:aws:logs:*:*:log-group:log_group_name",
        "arn:aws:logs:*:*:log-group:log_group_name:"
      ],
      "Sid": "AllowLOGSDescribelogstreams"
    },
    {
      "Effect": "Allow",
      "Action": [
        "logs:DescribeLogGroups"
      ],
      "Resource": [
        "*"
      ],
      "Sid": "AllowLOGSDescribeloggroups"
    },
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket"
      ]
    }
  ]
}

```

```

    ],
    "Resource": [
        "arn:aws:s3:::bucket_name",
        "arn:aws:s3:::bucket_name/*"
    ],
    "Sid": "AllowS3Putobject"
  }
]
}

```

6. Anexe a política acima à sua função operator/job de execução.

Logs do operador do Spark

É possível definir a configuração de monitoramento da seguinte maneira ao realizar `helm install`:

```

helm install spark-operator spark-operator \
--namespace namespace \
--set emrContainers.awsRegion=aws_region \
--set emrContainers.monitoringConfiguration.image=log_agent_image_url \
--set
  emrContainers.monitoringConfiguration.s3MonitoringConfiguration.logUri=S3_bucket_uri \
--set
  emrContainers.monitoringConfiguration.cloudWatchMonitoringConfiguration.logGroupName=log_group
\
--set
  emrContainers.monitoringConfiguration.cloudWatchMonitoringConfiguration.logStreamNamePrefix=log_stream_name_prefix
\
--set emrContainers.monitoringConfiguration.sideCarResources.limits.cpuLimit=500m \
--set emrContainers.monitoringConfiguration.sideCarResources.limits.memoryLimit=512Mi \
--set
  emrContainers.monitoringConfiguration.containerLogRotationConfiguration.rotationSize=2GB
\
--set
  emrContainers.monitoringConfiguration.containerLogRotationConfiguration.maxFilesToKeep=10
\
--set webhook.enable=true \
--set emrContainers.operatorExecutionRoleArn=operator_execution_role_arn

```

Monitoramento de configuração

A seguir, estão apresentadas as opções de configuração disponíveis em `monitoringConfiguration`.

- Imagem (opcional): URL da imagem do agente de log. Será buscado `emrReleaseLabel` se não for fornecido.
- `s3 MonitoringConfiguration` — Defina essa opção para arquivar no Amazon S3.
 - `logUri` (necessário): o caminho do bucket do Amazon S3 em que você deseja armazenar seus logs.
 - A seguir estão alguns exemplos de formatos para os caminhos do bucket do S3, após o upload dos logs. O primeiro exemplo mostra que a alternância de logs não está habilitada.

```
s3://${logUri}/${POD_NAME}/operator/stdout.gz  
s3://${logUri}/${POD_NAME}/operator/stderr.gz
```

A alternância de log está habilitada por padrão. Você pode ver tanto um arquivo com alternância, com um índice incremental, quanto um arquivo atual, que é igual ao exemplo anterior.

```
s3://${logUri}/${POD_NAME}/operator/stdout_YYYYMMDD_index.gz  
s3://${logUri}/${POD_NAME}/operator/stderr_YYYYMMDD_index.gz
```

- `cloudWatchMonitoringConfiguração` — A chave de configuração para a qual configurar o encaminhamento. Amazon CloudWatch
 - `logGroupName`(obrigatório) — Nome do grupo de Amazon CloudWatch registros para o qual você deseja enviar registros. O grupo é criado automaticamente, se não existir.
 - `logStreamNamePrefix` (opcional) — Nome do fluxo de registros para o qual você deseja enviar os registros. O valor padrão é uma string vazia. O formato em Amazon CloudWatch é o seguinte:

```
${logStreamNamePrefix}/${POD_NAME}/STDOUT or STDERR
```

- `sideCarResources`(opcional) — A chave de configuração para definir limites de recursos no contêiner auxiliar Fluentd lançado.
 - `memoryLimit` (opcional): o limite de memória. Ajuste de acordo com suas necessidades. O padrão é de 512Mi.
 - `cpuLimit` (opcional): o limite da CPU. Ajuste de acordo com suas necessidades. O padrão é 500m.
- `containerLogRotationConfiguração` (opcional) — controla o comportamento de rotação do log do contêiner. Ele é habilitado por padrão.

- `rotationSize` (necessário): especifica o tamanho do arquivo para a alternância de log. O intervalo de valores possíveis é de 2 KB a 2 GB. A parcela numérica da unidade do parâmetro `rotationSize` é transferida como um número inteiro. Como não há suporte para valores decimais, você pode especificar um tamanho de rotação de 1,5 GB, por exemplo, com o valor 1.500 MB. O padrão é 2 GB.
- `maxFilesToManter` (obrigatório) — Especifica o número máximo de arquivos a serem retidos no contêiner após a rotação. O valor mínimo é de 1 e o valor máximo é de 50. O padrão é 10.

Depois de configurar o `MonitoringConfiguration`, você deve ser capaz de verificar os registros do pod do operador do Spark em um bucket do Amazon S3 ou em ambos. Amazon CloudWatch Para um bucket do Amazon S3, você precisa esperar 2 minutos para que o primeiro arquivo de log seja liberado.

Para encontrar os logs Amazon CloudWatch, você pode navegar até o seguinte: `CloudWatch> Grupos de registros > > Log group namePod name/operator/stderr`

Ou você pode navegar até: `CloudWatch> Grupos de registros > > Log group namePod name/operator/stdout`

Logs da aplicação do Spark

Você pode definir essa configuração da maneira apresentada a seguir.

```
apiVersion: "sparkoperator.k8s.io/v1beta2"
kind: SparkApplication
metadata:
  name: spark-pi
  namespace: namespace
spec:
  type: Scala
  mode: cluster
  imagePullPolicy: Always
  mainClass: org.apache.spark.examples.SparkPi
  mainApplicationFile: "local:///usr/lib/spark/examples/jars/spark-examples.jar"
  sparkVersion: "3.3.1"
  emrReleaseLabel: emr_release_label
  executionRoleArn: job_execution_role_arn
  restartPolicy:
    type: Never
  volumes:
```

```

- name: "test-volume"
  hostPath:
    path: "/tmp"
    type: Directory
driver:
  cores: 1
  coreLimit: "1200m"
  memory: "512m"
  labels:
    version: 3.3.1
  volumeMounts:
    - name: "test-volume"
      mountPath: "/tmp"
executor:
  cores: 1
  instances: 1
  memory: "512m"
  labels:
    version: 3.3.1
  volumeMounts:
    - name: "test-volume"
      mountPath: "/tmp"
monitoringConfiguration:
  image: "log_agent_image"
  s3MonitoringConfiguration:
    logUri: "S3_bucket_uri"
  cloudWatchMonitoringConfiguration:
    logGroupName: "log_group_name"
    logStreamNamePrefix: "log_stream_prefix"
  sideCarResources:
    limits:
      cpuLimit: "500m"
      memoryLimit: "250Mi"
  containerLogRotationConfiguration:
    rotationSize: "2GB"
    maxFilesToKeep: "10"

```

A seguir, estão apresentadas as opções de configuração disponíveis em `monitoringConfiguration`.

- Imagem (opcional): URL da imagem do agente de log. Será buscado `emrReleaseLabel` se não for fornecido.
- `s3 MonitoringConfiguration` — Defina essa opção para arquivar no Amazon S3.

- `logUri` (necessário): o caminho do bucket do Amazon S3 em que você deseja armazenar seus logs. O primeiro exemplo mostra que a alternância de logs não está habilitada:

```
s3://${logUri}/${APPLICATION_NAME}-${APPLICATION_UID}/${POD_NAME}/stdout.gz
s3://${logUri}/${APPLICATION_NAME}-${APPLICATION_UID}/${POD_NAME}/stderr.gz
```

A alternância de log está habilitada por padrão. Você pode usar tanto um arquivo com alternância (com índice incremental) quanto um arquivo atual (sem carimbo de data/hora).

```
s3://${logUri}/${APPLICATION_NAME}-${APPLICATION_UID}/${POD_NAME}/
stdout_YYYYMMDD_index.gz
s3://${logUri}/${APPLICATION_NAME}-${APPLICATION_UID}/${POD_NAME}/
stderr_YYYYMMDD_index.gz
```

- `cloudWatchMonitoringConfiguração` — A chave de configuração para a qual configurar o encaminhamento. Amazon CloudWatch
- `logGroupName`(obrigatório) — O nome do grupo de logs do Cloudwatch para o qual você deseja enviar registros. O grupo é criado automaticamente, se não existir.
- `logStreamNamePrefix` (opcional) — O nome do fluxo de registros para o qual você deseja enviar os registros. O valor padrão é uma string vazia. O formato em CloudWatch é o seguinte:

```
${logStreamNamePrefix}/${APPLICATION_NAME}-${APPLICATION_UID}/${POD_NAME}/stdout
${logStreamNamePrefix}/${APPLICATION_NAME}-${APPLICATION_UID}/${POD_NAME}/stderr
```

- `sideCarResources`(opcional) — A chave de configuração para definir limites de recursos no contêiner auxiliar Fluentd lançado.
- `memoryLimit` (opcional): o limite de memória. Ajuste de acordo com suas necessidades. O padrão é 250Mi.
- `cpuLimit`: o limite da CPU. Ajuste de acordo com suas necessidades. O padrão é 500m.
- `containerLogRotationConfiguração` (opcional) — controla o comportamento de rotação do log do contêiner. Ele é habilitado por padrão.
- `rotationSize` (necessário): especifica o tamanho do arquivo para a alternância de log. O intervalo de valores possíveis é de 2 KB a 2 GB. A parcela numérica da unidade do parâmetro `rotationSize` é transferida como um número inteiro. Como não há suporte para valores decimais, você pode especificar um tamanho de rotação de 1,5 GB, por exemplo, com o valor 1.500 MB. O padrão é 2 GB.

- `maxFilesToManter` (obrigatório) — Especifica o número máximo de arquivos a serem retidos no contêiner após a rotação. O valor mínimo é 1. O valor máximo é 50. O padrão é 10.

Depois de configurar o `MonitoringConfiguration`, você deve ser capaz de verificar os registros do driver e do executor do aplicativo Spark em um bucket do Amazon S3 ou em ambos. CloudWatch

Para um bucket do Amazon S3, você precisa esperar 2 minutos para que o primeiro arquivo de log seja liberado. Por exemplo, no Amazon S3, o caminho do bucket aparece da seguinte maneira:

```
Amazon S3 > Buckets > > > Bucket name > stderr.gz Spark application name - UUID Pod Name
```

Ou:

```
Amazon S3 > Buckets > > > Bucket name > stdout.gz Spark application name - UUID Pod Name
```

Em CloudWatch, o caminho aparece da seguinte forma:

```
CloudWatch > Grupos de registros > Log group name > Spark application name - UUID/Pod name/stderr
```

Ou:

```
CloudWatch > Grupos de registros > Log group name > Spark application name - UUID/Pod name/stdout
```

Segurança e o operador do Spark com o Amazon EMR no EKS

Há algumas maneiras de configurar as permissões de acesso ao cluster ao usar o operador do Spark. A primeira é usar o controle de acesso baseado em perfil. O controle de acesso por perfil (RBAC) restringe o acesso com base no perfil de uma pessoa dentro de uma organização. Ele se tornou-se a principal forma de lidar com o acesso. O segundo método de acesso é assumir uma AWS Identity and Access Management função, que fornece acesso a recursos por meio de permissões específicas atribuídas.

Tópicos

- [Configuração de permissões de acesso ao cluster com o controle de acesso por perfil \(RBAC\)](#)
- [Configuração de permissões de acesso ao cluster com perfis do IAM para contas de serviço \(IRSA\)](#)

Configuração de permissões de acesso ao cluster com o controle de acesso por perfil (RBAC)

Para implantar o operador do Spark, o Amazon EMR no EKS cria dois perfis e duas contas de serviço para o operador do Spark e para as aplicações do Spark.

Tópicos

- [Perfil e conta de serviço do operador](#)
- [Perfil e conta de serviço do Spark](#)

Perfil e conta de serviço do operador

O Amazon EMR no EKS cria o perfil e a conta de serviço do operador para gerenciar SparkApplications para trabalhos do Spark e para outros recursos, como serviços.

O nome padrão para esta conta de serviço é `emr-containers-sa-spark-operator`.

As seguintes regras se aplicam para este perfil de serviço:

```
rules:
- apiGroups:
  - ""
  resources:
  - pods
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - services
  - configmaps
  - secrets
  verbs:
  - create
  - get
  - delete
  - update
- apiGroups:
  - extensions
  - networking.k8s.io
  resources:
  - ingresses
```

```
verbs:
- create
- get
- delete
- apiGroups:
- ""
resources:
- nodes
verbs:
- get
- apiGroups:
- ""
resources:
- events
verbs:
- create
- update
- patch
- apiGroups:
- ""
resources:
- resourcequotas
verbs:
- get
- list
- watch
- apiGroups:
- apiextensions.k8s.io
resources:
- customresourcedefinitions
verbs:
- create
- get
- update
- delete
- apiGroups:
- admissionregistration.k8s.io
resources:
- mutatingwebhookconfigurations
- validatingwebhookconfigurations
verbs:
- create
- get
- update
```

```

- delete
- apiGroups:
  - sparkoperator.k8s.io
resources:
- sparkapplications
- sparkapplications/status
- scheduledsparkapplications
- scheduledsparkapplications/status
verbs:
- "*"
{{- if .Values.batchScheduler.enable }}
# required for the `volcano` batch scheduler
- apiGroups:
  - scheduling.incubator.k8s.io
  - scheduling.sigs.dev
  - scheduling.volcano.sh
resources:
- podgroups
verbs:
- "*"
{{- end }}
{{ if .Values.webhook.enable }}
- apiGroups:
  - batch
resources:
- jobs
verbs:
- delete
{{- end }}

```

Perfil e conta de serviço do Spark

Um pod do driver do Spark precisa de uma conta de serviço do Kubernetes no mesmo namespace que o pod. Esta conta de serviço precisa de permissões para criar, obter, listar, aplicar patches e excluir pods de executores e para criar um serviço descentralizado do Kubernetes para o driver. O driver apresentará falhas e será encerrado sem a conta de serviço, a menos que a conta de serviço padrão no namespace do pod tenha as permissões obrigatórias.

O nome padrão para esta conta de serviço é `emr-containers-sa-spark`.

As seguintes regras se aplicam para este perfil de serviço:

```
rules:
```

```
- apiGroups:
  - ""
  resources:
  - pods
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - services
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - configmaps
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - persistentvolumeclaims
  verbs:
  - "*"
```

Configuração de permissões de acesso ao cluster com perfis do IAM para contas de serviço (IRSA)

Esta seção usa um exemplo para demonstrar como configurar uma conta de serviço do Kubernetes para assumir uma função. AWS Identity and Access Management Os pods que usam a conta de serviço podem então acessar qualquer AWS serviço que a função tenha permissão para acessar.

O exemplo apresentado a seguir executa uma aplicação do Spark para contar as palavras de um arquivo no Amazon S3. Para fazer isso, você pode configurar perfis do IAM para contas de serviço (IRSA) com a finalidade de autenticar e autorizar as contas de serviço do Kubernetes.

Note

Este exemplo usa o namespace “spark-operator” para o operador do Spark e para o namespace no qual a aplicação do Spark é enviada.

Pré-requisitos

Antes de testar o exemplo apresentado nesta página, complete os seguintes pré-requisitos:

- [Prepare-se para usar o operador do Spark.](#)
- [Instalação do operador do Spark.](#)
- [Crie um bucket do Amazon S3.](#)
- Salve seu poema favorito em um arquivo de texto chamado `poem.txt` e faça o upload do arquivo em seu bucket do S3. A aplicação do Spark criada nesta página realizará a leitura do conteúdo do arquivo de texto. Para obter mais informações sobre como fazer o upload de arquivos para o S3, consulte [Fazer upload de um objeto para o seu bucket](#) no Guia do usuário do Amazon Simple Storage Service.

Configuração de uma conta de serviço do Kubernetes para assumir um perfil do IAM

Use as etapas a seguir para configurar uma conta de serviço do Kubernetes para assumir um papel do IAM que os pods possam usar para acessar AWS serviços que o papel tem permissões para acessar.

1. Depois de concluir o [Pré-requisitos](#), use o AWS Command Line Interface para criar um `example-policy.json` arquivo que permita acesso somente para leitura ao arquivo que você enviou para o Amazon S3:

```
cat >example-policy.json <<EOF
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::my-pod-bucket",
        "arn:aws:s3:::my-pod-bucket/*"
      ]
    }
  ]
}
```

```
EOF
```

2. Em seguida, crie uma política do IAM `example-policy`:

```
aws iam create-policy --policy-name example-policy --policy-document file://  
example-policy.json
```

3. Depois disso, crie um perfil do IAM `example-role` e associe-o a uma conta de serviço do Kubernetes para o driver do Spark:

```
eksctl create iamserviceaccount --name driver-account-sa --namespace spark-operator  
\  
--cluster my-cluster --role-name "example-role" \  
--attach-policy-arn arn:aws:iam::111122223333:policy/example-policy --approve
```

4. Crie um arquivo em YAML com as associações de perfil do cluster que são obrigatórias para a conta de serviço do driver do Spark:

```
cat >spark-rbac.yaml <<EOF  
apiVersion: v1  
kind: ServiceAccount  
metadata:  
  name: driver-account-sa  
---  
apiVersion: rbac.authorization.k8s.io/v1  
kind: ClusterRoleBinding  
metadata:  
  name: spark-role  
roleRef:  
  apiGroup: rbac.authorization.k8s.io  
  kind: ClusterRole  
  name: edit  
subjects:  
  - kind: ServiceAccount  
    name: driver-account-sa  
    namespace: spark-operator  
EOF
```

5. Aplique as configurações de associação de perfil do cluster:

```
kubectl apply -f spark-rbac.yaml
```

O comando `kubectl` deve confirmar a criação com êxito da conta:

```
serviceaccount/driver-account-sa created
clusterrolebinding.rbac.authorization.k8s.io/spark-role configured
```

Execução de uma aplicação do operador do Spark

Após [configurar a conta de serviço do Kubernetes](#), você poderá executar uma aplicação do Spark que conta o número de palavras no arquivo de texto carregado como parte dos [Pré-requisitos](#).

1. Crie um novo arquivo `word-count.yaml` com uma definição `SparkApplication` para sua aplicação de contagem de palavras, com base na versão 6 do Amazon EMR.

```
cat >word-count.yaml <<EOF
apiVersion: "sparkoperator.k8s.io/v1beta2"
kind: SparkApplication
metadata:
  name: word-count
  namespace: spark-operator
spec:
  type: Java
  mode: cluster
  image: "895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.10.0:latest"
  imagePullPolicy: Always
  mainClass: org.apache.spark.examples.JavaWordCount
  mainApplicationFile: local:///usr/lib/spark/examples/jars/spark-examples.jar
  arguments:
    - s3://my-pod-bucket/poem.txt
  hadoopConf:
    # EMRFS filesystem
    fs.s3.customAWSCredentialsProvider:
com.amazonaws.auth.WebIdentityTokenCredentialsProvider
    fs.s3.impl: com.amazon.ws.emr.hadoop.fs.EmrFileSystem
    fs.AbstractFileSystem.s3.impl: org.apache.hadoop.fs.s3.EMRFSDelegate
    fs.s3.buffer.dir: /mnt/s3
    fs.s3.getObject.initialSocketTimeoutMilliseconds: "2000"

    mapreduce.fileoutputcommitter.algorithm.version.emr_internal_use_only.EmrFileSystem:
"2"
    mapreduce.fileoutputcommitter.cleanup-
failures.ignored.emr_internal_use_only.EmrFileSystem: "true"
  sparkConf:
    # Required for EMR Runtime
```

```

    spark.driver.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/
hadoop-aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/
share/aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/
security/conf:/usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-
glue-datacatalog-spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-
serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/
hadoop/extrajars/*
    spark.driver.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-lzo/
lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/native
    spark.executor.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/
hadoop-aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/
share/aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/
security/conf:/usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-
glue-datacatalog-spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-
serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/
hadoop/extrajars/*
    spark.executor.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-
lzo/lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/
native
    sparkVersion: "3.3.1"
    restartPolicy:
      type: Never
    driver:
      cores: 1
      coreLimit: "1200m"
      memory: "512m"
      labels:
        version: 3.3.1
      serviceAccount: my-spark-driver-sa
    executor:
      cores: 1
      instances: 1
      memory: "512m"
      labels:
        version: 3.3.1
EOF

```

Se estiver usando o operador Spark com uma versão 7, ajuste alguns dos valores de configuração:

```

cat >word-count.yaml <<EOF
apiVersion: "sparkoperator.k8s.io/v1beta2"
kind: SparkApplication

```

```

metadata:
  name: word-count
  namespace: spark-operator
spec:
  type: Java
  mode: cluster
  image: "895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-7.7.0:latest"
  imagePullPolicy: Always
  mainClass: org.apache.spark.examples.JavaWordCount
  mainApplicationFile: local:///usr/lib/spark/examples/jars/spark-examples.jar
  arguments:
    - s3://my-pod-bucket/poem.txt
  hadoopConf:
    # EMRFS filesystem
    fs.s3.customAWSCredentialsProvider:
com.amazonaws.auth.WebIdentityTokenCredentialsProvider
    fs.s3.impl: com.amazon.ws.emr.hadoop.fs.EmrFileSystem
    fs.AbstractFileSystem.s3.impl: org.apache.hadoop.fs.s3.EMRFSDelegate
    fs.s3.buffer.dir: /mnt/s3
    fs.s3.getObject.initialSocketTimeoutMilliseconds: "2000"

  mapreduce.fileoutputcommitter.algorithm.version.emr_internal_use_only.EmrFileSystem:
"2"
    mapreduce.fileoutputcommitter.cleanup-
failures.ignored.emr_internal_use_only.EmrFileSystem: "true"
  sparkConf:
    # Required for EMR Runtime
    spark.driver.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/hadoop-
aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/aws-java-sdk-v2/*:/usr/share/
aws/emr/emrfs/conf:/usr/share/aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/
*/usr/share/aws/emr/security/conf:/usr/share/aws/emr/security/lib/*:/usr/share/
aws/hmclient/lib/aws-glue-datacatalog-spark-client.jar:/usr/share/java/Hive-JSON-
Serde/hive-openx-serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-spark-
sdk.jar:/home/hadoop/extrajars/*
    spark.driver.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-lzo/
lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/native
    spark.executor.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/
hadoop-aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/aws-java-sdk-v2/*:/usr/
share/aws/emr/emrfs/conf:/usr/share/aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/
auxlib/*:/usr/share/aws/emr/security/conf:/usr/share/aws/emr/security/lib/*:/usr/
share/aws/hmclient/lib/aws-glue-datacatalog-spark-client.jar:/usr/share/java/Hive-
JSON-Serde/hive-openx-serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-
spark-sdk.jar:/home/hadoop/extrajars/*

```

```

    spark.executor.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-
lzo/lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/
native
    sparkVersion: "3.3.1"
    restartPolicy:
      type: Never
    driver:
      cores: 1
      coreLimit: "1200m"
      memory: "512m"
      labels:
        version: 3.3.1
      serviceAccount: my-spark-driver-sa
    executor:
      cores: 1
      instances: 1
      memory: "512m"
      labels:
        version: 3.3.1
EOF

```

2. Envie a aplicação do Spark.

```
kubectl apply -f word-count.yaml
```

O comando `kubectl` deve retornar a confirmação de que você criou com êxito um objeto `SparkApplication` chamado `word-count`.

```
sparkapplication.sparkoperator.k8s.io/word-count configured
```

3. Para verificar os eventos do objeto `SparkApplication`, execute o seguinte comando:

```
kubectl describe sparkapplication word-count -n spark-operator
```

O comando `kubectl` deve retornar a descrição da `SparkApplication` com os eventos:

```

Events:
  Type          Reason          Age          From
  Message
  ----          -
  -----

```

```

Normal    SparkApplicationSpecUpdateProcessed    3m2s (x2 over 17h)    spark-
operator  Successfully processed spec update for SparkApplication word-count
Warning   SparkApplicationPendingRerun           3m2s (x2 over 17h)    spark-
operator  SparkApplication word-count is pending rerun
Normal    SparkApplicationSubmitted               2m58s (x2 over 17h)    spark-
operator  SparkApplication word-count was submitted successfully
Normal    SparkDriverRunning                     2m56s (x2 over 17h)    spark-
operator  Driver word-count-driver is running
Normal    SparkExecutorPending                   2m50s                  spark-
operator  Executor [javawordcount-fdd1698807392c66-exec-1] is pending
Normal    SparkExecutorRunning                   2m48s                  spark-
operator  Executor [javawordcount-fdd1698807392c66-exec-1] is running
Normal    SparkDriverCompleted                   2m31s (x2 over 17h)    spark-
operator  Driver word-count-driver completed
Normal    SparkApplicationCompleted              2m31s (x2 over 17h)    spark-
operator  SparkApplication word-count completed
Normal    SparkExecutorCompleted                 2m31s (x2 over 2m31s)  spark-
operator  Executor [javawordcount-fdd1698807392c66-exec-1] completed

```

Agora, a aplicação está realizando a contagem das palavras em seu arquivo do S3. Para localizar a contagem de palavras, consulte os arquivos de log do seu driver:

```
kubectl logs pod/word-count-driver -n spark-operator
```

O comando `kubectl` deve retornar o conteúdo do arquivo de log com os resultados da sua aplicação de contagem de palavras.

```

INFO DAGScheduler: Job 0 finished: collect at JavaWordCount.java:53, took 5.146519 s
      Software: 1

```

Para obter mais informações sobre como enviar aplicativos ao Spark por meio do operador Spark, consulte [Usando um SparkApplication](#) na documentação do operador Kubernetes para Apache Spark (operador 8s) em `spark-on-k` GitHub

Execução de trabalhos do Spark com `spark-submit`

As versões 6.10.0 e superiores do Amazon EMR oferecem suporte ao `spark-submit` como uma ferramenta de linha de comando que você pode usar para enviar e executar aplicações do Spark para um cluster do Amazon EMR no EKS.

Note

O Amazon EMR calcula preços no Amazon EKS com base no consumo de memória e vCPU. Esse cálculo se aplica aos pods de drivers e de executores. Esse cálculo começa quando você baixa a imagem da aplicação do Amazon EMR até que o pod do Amazon EKS seja encerrado e arredondado para o segundo mais próximo.

Tópicos

- [Configuração do spark-submit para o Amazon EMR no EKS](#)
- [Conceitos básicos do spark-submit para o Amazon EMR no EKS](#)
- [Verificação dos requisitos de segurança da conta de serviço do driver do Spark para spark-submit](#)

Configuração do spark-submit para o Amazon EMR no EKS

Conclua as tarefas apresentadas a seguir para se preparar antes de executar uma aplicação com spark-submit no Amazon EMR no EKS. Se você já se inscreveu na Amazon Web Services (AWS) e usou o Amazon EKS, está com quase tudo pronto para usar o Amazon EMR no EKS. Se você já completou algum dos pré-requisitos, pode ignorá-los e passar para os próximos.

- [Instale ou atualize para a versão mais recente do AWS CLI](#) — Se você já instalou o AWS CLI, confirme se você tem a versão mais recente.
- [Instale o kubectl e o eksctl](#) : o eksctl é uma ferramenta de linha de comando que você usa para se comunicar com o Amazon EKS.
- [Comece a usar o Amazon EKS \(eksctl\)](#): siga as etapas para criar um cluster do Kubernetes com nós no Amazon EKS.
- [Selecione um URI de imagem base do Amazon EMR](#) (versão 6.10.0 ou superiores): o comando spark-submit é compatível com as versões 6.10.0 e superiores do Amazon EMR.
- Confirme se a conta de serviço do driver tem permissões apropriadas para criar e monitorar os pods de executores. Para obter mais informações, consulte [Verificação dos requisitos de segurança da conta de serviço do driver do Spark para spark-submit](#).
- Configure seu [perfil de credenciais locais da AWS](#).
- No console do Amazon EKS, escolha seu cluster do EKS e encontre o endpoint do cluster do EKS, localizado em Visão geral, Detalhes e, em seguida, Endpoint do servidor de API.

Conceitos básicos do spark-submit para o Amazon EMR no EKS

O Amazon EMR 6.10.0 e versões superiores oferecem suporte ao spark-submit para a execução de aplicações do Spark em um cluster do Amazon EKS. A seção a seguir mostra como enviar um comando para uma aplicação do Spark.

Execução de uma aplicação do Spark

Para executar a aplicação do Spark, siga estas etapas:

1. Antes de executar uma aplicação do Spark com o comando `spark-submit`, conclua as etapas em [Configuração do spark-submit para o Amazon EMR no EKS](#).
2. Execute um contêiner com uma imagem base do Amazon EMR no EKS. Consulte [How to select a base image URI](#) para obter mais informações.

```
kubectl run -it containerName --image=EMRonEKSImage --command -n namespace /bin/  
bash
```

3. Defina os valores para as seguintes variáveis de ambiente:

```
export SPARK_HOME=spark-home  
export MASTER_URL=k8s://Amazon EKS-cluster-endpoint
```

4. Agora, envie a aplicação do Spark com o seguinte comando:

```
$SPARK_HOME/bin/spark-submit \  
  --class org.apache.spark.examples.SparkPi \  
  --master $MASTER_URL \  
  --conf spark.kubernetes.container.image=895885662937.dkr.ecr.us-  
west-2.amazonaws.com/spark/emr-6.10.0:latest \  
  --conf spark.kubernetes.authenticate.driver.serviceAccountName=spark \  
  --deploy-mode cluster \  
  --conf spark.kubernetes.namespace=spark-operator \  
  local:///usr/lib/spark/examples/jars/spark-examples.jar 20
```

Para obter mais informações sobre o envio de aplicações para o Spark, consulte [Submitting applications](#) na documentação do Apache Spark.

 Important

O `spark-submit` oferece suporte somente para o modo de cluster como o mecanismo de envio.

Verificação dos requisitos de segurança da conta de serviço do driver do Spark para `spark-submit`

O pod do driver do Spark usa uma conta de serviço do Kubernetes para acessar o servidor da API do Kubernetes para criar e monitorar pods de executores. A conta de serviço do driver deve ter as permissões apropriadas para listar, criar, editar, aplicar patches e excluir pods em seu cluster. É possível verificar se consegue listar esses recursos ao executar o seguinte comando:

```
kubectl auth can-i list/create/edit/delete/patch pods
```

Verifique se você tem as permissões necessárias executando cada comando.

```
kubectl auth can-i list pods
kubectl auth can-i create pods
kubectl auth can-i edit pods
kubectl auth can-i delete pods
kubectl auth can-i patch pods
```

As seguintes regras se aplicam para este perfil de serviço:

```
rules:
- apiGroups:
  - ""
  resources:
  - pods
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - services
  verbs:
  - "*"
- apiGroups:
```

```
- ""
resources:
- configmaps
verbs:
- "*"
- apiGroups:
- ""
resources:
- persistentvolumeclaims
verbs:
- "*"

```

Configuração de perfis do IAM para contas de serviço (IRSA) do spark-submit

As seções a seguir explicam como configurar perfis do IAM para contas de serviço (IRSA) com a finalidade de autenticar e autorizar as contas de serviço do Kubernetes para que você possa executar aplicações do Spark armazenadas no Amazon S3.

Pré-requisitos

Antes de testar qualquer um dos exemplos desta documentação, certifique-se de ter cumprido os seguintes pré-requisitos:

- [Concluir a configuração do spark-submit](#)
- [Criar um bucket do S3](#) e [fazer upload](#) do JAR da aplicação do Spark

Configuração de uma conta de serviço do Kubernetes para assumir um perfil do IAM

As etapas a seguir abordam como configurar uma conta de serviço do Kubernetes para assumir um perfil do AWS Identity and Access Management (IAM). Depois de configurar os pods para usar a conta de serviço, eles poderão acessar qualquer um AWS service (Serviço da AWS) que a função tenha permissão para acessar.

1. Crie um arquivo de política para permitir acesso somente leitura ao objeto do Amazon S3 do qual você fez [upload](#):

```
cat >my-policy.json <<EOF
{
  "Version": "2012-10-17",
  "Statement": [
    {

```

```

        "Effect": "Allow",
        "Action": [
            "s3:GetObject",
            "s3:ListBucket"
        ],
        "Resource": [
            "arn:aws:s3:::<my-spark-jar-bucket>",
            "arn:aws:s3:::<my-spark-jar-bucket>/*"
        ]
    }
}
EOF

```

2. Crie a política do IAM.

```
aws iam create-policy --policy-name my-policy --policy-document file://my-policy.json
```

3. Crie um perfil do IAM e associe-o a uma conta de serviço do Kubernetes para o driver do Spark

```
eksctl create iamserviceaccount --name my-spark-driver-sa --namespace spark-operator \
--cluster my-cluster --role-name "my-role" \
--attach-policy-arn arn:aws:iam::111122223333:policy/my-policy --approve
```

4. Crie um arquivo YAML com as [permissões](#) obrigatórias para a conta de serviço do driver do Spark:

```
cat >spark-rbac.yaml <<EOF
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  namespace: default
  name: emr-containers-role-spark
rules:
- apiGroups:
  - ""
  resources:
  - pods
  verbs:
  - "*"
- apiGroups:
```

```
- ""
resources:
- services
verbs:
- "*"
- apiGroups:
  - ""
  resources:
  - configmaps
  verbs:
  - "*"
- apiGroups:
  - ""
  resources:
  - persistentvolumeclaims
  verbs:
  - "*"
---
apiVersion: rbac.authorization.k8s.io/v1
kind: RoleBinding
metadata:
  name: spark-role-binding
  namespace: default
roleRef:
  apiGroup: rbac.authorization.k8s.io
  kind: Role
  name: emr-containers-role-spark
subjects:
- kind: ServiceAccount
  name: emr-containers-sa-spark
  namespace: default
EOF
```

5. Aplique as configurações de associação de perfil do cluster.

```
kubectl apply -f spark-rbac.yaml
```

6. O comando `kubectl` deve retornar a confirmação da conta criada.

```
serviceaccount/emr-containers-sa-spark created
clusterrolebinding.rbac.authorization.k8s.io/emr-containers-role-spark configured
```

Execução da aplicação do Spark

O Amazon EMR 6.10.0 e versões superiores oferecem suporte ao spark-submit para a execução de aplicações do Spark em um cluster do Amazon EKS. Para executar a aplicação do Spark, siga estas etapas:

1. Certifique-se de ter concluído as etapas em [Setting up spark-submit for Amazon EMR on EKS](#).
2. Defina os valores para as seguintes variáveis de ambiente:

```
export SPARK_HOME=spark-home
export MASTER_URL=k8s://Amazon EKS-cluster-endpoint
```

3. Agora, envie a aplicação do Spark com o seguinte comando:

```
$SPARK_HOME/bin/spark-submit \
  --class org.apache.spark.examples.SparkPi \
  --master $MASTER_URL \
  --conf spark.kubernetes.container.image=895885662937.dkr.ecr.us-
west-2.amazonaws.com/spark/emr-6.15.0:latest \
  --conf spark.kubernetes.authenticate.driver.serviceAccountName=emr-containers-sa-
spark \
  --deploy-mode cluster \
  --conf spark.kubernetes.namespace=default \
  --conf "spark.driver.extraClassPath=/usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/
hadoop-aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/
share/aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/
security/conf:/usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-
glue-datacatalog-spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-
serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/
hadoop/extrajars/*" \
  --conf "spark.driver.extraLibraryPath=/usr/lib/hadoop/lib/native:/usr/lib/hadoop-
lzo/lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/
native" \
  --conf "spark.executor.extraClassPath=/usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/
hadoop-aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/
share/aws/emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/
security/conf:/usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-
glue-datacatalog-spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-
serde.jar:/usr/share/aws/sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/
hadoop/extrajars/*" \
  --conf "spark.executor.extraLibraryPath=/usr/lib/hadoop/lib/native:/usr/lib/
hadoop-lzo/lib/native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/
lib/native" \
```

```
--conf
spark.hadoop.fs.s3.customAWSCredentialsProvider=com.amazonaws.auth.WebIdentityTokenCredent
\
--conf spark.hadoop.fs.s3.impl=com.amazon.ws.emr.hadoop.fs.EmrFileSystem \
--conf
spark.hadoop.fs.AbstractFileSystem.s3.impl=org.apache.hadoop.fs.s3.EMRFSDelegate \
--conf spark.hadoop.fs.s3.buffer.dir=/mnt/s3 \
--conf spark.hadoop.fs.s3.getObject.initialSocketTimeoutMilliseconds="2000" \
--conf
spark.hadoop.mapreduce.fileoutputcommitter.algorithm.version.emr_internal_use_only.EmrFile
\
--conf spark.hadoop.mapreduce.fileoutputcommitter.cleanup-
failures.ignored.emr_internal_use_only.EmrFileSystem="true" \
s3://my-pod-bucket/spark-examples.jar 20
```

4. Depois que o driver do Spark terminar o trabalho do Spark, você verá uma linha de log no final do envio indicando que o trabalho do Spark foi concluído.

```
23/11/24 17:02:14 INFO LoggingPodStatusWatcherImpl: Application
org.apache.spark.examples.SparkPi with submission ID default:org-apache-spark-
examples-sparkpi-4980808c03ff3115-driver finished
23/11/24 17:02:14 INFO ShutdownHookManager: Shutdown hook called
```

Limpeza

Quando terminar de executar as aplicações, você poderá realizar a limpeza com o comando a seguir.

```
kubectl delete -f spark-rbac.yaml
```

Uso do Apache Livy com o Amazon EMR no EKS

Com as versões 7.1.0 e posteriores do Amazon EMR, é possível usar o Apache Livy para enviar trabalhos no Amazon EMR no EKS. Usando o Apache Livy, você pode configurar seu próprio endpoint REST do Apache Livy e usá-lo para implantar e gerenciar aplicações do Spark em clusters do Amazon EKS. Após instalar o Livy no cluster do Amazon EKS, você poderá usar o endpoint do Livy para enviar aplicações do Spark ao servidor do Livy. O servidor gerencia o ciclo de vida das aplicações do Spark.

 Note

O Amazon EMR calcula preços no Amazon EKS com base no consumo de memória e vCPU. Esse cálculo se aplica aos pods de drivers e de executores. Esse cálculo começa quando você baixa a imagem da aplicação do Amazon EMR até que o pod do Amazon EKS seja encerrado e arredondado para o segundo mais próximo.

Tópicos

- [Configuração do Apache Livy para o Amazon EMR no EKS](#)
- [Conceitos básicos do Apache Livy para Amazon EMR no EKS](#)
- [Execução de uma aplicação do Spark com o Apache Livy para o Amazon EMR no EKS](#)
- [Desinstalação do Apache Livy com o Amazon EMR no EKS](#)
- [Segurança para o Apache Livy com o Amazon EMR no EKS](#)
- [Propriedades de instalação do Apache Livy em versões do Amazon EMR no EKS](#)
- [Solução de erros comuns de formato de variável de ambiente](#)

Configuração do Apache Livy para o Amazon EMR no EKS

Antes de instalar o Apache Livy no cluster do Amazon EKS, é necessário instalar e configurar um conjunto de ferramentas de pré-requisitos. Isso inclui o AWS CLI, que é uma ferramenta de linha de comando fundamental para trabalhar com AWS recursos, ferramentas de linha de comando para trabalhar com o Amazon EKS e um controlador usado nesse caso de uso para disponibilizar seu aplicativo de cluster na Internet e rotear o tráfego de rede.

- [Instale ou atualize para a versão mais recente do AWS CLI](#) — Se você já instalou o AWS CLI, confirme se você tem a versão mais recente.
- [Instale o kubectl e o eksctl](#) : o eksctl é uma ferramenta de linha de comando que você usa para se comunicar com o Amazon EKS.
- [Instale o Helm](#): o gerenciador de pacotes Helm para o Kubernetes ajuda a instalar e gerenciar aplicações em seu cluster do Kubernetes.
- [Comece a usar o Amazon EKS \(eksctl\)](#): siga as etapas para criar um cluster do Kubernetes com nós no Amazon EKS.
- [Selecione um rótulo de versão do Amazon EMR](#): o Apache Livy é compatível com as versões 7.1.0 e superiores do Amazon EMR.

- [Instale o controlador ALB — o controlador](#) ALB gerencia o AWS Elastic Load Balancing para clusters Kubernetes. Ele cria um AWS Network Load Balancer (NLB) quando você cria um Kubernetes Ingress enquanto configura o Apache Livy.

Conceitos básicos do Apache Livy para Amazon EMR no EKS

Conclua as etapas a seguir para instalar o Apache Livy. Eles incluem a configuração do gerenciador de pacotes, a criação de um namespace para executar workloads do Spark, a instalação do Livy, a configuração do balanceamento de carga e as etapas de verificação. Você precisa concluir essas etapas para executar um trabalho em lotes com o Spark.

1. Se ainda não tiver feito isso, configure o [Apache Livy para o Amazon EMR no EKS](#).
2. Autentique seu cliente Helm no registro do Amazon ECR. Você pode encontrar o ECR-registry-account valor correspondente para suas [contas Região da AWS de registro do Amazon ECR por região](#).

```
aws ecr get-login-password --region <AWS_REGION> | helm registry login \
--username AWS \
--password-stdin <ECR-registry-account>.dkr.ecr.<region-id>.amazonaws.com
```

3. A configuração do Livy cria uma conta de serviço para o servidor do Livy e outra conta para a aplicação do Spark. Para configurar o IRSA nas contas de serviço, consulte [Setting up access permissions with IAM roles for service accounts \(IRSA\)](#).
4. Crie um namespace para executar as workloads do Spark.

```
kubectl create ns <spark-ns>
```

5. Use o comando a seguir para instalar o Livy.

Esse endpoint do Livy só está disponível internamente para a VPC no cluster do EKS. Para habilitar o acesso além da VPC, defina `--set loadbalancer.internal=false` no comando de instalação do Helm.

Note

Por padrão, o SSL não está habilitado nesse endpoint do Livy, e o endpoint só é visível dentro da VPC do cluster do EKS. Se você definir `loadbalancer.internal=false` e `ssl.enabled=false`, estará expondo um endpoint inseguro fora da sua VPC. Para

configurar um endpoint seguro do Livy, consulte [Configuring a secure Apache Livy endpoint with TLS/SSL](#).

```
helm install livy-demo \
  oci://895885662937.dkr.ecr.region-id.amazonaws.com/livy \
  --version 7.12.0 \
  --namespace livy-ns \
  --set image=ECR-registry-account.dkr.ecr.region-id.amazonaws.com/livy/
emr-7.12.0:latest \
  --set sparkNamespace=<spark-ns> \
  --create-namespace
```

Você verá a saída a seguir.

```
NAME: livy-demo
LAST DEPLOYED: Mon Mar 18 09:23:23 2024
NAMESPACE: livy-ns
STATUS: deployed
REVISION: 1
TEST SUITE: None
NOTES:
The Livy server has been installed.
Check installation status:
1. Check Livy Server pod is running
  kubectl --namespace livy-ns get pods -l "app.kubernetes.io/instance=livy-demo"
2. Verify created NLB is in Active state and it's target groups are healthy (if
  loadbalancer.enabled is true)

Access LIVY APIs:
  # Ensure your NLB is active and healthy
  # Get the Livy endpoint using command:
  LIVY_ENDPOINT=$(kubectl get svc -n livy-ns -l app.kubernetes.io/
instance=livy-demo,emr-containers.amazonaws.com/type=loadbalancer -o
jsonpath='{.items[0].status.loadBalancer.ingress[0].hostname}' | awk '{printf
"%s:8998\n", $0}')
  # Access Livy APIs using http://$LIVY_ENDPOINT or https://$LIVY_ENDPOINT (if
SSL is enabled)
  # Note: While uninstalling Livy, makes sure the ingress and NLB are deleted
after running the helm command to avoid dangling resources
```

Os nomes padrão da conta de serviço para o servidor do Livy e a sessão do Spark são `emr-containers-sa-livy` e `emr-containers-sa-spark-livy`. Para usar nomes personalizados, utilize os parâmetros `serviceAccounts.name` e `sparkServiceAccount.name`.

```
--set serviceAccounts.name=my-service-account-for-livy
--set sparkServiceAccount.name=my-service-account-for-spark
```

6. Verifique se você instalou o chart do Helm.

```
helm list -n livy-ns -o yaml
```

O comando `helm list` deve retornar as informações sobre o novo chart do Helm.

```
app_version: 0.7.1-incubating
chart: livy-emr-7.12.0
name: livy-demo
namespace: livy-ns
revision: "1"
status: deployed
updated: 2024-02-08 22:39:53.539243 -0800 PST
```

7. Verifique se o Network Load Balancer está ativo.

```
LIVY_NAMESPACE=<livy-ns>
LIVY_APP_NAME=<livy-app-name>
AWS_REGION=<AWS_REGION>

# Get the NLB Endpoint URL
NLB_ENDPOINT=$(kubectl --namespace $LIVY_NAMESPACE get svc -l "app.kubernetes.io/instance=$LIVY_APP_NAME,emr-containers.amazonaws.com/type=loadbalancer" -o jsonpath='{.items[0].status.loadBalancer.ingress[0].hostname}')

# Get all the load balancers in the account's region
ELB_LIST=$(aws elbv2 describe-load-balancers --region $AWS_REGION)

# Get the status of the NLB that matching the endpoint from the Kubernetes service
NLB_STATUS=$(echo $ELB_LIST | grep -A 8 "\"DNSName\": \"$NLB_ENDPOINT\"" | awk '/Code/{print $2}/' | tr -d '",'')
echo $NLB_STATUS
```

8. Agora, verifique se o grupo de destino no Network Load Balancer está íntegro.

```
LIVY_NAMESPACE=<livy-ns>
LIVY_APP_NAME=<livy-app-name>
AWS_REGION=<AWS_REGION>

# Get the NLB endpoint
NLB_ENDPOINT=$(kubectl --namespace $LIVY_NAMESPACE get svc -l "app.kubernetes.io/instance=$LIVY_APP_NAME,emr-containers.amazonaws.com/type=loadbalancer" -o jsonpath='{.items[0].status.loadBalancer.ingress[0].hostname}')

# Get all the load balancers in the account's region
ELB_LIST=$(aws elbv2 describe-load-balancers --region $AWS_REGION)

# Get the NLB ARN from the NLB endpoint
NLB_ARN=$(echo $ELB_LIST | grep -B 1 "\"DNSName\": \"$NLB_ENDPOINT\"" | awk '/"LoadBalancerArn":/,/,/' | awk '/:/{print $2}' | tr -d \",, )

# Get the target group from the NLB. Livy setup only deploys 1 target group
TARGET_GROUP_ARN=$(aws elbv2 describe-target-groups --load-balancer-arn $NLB_ARN --region $AWS_REGION | awk '/"TargetGroupArn":/,/,/' | awk '/:/{print $2}' | tr -d \",, )

# Get health of target group
aws elbv2 describe-target-health --target-group-arn $TARGET_GROUP_ARN
```

Este é um exemplo de saída que mostra o status do grupo de destino:

```
{
  "TargetHealthDescriptions": [
    {
      "Target": {
        "Id": "<target IP>",
        "Port": 8998,
        "AvailabilityZone": "us-west-2d"
      },
      "HealthCheckPort": "8998",
      "TargetHealth": {
        "State": "healthy"
      }
    }
  ]
}
```

```
}
```

Quando o status do NLB se tornar `active` e o grupo de destino `healthy`, você poderá continuar. Pode demorar alguns minutos.

9. Recupere o endpoint do Livy da instalação do Helm. Se o endpoint do Livy é seguro ou não, depende de você ter habilitado o SSL.

```
LIVY_NAMESPACE=<livy-ns>
LIVY_APP_NAME=livy-app-name
LIVY_ENDPOINT=$(kubectl get svc -n livy-ns -l app.kubernetes.io/
instance=livy-app-name,emr-containers.amazonaws.com/type=loadbalancer -o
jsonpath='{.items[0].status.loadBalancer.ingress[0].hostname}' | awk '{printf
"%s:8998\n", $0}')
echo "$LIVY_ENDPOINT"
```

10. Recuperação da conta de serviço do Spark na instalação do Helm

```
SPARK_NAMESPACE=spark-ns
LIVY_APP_NAME=<livy-app-name>
SPARK_SERVICE_ACCOUNT=$(kubectl --namespace $SPARK_NAMESPACE
get sa -l "app.kubernetes.io/instance=$LIVY_APP_NAME" -o
jsonpath='{.items[0].metadata.name}')
echo "$SPARK_SERVICE_ACCOUNT"
```

Você deverá ver algo semelhante ao resultado a seguir:

```
emr-containers-sa-spark-livy
```

11. Se você configurar `internalALB=true` para habilitar o acesso de fora da sua VPC, crie uma EC2 instância da Amazon e certifique-se de que o Network Load Balancer permita tráfego de rede proveniente da instância. EC2 Você deve fazer isso para que a instância tenha acesso ao endpoint do Livy. Para obter mais informações sobre como expor com segurança o endpoint fora da VPC, consulte [Setting up with a secure Apache Livy endpoint with TLS/SSL](#).
12. A instalação do Livy cria a conta de serviço `emr-containers-sa-spark` para executar as aplicações do Spark. Se seu aplicativo Spark usa AWS recursos como o S3 ou chama operações de AWS API ou CLI, você deve vincular uma função do IAM com as permissões necessárias à sua conta de serviço do Spark. Para obter mais informações, consulte [Setting up access permissions with IAM roles for service accounts \(IRSA\)](#).

O Apache Livy oferece suporte a configurações adicionais que você pode usar ao instalar o Livy. Para obter mais informações, consulte [Propriedades de instalação do Apache Livy no Amazon EMR nas versões do EKS](#).

Execução de uma aplicação do Spark com o Apache Livy para o Amazon EMR no EKS

Antes de executar uma aplicação do Spark com o Apache Livy, certifique-se de ter concluído as etapas em [Configuração do Apache Livy para o Amazon EMR no EKS](#) e [Getting started with Apache Livy for Amazon EMR on EKS](#).

Você pode usar o Apache Livy para executar dois tipos de aplicações:

- Sessões em lote: um tipo de workload do Livy para enviar trabalhos em lote do Spark.
- Sessões interativas: um tipo de workload do Livy que fornece uma interface programática e visual para executar consultas do Spark.

Note

Pods de drivers e de executores de sessões diferentes podem se comunicar entre si. Os namespaces não garantem nenhuma segurança entre os pods. O Kubernetes não aceita permissões seletivas em um subconjunto de pods dentro de um determinado namespace.

Execução de sessões em lote

Para enviar um trabalho em lote, use o comando a seguir.

```
curl -s -k -H 'Content-Type: application/json' -X POST \
  -d '{
    "name": "my-session",
    "file": "entryPoint_location (S3 or local)",
    "args": ["argument1", "argument2", ...],
    "conf": {
      "spark.kubernetes.namespace": "<spark-namespace>",
      "spark.kubernetes.container.image": "public.ecr.aws/emr-on-eks/spark/
emr-7.12.0:latest",
      "spark.kubernetes.authenticate.driver.serviceAccountName": "<spark-
service-account>"
    }
  }
```

```
    }
  }' <livy-endpoint>/batches
```

Para monitorar seu trabalho em lote, use o comando a seguir.

```
curl -s -k -H 'Content-Type: application/json' -X GET <livy-endpoint>/batches/my-session
```

Execução de sessões interativas

Para executar sessões interativas com o Apache Livy, consulte as etapas a seguir.

1. Certifique-se de ter acesso a um notebook Jupyter auto-hospedado ou gerenciado, como um notebook SageMaker AI Jupyter. O caderno Jupyter deve ter o [sparkmagic](#) instalado.
2. Crie um bucket para a configuração `spark.kubernetes.file.upload.path` do Spark. Certifique-se de que a conta de serviço do Spark tenha acesso de leitura e gravação ao bucket. Para obter mais detalhes sobre como configurar a conta de serviço do Spark, consulte [Setting up access permissions with IAM roles for service accounts \(IRSA\)](#)
3. Faça upload do `sparkmagic` no caderno Jupyter com o comando `%load_ext sparkmagic.magics`.
4. Execute o comando `%manage_spark` para configurar o endpoint do Livy com o caderno Jupyter. Selecione a guia Adicionar endpoints, escolha o tipo de autenticação configurado, adicione o endpoint do Livy ao caderno e escolha Adicionar endpoint.
5. Execute `%manage_spark` novamente para criar o contexto do Spark e vá para Criar sessão. Escolha o endpoint do Livy, especifique um nome de sessão exclusivo, escolha um idioma e adicione as propriedades a seguir.

```
{
  "conf": {
    "spark.kubernetes.namespace": "livy-namespace",
    "spark.kubernetes.container.image": "public.ecr.aws/emr-on-eks/spark/emr-7.12.0:latest",
    "spark.kubernetes.authenticate.driver.serviceAccountName": "<spark-service-account>",
    "spark.kubernetes.file.upload.path": "<URI_TO_S3_LOCATION>"
  }
}
```

6. Envie a aplicação e espere que ela crie o contexto do Spark.

7. Para monitorar o status da sessão interativa, execute o comando a seguir.

```
curl -s -k -H 'Content-Type: application/json' -X GET livy-endpoint/sessions/my-interactive-session
```

Monitoramento de aplicações do Spark

Para monitorar o progresso das aplicações do Spark com a interface de usuário do Livy, use o link `http://<livy-endpoint>/ui`.

Desinstalação do Apache Livy com o Amazon EMR no EKS

Siga estas etapas para desinstalar o Apache Livy.

1. Exclua a configuração do Livy usando os nomes do namespace e o nome da aplicação. Neste exemplo, o nome da aplicação é `livy-demo` e o namespace é `livy-ns`.

```
helm uninstall livy-demo -n livy-ns
```

2. Ao desinstalar, o Amazon EMR no EKS exclui o serviço Kubernetes no Livy, os balanceadores de carga e os AWS grupos-alvo que você criou durante a instalação. A exclusão de recursos pode levar alguns minutos. Certifique-se de que os recursos sejam excluídos antes de instalar o Livy no namespace novamente.
3. Exclua o namespace do Spark.

```
kubectl delete namespace spark-ns
```

Segurança para o Apache Livy com o Amazon EMR no EKS

Consulte os tópicos a seguir para saber mais sobre como configurar a segurança do Apache Livy com o Amazon EMR no EKS. Essas opções incluem o uso da segurança da camada de transporte, o controle de acesso baseado em perfis, que é o acesso baseado no perfil de uma pessoa dentro de uma organização, e o uso de perfis do IAM, que fornecem acesso aos recursos de acordo com as permissões concedidas.

Tópicos

- [Configuração de um endpoint do Apache Livy seguro com TLS/SSL](#)

- [Configuração das permissões de aplicações do Apache Livy e Spark com o controle de acesso por perfil \(RBAC\)](#)
- [Configuração de permissões de acesso com perfis do IAM para contas de serviço \(IRSA\)](#)

Configuração de um endpoint do Apache Livy seguro com TLS/SSL

Consulte as seções a seguir para saber mais sobre como configurar o Apache Livy para Amazon EMR no EKS com criptografia end-to-end TLS e SSL.

Configuração da criptografia TLS e SSL

Para configurar a criptografia SSL no endpoint do Apache Livy, siga estas etapas.

- [Instale o driver CSI do Secrets Store e o AWS Secrets and Configuration Provider \(ASCP\)](#) — o driver CSI e o ASCP do Secrets Store armazenam com segurança os certificados e senhas JKS do Livy que o pod do servidor Livy precisa para habilitar o SSL. Você também pode instalar apenas o driver CSI do Secrets Store e usar qualquer outro provedor de segredos compatível.
- [Crie um certificado do ACM](#): esse certificado é necessário para proteger a conexão entre o cliente e o endpoint do ALB.
- Configure um certificado JKS, uma senha de chave e uma senha de armazenamento de chaves para AWS Secrets Manager — necessários para proteger a conexão entre o endpoint ALB e o servidor Livy.
- Adicione permissões à conta de serviço Livy para recuperar segredos AWS Secrets Manager — o servidor Livy precisa dessas permissões para recuperar segredos do ASCP e adicionar as configurações Livy para proteger o servidor Livy. Para adicionar permissões do IAM a uma conta de serviço, consulte [Setting up access permissions with IAM roles for service accounts \(IRSA\)](#).

Configurando um certificado JKS com uma chave e uma senha do keystore para AWS Secrets Manager

Siga estas etapas para configurar um certificado do JKS com uma chave e uma senha do keystore.

1. Gere um arquivo do keystore para o servidor do Livy.

```
keytool -genkey -alias <host> -keyalg RSA -keysize 2048 -dname  
CN=<host>,OU=hw,O=hw,L=<your_location>,ST=<state>,C=<country> -  
keypass <keyPassword> -keystore <keystore_file> -storepass <storePassword> --  
validity 3650
```

2. Crie um certificado.

```
keytool -export -alias <host> -keystore mykeystore.jks -rfc -
file mycertificate.cert -storepass <storePassword>
```

3. Crie um arquivo da truststore.

```
keytool -import -noprompt -alias <host>-file <cert_file> -
keystore <truststore_file> -storepass <truststorePassword>
```

4. Salve o certificado JKS em AWS Secrets Manager. Substitua livy-jks-secret pelo segredo e fileb://mykeystore.jks pelo caminho para o certificado do JKS do keystore.

```
aws secretsmanager create-secret \
--name livy-jks-secret \
--description "My Livy keystore JKS secret" \
--secret-binary fileb://mykeystore.jks
```

5. Salve o a senha do keystore e da chave no Secrets Manager. Use seus próprios parâmetros.

```
aws secretsmanager create-secret \
--name livy-jks-secret \
--description "My Livy key and keystore password secret" \
--secret-string "{\"keyPassword\":\"<test-key-password>\",\"keyStorePassword\":
\"<test-key-store-password>\"}"
```

6. Crie um namespace de servidor do Livy com o comando a seguir.

```
kubectl create ns <livy-ns>
```

7. Crie o objeto ServiceProviderClass para o servidor do Livy que tem o certificado do JKS e as senhas.

```
cat >livy-secret-provider-class.yaml << EOF
apiVersion: secrets-store.csi.x-k8s.io/v1
kind: SecretProviderClass
metadata:
  name: aws-secrets
spec:
  provider: aws
  parameters:
    objects: |
```

```
- objectName: "livy-jks-secret"
  objectType: "secretsmanager"
- objectName: "livy-passwords"
  objectType: "secretsmanager"
```

EOF

```
kubectl apply -f livy-secret-provider-class.yaml -n <livy-ns>
```

Conceitos básicos do Apache Livy habilitado por SSL

Depois de habilitar o SSL no servidor do Livy, você deve configurar a `serviceAccount` para ter acesso aos segredos de `keyStore` e `keyPasswords` no AWS Secrets Manager.

1. Crie o namespace do servidor do Livy.

```
kubectl create namespace <livy-ns>
```

2. Configure a conta de serviço do Livy para ter acesso aos segredos no Secrets Manager. Para obter mais informações sobre como configurar o IRSA, consulte [Setting up IRSA while installing Apache Livy](#).

```
aws ecr get-login-password --region region-id | helm registry login \
--username AWS \
--password-stdin ECR-registry-account.dkr.ecr.region-id.amazonaws.com
```

3. Instale o Livy. Para o parâmetro de versão do chart do Helm, use o rótulo de lançamento do Amazon EMR, como 7.1.0. Você também deve substituir o ID da conta de registro e o ID da região do Amazon ECR pelos seus IDs. Você pode encontrar o ECR-registry-account valor correspondente para suas [contas Região da AWS de registro do Amazon ECR por região](#).

```
helm install <livy-app-name> \
oci://895885662937.dkr.ecr.region-id.amazonaws.com/livy \
--version 7.12.0 \
--namespace <livy-namespace-name> \
--set image=<ECR-registry-account.dkr.ecr>.<region>.amazonaws.com/livy/
emr-7.12.0:latest \
--set sparkNamespace=<spark-namespace> \
--set ssl.enabled=true
--set ssl.CertificateArn=livy-acm-certificate-arn
--set ssl.secretProviderClassName=aws-secrets
--set ssl.keyStoreObjectName=livy-jks-secret
```

```
--set ssl.keyPasswordsObjectName=livy-passwords
--create-namespace
```

4. Continue a partir da etapa 5 em [Installing Apache Livy on Amazon EMR on EKS](#).

Configuração das permissões de aplicações do Apache Livy e Spark com o controle de acesso por perfil (RBAC)

Para implantar o Livy, o Amazon EMR no EKS cria uma conta e perfil de serviço do servidor e uma conta e perfil de serviço do Spark. Esses perfis devem ter as permissões do RBAC necessárias para concluir a configuração e executar as aplicações do Spark.

Permissões do RBAC para o perfil e a conta de serviço do servidor

O Amazon EMR no EKS cria a conta e o perfil de serviço do servidor do Livy para gerenciar sessões do Livy para trabalhos do Spark e rotear o tráfego entre a entrada e outros recursos.

O nome padrão para esta conta de serviço é `emr-containers-sa-livy`. É necessário ter as permissões a seguir.

```
rules:
- apiGroups:
  - ""
  resources:
  - "namespaces"
  verbs:
  - "get"
- apiGroups:
  - ""
  resources:
  - "serviceaccounts"
  - "services"
  - "configmaps"
  - "events"
  - "pods"
  - "pods/log"
  verbs:
  - "get"
  - "list"
  - "watch"
  - "describe"
  - "create"
```

```
"edit"
"delete"
"deletecollection"
"annotate"
"patch"
"label"
- apiGroups:
  - ""
  resources:
  - "secrets"
  verbs:
  - "create"
    "patch"
    "delete"
    "watch"
- apiGroups:
  - ""
  resources:
  - "persistentvolumeclaims"
  verbs:
  - "get"
    "list"
    "watch"
    "describe"
    "create"
    "edit"
    "delete"
    "annotate"
    "patch"
    "label"
```

Permissões do RBAC para a conta e o perfil de serviço do Spark

Um pod do driver do Spark precisa de uma conta de serviço do Kubernetes no mesmo namespace que o pod. Essa conta de serviço precisa de permissões para gerenciar os pods do executor e todos os recursos exigidos pelo pod do driver. A menos que a conta de serviço padrão no namespace tenha as permissões necessárias, o driver falhará e será encerrado. As permissões RBAC a seguir são necessárias.

```
rules:
- apiGroups:
  - ""
  "batch"
```

```
"extensions"  
"apps"  
resources:  
- "configmaps"  
  "serviceaccounts"  
  "events"  
  "pods"  
  "pods/exec"  
  "pods/log"  
  "pods/portforward"  
  "secrets"  
  "services"  
  "persistentvolumeclaims"  
  "statefulsets"  
verbs:  
- "create"  
  "delete"  
  "get"  
  "list"  
  "patch"  
  "update"  
  "watch"  
  "describe"  
  "edit"  
  "deletecollection"  
  "patch"  
  "label"
```

Configuração de permissões de acesso com perfis do IAM para contas de serviço (IRSA)

Por padrão, o driver e os executores do servidor Livy e do aplicativo Spark não têm acesso aos recursos. A conta de serviço do servidor e a conta de serviço do Spark controlam o acesso aos recursos do servidor Livy e dos pods do aplicativo Spark. Para conceder acesso, você precisa mapear as contas de serviço com uma função do IAM que tenha as AWS permissões necessárias.

Você pode configurar o mapeamento do IRSA antes de instalar o Apache Livy, durante a instalação ou depois de concluir a instalação.

Configuração do IRSA durante a instalação do Apache Livy (para conta de serviço do servidor)

Note

Esse mapeamento é compatível somente com a conta de serviço do servidor.

1. Verifique se você concluiu a [configuração do Apache Livy para Amazon EMR no EKS](#) e está no meio da [instalação do Apache Livy com o Amazon EMR no EKS](#).
2. Crie um namespace do Kubernetes para o servidor do Livy. Neste exemplo, o nome do namespace é `livy-ns`.
3. Crie uma política do IAM que inclua as permissões Serviços da AWS para as quais você deseja que seus pods acessem. O exemplo a seguir cria uma política do IAM para obter recursos do Amazon S3 para o ponto de entrada do Spark.

```
cat >my-policy.json <<EOF{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "s3:GetObject",
      "Resource": "arn:aws:s3:::my-spark-entriypoint-bucket"
    }
  ]
}
EOF

aws iam create-policy --policy-name my-policy --policy-document file://my-policy.json
```

4. Use o comando a seguir para definir seu Conta da AWS ID como uma variável.

```
account_id=$(aws sts get-caller-identity --query "Account" --output text)
```

5. Defina o provedor de identidade OpenID Connect (OIDC) do cluster como uma variável de ambiente.

```
oidc_provider=$(aws eks describe-cluster --name my-cluster --region $AWS_REGION --
query "cluster.identity.oidc.issuer" --output text | sed -e "s/^https://\\//")
```

6. Defina variáveis para o namespace e o nome da conta de serviço. Use seus próprios valores.

```
export namespace=default
export service_account=my-service-account
```

7. Crie um arquivo de política de confiança com o comando a seguir. Se quiser conceder acesso ao perfil a todas as contas de serviço em um namespace, copie o comando a seguir e substitua `StringEquals` por `StringLike` e `$service_account` por `*`.

```
cat >trust-relationship.json <<EOF
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Federated": "arn:aws:iam::$account_id:oidc-provider/$oidc_provider"
      },
      "Action": "sts:AssumeRoleWithWebIdentity",
      "Condition": {
        "StringEquals": {
          "$oidc_provider:aud": "sts.amazonaws.com",
          "$oidc_provider:sub": "system:serviceaccount:$namespace:$service_account"
        }
      }
    }
  ]
}
EOF
```

8. Crie a função.

```
aws iam create-role --role-name my-role --assume-role-policy-document file://trust-relationship.json --description "my-role-description"
```

9. Use o comando de instalação do Helm a seguir para configurar o `serviceAccount.executionRoleArn` para mapear o IRSA. Confira a seguir um exemplo do comando de instalação do Helm. Você pode encontrar o ECR-registry-account valor correspondente para suas [contas Região da AWS de registro do Amazon ECR por região](#).

```
helm install livy-demo \
  oci://895885662937.dkr.ecr.us-west-2.amazonaws.com/livy \
```



```
--version 7.12.0 \
--namespace livy-ns \
--set image=ECR-registry-account.dkr.ecr.region-id.amazonaws.com/livy/
emr-7.12.0:latest \
--set sparkNamespace=spark-ns \
--set serviceAccount.executionRoleArn=arn:aws:iam::123456789012:role/my-role
```

Mapeamento do IRSA para uma conta de serviço do Spark

Antes de mapear o IRSA para uma conta de serviço do Spark, conclua os seguintes itens:

- Verifique se você concluiu a [configuração do Apache Livy para Amazon EMR no EKS](#) e está no meio da [instalação do Apache Livy com o Amazon EMR no EKS](#).
- Você deve ter um provedor OpenID Connect (OIDC) existente do IAM para o cluster. Para verificar se você já tem um provedor ou saber como criar um, consulte [Criar um provedor OIDC do IAM para o cluster](#).
- Certifique-se de ter instalado a versão 0.171.0 ou posterior da CLI do eksctl ou o AWS CloudShell. Para instalar ou atualizar o eksctl, consulte [Instalação](#) na documentação do eksctl.

Siga estas etapas para mapear o IRSA à conta de serviço do Spark:

1. Use o comando a seguir para obter a conta de serviço do Spark.

```
SPARK_NAMESPACE=<spark-ns>
LIVY_APP_NAME=<livy-app-name>
kubectl --namespace $SPARK_NAMESPACE describe sa -l "app.kubernetes.io/instance=
$LIVY_APP_NAME" | awk '/^Name:/ {print $2}'
```

2. Defina variáveis para o namespace e o nome da conta de serviço.

```
export namespace=default
export service_account=my-service-account
```

3. Use o comando a seguir para criar um arquivo de política de confiança para o perfil do IAM. O exemplo a seguir dá permissão a todas as contas de serviço dentro do namespace para usar o perfil. Para fazer isso, substitua `StringEquals` por `StringLike` e `$service_account` por `*`.

```
cat >trust-relationship.json <<EOF
```

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Principal": {
        "Federated": "arn:aws:iam::${account_id}:oidc-provider/${oidc_provider}"
      },
      "Action": "sts:AssumeRoleWithWebIdentity",
      "Condition": {
        "StringEquals": {
          "${oidc_provider}:aud": "sts.amazonaws.com",
          "${oidc_provider}:sub": "system:serviceaccount:${namespace}:${service_account}"
        }
      }
    }
  ]
}
EOF
```

4. Crie a função.

```
aws iam create-role --role-name my-role --assume-role-policy-document file://trust-relationship.json --description "my-role-description"
```

5. Mapeie o servidor ou a conta de serviço do Spark com o comando eksctl a seguir. Use seus próprios valores.

```
eksctl create iamserviceaccount --name spark-sa \
--namespace spark-namespace --cluster livy-eks-cluster \
--attach-role-arn arn:aws:iam::0123456789012:role/my-role \
--approve --override-existing-serviceaccounts
```

Propriedades de instalação do Apache Livy em versões do Amazon EMR no EKS

A instalação do Apache Livy permite que você selecione uma versão do chart do Helm no Livy. O chart do Helm oferece uma variedade de propriedades para personalizar sua experiência de instalação e configuração. Essas propriedades são compatíveis com o Amazon EMR no EKS nas versões 7.1.0 e superiores.

Tópicos

- [Propriedades de instalação do Amazon EMR 7.1.0](#)

Propriedades de instalação do Amazon EMR 7.1.0

A tabela a seguir descreve todas as propriedades do Livy compatíveis. Ao instalar o Apache Livy, você pode escolher a versão do chart do Helm no Livy. Para definir uma propriedade durante a instalação, use o comando `--set <property>=<value>`.

Propriedade	Description	Padrão
image	O URI de lançamento do Amazon EMR do servidor do Livy. Essa configuração é necessária.	""
sparkNamespace	Namespace para executar sessões do Livy do Spark. Por exemplo, especifique "livy". Essa configuração é necessária.	""
nameOverride	Forneça um nome em vez de livy. O nome é definido como um rótulo para todos os recursos do Livy	"livy"
fullnameOverride	Forneça um nome para usar em vez dos nomes completos dos recursos.	""
ssl.enabled	Habilita o end-to-end SSL do endpoint Livy para o servidor Livy.	FALSE
ssl.certificateArn	Se o SSL estiver habilitado, esse será o ARN do certifica	""

Propriedade	Description	Padrão
	do do ACM para o NLB criado pelo serviço.	
ssl. secretProviderClassName	Se o SSL estiver habilitado, esse é o nome da classe do provedor secreto para proteger o NLB na conexão do servidor do Livy com SSL.	""
ssl. keyStoreObjectName	Se o SSL estiver habilitado, o nome do objeto do certificado do do keystore na classe do provedor secreto.	""
ssl. keyPasswordsObjectName	Se o SSL estiver habilitado, o nome do objeto do segredo que tem a senha do keystore e de chaves.	""
rbac.create	Se verdadeiro, cria recursos do RBAC.	FALSE
serviceAccount.create	Se verdadeiro, cria uma conta de serviço do Livy.	TRUE
serviceAccount.name	O nome da conta de serviço a ser usada no Livy. Se você não definir essa propriedade e criar uma conta de serviço, o Amazon EMR no EKS gerará automaticamente um nome usando a propriedade de substituição fullname.	"emr-containers-sa-livy"
Conta de serviço. execution RoleArn	O ARN do perfil de execução da conta de serviço do Livy.	""

Propriedade	Description	Padrão
<code>sparkServiceAccount.criar</code>	SE verdadeiro, cria a conta de serviço do Spark no <code>.Release.Namespace</code>	TRUE
<code>sparkServiceAccount.name</code>	O nome da conta de serviço que será usada no Spark. Se você não definir essa propriedade e criar uma conta de serviço do Spark, o Amazon EMR no EKS gerará automaticamente um nome com a propriedade <code>fullnameOverride</code> e o sufixo <code>-spark-livy</code> .	"emr-containers-sa-spark-livio"
<code>service.name</code>	O nome do serviço do Livy	"emr-containers-livy"
<code>service.annotations</code>	Anotações do serviço do Livy	{}
<code>loadbalancer.enabled</code>	Se um balanceador de carga deve ser criado para o serviço Livy usado para expor o endpoint do Livy fora do cluster do Amazon EKS.	FALSE

Propriedade	Description	Padrão
loadbalancer.internal	Se o endpoint do Livy deve ser configurado como interno à VPC ou externo. Definir essa propriedade para FALSE expõe o endpoint a fontes fora da VPC. Recomendamos proteger seu endpoint com TLS/SSL. Para obter mais informações, consulte Setting up TLS and SSL encryption.	FALSE
imagePullSecrets	A lista de nomes <code>imagePullSecret</code> a serem usados para extrair a imagem do Livy de repositórios privados.	[]
recursos	As solicitações de recursos e os limites dos contêineres do Livy.	{}
nodeSelector	Os nós para os quais programar os pods do Livy.	{}
tolerations	Uma lista contendo as tolerâncias dos pods do Livy a serem definidas.	[]
affinity	As regras de afinidade dos pods do Livy.	{}
persistence.enabled	Se verdadeiro, habilita a persistência dos diretórios de sessões.	FALSE

Propriedade	Description	Padrão
<code>persistence.subPath</code>	O subcaminho da VPC a ser montado nos diretórios de sessões.	""
<code>persistence.existingClaim</code>	A VPC a ser usada em vez de criar uma nova.	{}
<code>persistence.storageClass</code>	A classe de armazenamento a ser usada. Para definir esse parâmetro, use o formato <code>storageClassName:</code> <i><storageClass></i> . Definir esse parâmetro para "-" desabilita o provisionamento dinâmico. Se você definir esse parâmetro como nulo ou não especificar nada, o Amazon EMR no EKS não definirá a e usará o <code>storageClassName</code> provisionador padrão.	""
<code>persistence.accessMode</code>	O modo de acesso da PVC.	<code>ReadWriteOnce</code>
<code>persistence.size</code>	O tamanho da VPC.	20 Gi
<code>persistence.annotations</code>	Anotações adicionais para a VPC.	{}
<code>env.*</code>	Ambientes adicionais a serem configurados no contêiner do Livy. Para obter mais informações, consulte Inputting your own Livy and Spark configurations while installing Livy .	{}

Propriedade	Description	Padrão
<code>envFrom.*</code>	Ambientes adicionais a serem definidos para o Livy usando um mapa de configuração ou segredo do Kubernetes.	<code>[]</code>
<code>livyConf.*</code>	Entradas adicionais do <code>livy.conf</code> a serem definidas usando um mapa de configuração ou segredo montado do Kubernetes.	<code>{}</code>
<code>sparkDefaultsConf.*</code>	Entradas adicionais de <code>spark-defaults.conf</code> a serem definidas usando um mapa de configuração ou segredo montado do Kubernetes.	<code>{}</code>

Solução de erros comuns de formato de variável de ambiente

Quando você insere as configurações do Livy e do Spark, há formatos de variáveis de ambiente que não são compatíveis e podem causar erros. O procedimento guia você por uma série de etapas que ajudam a garantir o uso de formatos corretos.

Como inserir suas próprias configurações do Livy e do Spark ao instalar o Livy

Você pode configurar qualquer variável de ambiente do Apache Livy ou do Apache Spark com a propriedade `env.*` do Helm. Siga as etapas abaixo para converter o exemplo de configuração `example.config.with-dash.withUppercase` em um formato de variável de ambiente compatível.

1. Substitua as letras maiúsculas por 1 e a forma minúscula da letra. Por exemplo, `example.config.with-dash.withUppercase` torna-se `example.config.with-dash.with1uppercase`.

2. Substitua traços (-) por 0. Por exemplo, `example.config.with-dash.with1uppercase` se torna `example.config.with0dash.with1uppercase`
3. Substitua pontos (.) por sublinhados (_). Por exemplo, `example.config.with0dash.with1uppercase` torna-se `example_config_with0dash_with1uppercase`.
4. Substitua todas as letras minúsculas por maiúsculas.
5. Adicione o prefixo `LIVY_` ao nome da variável.
6. Use a variável ao instalar o Livy por meio do gráfico de comando usando o formato `--set env. YOUR_VARIABLE_NAME.valor= yourvalue`

Por exemplo, para definir as configurações `livy.server.recovery.state-store = filesystem` e `spark.kubernetes.executor.podNamePrefix = my-prefix` do Livy e do Spark, use estas propriedades do Helm:

```
--set env.LIVY_LIVY_SERVER_RECOVERY_STATE0STORE.value=filesystem  
--set env.LIVY_SPARK_KUBERNETES_EXECUTOR_POD0NAME0PREFIX.value=myprefix
```

Gerenciamento de execuções de trabalhos do Amazon EMR no EKS

As seções a seguir abordam tópicos que ajudam você a gerenciar suas execuções de trabalhos do Amazon EMR no EKS. Isso inclui configurar os parâmetros de execução do trabalho ao usar o AWS CLI, configurar como seus dados de registro são armazenados, executar scripts do Spark SQL para executar consultas, entender os estados de execução do trabalho e saber como monitorar trabalhos. Você pode trabalhar com esses tópicos, geralmente em ordem, se quiser configurar e concluir uma execução de trabalho para processar dados.

Tópicos

- [Gerenciando execuções de trabalhos com o AWS CLI](#)
- [Executando scripts do Spark SQL por meio da API StartJobRun](#)
- [Estados de execução de trabalho](#)
- [Visualização de trabalhos no console do Amazon EMR](#)
- [Erros comuns ao executar trabalhos](#)

Gerenciando execuções de trabalhos com o AWS CLI

Este tópico aborda como gerenciar execuções de trabalhos com o AWS Command Line Interface (AWS CLI). São detalhadas as propriedades, como parâmetros de segurança, o driver e várias configurações de substituição. Também inclui subtópicos que abrangem várias maneiras de configurar o registro em log.

Tópicos

- [Opções para a configuração de uma execução de trabalho](#)
- [Configuração de uma execução de trabalho para usar logs do Amazon S3](#)
- [Configurar uma execução de trabalho para usar o Amazon CloudWatch Logs](#)
- [Listagem de execuções de trabalhos](#)
- [Descrição de uma execução de trabalho](#)
- [Cancelamento de uma execução de trabalho](#)

Opções para a configuração de uma execução de trabalho

Use as seguintes opções para configurar os parâmetros de execução de trabalho:

- `--execution-role-arn`: você deve fornecer um perfil do IAM que é usado para a execução de trabalhos. Para obter mais informações, consulte [Uso de perfis de execução de trabalho com o Amazon EMR no EKS](#).
- `--release-label`: você pode implantar o Amazon EMR no EKS com as versões 5.32.0 e 6.2.0 e posteriores do Amazon EMR. O Amazon EMR no EKS não é compatível com as versões anteriores do Amazon EMR. Para obter mais informações, consulte [Versões do Amazon EMR no EKS](#).
- `--job-driver`: o driver de trabalho usado para fornecer entradas sobre o trabalho principal. Este é um campo do tipo união no qual você só pode transferir um dos valores para o tipo de trabalho que deseja executar. Os tipos de trabalho com suporte incluem:
 - Trabalhos do Spark-submit: usados para executar um comando por meio do spark-submit. Você pode usar esse tipo de tarefa para executar Scala, SparkR PySpark, SparkSQL e qualquer outra tarefa compatível por meio do Spark Submit. Esse tipo de trabalho tem os seguintes parâmetros:
 - Ponto de entrada - Essa é a referência HCFS (sistema de arquivos compatível com Hadoop) ao jar/py arquivo principal que você deseja executar.

- `EntryPointArguments` - Essa é uma matriz de argumentos que você deseja passar para o jar/py arquivo principal. Você deve realizar a leitura desses parâmetros usando seu código de Entrypoint. Cada argumento na matriz deve ser separado por uma vírgula. `EntryPointArguments` não pode conter colchetes ou parênteses, como `()`, `{}` ou `[]`.
- `SparkSubmitParameters` - Esses são os parâmetros adicionais do Spark que você deseja enviar para o trabalho. Use este parâmetro para substituir as propriedades padrão do Spark, como a memória do driver ou o número de executores, como `—conf` ou `—class`. Para obter informações adicionais, consulte [Launching Applications with spark-submit](#).
- Trabalhos do Spark SQL: usados para executar um arquivo de consulta SQL por meio do Spark SQL. Você pode usar esse tipo de trabalho para executar trabalhos do Spark SQL. Esse tipo de trabalho tem os seguintes parâmetros:
 - Entrypoint: esta é a referência do HCFS (sistema de arquivos compatível com Hadoop) para o arquivo de consulta SQL que você deseja executar.

Para obter uma lista de parâmetros adicionais do Spark que você pode usar para um trabalho do Spark SQL, consulte [Executando scripts do Spark SQL por meio da API StartJobRun](#).

- `--configuration-overrides`: você pode substituir as configurações padrão para as aplicações ao fornecer um objeto de configuração. Você pode usar uma sintaxe abreviada para fornecer a configuração ou fazer referência ao objeto de configuração em um arquivo JSON. Os objetos de configuração consistem em uma classificação, propriedades e configurações opcionais aninhadas. As propriedades consistem nas configurações que você deseja substituir neste arquivo. Você pode especificar várias classificações para diversas aplicações em um único objeto JSON. As classificações de configuração disponíveis variam de acordo com a versão do Amazon EMR. Para obter uma lista das classificações de configuração disponíveis para cada versão de liberação do Amazon EMR, consulte [Versões do Amazon EMR no EKS](#).

Se você transferir a mesma configuração em uma substituição de aplicação e nos parâmetros do `spark-submit`, os parâmetros do `spark-submit` terão precedência. A lista completa de prioridades de configuração é apresentada a seguir, na ordem da prioridade mais alta para a prioridade mais baixa.

- Configuração fornecida ao criar `SparkSession`.
- Configuração fornecida como parte do `sparkSubmitParameters` usando `—conf`.
- Configuração fornecida como parte das substituições de aplicações.
- Configurações otimizadas escolhidas pelo Amazon EMR para a versão.
- Configurações padrão de código aberto para a aplicação.

Para monitorar a execução de trabalhos usando o Amazon CloudWatch ou o Amazon S3, você deve fornecer os detalhes da configuração do. CloudWatch Para obter mais informações, consulte [Configuração de uma execução de trabalho para usar logs do Amazon S3](#) e [Configurar uma execução de trabalho para usar o Amazon CloudWatch Logs](#). Se o bucket ou grupo de CloudWatch logs do S3 não existir, o Amazon EMR o criará antes de fazer o upload dos registros para o bucket.

- Para obter uma lista adicional de opções de configuração do Kubernetes, consulte [Spark Properties on Kubernetes](#).

As configurações do Spark apresentadas a seguir não têm suporte.

- `spark.kubernetes.authenticate.driver.serviceAccountName`
- `spark.kubernetes.authenticate.executor.serviceAccountName`
- `spark.kubernetes.namespace`
- `spark.kubernetes.driver.pod.name`
- `spark.kubernetes.container.image.pullPolicy`
- `spark.kubernetes.container.image`

 Note

Você pode usar `spark.kubernetes.container.image` para imagens do Docker personalizadas. Para obter mais informações, consulte [Personalização de imagens do Docker para o Amazon EMR no EKS](#).

Configuração de uma execução de trabalho para usar logs do Amazon S3

Para poder monitorar o progresso do trabalho e solucionar falhas, você deve configurar seus trabalhos para enviar informações de log para o Amazon S3, CloudWatch Amazon Logs ou ambos. Este tópico ajuda você a começar a publicar logs de aplicações no Amazon S3 em trabalhos iniciados com o Amazon EMR no EKS.

Política do IAM para logs do S3

Antes que os trabalhos possam enviar dados de log ao Amazon S3, as permissões apresentadas a seguir devem ser incluídas na política de permissões para o perfil de execução do trabalho. Substitua *amzn-s3-demo-logging-bucket* pelo nome do bucket de registro em log.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket",
        "arn:aws:s3:::amzn-s3-demo-bucket/*"
      ],
      "Sid": "AllowS3Putobject"
    }
  ]
}
```

 Note

O Amazon EMR no EKS também pode criar um bucket do Amazon S3. Se um bucket do Amazon S3 não estiver disponível, inclua a permissão “s3:CreateBucket” na política do IAM.

Depois de conceder ao perfil de execução as permissões adequadas para enviar logs ao Amazon S3, os dados de log serão enviados para os locais do Amazon S3 apresentados a seguir quando s3MonitoringConfiguration for transmitida na seção monitoringConfiguration de uma solicitação start-job-run, conforme mostrado em [Gerenciando execuções de trabalhos com o AWS CLI](#).

- Registros do remetente `--virtual-cluster-id/jobs/ /containers/logUri/(stderr.gz/stdout.gz) job-id pod-name`
- Registros de drivers `--virtual-cluster-id/jobs/ logUri job-id /containers/ /spark- -driver/ (spark-application-id stderr.gz/stdout.gz) job-id`

- Registros do executor `--virtual-cluster-id/jobs/ logUri job-id /containers///(spark-application-idstderr.gz/stdout.gz) executor-pod-name`

Configurar uma execução de trabalho para usar o Amazon CloudWatch Logs

Para monitorar o progresso do trabalho e solucionar falhas, você deve configurar seus trabalhos para enviar informações de log para o Amazon S3, CloudWatch Amazon Logs ou ambos. Este tópico ajuda você a começar a usar CloudWatch registros em seus trabalhos que são lançados com o Amazon EMR no EKS. Para obter mais informações sobre CloudWatch registros, consulte [Monitoramento de arquivos de log](#) no Guia CloudWatch do usuário da Amazon.

CloudWatch Política de IAM de registros

Para que seus trabalhos enviem dados de registro para o CloudWatch Logs, as seguintes permissões devem ser incluídas na política de permissões da função de execução do trabalho. Substitua `my_log_group_name` e `my_log_stream_prefix` por nomes de seu grupo de CloudWatch registros e nomes de fluxo de registros, respectivamente. O Amazon EMR no EKS cria o grupo de logs e o fluxo de logs se eles não existirem, desde que o ARN do perfil de execução tenha as permissões apropriadas.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "logs:CreateLogStream",
        "logs:DescribeLogGroups",
        "logs:DescribeLogStreams"
      ],
      "Resource": [
        "arn:aws:logs:*:*:*"
      ],
      "Sid": "AllowLOGSCreatelogstream"
    },
    {
      "Effect": "Allow",
      "Action": [
```

```

    "logs:PutLogEvents"
  ],
  "Resource": [
    "arn:aws:logs:*:*:log-group:my_log_group_name:log-
stream:my_log_stream_prefix/*"
  ],
  "Sid": "AllowLOGSPutlogevents"
}
]
}

```

Note

O Amazon EMR no EKS também pode criar um fluxo de logs. Se um fluxo de logs não existir, a política do IAM deverá incluir a permissão "logs:CreateLogGroup".

Depois de conceder à sua função de execução as permissões adequadas, seu aplicativo envia os dados de registro para o CloudWatch `cloudWatchMonitoringConfiguration` Logs quando são passados na `monitoringConfiguration` seção de uma `start-job-run` solicitação, conforme mostrado em [Gerenciando execuções de trabalhos com o AWS CLI](#).

Na `StartJobRun` API, `log_group_name` é o nome do grupo de registros para CloudWatch e `log_stream_prefix` é o prefixo do nome do fluxo de registros para CloudWatch. Você pode visualizar e pesquisar esses logs no Console de gerenciamento da AWS.

- Registros do remetente -`logGroup//virtual-cluster-id/jobs/ logStreamPrefix / containers//(stderr/stdout)job-id) pod-name`
- Registros de drivers -`logGroup//logStreamPrefixvirtual-cluster-id/jobs/ job-id / containers/ /spark- -driver/ (spark-application-idstderrstdout) job-id`
- Registros do executor -`logGroup//logStreamPrefixvirtual-cluster-id/jobs/ job-id / containers///(spark-application-idstderr/stdout) executor-pod-name`

Listagem de execuções de trabalhos

Você pode executar `list-job-run` para mostrar os estados das execuções de trabalhos, como demonstra o exemplo a seguir.

```
aws emr-containers list-job-runs --virtual-cluster-id <cluster-id>
```

Descrição de uma execução de trabalho

Você pode executar `describe-job-run` para obter mais detalhes sobre o trabalho, como o estado do trabalho, os detalhes do estado e o nome do trabalho, como demonstra o exemplo a seguir.

```
aws emr-containers describe-job-run --virtual-cluster-id cluster-id --id job-run-id
```

Cancelamento de uma execução de trabalho

Você pode executar `cancel-job-run` para cancelar trabalhos em execução, como demonstra o exemplo a seguir.

```
aws emr-containers cancel-job-run --virtual-cluster-id cluster-id --id job-run-id
```

Executando scripts do Spark SQL por meio da API StartJobRun

As versões 6.7.0 e posteriores do Amazon EMR no EKS incluem um driver de trabalho do Spark SQL para que você possa executar scripts do Spark SQL por meio da API `StartJobRun`. Você pode fornecer arquivos de ponto de entrada SQL para executar consultas do Spark SQL diretamente no Amazon EMR no EKS com a API `StartJobRun`, sem a necessidade de realizar modificações nos scripts do Spark SQL existentes. A tabela a seguir lista os parâmetros do Spark que são compatíveis com as tarefas do Spark SQL por meio da `StartJobRun` API.

Você pode escolher entre os parâmetros do Spark apresentados a seguir para enviar para um trabalho do Spark SQL. Use esses parâmetros para substituir as propriedades padrão do Spark.

Opção	Description
<code>--name NAME</code>	Nome da aplicação
<code>--jars JARS</code>	Lista separada por vírgulas de arquivos em JARs a serem incluídos no driver e no caminho de classe de execução.
<code>--packages</code>	Lista separada por vírgulas de coordenadas do Maven de arquivos em JARs a serem

Opção	Description
	inclusas nos caminhos de classe do driver e do executor.
<code>--exclude-packages</code>	Lista separada por vírgulas de groupId:artifactId, para excluir ao resolver as dependências fornecidas em <code>--packages</code> para evitar conflitos de dependência.
<code>--repositories</code>	Lista separada por vírgulas de repositórios remotos adicionais para pesquisar as coordenadas do Maven fornecidas com <code>--packages</code> .
<code>--files FILES</code>	Lista separada por vírgulas de arquivos a serem colocados no diretório de trabalho de cada executor.
<code>--conf PROP=VALUE</code>	Propriedade de configuração do Spark.
<code>--properties-file FILE</code>	Caminho para um arquivo do qual as propriedades extras serão carregadas.
<code>--driver-memory MEM</code>	Memória para o driver. O padrão é de 1.024 MB.
<code>--driver-java-options</code>	Opções extras do Java a serem transferidas para o driver.
<code>--driver-library-path</code>	Entradas extras de caminhos da biblioteca a serem transferidas para o driver.
<code>--driver-class-path</code>	Entradas extras de caminhos de classe a serem transferidas para o driver.
<code>--executor-memory MEM</code>	Memória por executor. O padrão é de 1 GB.
<code>--driver-cores NUM</code>	Número de núcleos usados pelo driver.

Opção	Description
-- total-executor-cores NÚMERO	Total de núcleos para todos os executores.
--executor-cores NUM	Número de núcleos usados por cada executor.
--num-executors NUM	Número de executores para iniciar.
-hivevar <key=value>	Substituição de variável para a aplicação dos comandos do Hive, por exemplo, -hivevar A=B.
-hiveconf <property=value>	Valor a ser usado para a propriedade em questão.

Para uma tarefa do Spark SQL, crie um start-job-run-request arquivo.json e especifique os parâmetros necessários para a execução da tarefa, como no exemplo a seguir:

```
{
  "name": "myjob",
  "virtualClusterId": "123456",
  "executionRoleArn": "iam_role_name_for_job_execution",
  "releaseLabel": "emr-6.7.0-latest",
  "jobDriver": {
    "sparkSqlJobDriver": {
      "entryPoint": "entryPoint_location",
      "sparkSqlParameters": "--conf spark.executor.instances=2 --conf
spark.executor.memory=2G --conf spark.executor.cores=2 --conf spark.driver.cores=1"
    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "spark-defaults",
        "properties": {
          "spark.driver.memory": "2G"
        }
      }
    ]
  },
  "monitoringConfiguration": {
    "persistentAppUI": "ENABLED",
```

```
    "cloudWatchMonitoringConfiguration": {  
      "logGroupName": "my_log_group",  
      "logStreamNamePrefix": "log_stream_prefix"  
    },  
    "s3MonitoringConfiguration": {  
      "logUri": "s3://my_s3_log_location"  
    }  
  }  
}
```

Estados de execução de trabalho

Quando você envia uma execução de trabalho para uma fila de trabalhos do Amazon EMR no EKS, a execução de trabalho entra no estado PENDING. Em seguida, ela passa pelos estados apresentados a seguir até obter êxito (sair com o código 0) ou falhar (sair com um código diferente de zero).

As execuções de trabalhos podem ter os seguintes estados:

- **PENDING:** o estado inicial do trabalho quando a execução de trabalho é enviada ao Amazon EMR no EKS. O trabalho está aguardando para ser enviado ao cluster virtual, e o Amazon EMR no EKS está trabalhando no envio desse trabalho.
- **SUBMITTED:** uma execução de trabalho que foi enviada com êxito ao cluster virtual. O programador do cluster tenta executar esse trabalho no cluster.
- **RUNNING:** uma execução de trabalho em execução no cluster virtual. Em aplicações do Spark, isso significa que o processo do driver do Spark está no estado `running`.
- **FAILED:** uma execução de trabalho que falhou ao ser enviada ao cluster virtual ou que foi concluída sem êxito. Examine `StateDetails` e `FailureReason` encontre informações adicionais sobre essa falha no trabalho.
- **COMPLETED:** uma execução de trabalho que foi concluída com êxito.
- **CANCEL_PENDING:** uma execução de trabalho foi solicitada para cancelamento. O Amazon EMR no EKS está tentando cancelar o trabalho no cluster virtual.
- **CANCELLED:** uma execução de trabalho que foi cancelada com êxito.

Visualização de trabalhos no console do Amazon EMR

Os dados de execução do trabalho estão disponíveis para exibição, para que você possa monitorar cada trabalho à medida que ele passa pelos estados. Para visualizar trabalhos no console do Amazon EMR, execute as etapas a seguir.

1. No menu à esquerda do console do Amazon EMR, em Amazon EMR no EKS, escolha Clusters virtuais.
2. Na lista de clusters virtuais, selecione o cluster virtual do qual deseja visualizar os trabalhos.
3. Na tabela Execuções de trabalhos, selecione Visualizar logs para visualizar os detalhes de uma execução de trabalho.

Note

O suporte para a experiência de um clique está habilitado por padrão. Ele pode ser desativado ao configurar `persistentAppUI` para `DISABLED` na `monitoringConfiguration` durante o envio do trabalho. Para obter mais informações, consulte [View Persistent Application User Interfaces](#).

Erros comuns ao executar trabalhos

Os erros a seguir podem ocorrer ao executar a API `StartJobRun`. A tabela lista cada erro e fornece etapas de mitigação para que você possa resolver os problemas rapidamente.

Mensagem de erro	Condição de erro	Próxima etapa recomendada
erro: argumento -- <i>argument</i> é obrigatório	Os parâmetros obrigatórios estão ausentes.	Adicione os argumentos ausentes à solicitação de API.
Ocorreu um erro (AccessDeniedException) ao chamar a StartJobRun operação: Usuário: não <i>ARN</i> está autorizado a realizar: emr-containers: StartJobRun	O perfil de execução está ausente.	Consulte Uso de perfis de execução de trabalho com o Amazon EMR no EKS .

Mensagem de erro	Condição de erro	Próxima etapa recomendada
Ocorreu um erro (AccessDeniedException) ao chamar a StartJobRun operação: Usuário: não ARN está autorizado a realizar: emr-containers: StartJobRun	O chamador não tem permissão para acessar o perfil de execução [formato válido ou inválido] por meio de chaves de condição.	Consulte Uso de perfis de execução de trabalho com o Amazon EMR no EKS .
Ocorreu um erro (AccessDeniedException) ao chamar a StartJobRun operação: Usuário: não ARN está autorizado a realizar: emr-containers: StartJobRun	O emissor de trabalho e o ARN do perfil de execução são de contas diferentes.	Certifique-se de que o ARN do emissor de trabalho e do perfil de execução sejam da mesma conta da AWS .
1 erro de validação detectado : o valor Role em 'executio nRoleArn' falhou em satisfazer o padrão de expressão regular do ARN: ^arn :(aws [a-zA-z0-9-]*) :iam : (\ d {12}) ? : (papel ((\ u002F) (\ u002F [\ u0021- \ u007F] + \ u002F)) [\ w+=, .@-] +)	O chamador tem permissões para acessar o perfil de execução por meio de chaves de condição, mas o perfil não atende às restrições do formato de ARN.	Forneça o perfil de execução seguindo o formato de ARN. Consulte Uso de perfis de execução de trabalho com o Amazon EMR no EKS .
Ocorreu um erro (ResourceNotFoundException) ao chamar a StartJobRun operação: O cluster virtual Virtual Cluster ID não existe.	O ID do cluster virtual não foi encontrado.	Forneça um ID do cluster virtual registrado no Amazon EMR no EKS.

Mensagem de erro	Condição de erro	Próxima etapa recomendada
Ocorreu um erro (ValidationException) ao chamar a StartJobRun operação: O estado do cluster virtual não state é válido para criar recursos JobRun.	O cluster virtual não está pronto para executar o trabalho.	Consulte Estados de um cluster virtual .
Ocorreu um erro (ResourceNotFoundException) ao chamar a StartJobRun operação: A liberação RELEASE não existe.	A versão especificada no envio do trabalho está incorreta.	Consulte Versões do Amazon EMR no EKS .
Ocorreu um erro (AccessDeniedException) ao chamar a StartJobRun operação: Usuário: não ARN está autorizado a realizar: emr-containers: StartJobRun on resource: ARN com uma negação explícita. Ocorreu um erro (AccessDeniedException) ao chamar a StartJobRun operação: Usuário: não ARN está autorizado a executar: emr-containers: StartJobRun on resource: ARN	O usuário não está autorizado a ligar StartJobRun.	Consulte Uso de perfis de execução de trabalho com o Amazon EMR no EKS .

Mensagem de erro	Condição de erro	Próxima etapa recomendada
Ocorreu um erro (ValidationException) ao chamar a StartJobRun operação: configurationOverrides.monitoringConfiguration.s3MonitoringConfiguration.logURI falhou em satisfazer a restrição: %s	A sintaxe do URI do caminho do S3 não é válida.	O logUri deve estar no formato s3://...

Os erros a seguir podem ocorrer ao executar a API DescribeJobRun antes da execução de trabalho.

Mensagem de erro	Condição de erro	Próxima etapa recomendada
StateDetails: falha no JobRun envio. Classificação <i>classification</i> não suportada. failureReason: VALIDATION_ERROR state: FAILED.	Os parâmetros em não StartJobRun são válidos.	Consulte Versões do Amazon EMR no EKS .
StateDetails: <i>EKS Cluster ID</i> O cluster não existe. failureReason: CLUSTER_UNAVAILABLE state: FAILED	O cluster do EKS não está disponível.	Verifique se o cluster do EKS existe e tem as permissões corretas. Para obter mais informações, consulte Configuração do Amazon EMR no EKS .
StateDetails: <i>EKS Cluster ID</i> O cluster não tem permissões suficientes.	O Amazon EMR não tem permissões para acessar o cluster do EKS.	Verifique se as permissões estão configuradas para o Amazon EMR no namespace

Mensagem de erro	Condição de erro	Próxima etapa recomendada
failureReason: CLUSTER_UNAVAILABLE state: FAILED		registrado. Para obter mais informações, consulte Configuração do Amazon EMR no EKS.
StateDetails: O cluster não <i>EKS Cluster ID</i> está acessível no momento. failureReason: CLUSTER_UNAVAILABLE state: FAILED	O cluster do EKS não está acessível.	Verifique se o cluster do EKS existe e tem as permissões corretas. Para obter mais informações, consulte Configuração do Amazon EMR no EKS.
StateDetails: falha no JobRun envio devido a um erro interno. failureReason: INTERNAL_ERROR state: FAILED	Ocorreu um erro interno com o cluster do EKS.	N/D
StateDetails: <i>EKS Cluster ID</i> O cluster não tem recursos suficientes. failureReason: USER_ERROR state: FAILED	Não há recursos suficientes no cluster do EKS para executar o trabalho.	Adicione mais capacidade ao grupo de nós do EKS ou configure o Autoscaler do EKS. Para obter mais informações, consulte Autoscaler do cluster.

Os erros a seguir podem ocorrer ao executar a API DescribeJobRun depois da execução de trabalho.

Mensagem de erro	Condição de erro	Próxima etapa recomendada
StateDetails: Problemas para monitorar seu. JobRun <i>EKS Cluster ID</i>O cluster não existe. failureReason: CLUSTER_UNAVAILABLE state: FAILED	O cluster do EKS não existe.	Verifique se o cluster do EKS existe e tem as permissões corretas. Para obter mais informações, consulte Configuração do Amazon EMR no EKS.
StateDetails: Problemas para monitorar seu. JobRun <i>EKS Cluster ID</i>O cluster não tem permissões suficientes. failureReason: CLUSTER_UNAVAILABLE state: FAILED	O Amazon EMR não tem permissões para acessar o cluster do EKS.	Verifique se as permissões estão configuradas para o Amazon EMR no namespace registrado. Para obter mais informações, consulte Configuração do Amazon EMR no EKS.
StateDetails: Problemas para monitorar seu. JobRun No momento, <i>EKS Cluster ID</i> o cluster não está acessível. failureReason: CLUSTER_UNAVAILABLE state: FAILED	O cluster do EKS não está acessível.	Verifique se o cluster do EKS existe e tem as permissões corretas. Para obter mais informações, consulte Configuração do Amazon EMR no EKS.
StateDetails: Problemas para monitorar seu JobRun devido a um erro interno	Ocorreu um erro interno que está impedindo o JobRun monitoramento.	N/D

Mensagem de erro	Condição de erro	Próxima etapa recomendada
failureReason: INTERNAL_ERROR state: FAILED		

O erro apresentado a seguir pode ocorrer quando um trabalho não pode ser iniciado e aguarda no estado SUBMITTED por 15 minutos. Isso pode ser causado pela falta de recursos do cluster.

Mensagem de erro	Condição de erro	Próxima etapa recomendada
cluster timeout	O trabalho está no estado SUBMITTED há 15 minutos ou mais.	Você pode substituir a configuração padrão de 15 minutos para este parâmetro com a substituição de configuração mostrada abaixo.

Use a configuração a seguir para alterar a configuração de tempo limite do cluster para 30 minutos. Observe que você fornece o novo valor para `job-start-timeout` em segundos:

```
{
  "configurationOverrides": {
    "applicationConfiguration": [{
      "classification": "emr-containers-defaults",
      "properties": {
        "job-start-timeout": "1800"
      }
    }]
  }
}
```

Uso de modelos de trabalho

Um modelo de trabalho armazena valores que podem ser compartilhados entre invocações da API `StartJobRun` ao iniciar uma execução de trabalho. Ele oferece suporte a dois casos de uso:

- Para evitar valores de solicitação da API `StartJobRun` repetitivos e recorrentes.

- Para impor uma regra, determinados valores devem ser fornecidos por meio de solicitações da API `StartJobRun`.

Os modelos de trabalho possibilitam definir um modelo reutilizável para execuções de trabalho com a finalidade de aplicar personalizações adicionais, por exemplo:

- Configuração da capacidade de computação dos executores e dos drivers.
- Definição de propriedades de segurança e de governança, como perfis do IAM.
- Personalização de uma imagem do Docker para usar em diversas aplicações e pipelines de dados.

Os tópicos a seguir fornecem informações detalhadas sobre o uso de modelos, incluindo como usá-los para iniciar a execução de um trabalho e como alterar os parâmetros do modelo.

Tópicos

- [Criação e uso de um modelo de trabalho para iniciar uma execução de trabalho](#)
- [Definição de parâmetros de modelos de trabalhos](#)
- [Controle do acesso aos modelos de trabalhos](#)

Criação e uso de um modelo de trabalho para iniciar uma execução de trabalho

Esta seção descreve a criação de um modelo de trabalho e o uso do modelo para iniciar a execução de um trabalho com o AWS Command Line Interface (AWS CLI).

Criar um modelo de trabalho

1. Crie um arquivo `create-job-template-request.json` e especifique os parâmetros obrigatórios para seu modelo de trabalho, conforme mostrado no arquivo JSON de exemplo a seguir. Para obter informações sobre todos os parâmetros disponíveis, consulte a [CreateJobTemplateAPI](#).

A maioria dos valores obrigatórios para a API `StartJobRun` também são obrigatórios para `jobTemplateData`. Se você quiser usar espaços reservados para qualquer parâmetro e fornecer valores ao invocar `StartJobRun` usando um modelo de trabalho, consulte a próxima seção sobre parâmetros do modelo de trabalho.

```
{
  "name": "mytemplate",
  "jobTemplateData": {
    "executionRoleArn": "iam_role_arn_for_job_execution",
    "releaseLabel": "emr-6.7.0-latest",
    "jobDriver": {
      "sparkSubmitJobDriver": {
        "entryPoint": "entryPoint_location",
        "entryPointArguments": [ "argument1", "argument2", ... ],
        "sparkSubmitParameters": "--class <main_class> --conf
spark.executor.instances=2 --conf spark.executor.memory=2G --conf
spark.executor.cores=2 --conf spark.driver.cores=1"
      }
    },
    "configurationOverrides": {
      "applicationConfiguration": [
        {
          "classification": "spark-defaults",
          "properties": {
            "spark.driver.memory": "2G"
          }
        }
      ],
      "monitoringConfiguration": {
        "persistentAppUI": "ENABLED",
        "cloudWatchMonitoringConfiguration": {
          "logGroupName": "my_log_group",
          "logStreamNamePrefix": "log_stream_prefix"
        },
        "s3MonitoringConfiguration": {
          "logUri": "s3://my_s3_log_location/"
        }
      }
    }
  }
}
```

2. Use o comando `create-job-template` com um caminho para o arquivo `create-job-template-request.json` armazenado localmente.

```
aws emr-containers create-job-template \
--cli-input-json file:///./create-job-template-request.json
```

Iniciar uma execução de trabalho usando um modelo de trabalho

Forneça o ID do cluster virtual, o ID do modelo de trabalho e o nome do trabalho no comando `StartJobRun`, conforme mostrado no exemplo a seguir.

```
aws emr-containers start-job-run \  
--virtual-cluster-id 123456 \  
--name myjob \  
--job-template-id 1234abcd
```

Definição de parâmetros de modelos de trabalhos

Os parâmetros de modelos de trabalhos permitem especificar variáveis no modelo de trabalho. Os valores para essas variáveis de parâmetro precisarão ser especificados ao iniciar uma execução de trabalho usando esse modelo de trabalho. Os parâmetros do modelo de trabalho são especificados no formato `${parameterName}`. Você pode optar por especificar qualquer valor em um campo `jobTemplateData` como um parâmetro do modelo de trabalho. Para cada uma das variáveis de parâmetro do modelo de trabalho, especifique seu tipo de dados (STRING ou NUMBER) e, opcionalmente, um valor padrão. O exemplo abaixo mostra como você pode especificar os parâmetros do modelo de trabalho para os valores de local do ponto de entrada, classe principal e local do log do S3.

Para especificar o local do ponto de entrada, a classe principal e o local do log do Amazon S3 como parâmetros do modelo de trabalho

1. Crie um arquivo `create-job-template-request.json` e especifique os parâmetros obrigatórios para seu modelo de trabalho, conforme mostrado no arquivo JSON de exemplo a seguir. Para obter mais informações sobre os parâmetros, consulte a [CreateJobTemplateAPI](#).

```
{  
  "name": "mytemplate",  
  "jobTemplateData": {  
    "executionRoleArn": "iam_role_arn_for_job_execution",  
    "releaseLabel": "emr-6.7.0-latest",  
    "jobDriver": {  
      "sparkSubmitJobDriver": {  
        "entryPoint": "${EntryPointLocation}",  
        "entryPointArguments": [ "argument1", "argument2", ... ],  
        "sparkSubmitParameters": "--class ${MainClass} --conf  
spark.executor.instances=2 --conf spark.executor.memory=2G --conf  
spark.executor.cores=2 --conf spark.driver.cores=1"
```

```

    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "spark-defaults",
        "properties": {
          "spark.driver.memory": "2G"
        }
      }
    ],
    "monitoringConfiguration": {
      "persistentAppUI": "ENABLED",
      "cloudWatchMonitoringConfiguration": {
        "logGroupName": "my_log_group",
        "logStreamNamePrefix": "log_stream_prefix"
      },
      "s3MonitoringConfiguration": {
        "logUri": "${LogS3BucketUri}"
      }
    }
  },
  "parameterConfiguration": {
    "EntryPointLocation": {
      "type": "STRING"
    },
    "MainClass": {
      "type": "STRING",
      "defaultValue": "Main"
    },
    "LogS3BucketUri": {
      "type": "STRING",
      "defaultValue": "s3://my_s3_log_location/"
    }
  }
}

```

2. Use o comando `create-job-template` com um caminho para o arquivo `create-job-template-request.json` armazenado localmente ou no Amazon S3.

```

aws emr-containers create-job-template \
--cli-input-json file://./create-job-template-request.json

```

Para iniciar uma execução de trabalho usando um modelo de trabalho com parâmetros de modelos de trabalhos

Para iniciar uma execução de trabalho com um modelo de trabalho contendo parâmetros de modelos de trabalhos, especifique o ID do modelo de trabalho, bem como os valores dos parâmetros do modelo de trabalho na solicitação da API `StartJobRun`, conforme mostrado abaixo.

```
aws emr-containers start-job-run \  
--virtual-cluster-id 123456 \  
--name myjob \  
--job-template-id 1234abcd \  
--job-template-parameters '{"EntryPointLocation": "entry_point_location", "MainClass": "ExampleMainClass", "LogS3BucketUri": "s3://example_s3_bucket/"}'
```

Controle do acesso aos modelos de trabalhos

A política `StartJobRun` permite impor que um usuário ou um perfil possa somente executar trabalhos usando modelos de trabalhos especificados e não possa executar operações `StartJobRun` sem usar os modelos de trabalhos especificados. Para conseguir isso, primeiro, certifique-se de conceder ao usuário ou ao perfil uma permissão de leitura para os modelos de trabalhos especificados, conforme mostrado abaixo.

JSON

```
{  
  "Version": "2012-10-17",  
  "Statement": [  
    {  
      "Effect": "Allow",  
      "Action": [  
        "emr-containers:DescribeJobRun"  
      ],  
      "Resource": [  
        "arn:aws:emr-containers::*:jobtemplate/job_template_1_id",  
        "arn:aws:emr-containers::*:jobtemplate/job_template_2_id"  
      ],  
      "Sid": "AllowEMRCONTAINERSDescribejobtemplate"  
    }  
  ]  
}
```

Para garantir que um usuário ou que um perfil seja capaz de invocar a operação `StartJobRun` somente ao usar modelos de trabalhos especificados, você pode atribuir a permissão de política `StartJobRun` apresentada a seguir para um determinado usuário ou perfil.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "emr-containers:StartJobRun"
      ],
      "Resource": [
        "arn:aws:emr-containers:*:*:/virtualclusters/virtual_cluster_id"
      ],
      "Condition": {
        "ArnLike": {
          "emr-containers:JobTemplateArn": [
            "arn:aws:emr-containers:*:*:jobtemplate/job_template_1_id",
            "arn:aws:emr-containers:*:*:jobtemplate/job_template_2_id"
          ]
        }
      },
      "Sid": "AllowEMRCONTAINERSStartjobrun"
    }
  ]
}
```

Se o modelo de trabalho especificar um parâmetro de modelo de trabalho dentro do campo ARN do perfil de execução, o usuário poderá fornecer um valor para esse parâmetro e, assim, invocar `StartJobRun` usando um perfil de execução arbitrário. Para restringir os perfis de execução que o usuário pode fornecer, consulte Controle do acesso ao perfil de execução em [Uso de perfis de execução de trabalho com o Amazon EMR no EKS](#).

Se nenhuma condição for especificada na política de ação `StartJobRun` acima para um determinado usuário ou perfil, o usuário ou o perfil terá permissão para invocar a ação `StartJobRun` no cluster virtual especificado usando um modelo de trabalho arbitrário ao qual ele tenha acesso de leitura ou usando um perfil de execução arbitrário.

Uso de modelos de pod

A partir das versões 5.33.0 ou 6.3.0 do Amazon EMR, o Amazon EMR no EKS oferece suporte ao recurso de modelo de pod do Spark. Um pod corresponde a um grupo de um ou mais contêineres, com recursos de rede e armazenamento compartilhados, e uma especificação de como executar os contêineres. Os modelos de pod são especificações que determinam como ocorrerá a execução de cada pod. É possível usar arquivos de modelo de pod para definir as configurações de pods de drivers ou de executores para as quais as configurações do Spark não oferecem suporte. Para obter mais informações sobre o recurso de modelo de pod do Spark, consulte [Pod Template](#).

Note

O recurso de modelo de pod funciona somente com pods de drivers e de executores. Não é possível configurar pods de emissores de trabalhos usando o modelo de pods.

Cenários comuns

Você pode definir como executar trabalhos do Spark em clusters do EKS compartilhados ao usar modelos de pod com o Amazon EMR no EKS, e economizar custos e aprimorar a utilização e a performance dos recursos.

- Para reduzir custos, você pode programar tarefas do driver do Spark para serem executadas nas instâncias EC2 sob demanda da Amazon e programar tarefas do executor do Spark para serem executadas nas instâncias Amazon Spot. EC2
- Para aumentar a utilização de recursos, você pode oferecer suporte a diversas equipes que executam as workloads no mesmo cluster do EKS. Cada equipe receberá um grupo de EC2 nós designado da Amazon para executar suas cargas de trabalho. Você pode usar os modelos de pod para aplicar uma tolerância correspondente à workload.
- Para aprimorar o monitoramento, você pode executar um contêiner de registro em log separado para encaminhar os logs para a aplicação de monitoramento existente.

Por exemplo, o arquivo de modelo de pod a seguir demonstra um cenário de uso comum.

```
apiVersion: v1
kind: Pod
spec:
```

```

volumes:
  - name: source-data-volume
    emptyDir: {}
  - name: metrics-files-volume
    emptyDir: {}
nodeSelector:
  eks.amazonaws.com/nodegroup: emr-containers-nodegroup
containers:
  - name: spark-kubernetes-driver # This will be interpreted as driver Spark main
    container
    env:
      - name: RANDOM
        value: "random"
    volumeMounts:
      - name: shared-volume
        mountPath: /var/data
      - name: metrics-files-volume
        mountPath: /var/metrics/data
  - name: custom-side-car-container # Sidecar container
    image: <side_car_container_image>
    env:
      - name: RANDOM_SIDE CAR
        value: random
    volumeMounts:
      - name: metrics-files-volume
        mountPath: /var/metrics/data
    command:
      - /bin/sh
      - '-c'
      - <command-to-upload-metrics-files>
initContainers:
  - name: spark-init-container-driver # Init container
    image: <spark-pre-step-image>
    volumeMounts:
      - name: source-data-volume # Use EMR predefined volumes
        mountPath: /var/data
    command:
      - /bin/sh
      - '-c'
      - <command-to-download-dependency-jars>

```

O modelo de pod conclui as seguintes tarefas:

- Adiciona um novo [contêiner Init](#) que é executado antes do início do contêiner principal do Spark. O contêiner init compartilha o [EmptyDirvolume](#) chamado `source-data-volume` com o contêiner principal do Spark. Você pode fazer com que seu contêiner Init execute as etapas de inicialização, como fazer download de dependências ou gerar dados de entrada. Em seguida, o contêiner principal do Spark consumirá os dados.
- Adiciona outro [contêiner sidecar](#) que é executado junto com o contêiner principal do Spark. Os dois contêineres estão compartilhando outro volume EmptyDir chamado `metrics-files-volume`. Seu trabalho do Spark pode gerar métricas, como as métricas do Prometheus. Em seguida, o trabalho do Spark pode colocar as métricas em um arquivo e fazer com que o contêiner sidecar carregue os arquivos em seu próprio sistema de BI para análise futura.
- Adiciona uma nova variável de ambiente ao contêiner principal do Spark. Você pode fazer com que seu trabalho consuma a variável de ambiente.
- Defina um [seletor de nó](#), para que o pod seja programado somente no grupo de nós `emr-containers-nodegroup`. Isso ajuda a isolar os recursos de computação entre trabalhos e equipes.

Habilitação de modelos de pod com o Amazon EMR no EKS

Para habilitar o recurso de modelo de pod com o Amazon EMR no EKS, configure as propriedades do Spark `spark.kubernetes.driver.podTemplateFile` e `spark.kubernetes.executor.podTemplateFile` para direcionar aos arquivos de modelo de pod no Amazon S3. O Spark fará download do arquivo de modelo de pod e o usará para estruturar pods de drivers e de executores.

Note

O Spark usa o perfil de execução de trabalho para carregar o modelo de pod, portanto, o perfil de execução de trabalho deve ter permissões para acessar o Amazon S3 com a finalidade de carregar os modelos de pod. Para obter mais informações, consulte [Criação de um perfil de execução de trabalho](#).

Você pode usar `SparkSubmitParameters` para especificar o caminho do Amazon S3 para o modelo de pod, como demonstra o arquivo JSON de execução de trabalho a seguir.

```
{  
  "name": "myjob",
```

```

"virtualClusterId": "123456",
"executionRoleArn": "iam_role_name_for_job_execution",
"releaseLabel": "release_label",
"jobDriver": {
  "sparkSubmitJobDriver": {
    "entryPoint": "entryPoint_location",
    "entryPointArguments": [argument1, argument2, ...],
    "sparkSubmitParameters": "--class <main_class> \
      --conf
spark.kubernetes.driver.podTemplateFile=s3://path_to_driver_pod_template \
      --conf
spark.kubernetes.executor.podTemplateFile=s3://path_to_executor_pod_template \
      --conf spark.executor.instances=2 \
      --conf spark.executor.memory=2G \
      --conf spark.executor.cores=2 \
      --conf spark.driver.cores=1"
  }
}
}

```

Como alternativa, você pode usar `configurationOverrides` para especificar o caminho do Amazon S3 para o modelo de pod, como demonstra o arquivo JSON de execução de trabalho a seguir.

```

{
  "name": "myjob",
  "virtualClusterId": "123456",
  "executionRoleArn": "iam_role_name_for_job_execution",
  "releaseLabel": "release_label",
  "jobDriver": {
    "sparkSubmitJobDriver": {
      "entryPoint": "entryPoint_location",
      "entryPointArguments": [argument1, argument2, ...],
      "sparkSubmitParameters": "--class <main_class> \
        --conf spark.executor.instances=2 \
        --conf spark.executor.memory=2G \
        --conf spark.executor.cores=2 \
        --conf spark.driver.cores=1"
    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {

```

```
"classification": "spark-defaults",
"properties": {
  "spark.driver.memory": "2G",
  "spark.kubernetes.driver.podTemplateFile": "s3://path_to_driver_pod_template",
  "spark.kubernetes.executor.podTemplateFile": "s3://path_to_executor_pod_template"
}
]
```

Note

1. Você precisa seguir as diretrizes de segurança ao usar o recurso de modelo de pod com o Amazon EMR no EKS, por exemplo, como isolar códigos de aplicações não confiáveis. Para obter mais informações, consulte [Práticas recomendadas de segurança para o Amazon EMR no EKS](#).
2. Não é possível alterar os nomes dos contêineres principais do Spark ao usar `spark.kubernetes.driver.podTemplateContainerName` e `spark.kubernetes.executor.podTemplateContainerName`, porque esses nomes são codificados como `spark-kubernetes-driver` e `spark-kubernetes-executors`. Se desejar personalizar o contêiner principal do Spark, deverá especificar o contêiner em um modelo de pod com esses nomes codificados.

Campos do modelo de pod

Considere as restrições para campos apresentadas a seguir ao configurar um modelo de pod com o Amazon EMR no EKS.

- O Amazon EMR no EKS permite somente os campos a seguir em um modelo de pod para habilitar a programação adequada de trabalhos.

Estes são os campos permitidos em nível de pod:

- `apiVersion`
- `kind`
- `metadata`

- `spec.activeDeadlineSeconds`
- `spec.affinity`
- `spec.containers`
- `spec.enableServiceLinks`
- `spec.ephemeralContainers`
- `spec.hostAliases`
- `spec.hostname`
- `spec.imagePullSecrets`
- `spec.initContainers`
- `spec.nodeName`
- `spec.nodeSelector`
- `spec.overhead`
- `spec.preemptionPolicy`
- `spec.priority`
- `spec.priorityClassName`
- `spec.readinessGates`
- `spec.runtimeClassName`
- `spec.schedulerName`
- `spec.subdomain`
- `spec.terminationGracePeriodSeconds`
- `spec.tolerations`
- `spec.topologySpreadConstraints`
- `spec.volumes`

Estes são os campos permitidos em nível de contêiner principal do Spark:

- `env`
- `envFrom`
- `name`
- `lifecycle`

- `livenessProbe`
- `readinessProbe`

- `resources`
- `startupProbe`
- `stdin`
- `stdinOnce`
- `terminationMessagePath`
- `terminationMessagePolicy`
- `tty`
- `volumeDevices`
- `volumeMounts`
- `workingDir`

Quando você usa qualquer campo não permitido no modelo de pod, o Spark gera uma exceção e o trabalho falha. O exemplo a seguir mostra uma mensagem de erro no log do controlador do Spark devido ao uso de campos não permitidos.

```
Executor pod template validation failed.  
Field container.command in Spark main container not allowed but specified.
```

- O Amazon EMR no EKS define previamente os parâmetros apresentados a seguir em um modelo de pod. Os campos especificados em um modelo de pod não devem se sobrepor a esses campos.

Estes são os nomes de volumes definidos previamente:

- `emr-container-communicate`
- `config-volume`
- `emr-container-application-log-dir`
- `emr-container-event-log-dir`
- `temp-data-dir`
- `mnt-dir`
- `home-dir`
- `emr-container-s3`

Estas são as montagens de volume definidas previamente que se aplicam somente ao contêiner principal do Spark:

Campos do modelo de pod

- `Nome:emr-container-communicate; MountPath: /var/log/fluend`

- Nome: `emr-container-application-log-dir`; MountPath: `/var/log/spark/user`
- Nome: `emr-container-event-log-dir`; MountPath: `/var/log/spark/apps`
- Nome: `mnt-dir`; MountPath: `/mnt`
- Nome: `temp-data-dir`; MountPath: `/tmp`
- Nome: `home-dir`; MountPath: `/home/hadoop`

Estas são as variáveis de ambiente definidas previamente que se aplicam somente ao contêiner principal do Spark:

- `SPARK_CONTAINER_ID`
- `K8S_SPARK_LOG_URL_STDERR`
- `K8S_SPARK_LOG_URL_STDOUT`
- `SIDECAR_SIGNAL_FILE`

Note

Você ainda pode usar esses volumes definidos previamente e montá-los em seus contêineres sidecar adicionais. Por exemplo, é possível usar `emr-container-application-log-dir` e montá-lo em seu próprio contêiner sidecar definido no modelo de pod.

Se os campos especificados entrarem em conflito com qualquer um dos campos definidos previamente no modelo de pod, o Spark gerará uma exceção e o trabalho falhará. O exemplo a seguir mostra uma mensagem de erro no log da aplicação do Spark devido a conflitos com os campos definidos previamente.

```
Defined volume mount path on main container must not overlap with reserved mount paths: [<reserved-paths>]
```

Considerações sobre contêineres sidecar

O Amazon EMR controla o ciclo de vida dos pods provisionados pelo Amazon EMR no EKS. Os contêineres sidecar devem seguir um ciclo de vida semelhante ao do contêiner principal do Spark. Se você injetar contêineres sidecar adicionais em seus pods, recomendamos a integração com o

gerenciamento do ciclo de vida do pod definido pelo Amazon EMR para que o contêiner sidecar possa ser interrompido sozinho quando o contêiner principal do Spark sair.

Para reduzir custos, recomendamos implementar um processo que impeça que pods de drivers com contêineres sidecar continuem em execução após a conclusão do seu trabalho. O driver do Spark exclui os pods de executores quando o executor é encerrado. No entanto, quando um programa de driver é concluído, os contêineres sidecar adicionais continuam em execução. O pod é faturado até que o Amazon EMR no EKS limpe o pod do driver. Geralmente, isso ocorre menos de um minuto após a conclusão do contêiner principal do driver do Spark. Para reduzir custos, você pode integrar os contêineres sidecar adicionais ao mecanismo de gerenciamento do ciclo de vida que o Amazon EMR no EKS define para os pods de drivers e de executores, conforme descrito na seção a seguir.

O contêiner principal do Spark nos pods de drivers e de executores envia heartbeat para um arquivo `/var/log/fluentd/main-container-terminated` a cada dois segundos. Ao adicionar a montagem de volume `emr-container-communicate` definida previamente do Amazon EMR ao contêiner sidecar, você pode definir um subprocesso do contêiner sidecar para monitorar periodicamente o horário da última modificação desse arquivo. O subprocesso é interrompido sozinho caso descubra que o contêiner principal do Spark interrompeu a heartbeat por um período mais longo.

O exemplo apresentado a seguir demonstra um subprocesso que rastreia o arquivo de pulsação e é interrompido sozinho. *your_volume_mount* Substitua pelo caminho em que você monta o volume predefinido. O script é empacotado dentro da imagem usada pelo contêiner sidecar. Em um arquivo de modelo de pod, você pode especificar um contêiner sidecar com os seguintes comandos: `sub_process_script.sh` e `main_command`.

```
MOUNT_PATH="your_volume_mount"
FILE_TO_WATCH="$MOUNT_PATH/main-container-terminated"
INITIAL_HEARTBEAT_TIMEOUT_THRESHOLD=60
HEARTBEAT_TIMEOUT_THRESHOLD=15
SLEEP_DURATION=10

function terminate_main_process() {
    # Stop main process
}

# Waiting for the first heartbeat sent by Spark main container
echo "Waiting for file $FILE_TO_WATCH to appear..."
start_wait=$(date +%s)
while ! [[ -f "$FILE_TO_WATCH" ]]; do
```

```

    elapsed_wait=$(expr $(date +%s) - $start_wait)
    if [ "$elapsed_wait" -gt "$INITIAL_HEARTBEAT_TIMEOUT_THRESHOLD" ]; then
        echo "File $FILE_TO_WATCH not found after $INITIAL_HEARTBEAT_TIMEOUT_THRESHOLD
seconds; aborting"
        terminate_main_process
        exit 1
    fi
    sleep $SLEEP_DURATION;
done;
echo "Found file $FILE_TO_WATCH; watching for heartbeats..."

while [[ -f "$FILE_TO_WATCH" ]]; do
    LAST_HEARTBEAT=$(stat -c %Y $FILE_TO_WATCH)
    ELAPSED_TIME_SINCE_AFTER_HEARTBEAT=$(expr $(date +%s) - $LAST_HEARTBEAT)
    if [ "$ELAPSED_TIME_SINCE_AFTER_HEARTBEAT" -gt "$HEARTBEAT_TIMEOUT_THRESHOLD" ];
then
        echo "Last heartbeat to file $FILE_TO_WATCH was more than
$HEARTBEAT_TIMEOUT_THRESHOLD seconds ago at $LAST_HEARTBEAT; terminating"
        terminate_main_process
        exit 0
    fi
    sleep $SLEEP_DURATION;
done;
echo "Outside of loop, main-container-terminated file no longer exists"

# The file will be deleted once the fluentd container is terminated

echo "The file $FILE_TO_WATCH doesn't exist any more;"
terminate_main_process
exit 0

```

Uso de políticas de repetição de trabalho

Nas versões 6.9.0 e posteriores do Amazon EMR no EKS, você pode definir uma política de repetição para as execuções de trabalhos. As políticas de repetição fazem com que um pod do driver de trabalho seja reiniciado automaticamente se falhar ou for excluído. Isso torna os trabalhos de transmissão do Spark de execução prolongada mais resistentes a falhas.

Definição de uma política de repetição para um trabalho

Para configurar uma política de repetição, você fornece um `RetryPolicyConfiguration` campo usando a [StartJobRun](#) API. Um exemplo de `retryPolicyConfiguration` é mostrado aqui:

```
aws emr-containers start-job-run \
--virtual-cluster-id cluster_id \
--name sample-job-name \
--execution-role-arn execution-role-arn \
--release-label emr-6.9.0-latest \
--job-driver '{
  "sparkSubmitJobDriver": {
    "entryPoint": "local:///usr/lib/spark/examples/src/main/python/pi.py",
    "entryPointArguments": [ "2" ],
    "sparkSubmitParameters": "--conf spark.executor.instances=2 --conf
spark.executor.memory=2G --conf spark.executor.cores=2 --conf spark.driver.cores=1"
  }
}' \
--retry-policy-configuration '{
  "maxAttempts": 5
}' \
--configuration-overrides '{
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "my_log_group_name",
      "logStreamNamePrefix": "my_log_stream_prefix"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://amzn-s3-demo-logging-bucket"
    }
  }
}'
```

Note

retryPolicyConfigurationsó está disponível a partir da versão AWS CLI 1.27.68. Para atualizar o AWS CLI para a versão mais recente, consulte [Instalando ou atualizando a versão mais recente do AWS CLI](#)

Configure o campo maxAttempts com o número máximo de vezes que você deseja que o pod do driver de trabalho seja reiniciado em casos de falhas ou exclusões. O intervalo de execução entre duas tentativas de repetição do driver de trabalho é um intervalo de repetição exponencial de (10 segundos, 20 segundos, 40 segundos...) que é limitado a seis minutos, conforme descrito na [documentação do Kubernetes](#).

 Note

Cada execução adicional de um driver de trabalho será cobrada como outra execução de trabalho e estará sujeita aos [preços do Amazon EMR no EKS](#).

Valores de configuração da política de repetição

- Política de repetição padrão para um trabalho: `StartJobRun` inclui uma política de repetição definida como uma tentativa máxima, por padrão. Você pode configurar a política de repetição conforme desejado.

 Note

Se `maxAttempts` da `retryPolicyConfiguration` for definido como uma, significa que nenhuma nova tentativa será feita para ativar o pod do driver em caso de falha.

- Desabilitando a política de repetição de um trabalho: para desativar uma política de repetição, defina o valor máximo de tentativas como 1. `retryPolicyConfiguration`

```
"retryPolicyConfiguration": {  
  "maxAttempts": 1  
}
```

- Definição de `maxAttempts` para um trabalho dentro do intervalo válido: a chamada `StartJobRun` falhará se o valor de `maxAttempts` estiver fora do intervalo válido. O intervalo válido de `maxAttempts` é de 1 a 2.147.483.647 (número inteiro de 32 bits), que corresponde ao intervalo compatível com a configuração `backOffLimit` do Kubernetes. Para obter mais informações, consulte [Pod backoff failure policy](#) na documentação do Kubernetes. Se o valor de `maxAttempts` for inválido, a seguinte mensagem de erro será retornada:

```
{  
  "message": "Retry policy configuration's parameter value of maxAttempts is invalid"  
}
```

Recuperação de um status da política de repetição para um trabalho

Você pode ver o status das tentativas de repetição de um trabalho com [ListJobRuns](#).

[DescribeJobRun](#) APIs Depois de solicitar um trabalho com uma configuração de política de repetição habilitada, as respostas `ListJobRun` e `DescribeJobRun` conterão o status da política de repetição no campo `RetryPolicyExecution`. Além disso, a resposta `DescribeJobRun` conterá a `RetryPolicyConfiguration` que foi inserida na solicitação `StartJobRun` para o trabalho.

Exemplo de respostas

ListJobRuns response

```
{
  "jobRuns": [
    ...
    ...
    "retryPolicyExecution" : {
      "currentAttemptCount": 2
    }
    ...
    ...
  ]
}
```

DescribeJobRun response

```
{
  ...
  ...
  "retryPolicyConfiguration": {
    "maxAttempts": 5
  },
  "retryPolicyExecution" : {
    "currentAttemptCount": 2
  },
  ...
  ...
}
```

Esses campos não ficarão visíveis quando a política de repetição estiver desabilitada no trabalho, conforme descrito abaixo em [Valores de configuração da política de repetição](#).

Monitoramento de um trabalho com uma política de repetição

Quando você ativa uma política de repetição, um CloudWatch evento é gerado para cada driver de trabalho criado. Para se inscrever nesses eventos, configure uma regra de CloudWatch evento usando o seguinte comando:

```
aws events put-rule \  
--name cwe-test \  
--event-pattern '{"detail-type": ["EMR Job Run New Driver Attempt"]}'
```

O evento retornará informações sobre o `newDriverPodName`, o carimbo de data/hora `newDriverCreatedAt`, a `previousDriverFailureMessage` e o `currentAttemptCount` dos drivers de trabalho. Esses eventos não serão criados se a política de repetição estiver desabilitada.

Para obter mais informações sobre como monitorar seu trabalho com CloudWatch eventos, consulte [Monitore trabalhos com a Amazon CloudWatch Events](#).

Descoberta de logs para drivers e executores

Os nomes dos pods de drivers seguem o formato `spark-<job id>-driver-<random-suffix>`. O mesmo `random-suffix` é adicionado aos nomes dos pods de executores que o driver gera. Ao usar esse `random-suffix`, você pode localizar logs de um driver e seus executores associados. O `random-suffix` estará presente somente se a [política de repetição estiver habilitada](#) para o trabalho. Caso contrário, o `random-suffix` estará ausente.

Para obter mais informações sobre como configurar trabalhos com uma configuração de monitoramento para o registro em log, consulte [Execução de uma aplicação do Spark](#).

Uso da alternância de log de eventos do Spark

Com as versões 6.3.0 e posteriores do Amazon EMR, você pode ativar o recurso de alternância de log de eventos do Spark para o Amazon EMR no EKS. Em vez de gerar um único arquivo de log de eventos, esse recurso alterna o arquivo com base no intervalo de tempo configurado e remove os arquivos de log de eventos mais antigos.

A alternância de logs de eventos do Spark pode ajudar você a evitar possíveis problemas com um grande arquivo de log de eventos do Spark gerado para trabalhos de execução prolongada ou de transmissão. Por exemplo, você inicia um trabalho de execução prolongada do Spark com um log

de eventos habilitado com o parâmetro `persistantAppUI`. O driver do Spark gera um arquivo de log de eventos. Se o trabalho for executado por horas ou por dias, e houver um espaço em disco limitado no nó do Kubernetes, o arquivo de log de eventos poderá consumir todo o espaço em disco disponível. Ativar o recurso de alternância de log de eventos do Spark resolve o problema ao dividir o arquivo de log em vários arquivos e remover os arquivos mais antigos.

Note

Esse recurso funciona somente com o Amazon EMR no EKS. O Amazon EMR executado na Amazon EC2 não oferece suporte à rotação do log de eventos do Spark.

Para ativar o recurso de alternância de log de eventos do Spark, configure os seguintes parâmetros do Spark:

- `spark.eventLog.rotation.enabled`: ativa a alternância de log. Por padrão, ele está desabilitado no arquivo de configuração do Spark. Defina-o como verdadeiro para ativar esse recurso.
- `spark.eventLog.rotation.interval`: especifica o intervalo de tempo para a alternância de log. O valor mínimo é 60 segundos. O valor de padrão é de 300 segundos.
- `spark.eventLog.rotation.minFileSize`: especifica um tamanho mínimo de arquivo para alternar o arquivo de log. O valor mínimo e padrão é de 1 MB.
- `spark.eventLog.rotation.maxFilesToRetain`: especifica quantos arquivos de log alternados serão mantidos durante a limpeza. O intervalo válido é de 1 a 10. O valor padrão é 2.

Você pode especificar esses parâmetros na seção `sparkSubmitParameters` da API [StartJobRun](#), como mostra o exemplo a seguir.

```
"sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi --conf  
spark.eventLog.rotation.enabled=true --conf spark.eventLog.rotation.interval=300 --  
conf spark.eventLog.rotation.minFileSize=1m --conf  
spark.eventLog.rotation.maxFilesToRetain=2"
```

Uso da alternância de log do contêiner do Spark

Com as versões 6.11.0 e posteriores do Amazon EMR, você pode ativar o recurso de alternância de log do contêiner do Spark para o Amazon EMR no EKS. Em vez de gerar um arquivo único

de log `stdout` ou `stderr`, esse recurso alterna o arquivo com base na dimensão de alternância configurada e remove os arquivos de log mais antigos do contêiner.

A alternância de logs do contêiner do Spark pode ajudar você a evitar possíveis problemas com grandes arquivos de log do Spark gerados para trabalhos de execução prolongada ou de transmissão. Por exemplo, é possível iniciar um trabalho do Spark de execução prolongada e o driver do Spark gerar um arquivo de log do contêiner. Se o trabalho for executado por horas ou por dias, e houver um espaço em disco limitado no nó do Kubernetes, o arquivo de log do contêiner poderá consumir todo o espaço em disco disponível. Ao ativar a alternância de log do contêiner do Spark, você divide o arquivo de log em vários arquivos e remove os arquivos mais antigos.

Para ativar o recurso de alternância de log do contêiner do Spark, configure os seguintes parâmetros do Spark:

`containerLogRotationConfiguration`

Inclua esse parâmetro em `monitoringConfiguration` para ativar a alternância de log. O recurso é desabilitado por padrão. Você deve usar `containerLogRotationConfiguration` além de `s3MonitoringConfiguration`.

`rotationSize`

O parâmetro `rotationSize` especifica o tamanho do arquivo para a alternância de log. O intervalo de valores possíveis é de 2KB a 2GB. A parcela numérica da unidade do parâmetro `rotationSize` é transferida como um número inteiro. Como não há suporte para valores decimais, você pode especificar um tamanho de rotação de 1,5 GB, por exemplo, com o valor `1500MB`.

`maxFilesToKeep`

O parâmetro `maxFilesToKeep` especifica o número máximo de arquivos a serem retidos no contêiner após a alternância ter ocorrido. O valor mínimo é de 1 e o valor máximo é de 50.

Você pode especificar esses parâmetros na seção `monitoringConfiguration` da API `StartJobRun`, como mostra o exemplo a seguir. Neste exemplo, com `rotationSize = "10 MB"` e `maxFilesToKeep = 3`, o Amazon EMR no EKS alterna seus logs em 10 MB, gera um novo arquivo de log e, em seguida, limpa o arquivo de log mais antigo quando o número de arquivos de log atinge três.

```
{  
  "name": "my-long-running-job",
```



```

"virtualClusterId": "123456",
"executionRoleArn": "iam_role_name_for_job_execution",
"releaseLabel": "emr-6.11.0-latest",
"jobDriver": {
  "sparkSubmitJobDriver": {
    "entryPoint": "entryPoint_location",
    "entryPointArguments": ["argument1", "argument2", ...],
    "sparkSubmitParameters": "--class main_class --conf spark.executor.instances=2
--conf spark.executor.memory=2G --conf spark.executor.cores=2 --conf
spark.driver.cores=1"
  }
},
"configurationOverrides": {
  "applicationConfiguration": [
    {
      "classification": "spark-defaults",
      "properties": {
        "spark.driver.memory": "2G"
      }
    }
  ],
  "monitoringConfiguration": {
    "persistentAppUI": "ENABLED",
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "my_log_group",
      "logStreamNamePrefix": "log_stream_prefix"
    },
    "s3MonitoringConfiguration": {
      "logUri": "s3://my_s3_log_location"
    },
    "containerLogRotationConfiguration": {
      "rotationSize": "10MB",
      "maxFilesToKeep": "3"
    }
  }
}
}

```

Para iniciar uma execução de trabalho com a alternância de log do contêiner do Spark, inclua um caminho para o arquivo JSON que você configurou com esses parâmetros no comando [StartJobRun](#).

```
aws emr-containers start-job-run \
```

```
--cli-input-json file://path-to-json-request-file
```

Uso da escalabilidade automática vertical com trabalhos do Spark no Amazon EMR

A escalabilidade automática vertical do Amazon EMR no EKS ajusta automaticamente os recursos de memória e de CPU para se adaptar às necessidades da workload fornecida para aplicações do Spark no Amazon EMR. Isso simplifica o gerenciamento de recursos.

Para rastrear a utilização histórica e em tempo real dos recursos de suas aplicações do Spark no Amazon EMR, a escalabilidade automática vertical utiliza o [Vertical Pod Autoscaler \(VPA\)](#) do Kubernetes. A funcionalidade de escalabilidade automática vertical usa os dados que o VPA coleta para ajustar automaticamente os recursos de memória e de CPU atribuídos às aplicações do Spark. Este processo simplificado aumenta a confiabilidade e otimiza os custos.

Tópicos

- [Configuração da escalabilidade automática vertical para o Amazon EMR no EKS](#)
- [Conceitos básicos da escalabilidade automática vertical para o Amazon EMR no EKS](#)
- [Configuração da escalabilidade automática vertical para o Amazon EMR no EKS](#)
- [Monitoramento da escalabilidade automática vertical para o Amazon EMR no EKS](#)
- [Desinstalação do operador de escalabilidade automática vertical do Amazon EMR no EKS](#)

Configuração da escalabilidade automática vertical para o Amazon EMR no EKS

Este tópico ajuda você a preparar o cluster do Amazon EKS para enviar trabalhos do Spark no Amazon EMR com a escalabilidade automática vertical. O processo de configuração requer que você confirme ou conclua as tarefas apresentadas nas seguintes seções:

Tópicos

- [Pré-requisitos](#)
- [Instalação do Operator Lifecycle Manager \(OLM\) no cluster do Amazon EKS](#)
- [Instalação do operador de escalabilidade automática vertical do Amazon EMR no EKS](#)

Pré-requisitos

Conclua as tarefas apresentadas a seguir antes de instalar o operador do Kubernetes para escalabilidade automática vertical em seu cluster. Se você já completou algum dos pré-requisitos, pode ignorá-los e passar para os próximos.

- [Instale ou atualize para a versão mais recente do AWS CLI](#) — Se você já instalou o AWS CLI, confirme se você tem a versão mais recente.
- [Instale o kubectl](#): o kubectl é uma ferramenta de linha de comando que você usa para se comunicar com o servidor de API do Kubernetes. Você precisa do kubectl para instalar e monitorar artefatos relacionados à escalabilidade automática vertical no cluster do Amazon EKS.
- [Instale o Operator SDK](#): o Amazon EMR no EKS usa o Operator SDK como um gerenciador de pacotes durante a vida útil do operador de escalabilidade automática vertical instalado no cluster.
- [Instale o Docker](#): você precisa de acesso à CLI do Docker para autenticar e buscar as imagens do Docker relacionadas à escalabilidade automática vertical para instalar no cluster do Amazon EKS.
- [Instale o servidor de métricas do Kubernetes](#): você deve primeiro instalar o servidor de métricas para que o escalador automático vertical do pod possa buscar métricas do servidor da API do Kubernetes.
- [Comece a usar o Amazon EKS \(eksctl\)](#) (versão 1.24 ou superior): o ajuste de escala automático vertical é compatível com o Amazon EKS nas versões 1.24 e superior. Após criar o cluster, [registre-o para uso com o Amazon EMR](#).
- [Selecione um URI de imagem base do Amazon EMR](#) (versão 6.10.0 ou superiores): a escalabilidade automática vertical é compatível com as versões 6.10.0 e superiores do Amazon EMR.

Instalação do Operator Lifecycle Manager (OLM) no cluster do Amazon EKS

Use a CLI do Operator SDK para instalar o Operator Lifecycle Manager (OLM) no cluster do Amazon EMR no EKS no qual você deseja configurar a escalabilidade automática vertical, conforme mostrado no exemplo a seguir. Após configurá-lo, será possível usar o OLM para instalar e gerenciar o ciclo de vida do [operador de escalabilidade automática vertical do Amazon EMR](#).

```
operator-sdk olm install
```

Para validar a instalação, execute o comando `olm status`:

```
operator-sdk olm status
```

Verifique se o comando retorna um resultado com êxito semelhante ao seguinte exemplo de saída:

```
INFO[0007] Successfully got OLM status for version X.XX
```

Se a instalação não ocorrer com êxito, consulte [Solução de problemas de escalabilidade automática vertical do Amazon EMR no EKS](#).

Instalação do operador de escalabilidade automática vertical do Amazon EMR no EKS

Use as seguintes etapas para instalar o operador de escalabilidade automática vertical no cluster do Amazon EKS:

1. Configure as seguintes variáveis de ambiente que serão usadas para concluir a instalação:
 - **\$REGION** direciona para a Região da AWS do seu cluster. Por exemplo, `.us-west-2`
 - **\$ACCOUNT_ID** direciona para o ID da conta do Amazon ECR para sua região. Para obter mais informações, consulte [Contas de registro do Amazon ECR por região](#).
 - **\$RELEASE** direciona para a versão do Amazon EMR que você deseja usar para o cluster. Com a escalabilidade automática vertical, você deve usar o Amazon EMR versão 6.10.0 ou superiores.
2. Em seguida, obtenha tokens de autenticação para o [registro do Amazon ECR](#) do operador.

```
aws ecr get-login-password \
  --region region-id | docker login \
  --username AWS \
  --password-stdin $ACCOUNT_ID.dkr.ecr.region-id.amazonaws.com
```

3. Instale o operador de escalabilidade automática vertical do Amazon EMR no EKS com o seguinte comando:

```
ECR_URL=$ACCOUNT_ID.dkr.ecr.$REGION.amazonaws.com && \
REPO_DEST=dynamic-sizing-k8s-operator-olm-bundle && \
BUNDLE_IMG=emr-$RELEASE-dynamic-sizing-k8s-operator && \
operator-sdk run bundle \
$ECR_URL/$REPO_DEST/$BUNDLE_IMG\:latest
```

Isso criará uma versão do operador de escalabilidade automática vertical no namespace padrão do cluster do Amazon EKS. Use este comando para realizar a instalação em um namespace diferente:

```
operator-sdk run bundle \  
$ACCOUNT_ID.dkr.ecr.$REGION.amazonaws.com/dynamic-sizing-k8s-operator-olm-bundle/  
emr-$RELEASE-dynamic-sizing-k8s-operator:latest \  
-n operator-namespace
```

Note

Se o namespace especificado não existir, o OLM não instalará o operador. Para obter mais informações, consulte [Namespace do Kubernetes não encontrado](#).

4. Verifique se você instalou o operador com êxito usando a ferramenta de linha de comando `kubectl` do Kubernetes.

```
kubectl get csv -n operator-namespace
```

O comando `kubectl` deve retornar o operador de escalabilidade automática vertical recém-implantado com um status de Fase como Com êxito. Se você tiver problemas com a instalação ou com a configuração, consulte [Solução de problemas de escalabilidade automática vertical do Amazon EMR no EKS](#).

Conceitos básicos da escalabilidade automática vertical para o Amazon EMR no EKS

Use o ajuste de escala automático vertical para o Amazon EMR no EKS quando desejar que o ajuste automático de memória e recursos de CPU se adapte à workload da aplicação do Spark no Amazon EMR. Para obter mais informações, consulte [Using vertical autoscaling with Amazon EMR Spark jobs](#).

Envio de um trabalho do Spark com a escalabilidade automática vertical

Ao enviar um trabalho por meio da [StartJobRun](#) API, adicione as duas configurações a seguir ao driver do seu trabalho do Spark para ativar o escalonamento automático vertical:

```
"spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/  
dynamic.sizing":"true",  
"spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/  
dynamic.sizing.signature":"YOUR_JOB_SIGNATURE"
```

No código acima, a primeira linha ativa a funcionalidade de escalabilidade automática vertical. A linha seguinte é uma configuração de assinatura obrigatória que permite que você escolha uma assinatura para o seu trabalho.

Para obter mais informações sobre essas configurações e valores de parâmetros aceitáveis, consulte [Configuração da escalabilidade automática vertical para o Amazon EMR no EKS](#). Por padrão, seu trabalho é enviado com a opção somente monitoramento no modo Desativado para a escalabilidade automática vertical. Esse estado de monitoramento permite calcular e visualizar recomendações de recursos sem realizar a escalabilidade automática. Para obter mais informações, consulte [Modos da escalabilidade automática vertical](#).

O seguinte exemplo mostra como concluir um comando `start-job-run` de exemplo com a escalabilidade automática vertical:

```
aws emr-containers start-job-run \  
--virtual-cluster-id $VIRTUAL_CLUSTER_ID \  
--name $JOB_NAME \  
--execution-role-arn $EMR_ROLE_ARN \  
--release-label emr-6.10.0-latest \  
--job-driver '{  
  "sparkSubmitJobDriver": {  
    "entryPoint": "local:///usr/lib/spark/examples/src/main/python/pi.py"  
  }  
' \  
--configuration-overrides '{  
  "applicationConfiguration": [{  
    "classification": "spark-defaults",  
    "properties": {  
      "spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/  
dynamic.sizing": "true",  
      "spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/  
dynamic.sizing.signature": "test-signature"  
    }  
  }]  
'
```

Verificação de funcionalidade da escalabilidade automática vertical

Para verificar se a escalabilidade automática vertical está funcionando corretamente para o trabalho enviado, use `kubectl` para obter o recurso personalizado `verticalpodautoscaler` e visualizar suas recomendações de escalabilidade. Por exemplo, o seguinte comando consulta recomendações sobre o trabalho de exemplo da seção [Envio de um trabalho do Spark com a escalabilidade automática vertical](#):

```
kubectl get verticalpodautoscalers --all-namespaces \
-l=emr-containers.amazonaws.com/dynamic.sizing.signature=test-signature
```

A saída desta consulta deve ser semelhante à seguinte:

NAME	MODE	CPU	MEM
PROVIDED AGE			
ds-jceyefkxnhrvdzw6djum3naf2abm6o63a6dvjkkedqtkhlrf25eq-vpa 87m	Off	3304504865	True

Se a saída não for semelhante ou tiver um código de erro, consulte [Solução de problemas de escalabilidade automática vertical do Amazon EMR no EKS](#) para obter passos que ajudam a resolver o problema.

Configuração da escalabilidade automática vertical para o Amazon EMR no EKS

Você pode configurar o escalonamento automático vertical ao enviar trabalhos do Amazon EMR Spark por meio da API. [StartJobRun](#) Defina os parâmetros de configuração relacionados à escalabilidade automática no pod do driver do Spark, conforme mostrado no exemplo em [Envio de um trabalho do Spark com a escalabilidade automática vertical](#).

O operador de escalabilidade automática vertical do Amazon EMR no EKS recebe os pods de drivers que têm escalabilidade automática e, em seguida, configura a integração com o Vertical Pod Autoscaler (VPA) do Kubernetes usando as configurações no pod do driver. Isso facilita o rastreamento de recursos e a escalabilidade automática de pods de executores do Spark.

As seções a seguir descrevem os parâmetros que você pode usar ao configurar a escalabilidade automática vertical para o cluster do Amazon EKS.

Note

Configure o parâmetro de alternância de recursos como um rótulo e configure os parâmetros restantes como anotações no pod do driver do Spark. Os parâmetros de escalabilidade automática pertencem ao domínio `emr-containers.amazonaws.com/` e têm o prefixo `dynamic.sizing`.

Parâmetros necessários

Você deve incluir os dois seguintes parâmetros no driver de trabalho do Spark ao enviar o trabalho:

Chave	Description	Valores aceitos	Valor padrão	Tipo	Parâmetro do Spark ¹
<code>dynamic.sizing</code>	Alternância de recursos	<code>true</code> , <code>false</code>	não definido	rótulo	<code>spark.kubernetes.driver.label.emr-containers.amazonaws.com/dynamic.sizing</code>
<code>dynamic.sizing.signature</code>	Assinatura do trabalho	<code>string</code>	não definido	anotação	<code>spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.signature</code>

¹ Use esse parâmetro como um `SparkSubmitParameter` ou uma `ConfigurationOverride` na API `StartJobRun`.

- **dynamic.sizing**: é possível ativar e desativar a escalabilidade automática vertical com o rótulo `dynamic.sizing`. Para ativar a escalabilidade automática vertical, defina `dynamic.sizing` como `true` no pod do driver do Spark. Se você omitir esse rótulo ou defini-lo com qualquer valor diferente de `true`, a escalabilidade automática vertical será desativada.
- **dynamic.sizing.signature**: defina a assinatura do trabalho com a anotação `dynamic.sizing.signature` no pod do driver. A escalabilidade automática vertical agrega dados de uso de recursos em diferentes execuções de trabalhos do Spark no Amazon EMR para derivar recomendações de recursos. Você fornece o identificador exclusivo para unir os trabalhos.

Note

Se o seu trabalho se repetir em um intervalo fixo, como diariamente ou semanalmente, a assinatura do trabalho deverá permanecer a mesma para cada nova instância dele. Isso garante que a escalabilidade automática vertical possa computar e agregar recomendações em diferentes execuções do trabalho.

¹ Use esse parâmetro como um `SparkSubmitParameter` ou uma `ConfigurationOverride` na API `StartJobRun`.

Parâmetros opcionais

A escalabilidade automática vertical também oferece suporte aos parâmetros opcionais apresentados a seguir. Defina-os como anotações no pod do driver.

Chave	Description	Valores aceitos	Valor padrão	Tipo	Parâmetro do Spark ¹
dynamic.sizing.mode	Modo da escalabilidade automática vertical	Off, Initial, Auto	Off	anotação	<code>spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.mode</code>

Chave	Description	Valores aceitos	Valor padrão	Tipo	Parâmetro do Spark ¹
					onaws.com/dynamic.sizing.mode
dynamic.sizing.scale.memory	Habilitação da escalabilidade de memória	<i>true, false</i>	true	anotação	spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.scale.memory
dynamic.sizing.scale.cpu	Ativação ou desativação da escalabilidade de CPU	<i>true, false</i>	false	anotação	spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.scale.cpu

Chave	Description	Valores aceitos	Valor padrão	Tipo	Parâmetro do Spark ¹
<u>dynamic.sizing.scale.memory.min</u>	Limite mínimo para a escalabilidade de memória	string, <u>K8s resource.Quantity</u> , por exemplo: 1G	não definido	anotação	spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.scale.memory.min
<u>dynamic.sizing.scale.memory.max</u>	Limite máximo para a escalabilidade de memória	string, <u>K8s resource.Quantity</u> , por exemplo: 4G	não definido	anotação	spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.scale.memory.max

Chave	Description	Valores aceitos	Valor padrão	Tipo	Parâmetro do Spark ¹
dynamic.sizing.scale.cpu.min	Limite mínimo para a escalabilidade de CPU	string, K8s resource.Quantity , por exemplo: 1	não definido	anotação	<code>spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.scale.cpu.min</code>
dynamic.sizing.scale.cpu.max	Limite máximo para a escalabilidade de CPU	string, K8s resource.Quantity , por exemplo: 2	não definido	anotação	<code>spark.kubernetes.driver.annotation.emr-containers.amazonaws.com/dynamic.sizing.scale.cpu.max</code>

Modos da escalabilidade automática vertical

O parâmetro `mode` é mapeado para os diferentes modos de escalabilidade automática compatíveis com o VPA. Use a anotação `dynamic.sizing.mode` no pod do driver para definir o modo. Os seguintes valores têm suporte para este parâmetro:

- **Desativado:** um modo de simulação no qual é possível monitorar recomendações, mas a escalabilidade automática não é executada. Este é o modo padrão para a escalabilidade automática vertical. Nesse modo, o recurso de escalabilidade automática vertical do pod associado

computa recomendações e você pode monitorá-las usando ferramentas como o kubectl, o Prometheus e o Grafana.

- Inicial: neste modo, o VPA escala automaticamente os recursos quando o trabalho é iniciado, se houver recomendações disponíveis com base no histórico de execuções do trabalho, como no caso de um trabalho recorrente.
- Automático: neste modo, o VPA realiza a remoção de pods de executores do Spark e os escala automaticamente com as configurações de recursos recomendadas quando o pod do driver do Spark os reinicia. Às vezes, o VPA realiza a remoção de pods de executores do Spark em execução, portanto, isso pode resultar em latência adicional ao tentar novamente o executor interrompido.

Escalabilidade de recursos

Ao configurar a escalabilidade automática vertical, você pode escolher se deseja escalar os recursos de CPU e de memória. Defina as anotações `dynamic.sizing.scale.cpu` e `dynamic.sizing.scale.memory` como `true` ou `false`. Por padrão, a escalabilidade de CPU é definida como `false` e a escalabilidade de memória é definida como `true`.

Mínimos e máximos de recursos (limites)

Como opção, também é possível definir limites para os recursos de CPU e de memória. Escolha valores mínimo e máximo para esses recursos com as anotações `dynamic.sizing.[memory/cpu].[min/max]` ao ativar a escalabilidade automática. Por padrão, os recursos não têm limitações. Defina as anotações como valores de string que representam uma quantidade de recursos do Kubernetes. Por exemplo, defina `dynamic.sizing.memory.max` como `4G` para representar 4 GB.

Monitoramento da escalabilidade automática vertical para o Amazon EMR no EKS

Você pode usar a ferramenta de linha de comando kubectl do Kubernetes para listar as recomendações ativas relacionadas ao ajuste de escala automático vertical em seu cluster. Também é possível visualizar as assinaturas de trabalho rastreadas e limpar quaisquer recursos desnecessários associados às assinaturas.

Listagem das recomendações de escalabilidade automática vertical para o cluster

Use `kubectl` para obter o recurso `verticalpodautoscaler` e visualizar o status atual e as recomendações. O exemplo de consulta a seguir retorna todos os recursos ativos no cluster do Amazon EKS.

```
kubectl get verticalpodautoscalers \
-o custom-columns="NAME:.metadata.name, "\
"SIGNATURE:.metadata.labels.emr-containers\.amazonaws\.com/dynamic\.sizing
\.signature, "\
"MODE:.spec.updatePolicy.updateMode, "\
"MEM:.status.recommendation.containerRecommendations[0].target.memory" \
--all-namespaces
```

A saída desta consulta é semelhante à seguinte:

NAME	SIGNATURE	MODE	MEM
ds- <i>example-id-1</i> -vpa	<i>job-signature-1</i>	Off	<i>none</i>
ds- <i>example-id-2</i> -vpa	<i>job-signature-2</i>	Initial	12936384283

Consulta e exclusão das recomendações de escalabilidade automática vertical para o cluster

Quando você exclui um recurso de execução de trabalho de escalabilidade automática vertical do Amazon EMR, ele exclui automaticamente o objeto VPA associado que rastreia e armazena recomendações.

O seguinte exemplo usa `kubectl` para limpar as recomendações para um trabalho identificado por uma assinatura:

```
kubectl delete jobrun -n emr -l=emr-containers\.amazonaws\.com/dynamic\.sizing
\.signature=integ-test
jobrun.dynamicsizing.emr.services.k8s.aws "ds-job-signature" deleted
```

Se você não souber a assinatura específica do trabalho ou desejar limpar todos os recursos do cluster, poderá usar `--all` ou `--all-namespaces` em seu comando, em vez do ID exclusivo do trabalho, conforme mostrado no seguinte exemplo:

```
kubectl delete jobruns --all --all-namespaces
```

```
jobrun.dynamicsizing.emr.services.k8s.aws "ds-example-id" deleted
```

Desinstalação do operador de escalabilidade automática vertical do Amazon EMR no EKS

Se você deseja remover o operador de escalabilidade automática vertical do cluster do Amazon EKS, use o comando `cleanup` com a CLI do Operator SDK, conforme mostrado no exemplo a seguir. Isso também excluirá as dependências upstream instaladas com o operador, como o Vertical Pod Autoscaler.

```
operator-sdk cleanup emr-dynamic-sizing
```

Se houver trabalhos em execução no cluster quando você excluir o operador, esses trabalhos continuarão em execução sem a escalabilidade automática vertical. Se você enviar trabalhos no cluster após a exclusão o operador, o Amazon EMR no EKS ignorará quaisquer parâmetros relacionados à escalabilidade automática vertical que você possa ter definido durante a [configuração](#).

Execução de workloads interativas no Amazon EMR no EKS

Um endpoint interativo corresponde a um gateway que conecta o Amazon EMR Studio ao Amazon EMR no EKS para que você possa executar workloads interativas. É possível usar endpoints interativos com o EMR Studio para executar analytics interativos com conjuntos de dados em armazenamentos de dados como o [Amazon S3](#) e o [Amazon DynamoDB](#).

Casos de uso

- Criação de um script de ETL com a experiência do IDE do EMR Studio. O IDE ingere dados on-premises e os armazena no Amazon S3 após as transformações para análises posteriores.
- Uso de cadernos para explorar conjuntos de dados e treinar um modelo de machine learning para detectar anomalias nos conjuntos de dados.
- Criação de scripts que geram relatórios diários para aplicações de análise, como painéis de negócios.

Tópicos

- [Visão geral dos endpoints interativos](#)
- [Pré-requisitos para a criação de um endpoint interativo no Amazon EMR no EKS](#)
- [Criação de um endpoint interativo para o cluster virtual](#)
- [Definição de configurações para endpoints interativos](#)
- [Monitoramento de endpoints interativos](#)
- [Uso de cadernos Jupyter de hospedagem própria](#)
- [Como obter informações sobre endpoints interativos com comandos da CLI](#)

Visão geral dos endpoints interativos

Um endpoint interativo fornece a funcionalidade para os clientes interativos, como os que usam o Amazon EMR Studio, de se conectarem ao Amazon EMR em clusters do EKS para executar workloads interativas. O endpoint interativo está respaldado pelo Jupyter Enterprise Gateway que fornece a funcionalidade de gerenciamento remoto do ciclo de vida do kernel de que os clientes interativos precisam. Os kernels são processos específicos de linguagem que interagem com o cliente do Amazon EMR Studio baseado em Jupyter para executar workloads interativas.

Os endpoints interativos oferecem suporte aos seguintes kernels:

- Python 3
- PySpark no Kubernetes
- Apache Spark com o Scala

 Note

Os preços do Amazon EMR no EKS se aplicam aos endpoints e aos kernels interativos. Para obter mais informações, consulte a página [Preços do Amazon EMR no EKS](#).

As entidades apresentadas a seguir são necessárias para que o EMR Studio se conecte ao Amazon EMR no EKS.


- Cluster virtual do Amazon EMR no EKS: um cluster virtual corresponde a um namespace do Kubernetes no qual você registra o Amazon EMR. O Amazon EMR usa clusters virtuais para executar trabalhos e hospedar endpoints. É possível fazer backup de vários clusters virtuais usando o mesmo cluster físico. No entanto, cada cluster virtual é mapeado para um namespace em um cluster do Amazon EKS. Os clusters virtuais não criam quaisquer recursos ativos que contribuam para o seu faturamento ou que requeiram gerenciamento do ciclo de vida de forma externa ao serviço.
- Endpoint interativo do Amazon EMR no EKS: um endpoint interativo corresponde a um endpoint HTTPS ao qual os usuários do EMR Studio podem conectar um Workspace. É possível acessar os endpoints HTTPS somente ao usar o EMR Studio e criá-los em uma sub-rede privada da Amazon Virtual Private Cloud (Amazon VPC) para o cluster do Amazon EKS.

Os kernels Python, PySpark, e Spark Scala usam as permissões definidas na função de execução de tarefas do Amazon EMR no EKS para invocar outras. Serviços da AWS Todos os kernels e os usuários que se conectam ao endpoint interativo utilizam o perfil que você especificou ao criar o endpoint. Recomendamos que você crie endpoints separados para usuários diferentes e que os usuários tenham funções diferentes AWS Identity and Access Management (IAM).

- AWS Controlador do Application Load Balancer — O controlador do AWS Application Load Balancer gerencia o Elastic Load Balancing para um cluster Amazon EKS Kubernetes. O controlador provisiona um Application Load Balancer (ALB) quando você cria um recurso Ingress do Kubernetes. Um ALB revela um serviço do Kubernetes, como um endpoint interativo, de forma externa ao cluster do Amazon EKS, mas dentro da mesma Amazon VPC. Ao criar um endpoint interativo, também ocorre a implementação de um recurso Ingress que revela o endpoint

interativo por meio do ALB para os clientes interativos se conectarem. Você só precisa instalar um controlador do AWS Application Load Balancer para cada cluster do Amazon EKS.

O diagrama a seguir descreve a arquitetura dos endpoints interativos no Amazon EMR no EKS. Um cluster do Amazon EKS compreende a computação para executar as workloads de análise e o endpoint interativo. O controlador do Application Load Balancer é executado no namespace kube-system, enquanto as workloads e os endpoints interativos são executados no namespace especificado ao criar o cluster virtual. Quando você cria um endpoint interativo, o ambiente de gerenciamento do Amazon EMR no EKS cria a implantação do endpoint interativo no cluster do Amazon EKS. Além disso, uma instância da entrada do balanceador de carga do aplicativo é criada pelo controlador do balanceador de AWS carga. O Application Load Balancer fornece a interface externa para que os clientes, como o EMR Studio, se conectem ao cluster do Amazon EMR e executem workloads interativas.



Pré-requisitos para a criação de um endpoint interativo no Amazon EMR no EKS

Esta seção descreve os pré-requisitos para configurar um endpoint interativo que o EMR Studio poderá usar para se conectar a um cluster do Amazon EMR no EKS e executar workloads interativas.

AWS CLI

Siga as etapas em [Instalar ou atualizar para a versão mais recente do AWS CLI](#) para instalar a versão mais recente do AWS Command Line Interface (AWS CLI).

Instalação do eksctl

Siga as etapas descritas em [Instalar o kubectl](#) para instalar a versão mais recente do eksctl. Se você estiver usando a versão 1.22 ou versões posteriores do Kubernetes para o cluster do Amazon EKS, use uma versão do eksctl superior a 0.117.0.

Cluster Amazon EKS

Crie um cluster do Amazon EKS. Registre o cluster como um cluster virtual com o Amazon EMR no EKS. Confira abaixo os requisitos e as considerações para este cluster:

- O cluster deve estar na mesma Amazon Virtual Private Cloud (VPC) que seu EMR Studio.
- O cluster deve ter, no mínimo, uma sub-rede privada para ativar os endpoints interativos, vincular repositórios baseados em Git e iniciar o Application Load Balancer no modo privado.
- Deve existir, no mínimo, uma sub-rede privada em comum entre o EMR Studio e o cluster do Amazon EKS usado para registrar o cluster virtual. Isso garante que seu endpoint interativo apareça como uma opção nos WorkSpaces do Studio e ative a conectividade do Studio com o Application Load Balancer.

Existem dois métodos que você pode escolher para conectar o Studio e o cluster do Amazon EKS:

- Criar um cluster do Amazon EKS e associá-lo às sub-redes que pertencem ao seu EMR Studio.
- Como alternativa, crie um EMR Studio e especifique as sub-redes privadas para o cluster do Amazon EKS.
- ARM otimizado para Amazon EKS O Amazon Linux não é AMIs compatível com o Amazon EMR em endpoints interativos EKS.
- Somente [grupos de nós gerenciados pelo Amazon EKS e nós](#) provisionados do Karpenter são suportados.

Concessão de acesso ao cluster para o Amazon EMR no EKS

Use as etapas em [Concessão de acesso ao cluster para o Amazon EMR no EKS](#) para conceder acesso a um namespace específico em seu cluster para o Amazon EMR no EKS.

Ativação de IRSA no cluster do Amazon EKS

Para ativar os perfis do IAM para contas de serviço (IRSA) no cluster do Amazon EKS, siga as etapas em [Habilitação de perfis do IAM para contas de serviço \(IRSA\)](#).

Criação de um perfil de execução de trabalho do IAM

Você deve criar um perfil do IAM para executar workloads em endpoints interativos do Amazon EMR no EKS. Referimo-nos a esse perfil do IAM como perfil de execução de trabalho nesta documentação. Esse perfil do IAM é atribuído ao contêiner de endpoint interativo e aos contêineres de execução reais criados quando você envia trabalhos com o EMR Studio. Você precisará do nome do recurso da Amazon (ARN) do seu perfil de execução de trabalho para o Amazon EMR no EKS. Para isso, são necessárias duas etapas:

- [Crie um perfil do IAM para execução de trabalhos.](#)
- [Atualize a política de confiança do perfil de execução de trabalho.](#)

Concessão de acesso ao Amazon EMR no EKS para os usuários

A entidade do IAM (usuário ou perfil) que faz a solicitação para criar um endpoint interativo também deve ter as permissões do Amazon EC2 e de `emr-containers` apresentadas a seguir. Siga as etapas descritas em [Concessão de acesso ao Amazon EMR no EKS para os usuários](#) para conceder as permissões que permitem que o Amazon EMR no EKS crie, gerencie e exclua os grupos de segurança que limitam o tráfego de entrada para o balanceador de carga do seu endpoint interativo.

As seguintes permissões de `emr-containers` permitem que o usuário execute operações básicas do endpoint interativo:

```
"ec2:CreateSecurityGroup",  
"ec2:DeleteSecurityGroup",  
"ec2:AuthorizeSecurityGroupEgress",  
"ec2:AuthorizeSecurityGroupIngress",  
"ec2:RevokeSecurityGroupEgress",  
"ec2:RevokeSecurityGroupIngress"
```

```
"emr-containers:CreateManagedEndpoint",  
"emr-containers:ListManagedEndpoints",  
"emr-containers:DescribeManagedEndpoint",  
"emr-containers>DeleteManagedEndpoint"
```

Registro do cluster do Amazon EKS com o Amazon EMR

Configure um cluster virtual e mapeie-o para o namespace no cluster do Amazon EKS no qual você deseja executar os trabalhos. Para clusters AWS Fargate somente, use o mesmo namespace para o Amazon EMR no cluster virtual EKS e para o perfil Fargate.

Para obter informações sobre como configurar um cluster virtual do Amazon EMR no EKS, consulte [Registro do cluster do Amazon EKS com o Amazon EMR](#).

Implemente AWS o Load Balancer Controller no cluster Amazon EKS

É necessário um AWS Application Load Balancer para seu cluster Amazon EKS. Você precisa configurar somente um controlador do Application Load Balancer por cluster do Amazon EKS. Para obter informações sobre como configurar o controlador do AWS Application Load Balancer, consulte [Instalando o complemento Load AWS Balancer Controller](#) no Guia do usuário do Amazon EKS.

Criação de um endpoint interativo para o cluster virtual

Este tópico descreve algumas maneiras de criar um endpoint interativo usando a interface de linha de AWS comando (AWS CLI) e inclui detalhes sobre os parâmetros de configuração disponíveis.

Criação de um endpoint interativo com o comando **create-managed-endpoint**

Especifique os parâmetros no comando `create-managed-endpoint`, conforme apresentado a seguir. O Amazon EMR no EKS oferece suporte à criação de endpoints interativos com as versões 6.7.0 e superiores do Amazon EMR.

```
aws emr-containers create-managed-endpoint \  
--type JUPYTER_ENTERPRISE_GATEWAY \  
--virtual-cluster-id 1234567890abcdef0xxxxxxx \  
--name example-endpoint-name \  
--execution-role-arn arn:aws:iam::444455556666:role/JobExecutionRole \  

```

```
--release-label emr-6.9.0-latest \
--configuration-overrides '{
  "applicationConfiguration": [{
    "classification": "spark-defaults",
    "properties": {
      "spark.driver.memory": "2G"
    }
  }],
  "monitoringConfiguration": {
    "cloudWatchMonitoringConfiguration": {
      "logGroupName": "log_group_name",
      "logStreamNamePrefix": "log_stream_prefix"
    },
    "persistentAppUI": "ENABLED",
    "s3MonitoringConfiguration": {
      "logUri": "s3://my_s3_log_location"
    }
  }
}'
```

Para obter mais informações, consulte [Parâmetros para a criação de um endpoint interativo](#).

Criação de um endpoint interativo com parâmetros especificados em um arquivo JSON

1. Crie um arquivo `create-managed-endpoint-request.json` e especifique os parâmetros obrigatórios para o endpoint, conforme mostrado no seguinte arquivo JSON:

```
{
  "name": "MY_TEST_ENDPOINT",
  "virtualClusterId": "MY_CLUSTER_ID",
  "type": "JUPYTER_ENTERPRISE_GATEWAY",
  "releaseLabel": "emr-6.9.0-latest",
  "executionRoleArn": "arn:aws:iam::444455556666:role/JobExecutionRole",
  "configurationOverrides":
  {
    "applicationConfiguration":
    [
      {
        "classification": "spark-defaults",
        "properties":
        {
```

```

        "spark.driver.memory": "8G"
    }
}
],
"monitoringConfiguration":
{
    "persistentAppUI": "ENABLED",
    "cloudWatchMonitoringConfiguration":
    {
        "logGroupName": "my_log_group",
        "logStreamNamePrefix": "log_stream_prefix"
    },
    "s3MonitoringConfiguration":
    {
        "logUri": "s3://my_s3_log_location"
    }
}
}
}

```

2. Use o comando `create-managed-endpoint` com um caminho para o arquivo `create-managed-endpoint-request.json` armazenado localmente ou no Amazon S3.

```

aws emr-containers create-managed-endpoint \
--cli-input-json file:///./create-managed-endpoint-request.json --region AWS-Region

```

Saída da criação de endpoint interativo

Você deverá visualizar a saída a seguir no terminal. A saída inclui o nome e o identificador do seu novo endpoint interativo:

```

{
  "id": "1234567890abcdef0",
  "name": "example-endpoint-name",
  "arn": "arn:aws:emr-containers:us-west-2:111122223333:/
virtualclusters/444455556666/endpoints/444455556666",
  "virtualClusterId": "111122223333xxxxxxxx"
}

```

A execução de `aws emr-containers create-managed-endpoint` cria um certificado autoassinado que permite a comunicação HTTPS entre o EMR Studio e o servidor do endpoint interativo.

Se você executar `create-managed-endpoint` e não tiver concluído os pré-requisitos, o Amazon EMR retornará uma mensagem de erro com as ações que você deve realizar para continuar.

Parâmetros para a criação de um endpoint interativo

Tópicos

- [Parâmetros obrigatórios para endpoints interativos](#)
- [Parâmetros opcionais para endpoints interativos](#)

Parâmetros obrigatórios para endpoints interativos

Você deve especificar os seguintes parâmetros ao criar um endpoint interativo:

--type

Use `JUPYTER_ENTERPRISE_GATEWAY`. Este é o único tipo com suporte.

--virtual-cluster-id

O identificador do cluster virtual registrado com o Amazon EMR no EKS.

--name

Um nome descritivo para o endpoint interativo que auxilia os usuários do EMR Studio a selecioná-lo na lista suspensa.

--execution-role-arn

O nome do recurso da Amazon (ARN) do perfil de execução de trabalho do IAM para o Amazon EMR no EKS que foi criado como parte dos pré-requisitos.

--release-label

O rótulo da versão do Amazon EMR a ser usado para o endpoint. Por exemplo, `emr-6.9.0-latest`. O Amazon EMR no EKS oferece suporte a endpoints interativos com as versões 6.7.0 e superiores do Amazon EMR.

Parâmetros opcionais para endpoints interativos

Como opção, também é possível especificar os seguintes parâmetros ao criar um endpoint interativo:

--configuration-overrides

Para substituir as configurações padrão das aplicações, forneça um objeto de configuração. Você pode usar uma sintaxe abreviada para fornecer a configuração ou fazer referência ao objeto de configuração em um arquivo JSON.

Os objetos de configuração consistem em uma classificação, propriedades e configurações opcionais aninhadas. As propriedades consistem nas configurações que você deseja substituir neste arquivo. Você pode especificar várias classificações para diversas aplicações em um único objeto JSON. As classificações de configuração disponíveis variam de acordo com a versão do Amazon EMR no EKS. Para obter uma lista das classificações de configuração disponíveis para cada versão do Amazon EMR no EKS, consulte [Versões do Amazon EMR no EKS](#). Além das classificações de configuração listadas para cada versão, os endpoints interativos trazem a classificação adicional `jeg-config`. Para obter mais informações, consulte [Opções de configuração do Jupyter Enterprise Gateway \(JEG\)](#).

Definição de configurações para endpoints interativos

Esta seção contém uma série de tópicos que abrangem várias configurações para endpoints interativos e configurações de pod. Eles permitem monitorar e solucionar falhas, enviar informações de log para o Amazon S3 ou Amazon CloudWatch Logs para, ou criar endpoints interativos nos quais você especifica modelos de pod personalizados.

Tópicos

- [Monitorar trabalhos Spark do](#)
- [Especificação de modelos de pod personalizados com endpoints interativos](#)
- [Implantação de um pod do JEG em um grupo de nós](#)
- [Opções de configuração do Jupyter Enterprise Gateway \(JEG\)](#)
- [Modificando os parâmetros PySpark da sessão](#)
- [Imagem de kernel personalizada com o endpoint interativo](#)

Monitorar trabalhos Spark do

Para que você possa monitorar e solucionar falhas, configure seus endpoints interativos para que os trabalhos iniciados com o endpoint possam enviar informações de log para o Amazon S3, Amazon CloudWatch Logs ou ambos. As seções a seguir descrevem como enviar logs de aplicações do Spark para o Amazon S3 para os trabalhos do Spark executados com endpoints interativos do Amazon EMR no EKS.

Configuração da política do IAM para os logs do Amazon S3

Antes que seus kernels possam enviar dados de log ao Amazon S3, a política de permissões para o perfil de execução de trabalho deve incluir as permissões apresentadas a seguir. Substitua *amzn-s3-demo-destination-bucket* pelo nome do bucket de registro em log.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:PutObject",
        "s3:GetObject",
        "s3:ListBucket"
      ],
      "Resource": [
        "arn:aws:s3:::amzn-s3-demo-bucket",
        "arn:aws:s3:::amzn-s3-demo-bucket/*"
      ],
      "Sid": "AllowS3Putobject"
    }
  ]
}
```

Note

O Amazon EMR no EKS também pode criar um bucket do S3. Se um bucket do S3 não estiver disponível, inclua a permissão `s3:CreateBucket` na política do IAM.

Após conceder as permissões necessárias para o envio de logs ao bucket do S3 ao perfil de execução, os dados de log serão enviados para os locais do Amazon S3 apresentados a seguir. Isso acontece quando `s3MonitoringConfiguration` é transferido na seção `monitoringConfiguration` de uma solicitação `create-managed-endpoint`.

- Logs de driver: `logUri/virtual-cluster-id/endpoints/endpoint-id/containers/spark-application-id/spark-application-id-driver/(stderr.gz/stdout.gz)`.
- Logs de executor: `logUri/virtual-cluster-id/endpoints/endpoint-id/containers/spark-application-id/executor-pod-name-exec-<Number>/(stderr.gz/stdout.gz)`.

Note

O Amazon EMR no EKS não faz o upload dos logs do endpoint para o bucket do S3.

Especificação de modelos de pod personalizados com endpoints interativos

É possível criar endpoints interativos nos quais você especifica modelos de pod personalizados para drivers e executores. Os modelos de pod são especificações que determinam como ocorrerá a execução de cada pod. Você pode usar arquivos de modelo de pod para definir as configurações de pods de drivers ou de executores para as quais as configurações do Spark não oferecem suporte. No momento, os modelos de pod são compatíveis com as versões 6.3.0 e posteriores do Amazon EMR.

Para obter mais informações sobre modelos de pod, consulte [Using pod templates](#) no Guia de desenvolvimento do Amazon EMR no EKS.

O seguinte exemplo mostra como criar um endpoint interativo com modelos de pod:

```
aws emr-containers create-managed-endpoint \
  --type JUPYTER_ENTERPRISE_GATEWAY \
  --virtual-cluster-id virtual-cluster-id \
  --name example-endpoint-name \
  --execution-role-arn arn:aws:iam::aws-account-id:role/EKSClusterRole \
  --release-label emr-6.9.0-latest \
  --configuration-overrides '{
    "applicationConfiguration": [
      {
        "classification": "spark-defaults",
```

```

        "properties": {
            "spark.kubernetes.driver.podTemplateFile": "path/to/driver/
template.yaml",
            "spark.kubernetes.executor.podTemplateFile": "path/to/executor/
template.yaml"
        }
    ]}
}'

```

Implantação de um pod do JEG em um grupo de nós

O posicionamento do pod do JEG (Jupyter Enterprise Gateway) é um recurso que permite implantar um endpoint interativo em um grupo de nós específico. Com esse recurso, você pode definir configurações, como `instance type`, para o endpoint interativo.

Associação de um pod do JEG a um grupo de nós gerenciado

A propriedade de configuração apresentada a seguir permite especificar o nome de um grupo de nós gerenciado no cluster do Amazon EKS em que o pod do JEG será implantado.

```

//payload
--configuration-overrides '{
    "applicationConfiguration": [
        {
            "classification": "endpoint-configuration",
            "properties": {
                "managed-nodegroup-name": NodeGroupName
            }
        }
    ]
}'

```

Um grupo de nós deve ter o rótulo `for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName` do Kubernetes anexado a todos os nós que fazem parte do grupo de nós. Para listar todos os nós de um grupo de nós que têm essa etiqueta, use o seguinte comando:

```

kubectl get nodes --show-labels | grep for-use-with-emr-containers-managed-endpoint-
ng=NodeGroupName

```

Se a saída do comando acima não retornar nós que fazem parte do seu grupo de nós gerenciado, então não há nós no grupo de nós que tenham o rótulo `for-use-with-emr-containers-`

managed-endpoint-ng=*NodeGroupName* do Kubernetes anexado. Nesse caso, siga as etapas abaixo para anexar esse rótulo aos nós do seu grupo de nós.

1. Use o comando a seguir para adicionar o rótulo `for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName` do Kubernetes a todos os nós em um grupo de nós gerenciado *NodeGroupName*:

```
kubectl label nodes --selector eks:nodegroup-name=NodeGroupName for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName
```

2. Verifique se os nós foram rotulados corretamente usando o seguinte comando:

```
kubectl get nodes --show-labels | grep for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName
```

Um grupo de nós gerenciado deve estar associado a um grupo de segurança do cluster do Amazon EKS, o que geralmente acontece se você criou o cluster e o grupo de nós gerenciado usando `eksctl`. Você pode verificar isso no AWS console usando as etapas a seguir.

1. Acesse o cluster no console do Amazon EKS.
2. Acesse a guia de redes do cluster e anote o grupo de segurança do cluster.
3. Acesse a guia de computação do seu cluster e clique no nome do grupo de nós gerenciado.
4. Na guia Detalhes do grupo de nós gerenciado, verifique se o grupo de segurança do cluster anotado anteriormente está listado em Grupos de segurança.

Se o grupo de nós gerenciado não estiver anexado ao grupo de segurança do cluster do Amazon EKS, será necessário anexar a etiqueta `for-use-with-emr-containers-managed-endpoint-sg=ClusterName/NodeGroupName` ao grupo de segurança do grupo de nós. Use as etapas abaixo para anexar essa etiqueta.

1. Acesse o console do Amazon EC2 e clique em grupos de segurança no painel de navegação à esquerda.
2. Selecione o grupo de segurança do seu grupo de nós gerenciado ao clicar na caixa de seleção.
3. Na guia Etiquetas, adicione a etiqueta `for-use-with-emr-containers-managed-endpoint-sg=ClusterName/NodeGroupName` usando o botão Gerenciar etiquetas.

Associação de um pod do JEG a um grupo de nós autogerenciado

A propriedade de configuração apresentada a seguir permite especificar o nome de um grupo de nós autogerenciado ou não gerenciado no cluster do Amazon EKS em que o pod do JEG será implantado.

```
//payload
--configuration-overrides '{
  "applicationConfiguration": [
    {
      "classification": "endpoint-configuration",
      "properties": {
        "self-managed-nodegroup-name": NodeGroupName
      }
    }
  ]
}'
```

O grupo de nós deve ter o rótulo `for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName` do Kubernetes anexado a todos os nós que fazem parte do grupo de nós. Para listar todos os nós de um grupo de nós que têm essa etiqueta, use o seguinte comando:

```
kubectl get nodes --show-labels | grep for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName
```

Se a saída do comando acima não retornar nós que fazem parte do seu grupo de nós autogerenciado, então não há nós no grupo de nós que tenham o rótulo `for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName` do Kubernetes anexado. Nesse caso, siga as etapas abaixo para anexar esse rótulo aos nós do seu grupo de nós.

1. Se você criou o grupo de nós autogerenciado usando `eksctl`, use o comando a seguir para adicionar o rótulo `for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName` do Kubernetes a todos os nós no grupo de nós autogerenciado *NodeGroupName* de uma vez só.

```
kubectl label nodes --selector alpha.eksctl.io/nodegroup-name=NodeGroupName for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName
```

Caso não tenha usado `eksctl` para criar o grupo de nós autogerenciado, você precisará substituir o seletor no comando acima por um rótulo diferente do Kubernetes que esteja anexado a todos os nós do grupo de nós.

2. Use o seguinte comando para verificar se os nós foram rotulados corretamente:

```
kubectl get nodes --show-labels | grep for-use-with-emr-containers-managed-endpoint-ng=NodeGroupName
```

O grupo de segurança do grupo de nós autogerenciado deve ter a etiqueta `for-use-with-emr-containers-managed-endpoint-sg=ClusterName/NodeGroupName` anexada. Use as etapas apresentadas a seguir para anexar a etiqueta ao grupo de segurança do Console de gerenciamento da AWS.

1. Navegue até o console do Amazon EC2. Selecione Grupos de segurança no painel de navegação à esquerda.
2. Selecione a caixa de seleção ao lado do grupo de segurança do seu grupo de nós autogerenciado.
3. Na guia Etiquetas, use o botão Gerenciar etiquetas para adicionar a etiqueta `for-use-with-emr-containers-managed-endpoint-sg=ClusterName/NodeGroupName`. Substitua *ClusterName* e *NodeGroupName* com os valores apropriados.

Associação de um pod do JEG a um grupo de nós gerenciado com instâncias sob demanda

Você também pode definir rótulos adicionais, conhecidos como seletores de rótulos do Kubernetes, para especificar limitações ou restrições adicionais à execução de um endpoint interativo em um determinado nó ou grupo de nós. O exemplo a seguir mostra como usar as instâncias sob demanda do Amazon EC2 para um pod do JEG.

```
--configuration-overrides '{
  "applicationConfiguration": [
    {
      "classification": "endpoint-configuration",
      "properties": {
        "managed-nodegroup-name": NodeGroupName,
        "node-labels": "eks.amazonaws.com/capacityType:ON_DEMAND"
```

```

    }
  }
]
}'

```

Note

Você pode usar a propriedade `node-labels` somente com uma propriedade `managed-nodegroup-name` ou `self-managed-nodegroup-name`.

Opções de configuração do Jupyter Enterprise Gateway (JEG)

O Amazon EMR no EKS usa o Jupyter Enterprise Gateway (JEG) para ativar os endpoints interativos. É possível definir os valores a seguir para as configurações do JEG listadas como permitidas ao criar o endpoint.

- **`RemoteMappingKernelManager.cull_idle_timeout`**: tempo limite em segundos (inteiro), após o qual um kernel é considerado inativo e pronto para ser descartado. Valores iguais ou inferiores a 0 desativam o descarte. Tempos limite curtos podem resultar no descarte de kernels para usuários com conexões de rede ruins.
- **`RemoteMappingKernelManager.cull_interval`**: o intervalo em segundos (inteiro) no qual verificar se há kernels inativos que excedem o valor do tempo limite de descarte.

Modificando os parâmetros PySpark da sessão

Começando com o Amazon EMR no EKS versão 6.9.0, no Amazon EMR Studio você pode ajustar a configuração do Spark associada a uma PySpark sessão executando o comando `%%configure` mágico na célula do notebook EMR.

O exemplo a seguir mostra uma carga útil de exemplo que você pode usar para modificar a memória, os núcleos e outras propriedades do driver e do executor do Spark. Para as configurações `conf`, você pode definir qualquer configuração do Spark mencionada na [documentação de configuração do Apache Spark](#).

```

%%configure -f
{
  "driverMemory": "16G",
  "driverCores": 4,

```



```

"executorMemory" : "32G",
"executorCores": 2,
"conf": {
  "spark.dynamicAllocation.maxExecutors" : 10,
  "spark.dynamicAllocation.minExecutors": 1
}
}

```

O exemplo a seguir mostra uma carga útil de exemplo que você pode usar para adicionar arquivos, pyFiles e dependências em JAR a um runtime do Spark.

```

%%configure -f
{
  "files": "s3://amzn-s3-demo-bucket-emr-eks/sample_file.txt",
  "pyFiles": : "path-to-python-files",
  "jars" : "path-to-jars"
}

```

Imagem de kernel personalizada com o endpoint interativo

Para garantir que você tenha as dependências corretas para sua aplicação ao executar as workloads interativas do Amazon EMR Studio, você pode personalizar as imagens do Docker para os endpoints interativos e executar imagens base de kernel personalizadas. Para criar um endpoint interativo e conectá-lo a uma imagem do Docker personalizada, execute as etapas a seguir.

Note

Você pode substituir somente as imagens base. Não é possível adicionar novos tipos de imagens de kernel.

1. Crie e publique uma imagem do Docker personalizada. A imagem base contém o runtime do Spark e os kernels do caderno que são executados com ele. Para criar a imagem, você pode seguir as etapas de 1 a 4 descritas em [Como personalizar imagens do Docker](#). Na etapa 1, o URI da imagem base em seu arquivo do Docker deve usar notebook-spark no lugar de spark.

```

ECR-registry-account.dkr.ecr.Region.amazonaws.com/notebook-spark/container-image-tag

```

Para obter mais informações sobre como selecionar Regiões da AWS e armazenar tags de imagem, consulte [Detalhes sobre como selecionar um URI de imagem base](#).

2. Crie um endpoint interativo que possa ser usado com a imagem personalizada.
 - a. Crie um arquivo JSON `custom-image-managed-endpoint.json` com o conteúdo apresentado a seguir. Este exemplo usa a versão 6.9.0 do Amazon EMR.

Example

```
{
  "name": "endpoint-name",
  "virtualClusterId": "virtual-cluster-id",
  "type": "JUPYTER_ENTERPRISE_GATEWAY",
  "releaseLabel": "emr-6.9.0-latest",
  "executionRoleArn": "execution-role-arn",
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "jupyter-kernel-overrides",
        "configurations": [
          {
            "classification": "python3",
            "properties": {
              "container-image": "123456789012.dkr.ecr.us-west-2.amazonaws.com/custom-notebook-python:latest"
            }
          },
          {
            "classification": "spark-python-kubernetes",
            "properties": {
              "container-image": "123456789012.dkr.ecr.us-west-2.amazonaws.com/custom-notebook-spark:latest"
            }
          }
        ]
      }
    ]
  }
}
```

- b. Crie um endpoint interativo com as configurações especificadas no arquivo JSON, conforme mostrado no exemplo a seguir. Para obter mais informações, consulte [Criação de um endpoint interativo com o comando create-managed-endpoint](#).

```
aws emr-containers create-managed-endpoint --cli-input-json custom-image-managed-endpoint.json
```

3. Conecte-se ao endpoint interativo usando o EMR Studio. Para obter mais informações e etapas a serem concluídas, consulte [Conectando-se do Studio](#) na seção Amazon EMR no EKS dos documentos do AWS Workshop Studio.

Monitoramento de endpoints interativos

Com o Amazon EMR no EKS versão 6.10 e posterior, os endpoints interativos emitem métricas da CloudWatch Amazon para monitorar e solucionar problemas nas operações do ciclo de vida do kernel. As métricas são acionadas por clientes interativos, como o EMR Studio ou os cadernos Jupyter de hospedagem própria. Cada uma das operações compatíveis com os endpoints interativos tem métricas associadas a elas. As operações são modeladas como dimensões para cada métrica, conforme mostrado na tabela abaixo. As métricas emitidas por endpoints interativos são visíveis em um namespace personalizado, EMRContainers, em sua conta.

Métrica	Description	Unidade
RequestCount	Número cumulativo de solicitações de uma operação processada pelo endpoint interativo.	Contagem
RequestLatency	O horário entre uma solicitação chegar ao endpoint interativo e uma resposta ser enviada pelo endpoint interativo.	Milissegundo
4 XXError	Emitido quando uma solicitação de uma operação resulta	Contagem

Métrica	Description	Unidade
	em um erro 4xx durante o processamento.	
5XXError	Emitido quando uma solicitação de uma operação resulta em um erro 5Xxx no lado do servidor.	Contagem
KernelLaunchSuccess	Aplicável somente para a CreateKernel operação. Indica o número cumulativo de inicializações de kernel que ocorreram com êxito até e incluindo esta solicitação.	Contagem
KernelLaunchFailure	Aplicável somente para a CreateKernel operação. Indica o número cumulativo de falhas de inicialização de kernel até e incluindo esta solicitação.	Contagem

Cada métrica do endpoint interativo tem as seguintes dimensões anexadas a ela:

- **ManagedEndpointId**: identificador para o endpoint interativo.
- **OperationName**: a operação acionada pelo cliente interativo.

Os valores possíveis para a dimensão **OperationName** são mostrados na seguinte tabela:

operationName	Descrição da operação
CreateKernel	Solicita que o endpoint interativo inicie um kernel.

operationName	Descrição da operação
ListKernels	Solicita que o endpoint interativo liste os kernels que foram iniciados anteriormente usando o mesmo token de sessão.
GetKernel	Solicita que o endpoint interativo obtenha detalhes sobre um kernel específico que foi iniciado anteriormente.
ConnectKernel	Solicita que o endpoint interativo estabeleça conectividade entre o cliente do caderno e o kernel.
ConfigureKernel	Publica %%configure magic request em um kernel do PySpark.
ListKernelSpecs	Solicita que o endpoint interativo liste as especificações de kernel disponíveis.
GetKernelSpec	Solicita que o endpoint interativo obtenha as especificações de kernel de um kernel que foi iniciado anteriormente.
GetKernelSpecResource	Solicita que o endpoint interativo obtenha recursos específicos associados às especificações do kernel que foram iniciadas anteriormente.

Exemplos

Para acessar o número total de kernels iniciados para um endpoint interativo em um determinado dia:

1. Selecione o namespace personalizado: EMRContainers.
2. Selecione o ManagedEndpointId e OperationName – CreateKernel.

3. A métrica `RequestCount` com a estatística `SUM` e o período de 1 day fornecerá todas as solicitações de inicialização do kernel realizadas nas últimas 24 horas.
4. `KernelLaunchSuccess` A métrica com estatística `SUM` e período 1 day fornecerá todas as solicitações bem-sucedidas de inicialização do kernel feitas nas últimas 24 horas.

Para acessar o número de falhas de kernel para um endpoint interativo em um determinado dia:

1. Selecione o namespace personalizado: `EMRContainers`
2. Selecione o `ManagedEndpointId` e `OperationName - CreateKernel`.
3. A métrica `KernelLaunchFailure` com a estatística `SUM` e o período de 1 day fornecerá todas as solicitações de inicialização do kernel com falha realizadas nas últimas 24 horas. Você também pode selecionar as métricas `4XXError` e `5XXError` para saber que tipo de falha na inicialização do kernel ocorreu.

Uso de cadernos Jupyter de hospedagem própria

Você pode hospedar e gerenciar o Jupyter ou JupyterLab notebooks em uma instância do Amazon EC2 ou em seu próprio cluster Amazon EKS como um notebook Jupyter auto-hospedado. Em seguida, é possível executar workloads interativas com seus cadernos Jupyter de hospedagem própria. As seções apresentadas a seguir descrevem o processo de configuração e de implantação de um caderno Jupyter de hospedagem própria em um cluster do Amazon EKS.

Criação de um caderno Jupyter de hospedagem própria em um cluster do EKS

- [Criar um grupo de segurança](#)
- [Criação de um endpoint interativo do Amazon EMR no EKS](#)
- [Recuperação do URL do servidor de gateway do endpoint interativo](#)
- [Recuperação de um token de autenticação para a conexão com o endpoint interativo](#)
- [Exemplo: implantar um JupyterLab notebook](#)
- [Exclusão de um caderno Jupyter de hospedagem própria](#)

Criar um grupo de segurança

Antes de criar um endpoint interativo e executar um Jupyter ou JupyterLab notebook auto-hospedado, você deve criar um grupo de segurança para controlar o tráfego entre seu notebook e o endpoint interativo. Para usar o console do Amazon EC2 ou o SDK do Amazon EC2 para criar o grupo de segurança, consulte as etapas em [Create a security group](#) no Guia do usuário do Amazon EC2. Você deve criar o grupo de segurança na VPC em que deseja implantar seu servidor de cadernos.

Para seguir o exemplo deste guia, use a mesma VPC do cluster do Amazon EKS. Se você quiser hospedar seu notebook em uma VPC diferente da VPC do seu cluster Amazon EKS, talvez seja necessário criar uma conexão de emparelhamento entre essas duas VPCs. Para ver as etapas para criar uma conexão de emparelhamento entre duas VPCs, consulte [Criar uma conexão de emparelhamento de VPC](#) no Amazon VPC Getting Started Guide.

Você precisará do ID do grupo de segurança para [criar um endpoint interativo do Amazon EMR no EKS](#) na próxima etapa.

Criação de um endpoint interativo do Amazon EMR no EKS

Após criar o grupo de segurança para o seu caderno, use as etapas fornecidas em [Criação de um endpoint interativo para o cluster virtual](#) para criar um endpoint interativo. Você deve fornecer o ID do grupo de segurança criado para o seu caderno em [Criar um grupo de segurança](#).

Insira o ID de segurança no lugar das *your-notebook-security-group-id* seguintes configurações de substituição de configuração:

```
--configuration-overrides '{
  "applicationConfiguration": [
    {
      "classification": "endpoint-configuration",
      "properties": {
        "notebook-security-group-id": "your-notebook-security-group-id"
      }
    }
  ],
  "monitoringConfiguration": {
    ...'
```

Recuperação do URL do servidor de gateway do endpoint interativo

Após criar um endpoint interativo, recupere o URL do servidor de gateway usando o comando `describe-managed-endpoint` na AWS CLI. Você precisa desse URL para conectar seu caderno ao endpoint. O URL do servidor de gateway é um endpoint privado.

```
aws emr-containers describe-managed-endpoint \  
--region region \  
--virtual-cluster-id virtualClusterId \  
--id endpointId
```

Inicialmente, seu endpoint está no estado CREATING. Após alguns minutos, ele passa para o estado ACTIVE. Quando o endpoint estiver ACTIVE, ele estará pronto para uso.

Anote o atributo `serverUrl` que o comando `aws emr-containers describe-managed-endpoint` retorna do endpoint ativo. Você precisa dessa URL para conectar seu notebook ao endpoint ao [implantar seu Jupyter ou notebook auto-hospedado](#). JupyterLab

Recuperação de um token de autenticação para a conexão com o endpoint interativo

Para se conectar a um endpoint interativo a partir de um Jupyter ou JupyterLab notebook, você deve gerar um token de sessão com a API. `GetManagedEndpointSessionCredentials` O token atua como prova de autenticação para a conexão com o servidor de endpoint interativo.

O comando apresentado a seguir é explicado com mais detalhes com um exemplo de saída abaixo.

```
aws emr-containers get-managed-endpoint-session-credentials \  
--endpoint-identifier endpointArn \  
--virtual-cluster-identifier virtualClusterArn \  
--execution-role-arn executionRoleArn \  
--credential-type "TOKEN" \  
--duration-in-seconds durationInSeconds \  
--region region
```

endpointArn

O ARN do seu endpoint. Você pode descobrir o ARN no resultado de uma chamada `describe-managed-endpoint`.

virtualClusterArn

O ARN do cluster virtual.

executionRoleArn

O ARN do perfil de execução.

durationInSeconds

A duração, em segundos, pela qual o token é válido. A duração padrão é de 15 minutos (900) e a duração máxima é de 12 horas (43200).

region

A mesma região do seu endpoint.

A saída deve ser semelhante ao exemplo apresentado a seguir. Anote o *session-token* valor que você usará ao [implantar seu Jupyter ou notebook auto-hospedado](#). JupyterLab

```
{
  "id": "credentialsId",
  "credentials": {
    "token": "session-token"
  },
  "expiresAt": "2022-07-05T17:49:38Z"
}
```

Exemplo: implantar um JupyterLab notebook

Depois de concluir as etapas acima, você pode tentar este procedimento de exemplo para implantar um JupyterLab notebook no cluster Amazon EKS com seu endpoint interativo.

1. Crie um namespace para executar o servidor de cadernos.
2. Crie um arquivo localmente, chamado `notebook.yaml`, com o conteúdo apresentado a seguir. O conteúdo para o arquivo é descrito abaixo.

```
apiVersion: v1
kind: Pod
metadata:
  name: jupyter-notebook
  namespace: namespace
spec:
```

```
containers:
- name: minimal-notebook
  image: jupyter/all-spark-notebook:lab-3.1.4 # open source image
  ports:
  - containerPort: 8888
  command: ["start-notebook.sh"]
  args: ["--LabApp.token=''"]
  env:
  - name: JUPYTER_ENABLE_LAB
    value: "yes"
  - name: KERNEL_LAUNCH_TIMEOUT
    value: "400"
  - name: JUPYTER_GATEWAY_URL
    value: "serverUrl"
  - name: JUPYTER_GATEWAY_VALIDATE_CERT
    value: "false"
  - name: JUPYTER_GATEWAY_AUTH_TOKEN
    value: "session-token"
```

Se você estiver implantando o caderno Jupyter em um cluster somente do Fargate, rotule o pod do Jupyter com um rótulo `role`, conforme mostrado no seguinte exemplo:

```
...
metadata:
  name: jupyter-notebook
  namespace: default
  labels:
    role: example-role-name-label
spec:
  ...
```

namespace

O namespace do Kubernetes no qual o caderno é implantado.

serverUrl

O atributo `serverUrl` que o comando `describe-managed-endpoint` retornou em [Recuperação do URL do servidor de gateway do endpoint interativo](#).

session-token

O atributo `session-token` que o comando `get-managed-endpoint-session-credentials` retornou em [Recuperação de um token de autenticação para a conexão com o endpoint interativo](#).

KERNEL_LAUNCH_TIMEOUT

A quantidade de tempo, em segundos, que o endpoint interativo aguarda até que o kernel chegue ao estado `RUNNING`. Garanta tempo suficiente para a inicialização do kernel ser concluída ao definir o tempo limite de inicialização do kernel para um valor apropriado (máximo de 400 segundos).

KERNEL_EXTRA_SPARK_OPTS

Como opção, você pode transferir configurações adicionais do Spark para os kernels do Spark. Defina essa variável de ambiente com os valores da propriedade de configuração do Spark, conforme mostrado no seguinte exemplo:

```
- name: KERNEL_EXTRA_SPARK_OPTS
  value: "--conf spark.driver.cores=2
        --conf spark.driver.memory=2G
        --conf spark.executor.instances=2
        --conf spark.executor.cores=2
        --conf spark.executor.memory=2G
        --conf spark.dynamicAllocation.enabled=true
        --conf spark.dynamicAllocation.shuffleTracking.enabled=true
        --conf spark.dynamicAllocation.minExecutors=1
        --conf spark.dynamicAllocation.maxExecutors=5
        --conf spark.dynamicAllocation.initialExecutors=1
        "
```

3. Implante a especificação do pod no cluster do Amazon EKS:

```
kubectl apply -f notebook.yaml -n namespace
```

Isso iniciará um JupyterLab notebook mínimo conectado ao seu Amazon EMR no endpoint interativo EKS. Aguarde até que o pod esteja `RUNNING`. Você pode verificar seu status com o seguinte comando:

```
kubectl get pod jupyter-notebook -n namespace
```

Quando o pod estiver pronto, o comando `get pod` retornará uma saída semelhante a esta:

NAME	READY	STATUS	RESTARTS	AGE
jupyter-notebook	1/1	Running	0	46s

4. Anexe o grupo de segurança do caderno ao nó em que o caderno está programado.

- Primeiro, identifique o nó em que o pod `jupyter-notebook` está programado com o comando `describe pod`.

```
kubectl describe pod jupyter-notebook -n namespace
```


- Abra o console do Amazon EKS em <https://console.aws.amazon.com/eks/home#/clusters>.
- Navegue até a guia Computação do cluster do Amazon EKS e selecione o nó identificado pelo comando `describe pod`. Selecione o ID da instância para o nó.
- No menu Ações, selecione Segurança > Alterar grupos de segurança para anexar o grupo de segurança que você criou em [Criar um grupo de segurança](#).
- Se você estiver implantando o pod do notebook Jupyter AWS Fargate, crie um [SecurityGroupPolicy](#) para aplicar ao pod do notebook Jupyter com o rótulo de função:

```
cat >my-security-group-policy.yaml <<EOF
apiVersion: vpcresources.k8s.aws/v1beta1
kind: SecurityGroupPolicy
metadata:
  name: example-security-group-policy-name
  namespace: default
spec:
  podSelector:
    matchLabels:
      role: example-role-name-label
  securityGroups:
    groupIds:
      - your-notebook-security-group-id
EOF
```

5. Agora, encaminhe a porta para que você possa acessar localmente a JupyterLab interface:

```
kubectl port-forward jupyter-notebook 8888:8888 -n namespace
```

Quando estiver em execução, navegue até o navegador local e visite `localhost:8888` para ver a JupyterLab interface:



- JupyterLabEm, crie um novo notebook Scala. Confira um exemplo de trecho de código que você pode executar para aproximar o valor de Pi:

```
import scala.math.random
import org.apache.spark.sql.SparkSession


/** Computes an approximation to pi */
val session = SparkSession
  .builder
  .appName("Spark Pi")
  .getOrCreate()

val slices = 2
// avoid overflow
val n = math.min(100000L * slices, Int.MaxValue).toInt

val count = session.sparkContext
  .parallelize(1 until n, slices)
```

```
.map { i =>
  val x = random * 2 - 1
  val y = random * 2 - 1
  if (x*x + y*y <= 1) 1 else 0
}.reduce(_ + _)

println(s"Pi is roughly ${4.0 * count / (n - 1)}")
session.stop()
```



Exclusão de um caderno Jupyter de hospedagem própria

Quando estiver com tudo pronto para excluir seu caderno de hospedagem própria, você também poderá excluir o endpoint interativo e o grupo de segurança. Execute as ações na seguinte ordem:

1. Use o seguinte comando para excluir o pod jupyter-notebook:

```
kubectl delete pod jupyter-notebook -n namespace
```

2. Em seguida, exclua o endpoint interativo com o comando `delete-managed-endpoint`. Para obter as etapas para a exclusão de um endpoint interativo, consulte [Exclusão de um endpoint](#)

[interativo](#). Inicialmente, seu endpoint estará no estado TERMINATING. Depois que todos os recursos forem limpos, ele transitará para o estado TERMINATED.

3. Caso não planeje usar o grupo de segurança de cadernos criado em [Criar um grupo de segurança](#) para outras implantações de caderno Jupyter, você poderá excluí-lo. Consulte [Excluir um grupo de segurança](#) no Guia do usuário do Amazon EC2 para obter mais informações.

Como obter informações sobre endpoints interativos com comandos da CLI

Este tópico aborda as operações com suporte em um endpoint interativo diferente de [create-managed-endpoint](#).

Busca de detalhes do endpoint interativo

Depois de criar um endpoint interativo, você pode recuperar seus detalhes usando o `describe-managed-endpoint` AWS CLI comando. Insira seus próprios valores para *managed-endpoint-id*, *virtual-cluster-id*, e *region*:

```
aws emr-containers describe-managed-endpoint --id managed-endpoint-id \
--virtual-cluster-id virtual-cluster-id --region region
```

A saída é semelhante à apresentada a seguir, com o endpoint especificado, como o ARN, o ID e o nome.

```
{
  "id": "as3ys2xxxxxxx",
  "name": "endpoint-name",
  "arn": "arn:aws:emr-containers:us-east-1:1828xxxxxxx:/virtualclusters/
1bhl6kwwyxxxxxxxxxxxxxxxxx/endpoints/as3ysxxxxxxxx",
  "virtualClusterId": "1bhl6kwwyxxxxxxxxxxxxxxxxx",
  "type": "JUPYTER_ENTERPRISE_GATEWAY",
  "state": "ACTIVE",
  "releaseLabel": "emr-6.9.0-latest",
  "executionRoleArn": "arn:aws:iam::1828xxxxxxx:role/RoleName",
  "certificateAuthority": {
    "certificateArn": "arn:aws:acm:us-east-1:1828xxxxxxx:certificate/zzzzzzzz-
e59b-4ed0-aaaa-bbbbbbbbbbbb",
    "certificateData": "certificate-data"
```

```

    },
    "configurationOverrides": {
      "applicationConfiguration": [
        {
          "classification": "spark-defaults",
          "properties": {
            "spark.driver.memory": "8G"
          }
        }
      ],
      "monitoringConfiguration": {
        "persistentAppUI": "ENABLED",
        "cloudWatchMonitoringConfiguration": {
          "logGroupName": "log-group-name",
          "logStreamNamePrefix": "log-stream-name-prefix"
        },
        "s3MonitoringConfiguration": {
          "logUri": "s3-bucket-name"
        }
      }
    },
    "serverUrl": "https://internal-k8s-namespace-ingressa-aaaaaaaaa-
zzzzzzzzzz.us-east-1.elb.amazonaws.com:18888 (https://internal-k8s-nspluto-
ingressa-51e860abbd-1620715833.us-east-1.elb.amazonaws.com:18888/)",
    "createdAt": "2022-09-19T12:37:49+00:00",
    "securityGroup": "sg-aaaaaaaaaaaaa",
    "subnetIds": [
      "subnet-1111111111",
      "subnet-2222222222",
      "subnet-3333333333"
    ],
    "stateDetails": "Endpoint created successfully. It took 3 Minutes 15 Seconds",
    "tags": {}
  }
}

```

Listagem de todos os endpoints interativos associados a um cluster virtual

Use o `list-managed-endpoints` AWS CLI comando para obter uma lista de todos os endpoints interativos associados a um cluster virtual especificado. Substitua `virtual-cluster-id` pelo ID do seu cluster virtual.

```
aws emr-containers list-managed-endpoints --virtual-cluster-id virtual-cluster-id
```


A saída do comando `list-managed-endpoint` é mostrada abaixo:

```
{
  "endpoints": [{
    "id": "as3ys2xxxxxxxx",
    "name": "endpoint-name",
    "arn": "arn:aws:emr-containers:us-east-1:1828xxxxxxxx:/virtualclusters/
lbhl6kwwyxxxxxxxxxxxxxxxxx/endpoints/as3ysxxxxxxxx",
    "virtualClusterId": "lbhl6kwwyxxxxxxxxxxxxxxxxx",
    "type": "JUPYTER_ENTERPRISE_GATEWAY",
    "state": "ACTIVE",
    "releaseLabel": "emr-6.9.0-latest",
    "executionRoleArn": "arn:aws:iam::1828xxxxxxxx:role/RoleName",
    "certificateAuthority": {
      "certificateArn": "arn:aws:acm:us-east-1:1828xxxxxxxx:certificate/zzzzzzzz-
e59b-4ed0-aaaa-bbbbbbbbbbbb",
      "certificateData": "certificate-data"
    },
    "configurationOverrides": {
      "applicationConfiguration": [{
        "classification": "spark-defaults",
        "properties": {
          "spark.driver.memory": "8G"
        }
      ]
    },
    "monitoringConfiguration": {
      "persistentAppUI": "ENABLED",
      "cloudWatchMonitoringConfiguration": {
        "logGroupName": "log-group-name",
        "logStreamNamePrefix": "log-stream-name-prefix"
      },
      "s3MonitoringConfiguration": {
        "logUri": "s3-bucket-name"
      }
    }
  ]
},
  "serverUrl": "https://internal-k8s-namespace-ingressa-aaaaaaaaaa-
zzzzzzzzzz.us-east-1.elb.amazonaws.com:18888 (https://internal-k8s-nspluto-
ingressa-51e860abbd-1620715833.us-east-1.elb.amazonaws.com:18888/)",
  "createdAt": "2022-09-19T12:37:49+00:00",
  "securityGroup": "sg-aaaaaaaaaaaaaa",
  "subnetIds": [
    "subnet-1111111111",
    "subnet-2222222222",
  ]
}
```

```
        "subnet-333333333333"
      ],
      "stateDetails": "Endpoint created successfully. It took 3 Minutes 15 Seconds",
      "tags": {}
    }]
  }
```

Exclusão de um endpoint interativo

Para excluir um endpoint interativo associado a um cluster virtual Amazon EMR no EKS, use `delete-managed-endpoint` AWS CLI o comando. Quando você exclui um endpoint interativo, o Amazon EMR no EKS remove os grupos de segurança padrão criados para esse endpoint.

Especifique valores para os seguintes parâmetros do comando:

- `--id`: o identificador do endpoint interativo que você deseja excluir.
- `--virtual-cluster-id` — O identificador do cluster virtual associado ao endpoint interativo que você deseja excluir. Esse é o mesmo ID do cluster virtual que foi especificado quando o endpoint interativo foi criado.

```
aws emr-containers delete-managed-endpoint --id managed-endpoint-id --virtual-cluster-id virtual-cluster-id
```

O comando retorna uma saída semelhante à seguinte para confirmar que você excluiu o endpoint interativo:

```
{
  "id": "8gai4l4exxxxxx",
  "virtualClusterId": "0b0qvauoy3ch1nqodxxxxxxxx"
}
```

Leia, grave e faça upload de dados no Amazon S3 Express One Zone com o Amazon EMR no EKS

Com as versões 7.2.0 e superiores do Amazon EMR, você pode usar o Amazon EMR no EKS com a classe de armazenamento [Amazon S3 Express One Zone](#) para melhorar a performance ao executar trabalhos e workloads. O S3 Express One Zone é uma classe de armazenamento de zona única e alta performance do Amazon S3 que oferece acesso consistente a dados de milissegundos de um dígito para a maioria das aplicações sensíveis à latência. Na hora da execução, o S3 Express One Zone oferece o armazenamento de objetos na nuvem com a menor latência e a maior performance do Amazon S3.

Pré-requisitos

Antes de usar o S3 Express One Zone com o Amazon EMR no EKS, você deve ter os seguintes pré-requisitos:

- [Configuração do Amazon EMR no EKS concluída](#).
- Depois de configurar o Amazon EMR no EKS, [crie um cluster virtual](#).

Conceitos básicos da classe S3 Express One Zone

Siga estas etapas para começar a usar o S3 Express One Zone

1. Adicione a permissão `CreateSession` ao perfil de execução do trabalho. Quando o S3 Express One Zone executa inicialmente uma ação como `GET`, `LIST`, ou `PUT` em um objeto do S3, a classe de armazenamento chama `CreateSession` em seu nome. A seguir está um exemplo de como conceder a permissão `CreateSession`.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Resource": [
```

```

        "arn:aws:s3express:*:*:bucket/DOC-EXAMPLE-BUCKET"
      ],
      "Action": [
        "s3express:CreateSession"
      ],
      "Sid": "AllowS3EXPRESSCreatesession"
    }
  ]
}

```

2. Você deve usar o conector Apache Hadoop S3A para acessar os buckets do S3 Express, então altere seu Amazon S3 para usar o esquema de uso do conector. URIs s3a Se não usarem o esquema, você poderá alterar a implementação do sistema de arquivos usada nos esquemas s3 e s3n.

Para alterar o esquema do s3, especifique as seguintes configurações de cluster:

```

[
  {
    "Classification": "core-site",
    "Properties": {
      "fs.s3.impl": "org.apache.hadoop.fs.s3a.S3AFileSystem",
      "fs.AbstractFileSystem.s3.impl": "org.apache.hadoop.fs.s3a.S3A"
    }
  }
]

```

Para alterar o esquema do s3n, especifique as seguintes configurações de cluster:

```

[
  {
    "Classification": "core-site",
    "Properties": {
      "fs.s3n.impl": "org.apache.hadoop.fs.s3a.S3AFileSystem",
      "fs.AbstractFileSystem.s3n.impl": "org.apache.hadoop.fs.s3a.S3A",
      "fs.s3a.endpoint.region": "us-west-2",
      "fs.s3a.change.detection.mode": "none",
      "fs.s3a.select.enabled": "false"
    }
  },
  {
    "Classification": "spark-defaults",

```

```
"Properties": {  
  "spark.hadoop.fs.s3a.aws.credentials.provider":  
    "software.amazon.awssdk.auth.credentials.WebIdentityTokenFileCredentialsProvider",  
  "spark.sql.sources.fastS3PartitionDiscovery.enabled": "false"  
}  
}
```

3. Na configuração spark-submit, use o provedor de credenciais de identidade da Web.

```
"spark.hadoop.fs.s3a.aws.credentials.provider=com.amazonaws.auth.WebIdentityTokenCredentialsProvider"
```

Monitorar trabalhos

Você pode usar o Amazon CloudWatch Events para rastrear trabalhos executados em um cluster virtual Amazon EMR no EKS. É possível usar os eventos para rastrear a atividade e a integridade de trabalhos executados em um cluster virtual. Os tópicos a seguir mostram maneiras de configurar o monitoramento de forma eficaz para manter a integridade de recursos.

Tópicos

- [Monitore trabalhos com a Amazon CloudWatch Events](#)
- [Automatize o Amazon EMR no EKS com eventos CloudWatch](#)
- [Exemplo: configuração de uma regra que invoque o Lambda](#)
- [Monitore o driver pod do trabalho com uma política de repetição usando o Amazon Events CloudWatch](#)

Monitore trabalhos com a Amazon CloudWatch Events

O Amazon EMR no EKS emite eventos quando o estado de uma execução de trabalho é alterado. Cada evento fornece informações, como a data e o horário em que o evento ocorreu, em conjunto com mais detalhes sobre o evento, como o ID do cluster virtual e o ID de uma execução de trabalho que foi afetada.

É possível usar os eventos para rastrear a atividade e a integridade de trabalhos executados em um cluster virtual. Você também pode usar o Amazon CloudWatch Events para definir uma ação a ser tomada quando a execução de um trabalho gera um evento que corresponde a um padrão especificado por você. Os eventos são úteis para monitorar uma ocorrência específica durante o ciclo de vida de uma execução de trabalho. Por exemplo, é possível monitorar quando uma execução de trabalho sofre alteração de estado de submitted para running. Para obter mais informações sobre CloudWatch eventos, consulte o [Guia EventBridge do usuário da Amazon](#).

A tabela apresentada a seguir lista os eventos do Amazon EMR no EKS em conjunto com o estado ou a alteração de estado que o evento indica, a severidade do evento e as mensagens do evento. Cada evento é representado como um objeto JSON que é enviado automaticamente a um stream de evento. O objeto JSON inclui mais detalhes sobre o evento. O objeto JSON é particularmente importante quando você configura regras para processamento de CloudWatch eventos usando Eventos, pois as regras buscam corresponder aos padrões no objeto JSON. Para obter mais

informações, consulte [Padrões de EventBridge eventos da Amazon](#) e Amazon EMR on EKS Events no Guia [EventBridge do usuário da Amazon](#).

Eventos de alteração de estado em execuções de trabalhos

Estado	Gravidade	Mensagem
SUBMITTED	INFO	Job Run <i>JobRunId</i> (<i>JobRunName</i>) foi enviado com sucesso ao cluster virtual <i>VirtualClusterId</i> no <i>Time</i> UTC.
RUNNING (Em execução)	INFO	Job Run <i>JobRunId</i> (<i>JobRunName</i>) no cluster virtual <i>VirtualClusterId</i> começou a ser executado em <i>Time</i> .
CONCLUÍDO	INFO	Job Run <i>jobRunId</i> (<i>JobRunName</i>) no cluster virtual <i>VirtualClusterId</i> concluído em <i>Time</i> . O Job Run começou a ser executado às <i>Time</i> e levou <i>Num</i> minutos para ser concluído.
CANCELADO	WARN	A solicitação de cancelamento foi bem-sucedida para Job Run <i>JobRunId</i> (<i>JobRunName</i>) no cluster virtual <i>VirtualClusterId</i> em <i>Time</i> e o Job Run agora está cancelado.
FAILED	ERRO	Job Run <i>JobRunId</i> (<i>JobRunName</i>) no cluster virtual <i>VirtualClusterId</i> falhou em <i>Time</i> .

Automatize o Amazon EMR no EKS com eventos CloudWatch

Você pode usar o Amazon CloudWatch Events para automatizar seus AWS serviços para responder a eventos do sistema, como problemas de disponibilidade de aplicativos ou alterações de recursos. Os eventos dos AWS serviços são entregues aos CloudWatch Eventos quase em tempo real. É possível criar regras simples para indicar quais eventos são de seu interesse, e quais ações automatizadas devem ser tomadas quando um evento corresponder a uma regra. Ações que podem ser automaticamente acionadas incluem:

- Invocando uma função AWS Lambda
- Invocar o comando de execução do Amazon EC2
- Transmitir o evento Amazon Kinesis Data Streams
- Ativando uma máquina de AWS Step Functions estado
- Notificando um tópico Amazon Simple Notification Service (SNS) ou uma fila Amazon Simple Queue Service (SQS)

Alguns exemplos do uso de CloudWatch eventos com o Amazon EMR no EKS incluem o seguinte:

- Ativação de uma função do Lambda quando uma execução de trabalho tiver êxito.
- Notificação de um tópico do Amazon SNS quando uma execução de trabalho falhar.

CloudWatch Eventos para `"detail-type": "EMR Job Run State Change"` são gerados pelo Amazon EMR no EKS para `SUBMITTED`, `RUNNING`, `CANCELLED`, `FAILED` e mudanças de `COMPLETED` estado.

Exemplo: configuração de uma regra que invoque o Lambda

Use as etapas a seguir para configurar uma regra de CloudWatch eventos que invoca o Lambda quando há um evento “EMR Job Run State Change”.

```
aws events put-rule \  
--name cwe-test \  
--event-pattern '{"detail-type": ["EMR Job Run State Change"]}'
```

Adicione a função Lambda que você possui como um novo destino e dê permissão a CloudWatch Events para invocar a função Lambda da seguinte forma. Substitua **123456789012** pelo ID da sua conta.

```
aws events put-targets \  
--rule cwe-test \  
--targets Id=1,Arn=arn:aws:lambda:us-east-1:123456789012:function:MyFunction
```

```
aws lambda add-permission \  
--function-name MyFunction \  
--statement-id MyId \  

```



```
--action 'lambda:InvokeFunction' \  
--principal events.amazonaws.com
```

 Note

Não é possível escrever um programa que dependa da ordem ou da existência de eventos de notificação, pois eles podem estar fora de sequência ou ausentes. Os eventos são emitidos com base no melhor esforço.

Monitore o driver pod do trabalho com uma política de repetição usando o Amazon Events CloudWatch

Usando CloudWatch eventos, você pode monitorar os grupos de drivers que foram criados em trabalhos que têm políticas de repetição. Para obter mais informações, consulte [Monitoramento de um trabalho com uma política de repetição](#) neste guia.

Gerenciamento de clusters virtuais

Um cluster virtual corresponde a um namespace do Kubernetes no qual o Amazon EMR está registrado. Você pode criar, descrever, listar e excluir clusters virtuais. Eles não consomem quaisquer recursos adicionais em seu sistema. Um único cluster virtual mapeia para um único namespace do Kubernetes. Dado esse relacionamento, você pode modelar clusters virtuais da mesma forma que modela namespaces Kubernetes para atender aos seus requisitos. Confira os possíveis casos de uso na documentação de [visão geral dos conceitos do Kubernetes](#).

Para registrar o Amazon EMR com um namespace do Kubernetes em um cluster do Amazon EKS, você precisa do nome do cluster do EKS e do namespace que foi configurado para executar sua workload. Esses clusters registrados no Amazon EMR são chamados de clusters virtuais porque não gerenciam computação ou armazenamento físicos, mas direcionam para um namespace do Kubernetes no qual sua workload está programada.

Note

Antes de criar um cluster virtual, você deve concluir as etapas de 1 a 8 em [Configuração do Amazon EMR no EKS](#).

Tópicos

- [Criação de um cluster virtual](#)
- [Listagem de clusters virtuais](#)
- [Descrição de um cluster virtual](#)
- [Exclusão de um cluster virtual](#)
- [Estados de um cluster virtual](#)

Criação de um cluster virtual

Execute o comando apresentado a seguir para criar um cluster virtual ao registrar o Amazon EMR com um namespace em um cluster do EKS. *virtual_cluster_name* Substitua por um nome que você forneça para seu cluster virtual. *eks_cluster_name* Substitua pelo nome do cluster EKS. Substitua o pelo namespace *namespace_name* com o qual você deseja registrar o Amazon EMR.

```
aws emr-containers create-virtual-cluster \  
--name virtual_cluster_name \  
--container-provider '{  
  "id": "eks_cluster_name",  
  "type": "EKS",  
  "info": {  
    "eksInfo": {  
      "namespace": "namespace_name"  
    }  
  }  
'
```

Como alternativa, você pode criar um arquivo JSON que inclua os parâmetros obrigatórios para o cluster virtual, como demonstra o exemplo a seguir.

```
{  
  "name": "virtual_cluster_name",  
  "containerProvider": {  
    "type": "EKS",  
    "id": "eks_cluster_name",  
    "info": {  
      "eksInfo": {  
        "namespace": "namespace_name"  
      }  
    }  
  }  
}
```

Em seguida, execute o comando `create-virtual-cluster` apresentado a seguir com o caminho para o arquivo JSON.

```
aws emr-containers create-virtual-cluster \  
--cli-input-json file:///./create-virtual-cluster-request.json
```

Note

Para validar a criação com êxito de um cluster virtual, visualize o status dos clusters virtuais ao executar o comando `list-virtual-clusters` ou ao acessar a página Clusters virtuais no console do Amazon EMR.

Listagem de clusters virtuais

Execute o comando apresentado a seguir para visualizar o status dos clusters virtuais.

```
aws emr-containers list-virtual-clusters
```

Descrição de um cluster virtual

Execute o comando apresentado a seguir para obter mais detalhes sobre um cluster virtual, como o namespace, o status e a data de registro. **123456** Substitua pelo ID do seu cluster virtual.

```
aws emr-containers describe-virtual-cluster --id 123456
```

Exclusão de um cluster virtual

Execute o comando apresentado a seguir para excluir um cluster virtual. **123456** Substitua pelo ID do seu cluster virtual.

```
aws emr-containers delete-virtual-cluster --id 123456
```

Estados de um cluster virtual

A tabela a seguir descreve os quatro estados possíveis de um cluster virtual.

State	Description
RUNNING	O cluster virtual está no estado RUNNING.
TERMINATING	O encerramento solicitado para o cluster virtual está em andamento.
TERMINATED	O encerramento solicitado foi concluído.
ARRESTED	O encerramento solicitado falhou devido a permissões insuficientes.

Tutoriais para o Amazon EMR no EKS

Esta seção descreve casos de uso comuns para quando você trabalha com aplicações do Amazon EMR no EKS. Cada aplicação é especializada e pode executar etapas exclusivas de configuração. Esses tópicos fornecem instruções para o uso de cada aplicação.

Tópicos

- [Uso do Delta Lake com o Amazon EMR no EKS](#)
- [Uso do Apache Iceberg com o Amazon EMR no EKS](#)
- [Usando PyFlink](#)
- [Usando AWS Glue com Flink](#)
- [Uso do Apache Hudi com o Apache Flink](#)
- [Uso do acelerador RAPIDS para Apache Spark com o Amazon EMR no EKS](#)
- [Uso da integração do Amazon Redshift para Apache Spark no Amazon EMR no EKS](#)
- [Uso do Volcano como um programador personalizado para Apache Spark no Amazon EMR no EKS](#)
- [Usando YuniKorn como um programador personalizado para o Apache Spark no Amazon EMR no EKS](#)

Uso do Delta Lake com o Amazon EMR no EKS

O Delta Lake é uma estrutura de armazenamento de código aberto para a criação de uma arquitetura do Lakehouse. O exemplo a seguir mostra como configurar para uso.

Para usar o [Delta Lake](#) com aplicações do Amazon EMR no EKS

1. Ao iniciar uma execução de trabalho para enviar um trabalho do Spark na configuração da aplicação, inclua os arquivos JAR do Delta Lake:

```
--job-driver '{"sparkSubmitJobDriver" : {  
    "sparkSubmitParameters" : "--jars local:///usr/share/aws/delta/lib/delta-  
core.jar,local:///usr/share/aws/delta/lib/delta-storage.jar,local:///usr/share/aws/  
delta/lib/delta-storage-s3-dynamodb.jar"}}'
```

Note

As versões 7.0.0 e superiores do Amazon EMR usam o Delta Lake 3.0, que renomeia `delta-core.jar` para `delta-spark.jar`. Se você usa o Amazon EMR nas versões 7.0.0 ou superiores, certifique-se de usar o nome de arquivo correto, como no exemplo a seguir:

```
--jars local:///usr/share/aws/delta/lib/delta-spark.jar
```

2. Inclua a configuração adicional do Delta Lake e use o AWS Glue Data Catalog como seu metastore.

```
--configuration-overrides '{
  "applicationConfiguration": [
    {
      "classification" : "spark-defaults",
      "properties" : {
        "spark.sql.extensions" : "io.delta.sql.DeltaSparkSessionExtension",

        "spark.sql.catalog.spark_catalog":"org.apache.spark.sql.delta.catalog.DeltaCatalog",
        "spark.hadoop.hive.metastore.client.factory.class":"com.amazonaws.glue.catalog.metastore.AWSGlueDataCatalogHiveClient"
      }
    }
  ]
}'
```

Uso do Apache Iceberg com o Amazon EMR no EKS

O JAR de runtime para o Iceberg contém as classes necessárias do Iceberg para suporte ao runtime do Spark. O procedimento a seguir mostra como iniciar uma execução de trabalho usando o runtime do Spark do Iceberg.

Usar o Apache Iceberg com as aplicações do Amazon EMR no EKS

1. Ao iniciar uma execução de trabalho para enviar um trabalho do Spark na configuração da aplicação, inclua o arquivo JAR de runtime do Iceberg para o Spark:

```
--job-driver '{"sparkSubmitJobDriver" : {"sparkSubmitParameters" : "--jars
local:///usr/share/aws/iceberg/lib/iceberg-spark3-runtime.jar"}}'
```

2. Inclua a configuração adicional do Iceberg:

```
--configuration-overrides '{
  "applicationConfiguration": [
    "classification" : "spark-defaults",
    "properties" : {
      "spark.sql.catalog.dev.warehouse" : "s3://amzn-s3-demo-bucket/EXAMPLE-
PREFIX/ ",
      "spark.sql.extensions ":"
org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions ",
      "spark.sql.catalog.dev" : "org.apache.iceberg.spark.SparkCatalog",
      "spark.sql.catalog.dev.catalog-impl" :
"org.apache.iceberg.aws.glue.GlueCatalog",
      "spark.sql.catalog.dev.io-impl": "org.apache.iceberg.aws.s3.S3FileIO"
    }
  ]
}'
```

Para saber mais sobre as versões de liberação do Apache Iceberg para o EMR, consulte [Iceberg release history](#).

Configurações de sessão do Spark para integração de catálogo

Configurações de sessão do Spark para integração do catálogo Iceberg AWS Glue

Este exemplo mostra como integrar o Iceberg com o Crawler do AWS Glue:

```
spark-sql \
--conf spark.sql.catalog.rms = org.apache.iceberg.spark.SparkCatalog \
--conf spark.sql.catalog.rms.type = glue \
--conf spark.sql.catalog.rms.glue.id = glue RMS catalog ID \
--conf spark.sql.catalog.rms.glue.account-id = AWS account ID \

--conf spark.sql.extensions=
org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
```

Veja a seguir um exemplo de consulta:

```
SELECT * FROM rms.rmsdb.table1
```

Configurações de sessão do Spark para integração do catálogo Iceberg REST AWS Glue

Este exemplo mostra como integrar o Iceberg REST com o Crawler do AWS Glue:

```
spark-sql \  
  --conf spark.sql.catalog.rms = org.apache.iceberg.spark.SparkCatalog \  
  --conf spark.sql.catalog.rms.type = rest \  
  --conf spark.sql.catalog.rms.warehouse = glue RMS catalog ID \  
  --conf spark.sql.catalog.rms.uri = glue endpoint URI/iceberg \  
  --conf spark.sql.catalog.rms.rest.sigv4-enabled = true \  
  --conf spark.sql.catalog.rms.rest.signing-name = glue \  
  
  --conf spark.sql.extensions=  
    org.apache.iceberg.spark.extensions.IcebergSparkSessionExtensions
```

Veja a seguir um exemplo de consulta:

```
SELECT * FROM rms.rmsdb.table1
```

Essa configuração funciona apenas para o Redshift Managed Storage. Não há suporte para o FGAC para o Amazon S3.

Usando PyFlink

Suporte para o Amazon EMR no EKS nas versões 6.15.0 e superiores. PyFlink Se você já tem um PyFlink script, você pode fazer o seguinte:

- Crie uma imagem personalizada com seu PyFlink script incluído.
- Faça upload do script em um local do Amazon S3

Se você ainda não tem um script, pode usar o exemplo a seguir para iniciar um PyFlink trabalho. Este exemplo recupera o script do S3. Caso esteja usando uma imagem personalizada com o script já incluído na imagem, atualize o caminho do script até o local em que você armazenou o script. Se o script estiver em um local do S3, o Amazon EMR no EKS recuperará o script e o colocará no diretório `/opt/flink/usrlib/` no contêiner do Flink.

```
apiVersion: flink.apache.org/v1beta1
```



```
kind: FlinkDeployment
metadata:
  name: python-example
spec:
  flinkVersion: v1_17
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "1"
  executionRoleArn: job-execution-role
  emrReleaseLabel: "emr-6.15.0-flink-latest"
  jobManager:
    highAvailabilityEnabled: false
    replicas: 1
    resource:
      memory: "2048m"
      cpu: 1
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
  job:
    jarURI: s3://S3 bucket with your script/pyflink-script.py
    entryClass: "org.apache.flink.client.python.PythonDriver"
    args: ["-py", "/opt/flink/usrlib/pyflink-script.py"]
    parallelism: 1
    upgradeMode: stateless
```

Usando AWS Glue com Flink

O Amazon EMR no EKS com Apache Flink, versões 6.15.0 e superiores, oferece suporte ao uso do AWS Glue Data Catalog como um armazenamento de metadados para fluxos de trabalho SQL em lote e streaming.

Primeiro, você deve criar um banco de dados AWS Glue chamado `default` que sirva como seu catálogo SQL do Flink. Esse catálogo do Flink armazena metadados como bancos de dados, tabelas, partições, visualizações, funções e outras informações necessárias para acessar dados em outros sistemas externos.

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

Para ativar o suporte ao AWS Glue, use uma FlinkDeployment especificação. Esse exemplo de especificação usa um script Python para emitir rapidamente algumas instruções SQL do Flink para interagir com o AWS catálogo Glue.

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: python-example
spec:
  flinkVersion: v1_17
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "1"
    aws.glue.enabled: "true"
  executionRoleArn: job-execution-role-arn;
  emrReleaseLabel: "emr-6.15.0-flink-latest"
  jobManager:
    highAvailabilityEnabled: false
    replicas: 1
    resource:
      memory: "2048m"
      cpu: 1
  taskManager:
    resource:
      memory: "2048m"
      cpu: 1
  job:
    jarURI: s3://<S3_bucket_with_your_scriptpyflink-glue-script.py"]
    parallelism: 1
    upgradeMode: stateless
```

Veja a seguir um exemplo da aparência do seu PyFlink script.

```
import logging
import sys
from pyflink.datastream import StreamExecutionEnvironment
from pyflink.table import StreamTableEnvironment

def glue_demo():
    env = StreamExecutionEnvironment.get_execution_environment()
    t_env = StreamTableEnvironment.create(stream_execution_environment=env)
    t_env.execute_sql("""
```

```

CREATE CATALOG glue_catalog WITH (
  'type' = 'hive',
  'default-database' = 'default',
  'hive-conf-dir' = '/glue/confs/hive/conf',
  'hadoop-conf-dir' = '/glue/confs/hadoop/conf'
)
    """)
t_env.execute_sql("""
    USE CATALOG glue_catalog;
    """)
t_env.execute_sql("""
    DROP DATABASE IF EXISTS eks_flink_db CASCADE;
    """)
t_env.execute_sql("""
    CREATE DATABASE IF NOT EXISTS eks_flink_db WITH ('hive.database.location-
uri'= 's3a://S3-bucket-to-store-metadata/flink/flink-glue-for-hive/warehouse/');
    """)
t_env.execute_sql("""
    USE eks_flink_db;
    """)
t_env.execute_sql("""
    CREATE TABLE IF NOT EXISTS eksglueorders (
      order_number BIGINT,
      price          DECIMAL(32,2),
      buyer          RO first_name STRING, last_name STRING,
      order_time      TIMESTAMP(3)
    ) WITH (
      'connector' = 'datagen'
    );
    """)
t_env.execute_sql("""
    CREATE TABLE IF NOT EXISTS eksdestglueorders (
      order_number BIGINT,
      price          DECIMAL(32,2),
      buyer          ROW first_name STRING, last_name STRING,
      order_time      TIMESTAMP(3)
    ) WITH (
      'connector' = 'filesystem',
      'path' = 's3://S3-bucket-to-store-metadata/flink/flink-glue-for-hive/
warehouse/eksdestglueorders',
      'format' = 'json'
    );
    """)
t_env.execute_sql("""

```

```

CREATE TABLE IF NOT EXISTS print_table (
    order_number BIGINT,
    price         DECIMAL(32,2),
    buyer         ROW first_name STRING, last_name STRING,
    order_time    TIMESTAMP(3)
) WITH (
    'connector' = 'print'
);

t_env.execute_sql("""
EXECUTE STATEMENT SET
BEGIN
INSERT INTO eksdestglueorders SELECT * FROM eks glueorders LIMIT 10;
INSERT INTO print_table SELECT * FROM eksdestglueorders;
END;
""")

if __name__ == '__main__':
    logging.basicConfig(stream=sys.stdout, level=logging.INFO, format="%(message)s")
    glue_demo()

```

Uso do Apache Hudi com o Apache Flink

O Apache Hudi é uma estrutura de gerenciamento de dados de código aberto com operações em nível de registro, como inserir, atualizar, upsert e excluir, que você pode usar para simplificar o gerenciamento de dados e o desenvolvimento de pipelines de dados. Quando combinado com o gerenciamento eficiente de dados no Amazon S3, o Hudi permite que você ingira e atualize dados em tempo real. O Hudi mantém os metadados de todas as operações que você executa no conjunto de dados, para que todas as ações permaneçam atômicas e consistentes.

O Apache Hudi está disponível no Amazon EMR no EKS com o Apache Flink, com as versões 7.2.0 e superiores do Amazon EMR. Confira as etapas a seguir para saber como começar e enviar trabalhos do Apache Hudi.

Envio de um trabalho do Apache Hudi

Confira as etapas a seguir para saber como enviar um trabalho do Apache Hudi.

1. Crie um banco de dados AWS Glue chamado `default`.

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

2. Siga as instruções em [Flink Kubernetes Operator SQL Example](#) para criar o arquivo `flink-sql-runner.jar`.
3. Crie um script SQL do Hudi como o mostrado a seguir.

```
CREATE CATALOG hudi_glue_catalog WITH (
  'type' = 'hudi',
  'mode' = 'hms',
  'table.external' = 'true',
  'default-database' = 'default',
  'hive.conf.dir' = '/glue/confs/hive/conf/',
  'catalog.path' = 's3://<hudi-example-bucket>/FLINK_HUDI/warehouse/'
);

USE CATALOG hudi_glue_catalog;
CREATE DATABASE IF NOT EXISTS hudi_db;
use hudi_db;

CREATE TABLE IF NOT EXISTS hudi-flink-example-table(
  uuid VARCHAR(20),
  name VARCHAR(10),
  age INT,
  ts TIMESTAMP(3),
  `partition` VARCHAR(20)
)
PARTITIONED BY (`partition`)
WITH (
  'connector' = 'hudi',
  'path' = 's3://<hudi-example-bucket>/hudi-flink-example-table',
  'hive_sync.enable' = 'true',
  'hive_sync.mode' = 'glue',
  'hive_sync.table' = 'hudi-flink-example-table',
  'hive_sync.db' = 'hudi_db',
  'compaction.delta_commits' = '1',
  'hive_sync.partition_fields' = 'partition',
  'hive_sync.partition_extractor_class' =
  'org.apache.hudi.hive.MultiPartKeysValueExtractor',
  'table.type' = 'COPY_ON_WRITE'
);

EXECUTE STATEMENT SET
```

```
BEGIN
```

```
INSERT INTO hudi-flink-example-table VALUES
  ('id1','Alex',23,TIMESTAMP '1970-01-01 00:00:01','par1'),
  ('id2','Stephen',33,TIMESTAMP '1970-01-01 00:00:02','par1'),
  ('id3','Julian',53,TIMESTAMP '1970-01-01 00:00:03','par2'),
  ('id4','Fabian',31,TIMESTAMP '1970-01-01 00:00:04','par2'),
  ('id5','Sophia',18,TIMESTAMP '1970-01-01 00:00:05','par3'),
  ('id6','Emma',20,TIMESTAMP '1970-01-01 00:00:06','par3'),
  ('id7','Bob',44,TIMESTAMP '1970-01-01 00:00:07','par4'),
  ('id8','Han',56,TIMESTAMP '1970-01-01 00:00:08','par4');
```

```
END;
```

4. Faça upload do script SQL do Hudi e do arquivo `flink-sql-runner.jar` em um local do S3.
5. No seu arquivo `FlinkDeployments` do YAML, defina `hudi.enabled` como `true`.

```
spec:
  flinkConfiguration:
    hudi.enabled: "true"
```

6. Crie um arquivo do YAML para executar sua configuração. Neste exemplo, o nome do arquivo é `hudi-write.yaml`.

```
apiVersion: flink.apache.org/v1beta1
kind: FlinkDeployment
metadata:
  name: hudi-write-example
spec:
  flinkVersion: v1_18
  flinkConfiguration:
    taskmanager.numberOfTaskSlots: "2"
    hudi.enabled: "true"
  executionRoleArn: "<JobExecutionRole>"
  emrReleaseLabel: "emr-7.12.0-flink-latest"
  jobManager:
    highAvailabilityEnabled: false
    replicas: 1
    resource:
      memory: "2048m"
      cpu: 1
  taskManager:
    resource:
```

```
memory: "2048m"
cpu: 1
job:
  jarURI: local:///opt/flink/usrlib/flink-sql-runner.jar
  args: ["/opt/flink/scripts/hudi-write.sql"]
  parallelism: 1
  upgradeMode: stateless
podTemplate:
  spec:
    initContainers:
      - name: flink-sql-script-download
        args:
          - s3
          - cp
          - s3://<s3_location>/hudi-write.sql
          - /flink-scripts
        image: amazon/aws-cli:latest
        imagePullPolicy: Always
        resources: {}
        terminationMessagePath: /dev/termination-log
        terminationMessagePolicy: File
        volumeMounts:
          - mountPath: /flink-scripts
            name: flink-scripts
      - name: flink-sql-runner-download
        args:
          - s3
          - cp
          - s3://<s3_location>/flink-sql-runner.jar
          - /flink-artifacts
        image: amazon/aws-cli:latest
        imagePullPolicy: Always
        resources: {}
        terminationMessagePath: /dev/termination-log
        terminationMessagePolicy: File
        volumeMounts:
          - mountPath: /flink-artifacts
            name: flink-artifact
    containers:
      - name: flink-main-container
        volumeMounts:
          - mountPath: /opt/flink/scripts
            name: flink-scripts
          - mountPath: /opt/flink/usrlib
```

```
      name: flink-artifact
volumes:
  - emptyDir: {}
    name: flink-scripts
  - emptyDir: {}
    name: flink-artifact
```

7. Envie um trabalho do Hudi no Flink para o [operador Kubernetes do Flink](#).

```
kubectl apply -f hudi-write.yaml
```

Uso do acelerador RAPIDS para Apache Spark com o Amazon EMR no EKS

Com o Amazon EMR no EKS, você pode executar trabalhos para o acelerador RAPIDS da Nvidia para Apache Spark. Este tutorial aborda como executar trabalhos do Spark usando o RAPIDS em tipos de instância de unidade de processamento gráfico (GPU) do EC2. O tutorial usa as seguintes versões:

- Amazon EMR no EKS na versão de liberação 6.9.0 e posteriores
- Apache Spark 3.x

Você pode acelerar o Spark com os tipos de instância de GPU do Amazon EC2 usando o plug-in do [acelerador RAPIDS da Nvidia para Apache Spark](#). Ao usar essas tecnologias em conjunto, você acelera os pipelines de ciência de dados sem a necessidade de realizar alterações no código. Isso reduz o tempo de execução necessário para o processamento de dados e para o treinamento de modelos. Ao fazer mais em menos tempo, você gasta menos com o custo da infraestrutura.

Antes de começar, certifique-se de ter os recursos apresentados a seguir.

- Cluster virtual do Amazon EMR no EKS
- Cluster do Amazon EKS com um grupo de nós habilitado para GPU

Um cluster virtual do Amazon EKS corresponde a um manipulador registrado para o namespace do Kubernetes em um cluster do Amazon EKS e é gerenciado pelo Amazon EMR no EKS. O manipulador permite que o Amazon EMR use o namespace do Kubernetes como destino para

a execução de trabalhos. Para obter mais informações sobre como configurar um cluster virtual, consulte [Configuração do Amazon EMR no EKS](#) neste guia.

Você deve configurar o cluster virtual do Amazon EKS com um grupo de nós que tenha instâncias de GPU. Você deve configurar os nós com um plug-in para dispositivos da Nvidia. Consulte [Grupos de nós gerenciados](#) para saber mais.

Para configurar o cluster do Amazon EKS para adicionar grupos de nós habilitados para GPU, execute o seguinte procedimento:

Adicionar grupos de nós habilitados para GPU

1. Crie um grupo de nós habilitado para GPU com o comando [create-nodegroup](#) apresentado a seguir. Certifique-se de realizar a substituição com os parâmetros corretos para o cluster do Amazon EKS. Use um tipo de instância compatível com RAPIDS para Spark, como P4, P3, G5 ou G4dn.

```
aws eks create-nodegroup \
  --cluster-name EKS_CLUSTER_NAME \
  --nodegroup-name NODEGROUP_NAME \
  --scaling-config minSize=0,maxSize=5,desiredSize=2 CHOOSE_APPROPRIATELY \
  --ami-type AL2_x86_64_GPU \
  --node-role NODE_ROLE \
  --subnets SUBNETS_SPACE_DELIMITED \
  --remote-access ec2SshKey= SSH_KEY \
  --instance-types GPU_INSTANCE_TYPE \
  --disk-size DISK_SIZE \
  --region AWS_REGION
```

2. Instale o plug-in do dispositivo Nvidia em seu cluster para emitir o número de GPUs em cada nó do seu cluster e para executar contêineres habilitados para GPU em seu cluster. Execute o seguinte código para instalar o plug-in:

```
kubectl apply -f https://raw.githubusercontent.com/NVIDIA/k8s-device-plugin/v0.9.0/
nvidia-device-plugin.yml
```

3. Para validar quantos GPUs estão disponíveis em cada nó do seu cluster, execute o seguinte comando:

```
kubectl get nodes "-o=custom-
columns=NAME:.metadata.name,GPU:.status.allocatable.nvidia\.com/gpu"
```

Executar um trabalho do RAPIDS para Spark

1. Envie um trabalho do RAPIDS para Spark ao cluster do Amazon EMR no EKS. O código a seguir apresenta um exemplo de comando para iniciar o trabalho. Na primeira vez em que você executar o trabalho, poderá demorar alguns minutos para fazer download da imagem e armazená-la em cache no nó.

```
aws emr-containers start-job-run \  
--virtual-cluster-id VIRTUAL_CLUSTER_ID \  
--execution-role-arn JOB_EXECUTION_ROLE \  
--release-label emr-6.9.0-spark-rapids-latest \  
--job-driver '{"sparkSubmitJobDriver": {"entryPoint": "local:///usr/lib/  
spark/examples/jars/spark-examples.jar", "entryPointArguments": ["10000"],  
"sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi "}}' \  
---configuration-overrides '{"applicationConfiguration": [{"classification":  
"spark-defaults", "properties": {"spark.executor.instances":  
"2", "spark.executor.memory": "2G"}}], "monitoringConfiguration":  
{ "cloudWatchMonitoringConfiguration": {"logGroupName": "LOG_GROUP  
_NAME", "s3MonitoringConfiguration": {"logUri": "LOG_GROUP_STREAM"}}}'
```

2. Para validar se o acelerador RAPIDS para Spark está habilitado, verifique os logs do driver do Spark. Esses registros são armazenados no CloudWatch local do S3 que você especifica ao executar o `start-job-run` comando. O seguinte exemplo apresenta como geralmente é a aparência das linhas de log:

```
22/11/15 00:12:44 INFO RapidsPluginUtils: RAPIDS Accelerator build:  
{version=22.08.0-amzn-0, user=release, url=, date=2022-11-03T03:32:45Z, revision=,  
cudf_version=22.08.0, branch=}  
22/11/15 00:12:44 INFO RapidsPluginUtils: RAPIDS Accelerator JNI build:  
{version=22.08.0, user=, url=https://github.com/NVIDIA/spark-rapids-jni.git,  
date=2022-08-18T04:14:34Z, revision=a1b23cd_sample, branch=HEAD}  
22/11/15 00:12:44 INFO RapidsPluginUtils: cudf build: {version=22.08.0,  
user=, url=https://github.com/rapidsai/cudf.git, date=2022-08-18T04:14:34Z,  
revision=a1b23ce_sample, branch=HEAD}  
22/11/15 00:12:44 WARN RapidsPluginUtils: RAPIDS Accelerator 22.08.0-amzn-0 using  
cudf 22.08.0.  
22/11/15 00:12:44 WARN RapidsPluginUtils:  
spark.rapids.sql.multiThreadedRead.numThreads is set to 20.  
22/11/15 00:12:44 WARN RapidsPluginUtils: RAPIDS Accelerator is enabled, to disable  
GPU support set `spark.rapids.sql.enabled` to false.
```

```
22/11/15 00:12:44 WARN RapidsPluginUtils: spark.rapids.sql.explain is set to
'NOT_ON_GPU'. Set it to 'NONE' to suppress the diagnostics logging about the query
placement on the GPU.
```

3. Para visualizar as operações que serão executadas em uma GPU, execute as etapas apresentadas a seguir para ativar o registro em log adicional. Observe a configuração “spark.rapids.sql.explain : ALL”.

```
aws emr-containers start-job-run \
--virtual-cluster-id VIRTUAL_CLUSTER_ID \
--execution-role-arn JOB_EXECUTION_ROLE \
--release-label emr-6.9.0-spark-rapids-latest \
--job-driver '{"sparkSubmitJobDriver": {"entryPoint": "local:///usr/lib/
spark/examples/jars/spark-examples.jar","entryPointArguments": ["10000"],
"sparkSubmitParameters": "--class org.apache.spark.examples.SparkPi "}}' \
---configuration-overrides '{"applicationConfiguration":
[{"classification": "spark-defaults","properties":
{"spark.rapids.sql.explain":"ALL","spark.executor.instances":
"2","spark.executor.memory": "2G"}]], "monitoringConfiguration":
{"cloudWatchMonitoringConfiguration": {"logGroupName":
"LOG_GROUP_NAME"},"s3MonitoringConfiguration": {"logUri": "LOG_GROUP_STREAM"}}}'
```

O comando anterior é um exemplo de trabalho que usa a GPU. Sua saída seria semelhante ao exemplo abaixo. Consulte esta legenda para obter ajuda para compreender a saída:

- *: marca uma operação que funciona em uma GPU.
- !: marca uma operação que não pode ser executada em uma GPU.
- @: marca uma operação que funciona em uma GPU, mas não será executada porque está em um plano que não pode ser executado em uma GPU.

```
22/11/15 01:22:58 INFO GpuOverrides: Plan conversion to the GPU took 118.64 ms
22/11/15 01:22:58 INFO GpuOverrides: Plan conversion to the GPU took 4.20 ms
22/11/15 01:22:58 INFO GpuOverrides: GPU plan transition optimization took 8.37 ms
22/11/15 01:22:59 WARN GpuOverrides:
  *Exec <ProjectExec> will run on GPU
    *Expression <Alias> substring(cast(date#149 as string), 0, 7) AS month#310
will run on GPU
      *Expression <Substring> substring(cast(date#149 as string), 0, 7) will run
on GPU
```

```

    *Expression <Cast> cast(date#149 as string) will run on GPU
*Exec <SortExec> will run on GPU
    *Expression <SortOrder> date#149 ASC NULLS FIRST will run on GPU
*Exec <ShuffleExchangeExec> will run on GPU
    *Partitioning <RangePartitioning> will run on GPU
    *Expression <SortOrder> date#149 ASC NULLS FIRST will run on GPU
*Exec <UnionExec> will run on GPU
    !Exec <ProjectExec> cannot run on GPU because not all expressions can
be replaced
    @Expression <AttributeReference> customerID#0 could run on GPU
    @Expression <Alias> Charge AS kind#126 could run on GPU
    @Expression <Literal> Charge could run on GPU
    @Expression <AttributeReference> value#129 could run on GPU
    @Expression <Alias> add_months(2022-11-15, cast(-(cast(_we0#142 as
bigint) + last_month#128L) as int)) AS date#149 could run on GPU
    ! <AddMonths> add_months(2022-11-15, cast(-
(cast(_we0#142 as bigint) + last_month#128L) as int)) cannot run
on GPU because GPU does not currently support the operator class
org.apache.spark.sql.catalyst.expressions.AddMonths
    @Expression <Literal> 2022-11-15 could run on GPU
    @Expression <Cast> cast(-(cast(_we0#142 as bigint) +
last_month#128L) as int) could run on GPU
    @Expression <UnaryMinus> -(cast(_we0#142 as bigint) +
last_month#128L) could run on GPU
    @Expression <Add> (cast(_we0#142 as bigint) +
last_month#128L) could run on GPU
    @Expression <Cast> cast(_we0#142 as bigint) could run on
GPU
    @Expression <AttributeReference> _we0#142 could run on
GPU
    @Expression <AttributeReference> last_month#128L could run
on GPU

```

Uso da integração do Amazon Redshift para Apache Spark no Amazon EMR no EKS

Com as versões 6.9.0 e posteriores do Amazon EMR, cada imagem de versão inclui um conector entre o [Apache Spark](#) e o Amazon Redshift. Dessa forma, você pode usar o Spark no Amazon EMR no EKS para processar dados armazenados no Amazon Redshift. A integração é baseada

no [conector de código aberto spark-redshift](#). Para o Amazon EMR no EKS, a [integração do Amazon Redshift para Apache Spark](#) está inclusa como uma integração nativa.

Tópicos

- [Inicialização de uma aplicação do Spark usando a integração do Amazon Redshift para Apache Spark](#)
- [Autenticação com a integração do Amazon Redshift para Apache Spark](#)
- [Leitura e gravação de e para o Amazon Redshift](#)
- [Considerações e limitações ao usar o conector do Spark](#)

Inicialização de uma aplicação do Spark usando a integração do Amazon Redshift para Apache Spark

Para usar a integração, você deve transferir as dependências obrigatórias do Redshift para Spark com o trabalho do Spark. Você deve usar `--jars` para incluir as bibliotecas relacionadas ao conector do Redshift. Para visualizar outros locais de arquivo com suporte pela opção `--jars`, consulte a seção [Advanced Dependency Management](#) da documentação do Apache Spark.

- `spark-redshift.jar`
- `spark-avro.jar`
- `RedshiftJDBC.jar`
- `minimal-json.jar`

Para iniciar uma aplicação do Spark com a integração do Amazon Redshift para Apache Spark na versão 6.9.0 ou em versões posteriores do Amazon EMR no EKS, use o comando de exemplo a seguir. Observe que os caminhos listados com a opção `--conf spark.jars` são os caminhos padrão para os arquivos JAR.

```
aws emr-containers start-job-run \  
  
--virtual-cluster-id cluster_id \  
--execution-role-arn arn \  
--release-label emr-6.9.0-latest \  
--job-driver '{  
    "sparkSubmitJobDriver": {  
        "entryPoint": "s3://script_path",
```

```

"sparkSubmitParameters":
"--conf spark.kubernetes.file.upload.path=s3://upload_path
--conf spark.jars=
    /usr/share/aws/redshift/jdbc/RedshiftJDBC.jar,
    /usr/share/aws/redshift/spark-redshift/lib/spark-redshift.jar,
    /usr/share/aws/redshift/spark-redshift/lib/spark-avro.jar,
    /usr/share/aws/redshift/spark-redshift/lib/minimal-json.jar"
    }
}'

```

Autenticação com a integração do Amazon Redshift para Apache Spark

As seções a seguir mostram as opções de autenticação com o Amazon Redshift durante a integração com o Apache Spark. As seções mostram como recuperar as credenciais de login e detalhes sobre o uso do driver JDBC com a autenticação do IAM.

Use AWS Secrets Manager para recuperar credenciais e conectar-se ao Amazon Redshift

Você pode armazenar credenciais no Secrets Manager para realizar a autenticação com segurança no Amazon Redshift. É possível fazer com que seu trabalho do Spark chame a API `GetSecretValue` para buscar as credenciais:

```

from pyspark.sql import SQLContextimport boto3

sc = # existing SparkContext
sql_context = SQLContext(sc)

secretsmanager_client = boto3.client('secretsmanager',
    region_name=os.getenv('AWS_REGION'))
secret_manager_response = secretsmanager_client.get_secret_value(
    SecretId='string',
    VersionId='string',
    VersionStage='string'
)
username = # get username from secret_manager_response
password = # get password from secret_manager_response
url = "jdbc:redshift://redshifthost:5439/database?user=" + username + "&password="
    + password

# Access to Redshift cluster using Spark

```

Uso da autenticação baseada no IAM com o perfil de execução de trabalho do Amazon EMR no EKS

A partir da versão 6.9.0 do Amazon EMR no EKS, a versão 2.1 ou as versões superiores do driver JDBC do Amazon Redshift são empacotadas no ambiente. Com a versão 2.1 e versões superiores do driver JDBC, é possível especificar o URL do JDBC e não incluir o nome de usuário e a senha brutos. Em vez disso, você pode especificar o esquema `jdbc:redshift:iam://`. Isso comanda o driver JDBC para usar seu perfil de execução de trabalho do Amazon EMR no EKS para buscar as credenciais automaticamente.

Consulte [Configurar uma conexão JDBC ou ODBC para usar credenciais do IAM](#) no Guia de gerenciamento do Amazon Redshift para obter mais informações.

O exemplo de URL a seguir usa um esquema `jdbc:redshift:iam://`.

```
jdbc:redshift:iam://examplecluster.abc123xyz789.us-west-2.redshift.amazonaws.com:5439/  
dev
```

As permissões apresentadas a seguir são obrigatórias para o seu perfil de execução de trabalho quando ele atende às condições fornecidas.

Permissão	Condições para se tornar obrigatória para o perfil de execução de trabalho
<code>redshift:GetClusterCredentials</code>	Obrigatória para que o driver JDBC busque as credenciais do Amazon Redshift.
<code>redshift:DescribeCluster</code>	Obrigatória se você especificar o cluster do Amazon Redshift e a Região da AWS no URL do JDBC em vez do endpoint.
<code>redshift-serverless:GetCredentials</code>	Obrigatória para que o driver JDBC busque as credenciais do Amazon Redshift sem servidor.
<code>redshift-serverless:GetWorkgroup</code>	Obrigatória se você estiver usando o Amazon Redshift sem servidor e especificar o URL em termos de nome e de região do grupo de trabalho.

Sua política de perfil de execução de trabalho deve ter as permissões apresentadas a seguir.

```
{
    "Effect": "Allow",
    "Action": [
        "redshift:GetClusterCredentials",
        "redshift:DescribeCluster",
        "redshift-serverless:GetCredentials",
        "redshift-serverless:GetWorkgroup"
    ],
    "Resource": [
        "arn:aws:redshift:AWS_REGION:ACCOUNT_ID:dbname:CLUSTER_NAME/DATABASE_NAME",
        "arn:aws:redshift:AWS_REGION:ACCOUNT_ID:dbuser:DATABASE_NAME/USER_NAME"
    ]
}
```

Autenticação no Amazon Redshift com um driver JDBC

Definição de um nome de usuário e de uma senha no URL do JDBC

Para autenticar um trabalho do Spark em um cluster do Amazon Redshift, você pode especificar o nome e a senha do banco de dados do Amazon Redshift no URL do JDBC.

Note

Se você transferir as credenciais do banco de dados no URL, qualquer pessoa que tenha acesso ao URL também poderá acessar as credenciais. Este método geralmente não é recomendado porque não é uma opção segura.

Se a segurança não for uma preocupação para sua aplicação, você poderá usar o seguinte formato para definir o nome de usuário e a senha no URL do JDBC:

```
jdbc:redshift://redshifthost:5439/database?user=username&password=password
```

Leitura e gravação de e para o Amazon Redshift

Os exemplos de código a seguir são usados PySpark para ler e gravar dados de amostra de e para um banco de dados do Amazon Redshift com uma API de fonte de dados e com o SparkSQL.

Data source API

Use PySpark para ler e gravar dados de amostra de e para um banco de dados do Amazon Redshift com uma API de fonte de dados.

```
import boto3
from pyspark.sql import SQLContext

sc = # existing SparkContext
sql_context = SQLContext(sc)

url = "jdbc:redshift:iam://redshifthost:5439/database"
aws_iam_role_arn = "arn:aws:iam::accountID:role/roleName"

df = sql_context.read \
    .format("io.github.spark_redshift_community.spark.redshift") \
    .option("url", url) \
    .option("dbtable", "tableName") \
    .option("tempdir", "s3://path/for/temp/data") \
    .option("aws_iam_role", "aws_iam_role_arn") \
    .load()

df.write \
    .format("io.github.spark_redshift_community.spark.redshift") \
    .option("url", url) \
    .option("dbtable", "tableName_copy") \
    .option("tempdir", "s3://path/for/temp/data") \
    .option("aws_iam_role", "aws_iam_role_arn") \
    .mode("error") \
    .save()
```

SparkSQL

Use PySpark para ler e gravar dados de amostra de e para um banco de dados do Amazon Redshift usando o SparkSQL.

```
import boto3
import json
import sys
import os
from pyspark.sql import SparkSession

spark = SparkSession \
```

```

    .builder \
    .enableHiveSupport() \
    .getOrCreate()

url = "jdbc:redshift:iam://redshifthost:5439/database"
aws_iam_role_arn = "arn:aws:iam::accountID:role/roleName"

bucket = "s3://path/for/temp/data"
tableName = "tableName" # Redshift table name

s = f"""CREATE TABLE IF NOT EXISTS {tableName} (country string, data string)
      USING io.github.spark_redshift_community.spark.redshift
      OPTIONS (dbtable '{tableName}', tempdir '{bucket}', url '{url}', aws_iam_role
      '{aws_iam_role_arn'} '); """

spark.sql(s)

columns = ["country" ,"data"]
data = [("test-country", "test-data")]
df = spark.sparkContext.parallelize(data).toDF(columns)

# Insert data into table
df.write.insertInto(tableName, overwrite=False)
df = spark.sql(f"SELECT * FROM {tableName}")
df.show()

```

Considerações e limitações ao usar o conector do Spark

O conector Spark oferece suporte a várias maneiras de gerenciar credenciais, configurar a segurança e se conectar a outros AWS serviços. Familiarize-se com as recomendações desta lista para configurar uma conexão funcional e resiliente.

- Recomendamos que você ative o SSL para a conexão JDBC do Spark no Amazon EMR para o Amazon Redshift.
- Recomendamos que você gerencie as credenciais do cluster do Amazon Redshift no AWS Secrets Manager como uma prática recomendada. Consulte [Usando AWS Secrets Manager para recuperar credenciais para se conectar ao Amazon Redshift para](#) ver um exemplo.
- Recomendamos que você transmita um perfil do IAM com o parâmetro `aws_iam_role` para o parâmetro de autenticação do Amazon Redshift.
- No momento, o parâmetro `tempformat` não é compatível com o formato Parquet.

- O URI `tempdir` aponta para um local do Amazon S3. Esse diretório temporário não é limpo automaticamente e, portanto, pode incorrer em custos adicionais.
- Considere as seguintes recomendações para o Amazon Redshift:
 - Recomendamos bloquear o acesso público ao cluster do Amazon Redshift.
 - Recomendamos ativar o [registro em log de auditoria do Amazon Redshift](#).
 - Recomendamos ativar a [criptografia em repouso do Amazon Redshift](#).
- Considere as seguintes recomendações para o Amazon S3:
 - Recomendamos [bloquear o acesso público aos buckets do Amazon S3](#).
 - Recomendamos usar a [criptografia do lado do servidor do Amazon S3](#) para criptografar os buckets do S3 que você usa.
 - Recomendamos usar as [políticas de ciclo de vida do Amazon S3](#) para definir as regras de retenção para o bucket do S3.
 - O Amazon EMR sempre verifica o código importado do código aberto para a imagem. Por motivos de segurança, não oferecemos suporte AWS à codificação de chaves de acesso no `tempdir` URI como método de autenticação do Spark para o Amazon S3.

Para obter mais informações sobre como usar o conector e os parâmetros compatíveis, consulte os seguintes recursos:

- [Integração do Amazon Redshift para Apache Spark](#) no Guia de gerenciamento do Amazon Redshift.
- O [repositório da comunidade spark-redshift](#) no GitHub.

Uso do Volcano como um programador personalizado para Apache Spark no Amazon EMR no EKS

Com o Amazon EMR no EKS, você pode usar o operador do Spark ou o `spark-submit` para executar trabalhos do Spark com programadores personalizados do Kubernetes. Este tutorial aborda como executar trabalhos do Spark com um programador do Volcano em uma fila personalizada.

Visão geral do

O [Volcano](#) pode ajudar a gerenciar a programação do Spark com funções avançadas, como a programação de filas, a programação de compartilhamento equitativo e a reserva de recursos. Para

obter mais informações sobre os benefícios do Volcano, consulte [Why Spark chooses Volcano as built-in batch scheduler on Kubernetes?](#) no blog CNCF da Linux Foundation.

Instalação e configuração do Volcano

1. Escolha um dos seguintes comandos kubectl para instalar o Volcano, com base em suas necessidades arquitetônicas:

```
# x86_64
kubectl apply -f https://raw.githubusercontent.com/volcano-sh/volcano/v1.5.1/
installer/volcano-development.yaml
# arm64:
kubectl apply -f https://raw.githubusercontent.com/volcano-sh/volcano/v1.5.1/
installer/volcano-development-arm64.yaml
```

2. Prepare uma fila de exemplo do Volcano. Uma fila é uma coleção de [PodGroups](#). A fila adota o FIFO e é a base para a divisão de recursos.

```
cat << EOF > volcanoQ.yaml
apiVersion: scheduling.volcano.sh/v1beta1
kind: Queue
metadata:
  name: sparkqueue
spec:
  weight: 4
  reclaimable: false
  capability:
    cpu: 10
    memory: 20Gi
EOF

kubectl apply -f volcanoQ.yaml
```

3. Faça upload de um exemplo de PodGroup manifesto para o Amazon S3. PodGroup é um grupo de grupos com forte associação. Você normalmente usa um PodGroup para agendamento em lote. Envie a amostra PodGroup a seguir para a fila que você definiu na etapa anterior.

```
cat << EOF > podGroup.yaml
apiVersion: scheduling.volcano.sh/v1beta1
kind: PodGroup
spec:
  # Set minMember to 1 to make a driver pod
```

```

minMember: 1
# Specify minResources to support resource reservation.
# Consider the driver pod resource and executors pod resource.
# The available resources should meet the minimum requirements of the Spark job
# to avoid a situation where drivers are scheduled, but they can't schedule
# sufficient executors to progress.
minResources:
  cpu: "1"
  memory: "1Gi"
# Specify the queue. This defines the resource queue that the job should be
submitted to.
queue: sparkqueue
EOF

aws s3 mv podGroup.yaml s3://bucket-name

```

Execução de uma aplicação do Spark usando o programador do Volcano com o operador do Spark

1. Se ainda não o fez, conclua as etapas apresentadas nas seguintes seções para se preparar para usar:
 - a. [Instalação e configuração do Volcano](#)
 - b. [Configuração do operador do Spark para o Amazon EMR no EKS](#)
 - c. [Instalação do operador do Spark](#)

Inclua os seguintes argumentos ao executar o comando `helm install spark-operator-demo`:

```

--set batchScheduler.enable=true
--set webhook.enable=true

```

2. Crie um arquivo SparkApplication de definição `spark-pi.yaml` com `batchScheduler` configurado.

```

apiVersion: "sparkoperator.k8s.io/v1beta2"
kind: SparkApplication
metadata:
  name: spark-pi
  namespace: spark-operator

```

```
spec:
  type: Scala
  mode: cluster
  image: "895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.10.0:latest"
  imagePullPolicy: Always
  mainClass: org.apache.spark.examples.SparkPi
  mainApplicationFile: "local:///usr/lib/spark/examples/jars/spark-examples.jar"
  sparkVersion: "3.3.1"
  batchScheduler: "volcano" #Note: You must specify the batch scheduler name as
                              'volcano'
  restartPolicy:
    type: Never
  volumes:
    - name: "test-volume"
      hostPath:
        path: "/tmp"
        type: Directory
  driver:
    cores: 1
    coreLimit: "1200m"
    memory: "512m"
    labels:
      version: 3.3.1
    serviceAccount: emr-containers-sa-spark
    volumeMounts:
      - name: "test-volume"
        mountPath: "/tmp"
  executor:
    cores: 1
    instances: 1
    memory: "512m"
    labels:
      version: 3.3.1
    volumeMounts:
      - name: "test-volume"
        mountPath: "/tmp"
```

3. Envie a aplicação do Spark com o comando apresentado a seguir. Isso também cria um objeto SparkApplication chamado spark-pi:

```
kubectl apply -f spark-pi.yaml
```

4. Verifique os eventos do objeto SparkApplication com o seguinte comando:

```
kubectl describe pods spark-pi-driver --namespace spark-operator
```

O primeiro evento do pod mostrará que o Volcano programou os pods:

Type	Reason	Age	From	Message
Normal	Scheduled	23s	volcano	Successfully assigned default/spark-pi-driver to integration-worker2

Execução de uma aplicação do Spark usando o programador do Volcano com o **spark-submit**

1. Primeiro, conclua as etapas na seção [Configuração do spark-submit para o Amazon EMR no EKS](#). Você deve desenvolver a distribuição do spark-submit com suporte do Volcano. Para obter mais informações, consulte a seção Build de [Using Volcano as Customized Scheduler for Spark on Kubernetes](#) na documentação do Apache Spark.
2. Defina os valores para as seguintes variáveis de ambiente:

```
export SPARK_HOME=spark-home
export MASTER_URL=k8s://Amazon-EKS-cluster-endpoint
```

3. Envie a aplicação do Spark com o seguinte comando:

```
$SPARK_HOME/bin/spark-submit \
  --class org.apache.spark.examples.SparkPi \
  --master $MASTER_URL \
  --conf spark.kubernetes.container.image=895885662937.dkr.ecr.us-  
west-2.amazonaws.com/spark/emr-6.10.0:latest \
  --conf spark.kubernetes.authenticate.driver.serviceAccountName=spark \
  --deploy-mode cluster \
  --conf spark.kubernetes.namespace=spark-operator \
  --conf spark.kubernetes.scheduler.name=volcano \
  --conf spark.kubernetes.scheduler.volcano.podGroupTemplateFile=/path/to/podgroup-  
template.yaml \
  --conf  
spark.kubernetes.driver.pod.featureSteps=org.apache.spark.deploy.k8s.features.VolcanoFeatu  
r
```

```
--conf
spark.kubernetes.executor.pod.featureSteps=org.apache.spark.deploy.k8s.features.VolcanoFea
\
local:///usr/lib/spark/examples/jars/spark-examples.jar 20
```

4. Verifique os eventos do objeto `SparkApplication` com o seguinte comando:

```
kubectl describe pod spark-pi --namespace spark-operator
```

O primeiro evento do pod mostrará que o Volcano programou os pods:

Type	Reason	Age	From	Message
----	-----	----	----	-----
Normal	Scheduled	23s	volcano	Successfully assigned default/spark-pi-driver to integration-worker2

Usando YuniKorn como um programador personalizado para o Apache Spark no Amazon EMR no EKS

Com o Amazon EMR no EKS, você pode usar o operador do Spark ou o `spark-submit` para executar trabalhos do Spark com programadores personalizados do Kubernetes. Este tutorial aborda como executar trabalhos do Spark com um YuniKorn agendador em uma fila personalizada e o agendamento de grupos.

Visão geral do

[O Apache YuniKorn](#) pode ajudar a gerenciar o agendamento do Spark com agendamento compatível com aplicativos, para que você possa ter um controle refinado sobre as cotas e prioridades dos recursos. Com o agendamento em grupo, YuniKorn agenda um aplicativo somente quando a solicitação mínima de recursos para o aplicativo pode ser satisfeita. Para obter mais informações, consulte [O que é agendamento de gangues](#) no site de YuniKorn documentação do Apache.

Crie seu cluster e prepare-se para YuniKorn

Use as etapas a seguir para implantar um cluster do Amazon EKS. Você pode alterar a Região da AWS (region) e as zonas de disponibilidade (availabilityZones).

1. Defina o cluster do Amazon EKS:


```
cat <<EOF >eks-cluster.yaml
---
apiVersion: eksctl.io/v1alpha5
kind: ClusterConfig

metadata:
  name: emr-eks-cluster
  region: eu-west-1

vpc:
  clusterEndpoints:
    publicAccess: true
    privateAccess: true

iam:
  withOIDC: true

nodeGroups:
  - name: spark-jobs
    labels: { app: spark }
    instanceType: m5.xlarge
    desiredCapacity: 2
    minSize: 2
    maxSize: 3
    availabilityZones: ["eu-west-1a"]
EOF
```

2. Crie o cluster:

```
eksctl create cluster -f eks-cluster.yaml
```

3. Crie o namespace spark-job em que você executará o trabalho do Spark:

```
kubectl create namespace spark-job
```

4. Em seguida, crie um perfil e uma associação de perfis do Kubernetes. Isso é obrigatório para a conta de serviço usada pela execução de trabalho do Spark.

a. Defina a conta de serviço, o perfil e a associação de perfis para os trabalhos do Spark.

```
cat <<EOF >emr-job-execution-rbac.yaml
---
```

```
apiVersion: v1
kind: ServiceAccount
metadata:
  name: spark-sa
  namespace: spark-job
automountServiceAccountToken: false
---
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  name: spark-role
  namespace: spark-job
rules:
  - apiGroups: [ "", "batch", "extensions" ]
    resources: [ "configmaps", "serviceaccounts", "events", "pods", "pods/
exec", "pods/log", "pods/
portforward", "secrets", "services", "persistentvolumeclaims" ]
    verbs: [ "create", "delete", "get", "list", "patch", "update", "watch" ]
  ---
apiVersion: rbac.authorization.k8s.io/v1
kind: RoleBinding
metadata:
  name: spark-sa-rb
  namespace: spark-job
roleRef:
  apiGroup: rbac.authorization.k8s.io
  kind: Role
  name: spark-role
subjects:
  - kind: ServiceAccount
    name: spark-sa
    namespace: spark-job
EOF
```

- b. Aplique a definição de perfil e de associação de perfis do Kubernetes com o seguinte comando:

```
kubectl apply -f emr-job-execution-rbac.yaml
```

Instalar e configurar YuniKorn

1. Use o seguinte comando kubectl para criar um namespace yunikorn para implantar o programador do Yunikorn:

```
kubectl create namespace yunikorn
```

2. Para instalar o programador, execute os seguintes comandos do Helm:

```
helm repo add yunikorn https://apache.github.io/yunikorn-release
```

```
helm repo update
```

```
helm install yunikorn yunikorn/yunikorn --namespace yunikorn
```

Execute um aplicativo Spark com YuniKorn agendador com o operador Spark

1. Se ainda não o fez, conclua as etapas apresentadas nas seguintes seções para se preparar para usar:
 - a. [Crie seu cluster e prepare-se para YuniKorn](#)
 - b. [Instalar e configurar YuniKorn](#)
 - c. [Configuração do operador do Spark para o Amazon EMR no EKS](#)
 - d. [Instalação do operador do Spark](#)

Inclua os seguintes argumentos ao executar o comando `helm install spark-operator-demo`:

```
--set batchScheduler.enable=true  
--set webhook.enable=true
```

2. Crie um arquivo de definição SparkApplication `spark-pi.yaml`.

Para usar YuniKorn como agendador para seus trabalhos, você deve adicionar certas anotações e rótulos à definição do seu aplicativo. As anotações e os rótulos especificam a fila do seu trabalho e a estratégia de programação que você deseja usar.

No exemplo a seguir, a anotação `schedulingPolicyParameters` determina o agendamento coletivo para a aplicação. Em seguida, o exemplo cria grupos de tarefas, ou “coletivos” de tarefas, para especificar a capacidade mínima que deve estar disponível antes da programação dos pods para iniciar a execução do trabalho. E, por fim, é especificado na definição do grupo de tarefas o uso de grupos de nós com o rótulo `"app": "spark"`, conforme definido na seção [Crie seu cluster e prepare-se para YuniKorn](#).

```
apiVersion: "sparkoperator.k8s.io/v1beta2"
kind: SparkApplication
metadata:
  name: spark-pi
  namespace: spark-job
spec:
  type: Scala
  mode: cluster
  image: "895885662937.dkr.ecr.us-west-2.amazonaws.com/spark/emr-6.10.0:latest"
  imagePullPolicy: Always
  mainClass: org.apache.spark.examples.SparkPi
  mainApplicationFile: "local:///usr/lib/spark/examples/jars/spark-examples.jar"
  sparkVersion: "3.3.1"
  restartPolicy:
    type: Never
  volumes:
    - name: "test-volume"
      hostPath:
        path: "/tmp"
        type: Directory
  driver:
    cores: 1
    coreLimit: "1200m"
    memory: "512m"
    labels:
      version: 3.3.1
    annotations:
      yunikorn.apache.org/schedulingPolicyParameters: "placeholderTimeoutSeconds=30
gangSchedulingStyle=Hard"
      yunikorn.apache.org/task-group-name: "spark-driver"
```

```

yunikorn.apache.org/task-groups: |-
  [{
    "name": "spark-driver",
    "minMember": 1,
    "minResource": {
      "cpu": "1200m",
      "memory": "1Gi"
    },
    "nodeSelector": {
      "app": "spark"
    }
  },
  {
    "name": "spark-executor",
    "minMember": 1,
    "minResource": {
      "cpu": "1200m",
      "memory": "1Gi"
    },
    "nodeSelector": {
      "app": "spark"
    }
  }
]
serviceAccount: spark-sa
volumeMounts:
  - name: "test-volume"
    mountPath: "/tmp"
executor:
  cores: 1
  instances: 1
  memory: "512m"
  labels:
    version: 3.3.1
  annotations:
    yunikorn.apache.org/task-group-name: "spark-executor"
  volumeMounts:
    - name: "test-volume"
      mountPath: "/tmp"

```

3. Envie a aplicação do Spark com o comando apresentado a seguir. Isso também cria um objeto SparkApplication chamado spark-pi:

```
kubectl apply -f spark-pi.yaml
```

4. Verifique os eventos do objeto `SparkApplication` com o seguinte comando:

```
kubectl describe sparkapplication spark-pi --namespace spark-job
```

O primeiro evento do pod mostrará que YuniKorn programou os pods:

Type	Reason	Age	From	Message
Normal	Scheduling	3m12s	yunikorn	spark-operator/org-apache-spark-examples-sparkpi-2a777a88b98b8a95-driver is queued and waiting for allocation
Normal	GangScheduling	3m12s	yunikorn	Pod belongs to the taskGroup spark-driver, it will be scheduled as a gang member
Normal	Scheduled	3m10s	yunikorn	Successfully assigned spark
Normal	PodBindSuccessful	3m10s	yunikorn	Pod spark-operator/
Normal	TaskCompleted	2m3s	yunikorn	Task spark-operator/
Normal	Pulling	3m10s	kubelet	Pulling

Execute um aplicativo Spark com YuniKorn agendador com **spark-submit**

1. Primeiro, conclua as etapas na seção [Configuração do spark-submit para o Amazon EMR no EKS](#).
2. Defina os valores para as seguintes variáveis de ambiente:

```
export SPARK_HOME=spark-home
export MASTER_URL=k8s://Amazon-EKS-cluster-endpoint
```

3. Envie a aplicação do Spark com o seguinte comando:

No exemplo a seguir, a anotação `schedulingPolicyParameters` determina o agendamento coletivo para a aplicação. Em seguida, o exemplo cria grupos de tarefas, ou “coletivos” de tarefas, para especificar a capacidade mínima que deve estar disponível antes da programação dos pods para iniciar a execução do trabalho. E, por fim, é especificado na definição do grupo de tarefas o uso de grupos de nós com o rótulo "app": "spark", conforme definido na seção [Crie seu cluster e prepare-se para YuniKorn](#).

```
$SPARK_HOME/bin/spark-submit \
--class org.apache.spark.examples.SparkPi \
```

```

--master $MASTER_URL \
--conf spark.kubernetes.container.image=895885662937.dkr.ecr.us-
west-2.amazonaws.com/spark/emr-6.10.0:latest \
--conf spark.kubernetes.authenticate.driver.serviceAccountName=spark-sa \
--deploy-mode cluster \
--conf spark.kubernetes.namespace=spark-job \
--conf spark.kubernetes.scheduler.name=yunikorn \
--conf spark.kubernetes.driver.annotation.yunikorn.apache.org/
schedulingPolicyParameters="placeholderTimeoutSeconds=30 gangSchedulingStyle=Hard"
\
--conf spark.kubernetes.driver.annotation.yunikorn.apache.org/task-group-
name="spark-driver" \
--conf spark.kubernetes.executor.annotation.yunikorn.apache.org/task-group-
name="spark-executor" \
--conf spark.kubernetes.driver.annotation.yunikorn.apache.org/task-groups='[{
    "name": "spark-driver",
    "minMember": 1,
    "minResource": {
        "cpu": "1200m",
        "memory": "1Gi"
    },
    "nodeSelector": {
        "app": "spark"
    }
},
{
    "name": "spark-executor",
    "minMember": 1,
    "minResource": {
        "cpu": "1200m",
        "memory": "1Gi"
    },
    "nodeSelector": {
        "app": "spark"
    }
}]' \
local:///usr/lib/spark/examples/jars/spark-examples.jar 20

```

4. Verifique os eventos do objeto SparkApplication com o seguinte comando:

```
kubectl describe pod spark-driver-pod --namespace spark-job
```

O primeiro evento do pod mostrará que YuniKorn programou os pods:

Type	Reason	Age	From	Message
----	-----	----	----	-----
Normal	Scheduling	3m12s	yunikorn	spark-operator/org-apache-spark-examples-sparkpi-2a777a88b98b8a95-driver is queued and waiting for allocation
Normal	GangScheduling	3m12s	yunikorn	Pod belongs to the taskGroup spark-driver, it will be scheduled as a gang member
Normal	Scheduled	3m10s	yunikorn	Successfully assigned spark
Normal	PodBindSuccessful	3m10s	yunikorn	Pod spark-operator/
Normal	TaskCompleted	2m3s	yunikorn	Task spark-operator/
Normal	Pulling	3m10s	kubelet	Pulling

Segurança no Amazon EMR no EKS

A segurança na nuvem AWS é a maior prioridade. Como AWS cliente, você se beneficia de data centers e arquiteturas de rede criados para atender aos requisitos das organizações mais sensíveis à segurança.

A segurança é uma responsabilidade compartilhada entre você AWS e você. O [Modelo de Responsabilidade Compartilhada](#) descreve isso como segurança da nuvem e segurança na nuvem:

- **Segurança da nuvem** — AWS é responsável por proteger a infraestrutura que executa AWS os serviços na AWS nuvem. AWS também fornece serviços que você pode usar com segurança. Auditores terceirizados testam e verificam regularmente a eficácia de nossa segurança como parte dos Programas de Conformidade Programas de [AWS](#) de . Para saber mais sobre os programas de conformidade que se aplicam ao Amazon EMR, consulte [AWS Serviços no escopo do programa de conformidade AWS Serviços no escopo do programa](#) .
- **Segurança na nuvem** — Sua responsabilidade é determinada pelo AWS serviço que você usa. Você também é responsável por outros fatores, incluindo a confidencialidade de seus dados, os requisitos da empresa e as leis e regulamentos aplicáveis.

Esta documentação ajuda você a entender como aplicar o modelo de responsabilidade compartilhada ao usar o Amazon EMR no EKS. Os tópicos a seguir demonstram como configurar o Amazon EMR no EKS para atender aos seus objetivos de segurança e de conformidade. Você também aprende a usar outros AWS serviços que ajudam a monitorar e proteger seus recursos do Amazon EMR no EKS.

Tópicos

- [Práticas recomendadas de segurança para o Amazon EMR no EKS](#)
- [Proteção de dados](#)
- [Gerenciamento de Identidade e Acesso](#)
- [Usando o Amazon EMR no EKS com AWS Lake Formation para controle de acesso refinado](#)
- [Registro em log e monitoramento](#)
- [Uso do Amazon S3 Access Grants com o Amazon EMR no EKS](#)
- [Validação de conformidade para o Amazon EMR no EKS](#)
- [Resiliência no Amazon EMR no EKS](#)

- [Segurança da infraestrutura no Amazon EMR no EKS](#)
- [Análise de configuração e vulnerabilidade](#)
- [Conexão com o Amazon EMR no EKS usando um endpoint da VPC de interface](#)
- [Configuração do acesso entre contas para o Amazon EMR no EKS](#)

Práticas recomendadas de segurança para o Amazon EMR no EKS

O Amazon EMR no EKS disponibiliza diversos recursos de segurança a serem considerados no desenvolvimento e na implementação das suas próprias políticas de segurança. As práticas recomendadas a seguir são diretrizes gerais e não representam uma solução completa de segurança. Como essas práticas recomendadas podem não ser adequadas ou suficientes para o seu ambiente, trate-as como considerações úteis em vez de prescrições.

Note

Para obter mais práticas recomendadas de segurança, consulte [Práticas recomendadas de segurança para o Amazon EMR no EKS](#).

Aplicação do princípio de privilégio mínimo

O Amazon EMR no EKS fornece uma política de acesso granular para aplicações que usam perfis do IAM, como perfis de execução. Esses perfis de execução são mapeados para as contas de serviço do Kubernetes por meio da política de confiança do perfil do IAM. O Amazon EMR no EKS cria pods em um namespace registrado do Amazon EKS que executa o código da aplicação fornecido pelo usuário. Os pods de trabalho que executam o código do aplicativo assumem a função de execução ao se conectar a outros AWS serviços. Recomendamos que os perfis de execução recebam somente o conjunto de privilégios mínimos obrigatórios para o trabalho, como a cobertura da aplicação e o acesso ao destino do log. Também recomendamos auditar regularmente as permissões dos trabalhos e após qualquer alteração no código da aplicação.

Listagem de controle de acesso para endpoints

Os endpoints gerenciados podem ser criados somente para clusters do EKS que foram configurados para usar, no mínimo, uma sub-rede privada em sua VPC. Essa configuração restringe o acesso aos

balanceadores de carga criados por endpoints gerenciados para que eles possam ser acessados somente usando a VPC. Para aumentar ainda mais a segurança, recomendamos configurar grupos de segurança com esses balanceadores de carga para que eles possam restringir o tráfego de entrada a um conjunto selecionado de endereços IP.

Obtenção das atualizações de segurança mais recentes para as imagens personalizadas

Para usar imagens personalizadas com o Amazon EMR no EKS, você pode instalar quaisquer binários e bibliotecas na imagem. Você é responsável pela aplicação de patches de segurança aos binários adicionados à imagem. As imagens do Amazon EMR no EKS têm aplicações regulares dos patches de segurança mais recentes. Para obter a imagem mais recente, você deve criar novamente as imagens personalizadas sempre que houver uma nova versão da imagem base da versão do Amazon EMR. Para obter mais informações, consulte [Versões do Amazon EMR no EKS](#) e [Detalhes sobre como selecionar um URI de imagem base](#).

Limitação do acesso à credencial do pod

O Kubernetes oferece suporte a diversos métodos de atribuição de credenciais para um pod. O provisionamento de múltiplos provedores de credenciais pode aumentar a complexidade do seu modelo de segurança. O Amazon EMR no EKS adotou o uso de [perfis do IAM para contas de serviços \(IRSA\)](#) como um provedor de credencial padrão em um namespace do EKS registrado. Outros métodos não têm suporte, incluindo [kube2iam](#), [kiam](#) e o uso de um perfil de instância do EC2 da instância em execução no cluster.

Isolamento de código de uma aplicação não confiável

O Amazon EMR no EKS não inspeciona a integridade do código de uma aplicação enviada pelos usuários do sistema. Se você estiver executando um cluster virtual multilocatário configurado usando diversos perfis de execução, que podem ser usados para enviar trabalhos por locatários não confiáveis que executam códigos arbitrários, há o risco de uma aplicação mal-intencionada escalar os privilégios. Nesta situação, considere isolar perfis de execução com privilégios semelhantes em um cluster virtual diferente.

Permissões de controle de acesso por perfil (RBAC)

Os administradores devem controlar rigorosamente as permissões de controle de acesso por perfil (RBAC) para o Amazon EMR em namespaces gerenciados pelo EKS. No mínimo, as permissões

apresentadas a seguir não devem ser concedidas aos emissores de trabalhos no Amazon EMR em namespaces gerenciados pelo EKS.

- Permissões de RBAC do Kubernetes para modificar o configmap: porque o Amazon EMR no EKS usa os configmaps do Kubernetes para gerar modelos de pod gerenciados que têm o nome da conta de serviço gerenciada. Este atributo não deve sofrer mutação.
- Permissões de RBAC do Kubernetes para executar em pods do Amazon EMR no EKS: para evitar conceder acesso a modelos de pod gerenciados que têm o nome da conta de serviço gerenciada. Este atributo não deve sofrer mutação. Essa permissão também pode conceder acesso ao token JWT montado no pod, que pode ser usado para recuperar as credenciais do perfil de execução.
- Permissões RBAC do Kubernetes para criar pods - para impedir que os usuários criem pods usando um Kubernetes ServiceAccount que pode ser mapeado para uma função do IAM com mais privilégios do que o usuário. AWS
- Permissões RBAC do Kubernetes para implantar webhook mutante - para impedir que os usuários usem o webhook mutante para alterar o nome do Kubernetes para pods criados pelo Amazon EMR no EKS. ServiceAccount
- Permissões de RBAC do Kubernetes para ler segredos do Kubernetes: para evitar que os usuários façam a leitura de dados confidenciais armazenados nesses segredos.

Restrição do acesso às credenciais do perfil do IAM ou do perfil de instância do grupo de nós

- Recomendamos que você atribua AWS permissões mínimas às funções do IAM do nodegroup. Isso ajuda a evitar a escalação de privilégios por código que pode ser executado usando credenciais do perfil de instância de nós de processamento do EKS.
- Para bloquear completamente o acesso às credenciais do perfil de instância para todos os pods executados no Amazon EMR em namespaces gerenciados pelo EKS, recomendamos que você execute comandos iptables em nós do EKS. Para obter mais informações, consulte [Restricting access to Amazon EC2 instance profile credentials](#). No entanto, é importante definir o escopo adequado para os perfis do IAM da sua conta de serviço para que os pods tenham todas as permissões necessárias. Por exemplo, o perfil do IAM do nó recebe permissões para extrair imagens de contêiner do Amazon ECR. Se essas permissões não forem atribuídas a um pod, o pod não poderá extrair imagens de contêiner do Amazon ECR. O plug-in CNI da VPC também precisa ser atualizado. Para obter mais informações, consulte [Walkthrough: Updating the VPC CNI plugin to use IAM roles for service accounts](#).

Proteção de dados

O [modelo de responsabilidade AWS compartilhada](#) se aplica à proteção de dados no Amazon EMR no EKS. Conforme descrito neste modelo, AWS é responsável por proteger a infraestrutura global que executa toda a AWS nuvem. Você é responsável por manter o controle sobre o conteúdo hospedado nessa infraestrutura. Esse conteúdo inclui as tarefas de configuração e gerenciamento de segurança dos serviços da AWS que você usa. Para obter mais informações sobre a privacidade de dados, consulte as [Perguntas frequentes sobre privacidade de dados](#). Para obter informações sobre proteção de dados na Europa, consulte [a postagem do blog sobre o Modelo de Responsabilidade AWS Compartilhada e o GDPR](#) no Blog AWS de Segurança.

Para fins de proteção de dados, recomendamos que você proteja as credenciais da AWS conta e configure contas individuais com AWS Identity and Access Management (IAM). Dessa maneira, cada usuário receberá apenas as permissões necessárias para cumprir suas obrigações de trabalho. Recomendamos também que você proteja seus dados das seguintes formas:

- Use uma autenticação multifator (MFA) com cada conta.
- Use SSL/TLS para se comunicar com AWS os recursos. Recomendamos usar o TLS 1.2 ou posterior.
- Configure a API e o registro de atividades do usuário com AWS CloudTrail.
- Use soluções AWS de criptografia, juntamente com todos os controles de segurança padrão nos AWS serviços.
- Use serviços gerenciados de segurança avançada, como o Amazon Macie, que ajuda a localizar e proteger dados pessoais armazenados no Amazon S3.
- Use as opções de criptografia do Amazon EMR no EKS para criptografar dados em repouso e em trânsito.
- Se você precisar de módulos criptográficos validados pelo FIPS 140-2 ao acessar AWS por meio de uma interface de linha de comando ou de uma API, use um endpoint FIPS. Para obter mais informações sobre endpoints do FIPS, consulte [Federal Information Processing Standard \(FIPS\) 140-2](#).

É altamente recomendável que você nunca coloque informações de identificação confidenciais, como números de conta dos seus clientes, em campos de formato livre, como um campo Nome. Isso inclui quando você trabalha com o Amazon EMR no EKS ou em outros AWS serviços usando o console, a API ou. AWS CLI AWS SDKs Todos os dados inseridos no Amazon EMR no EKS ou em

outros serviços podem ser coletados para a inclusão em logs de diagnóstico. Ao fornecer um URL para um servidor externo, não inclua informações de credenciais no URL para validar a solicitação a esse servidor.

Criptografia em repouso

A criptografia de dados ajuda a impedir que usuários não autorizados leiam dados em um cluster e em sistemas de armazenamento físico de dados associados. Isso inclui dados salvos em mídias persistentes, conhecidos como dados em repouso, e dados que podem ser interceptados enquanto viajam pela rede, conhecidos como dados em trânsito.

A criptografia de dados requer chaves e certificados. Você pode escolher entre várias opções, incluindo chaves gerenciadas por AWS Key Management Service, chaves gerenciadas pelo Amazon S3 e chaves e certificados de fornecedores personalizados fornecidos por você. Ao usar AWS KMS como seu provedor de chaves, cobranças se aplicam pelo armazenamento e uso de chaves de criptografia. Para obter mais informações, consulte [AWS KMS Preço](#).

Antes de especificar as opções de criptografia, decida quais sistemas de gerenciamento de chaves e de certificados você deseja usar. Em seguida, crie as chaves e os certificados para os provedores personalizados especificados como parte das configurações de criptografia.

Criptografia em repouso para dados do EMRFS no Amazon S3

A criptografia do Amazon S3 funciona com objetos do Sistema de Arquivos do EMR (EMRFS) lidos e gravados no Amazon S3. Você especifica a criptografia do lado do servidor (SSE) ou a criptografia do lado do cliente (CSE) do Amazon S3 como o modo de criptografia padrão ao habilitar a criptografia em repouso. Opcionalmente, você pode especificar diferentes métodos de criptografia para buckets individuais usando Per bucket encryption overrides (Substituições de criptografia por bucket). Independentemente de a criptografia do Amazon S3 estar habilitada, o Transport Layer Security (TLS) criptografa os objetos do EMRFS em trânsito entre os nós do cluster do EMR e o Amazon S3. Para obter informações detalhadas sobre a criptografia do Amazon S3, consulte [Proteger dados com criptografia](#) no Guia do desenvolvedor do Amazon Simple Storage Service.

Note

Quando você usa AWS KMS, cobranças são cobradas pelo armazenamento e uso de chaves de criptografia. Para obter mais informações, consulte [AWS KMS Preço](#).

Criptografia do lado do servidor do Amazon S3

Quando você configura a criptografia do lado do servidor do Amazon S3, o Amazon S3 criptografa os dados no nível do objeto à medida que os grava no disco e os descriptografa quando são acessados. Para obter mais informações sobre a SSE, consulte [Proteger os dados usando criptografia do lado do servidor](#) no Guia do desenvolvedor do Amazon Simple Storage Service.

Você pode escolher entre dois sistemas de gerenciamento de chaves diferentes ao especificar a SSE no Amazon EMR no EKS:

- SSE-S3: o Amazon S3 gerencia as chaves para você.
- SSE-KMS - Você usa um AWS KMS key para configurar políticas adequadas para o Amazon EMR no EKS.

A SSE com chaves fornecidas pelo cliente (SSE-C) não está disponível para o uso com o Amazon EMR no EKS.

Criptografia do lado do cliente do Amazon S3

Com a criptografia do lado do cliente do Amazon S3, a criptografia e a descriptografia do Amazon S3 ocorrem no cliente do EMRFS em seu cluster. Os objetos são criptografados antes de serem carregados no Amazon S3 e descriptografados após serem baixados. O provedor especificado por você fornece a chave de criptografia que o cliente usa. O cliente pode usar chaves fornecidas pelo AWS KMS (CSE-KMS) ou uma classe Java personalizada que fornece a chave raiz do lado do cliente (CSE-C). As especificações de criptografia são ligeiramente diferentes entre a CSE-KMS e a CSE-C, dependendo do provedor especificado e dos metadados do objeto que está sendo descriptografado ou criptografado. Para obter mais informações sobre essas diferenças, consulte [Proteger dados usando a criptografia do lado do cliente](#) no Guia do desenvolvedor do Amazon Simple Storage Service.

Note

A CSE do Amazon S3 garante somente que os dados do EMRFS trocados com o Amazon S3 sejam criptografados. Não são todos os dados nos volumes de instâncias do cluster que são criptografados. Além disso, como o Hue não usa o EMRFS, os objetos que o navegador de arquivos do S3 para Hue grava no Amazon S3 não são criptografados.

Criptografia de disco local

O Apache Spark oferece suporte à criptografia de dados temporários gravados em discos locais. Isso abrange arquivos embaralhados, vazamentos embaralhados e blocos de dados armazenados em disco para variáveis de armazenamento em cache e de transmissão. Não abrange a criptografia de dados de saída gerados por aplicativos com APIs `saveAsHadoopFile` ou `saveAsTable`. Também é possível que não haja abrangência para arquivos temporários criados explicitamente pelo usuário. Para obter mais informações, consulte [Local Storage Encryption](#) na documentação do Spark. O Spark não oferece suporte a dados criptografados no disco local, como dados intermediários gravados em um disco local por um processo executor quando os dados não se encaixam na memória. Os dados que persistem no disco têm como escopo o runtime do trabalho, e a chave usada para criptografar os dados é gerada dinamicamente pelo Spark para cada execução de trabalho. Depois que o trabalho do Spark for encerrado, nenhum outro processo poderá descriptografar os dados.

Para pod de drivers e de executores, você criptografa dados em repouso que persistem no volume montado. [Há três opções diferentes de armazenamento AWS nativo que você pode usar com o Kubernetes: EBS, FSx EFS e for Lustre.](#) Todos os três oferecem criptografia em repouso usando uma chave gerenciada pelo serviço ou uma AWS KMS key. Para obter mais informações, consulte [EKS Best Practices Guide](#). Com esta abordagem, todos os dados que persistem no volume montado são criptografados.

Gerenciamento de chaves

Você pode configurar o KMS para alternar automaticamente suas chaves do KMS. Isso alterna suas chaves uma vez por ano, enquanto salva as chaves antigas indefinidamente para que seus dados ainda possam ser descriptografados. Para obter informações adicionais, consulte [Rotação. AWS KMS keys](#)

Criptografia em trânsito

Vários mecanismos de criptografia estão habilitados com a criptografia em trânsito. Esses são recursos de código aberto, específicos da aplicação e podem variar de acordo com a versão do Amazon EMR no EKS. Os seguintes recursos de criptografia específicos da aplicação podem ser habilitados com o Amazon EMR no EKS:

- Spark
 - A comunicação de RPC interna entre os componentes do Spark, como o serviço de transferência de blocos e o serviço de shuffle externo, é criptografada usando a criptografia

AES-256 nas versões 5.9.0 e posteriores do Amazon EMR. Em versões anteriores, a comunicação RPC interna é criptografada usando SASL com DIGEST- MD5 como cifra.

- A comunicação do protocolo HTTP com interfaces de usuário, como o Spark History Server e servidores de arquivos habilitados para HTTPS é criptografada usando a configuração de SSL do Spark. Para obter mais informações, consulte [Configuração do SSL](#) na documentação do Spark.

Para obter mais informações, consulte as [configurações de segurança do Spark](#).

- Você deve permitir somente conexões criptografadas via HTTPS (TLS) usando [a SecureTransport condição aws: nas políticas](#) do Amazon S3 bucket IAM.
- Os resultados de consultas que transmitem para clientes JDBC ou ODBC são criptografados usando TLS.

Gerenciamento de Identidade e Acesso

AWS Identity and Access Management (IAM) é uma ferramenta AWS service (Serviço da AWS) que ajuda o administrador a controlar com segurança o acesso aos AWS recursos. Os administradores do IAM controlam quem pode ser autenticado (iniciar sessão) e autorizado (ter permissões) para usar os recursos do Amazon EMR no EKS. O IAM é um AWS service (Serviço da AWS) que você pode usar sem custo adicional.

Tópicos

- [Público](#)
- [Autenticação com identidades](#)
- [Gerenciar o acesso usando políticas](#)
- [Como o Amazon EMR no EKS funciona com o IAM](#)
- [Uso de perfis vinculados ao serviço para o Amazon EMR no EKS](#)
- [Políticas gerenciadas para o Amazon EMR no EKS](#)
- [Uso de perfis de execução de trabalho com o Amazon EMR no EKS](#)
- [Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS](#)
- [Políticas para controle de acesso baseado em etiquetas](#)
- [Solução de problemas de identidade e acesso do Amazon EMR no EKS](#)

Público

A forma como você usa AWS Identity and Access Management (IAM) difere com base na sua função:

- Usuário do serviço: solicite permissões ao seu administrador se você não conseguir acessar os atributos (consulte [Solução de problemas de identidade e acesso do Amazon EMR no EKS](#)).
- Administrador do serviço: determine o acesso do usuário e envie solicitações de permissão (consulte [Como o Amazon EMR no EKS funciona com o IAM](#))
- Administrador do IAM: escreva políticas para gerenciar o acesso (consulte [Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS](#))

Autenticação com identidades

A autenticação é como você faz login AWS usando suas credenciais de identidade. Você deve estar autenticado como usuário do IAM ou assumindo uma função do IAM. Usuário raiz da conta da AWS

Você pode fazer login como uma identidade federada usando credenciais de uma fonte de identidade como Centro de Identidade do AWS IAM (IAM Identity Center), autenticação de login único ou credenciais. Google/Facebook Para ter mais informações sobre como fazer login, consulte [Como fazer login em sua Conta da AWS](#) no Guia do usuário do Início de Sessão da AWS .

Para acesso programático, AWS fornece um SDK e uma CLI para assinar solicitações criptograficamente. Para ter mais informações, consulte [AWS Signature Version 4 para solicitações de API](#) no Guia do usuário do IAM.

Conta da AWS usuário root

Ao criar um Conta da AWS, você começa com uma identidade de login chamada usuário Conta da AWS raiz que tem acesso completo a todos Serviços da AWS os recursos. É altamente recomendável não usar o usuário-raiz em tarefas diárias. Consulte as tarefas que exigem credenciais de usuário-raiz em [Tarefas que exigem credenciais de usuário-raiz](#) no Guia do usuário do IAM.

Identidade federada

Como prática recomendada, exija que os usuários humanos usem a federação com um provedor de identidade para acessar Serviços da AWS usando credenciais temporárias.

Uma identidade federada é um usuário do seu diretório corporativo, provedor de identidade da web ou Directory Service que acessa Serviços da AWS usando credenciais de uma fonte de identidade. As identidades federadas assumem funções que oferecem credenciais temporárias.

Para o gerenciamento de acesso centralizado, recomendamos Centro de Identidade do AWS IAM. Para saber mais, consulte [O que é o IAM Identity Center?](#) no Guia do usuário do Centro de Identidade do AWS IAM .

Usuários e grupos do IAM

Um [usuário do IAM](#) é uma identidade com permissões específicas para uma única pessoa ou aplicação. É recomendável usar credenciais temporárias, em vez de usuários do IAM com credenciais de longo prazo. Para obter mais informações, consulte [Exigir que usuários humanos usem a federação com um provedor de identidade para acessar AWS usando credenciais temporárias](#) no Guia do usuário do IAM.

Um [grupo do IAM](#) especifica um conjunto de usuários do IAM e facilita o gerenciamento de permissões para grandes conjuntos de usuários. Para ter mais informações, consulte [Casos de uso de usuários do IAM](#) no Guia do usuário do IAM.

Perfis do IAM

Uma [perfil do IAM](#) é uma identidade com permissões específicas que oferece credenciais temporárias. Você pode assumir uma função [mudando de um usuário para uma função do IAM \(console\)](#) ou chamando uma operação de AWS API AWS CLI ou. Para saber mais, consulte [Métodos para assumir um perfil](#) no Manual do usuário do IAM.

Os perfis do IAM são úteis para acesso de usuário federado, permissões de usuário do IAM temporárias, acesso entre contas, acesso entre serviços e aplicações em execução no Amazon EC2. Consulte mais informações em [Acesso a recursos entre contas no IAM](#) no Guia do usuário do IAM.

Gerenciar o acesso usando políticas

Você controla o acesso AWS criando políticas e anexando-as a AWS identidades ou recursos. Uma política define permissões quando associada a uma identidade ou recurso. AWS avalia essas políticas quando um diretor faz uma solicitação. A maioria das políticas é armazenada AWS como documentos JSON. Para ter mais informações sobre documentos de política JSON, consulte [Visão geral das políticas JSON](#) no Guia do usuário do IAM.

Por meio de políticas, os administradores especificam quem tem acesso a que, definindo qual entidade principal pode realizar ações em quais recursos e sob quais condições.

Por padrão, usuários e perfis não têm permissões. Um administrador do IAM cria políticas do IAM e as adiciona aos perfis, os quais os usuários podem então assumir. As políticas do IAM definem permissões, independentemente do método usado para realizar a operação.

Políticas baseadas em identidade

As políticas baseadas em identidade são documentos de políticas de permissão JSON que você anexa a uma identidade (usuário, grupo ou perfil). Essas políticas controlam quais ações as identidades podem realizar, em quais recursos e sob quais condições. Para saber como criar uma política baseada em identidade, consulte [Definir permissões personalizadas do IAM com as políticas gerenciadas pelo cliente](#) no Guia do Usuário do IAM.

As políticas baseadas em identidade podem ser políticas em linha (incorporadas diretamente em uma única identidade) ou políticas gerenciadas (políticas autônomas anexadas a várias identidades). Para saber como escolher entre uma política gerenciada e políticas em linha, consulte [Escolher entre políticas gerenciadas e políticas em linha](#) no Guia do usuário do IAM.

Políticas baseadas em recursos

Políticas baseadas em recursos são documentos de políticas JSON que você anexa a um recurso. Entre os exemplos estão políticas de confiança de perfil do IAM e políticas de bucket do Amazon S3. Em serviços compatíveis com políticas baseadas em recursos, os administradores de serviço podem usá-las para controlar o acesso a um recurso específico. É necessário [especificar uma entidade principal](#) em uma política baseada em recursos.

Políticas baseadas em recursos são políticas em linha localizadas nesse serviço. Você não pode usar políticas AWS gerenciadas do IAM em uma política baseada em recursos.

Outros tipos de política

AWS oferece suporte a tipos de políticas adicionais que podem definir o máximo de permissões concedidas por tipos de políticas mais comuns:

- Limites de permissões: definem o número máximo de permissões que uma política baseada em identidade pode conceder a uma entidade do IAM. Para saber mais sobre limites de permissões, consulte [Limites de permissões para identidades do IAM](#) no Guia do usuário do IAM.

- Políticas de controle de serviço (SCPs) — Especifique as permissões máximas para uma organização ou unidade organizacional em AWS Organizations. Para saber mais, consulte [Políticas de controle de serviço](#) no Guia do usuário do AWS Organizations .
- Políticas de controle de recursos (RCPs) — Defina o máximo de permissões disponíveis para recursos em suas contas. Para obter mais informações, consulte [Políticas de controle de recursos \(RCPs\)](#) no Guia AWS Organizations do usuário.
- Políticas de sessão: políticas avançadas transmitidas como um parâmetro durante a criação de uma sessão temporária para um perfil ou um usuário federado. Para saber mais, consulte [Políticas de sessão](#) no Guia do usuário do IAM.

Vários tipos de política

Quando vários tipos de política são aplicáveis a uma solicitação, é mais complicado compreender as permissões resultantes. Para saber como AWS determinar se uma solicitação deve ser permitida quando vários tipos de políticas estão envolvidos, consulte [Lógica de avaliação de políticas](#) no Guia do usuário do IAM.

Como o Amazon EMR no EKS funciona com o IAM

Antes de usar o IAM para gerenciar o acesso ao Amazon EMR no EKS, saiba quais recursos do IAM estão disponíveis para uso com o Amazon EMR no EKS.

Recursos do IAM que podem ser usados com o Amazon EMR no EKS

Recurso do IAM	Compatível com o Amazon EMR no EKS
Políticas baseadas em identidade	Sim
Políticas baseadas em recurso	Não
Ações de políticas	Sim
Recursos de políticas	Sim
Chaves de condição de políticas	Sim
ACLs	Não
ABAC (tags em políticas)	Sim

Recurso do IAM	Compatível com o Amazon EMR no EKS
Credenciais temporárias	Sim
Permissões de entidade principal	Sim
Perfis de serviço	Não
Perfis vinculados ao serviço	Sim

Para ter uma visão de alto nível de como o Amazon EMR no EKS e em AWS outros serviços funcionam com a maioria dos recursos do IAM, [AWS consulte os serviços que funcionam com](#) o IAM no Guia do usuário do IAM.

Políticas baseadas em identidade para o Amazon EMR no EKS

Compatível com políticas baseadas em identidade: sim

As políticas baseadas em identidade são documentos de políticas de permissões JSON que podem ser anexados a uma identidade, como usuário do IAM, grupo de usuários ou perfil. Essas políticas controlam quais ações os usuários e perfis podem realizar, em quais recursos e em que condições. Para saber como criar uma política baseada em identidade, consulte [Definir permissões personalizadas do IAM com as políticas gerenciadas pelo cliente](#) no Guia do Usuário do IAM.

Com as políticas baseadas em identidade do IAM, é possível especificar ações e recursos permitidos ou negados, assim como as condições sob as quais as ações são permitidas ou negadas. Para saber mais sobre todos os elementos que podem ser usados em uma política JSON, consulte [Referência de elemento de política JSON do IAM](#) no Guia do usuário do IAM.

Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS

Para visualizar exemplos de políticas baseadas em identidade do Amazon EMR no EKS, consulte [Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS](#).

Políticas baseadas em recursos para o Amazon EMR no EKS

Compatibilidade com políticas baseadas em recursos: não

Políticas baseadas em recursos são documentos de políticas JSON que você anexa a um recurso. São exemplos de políticas baseadas em recursos as políticas de confiança de perfil do IAM e as

políticas de bucket do Amazon S3. Em serviços compatíveis com políticas baseadas em recursos, os administradores de serviço podem usá-las para controlar o acesso a um recurso específico. Para o atributo ao qual a política está anexada, a política define quais ações uma entidade principal especificado pode executar nesse atributo e em que condições. É necessário [especificar uma entidade principal](#) em uma política baseada em recursos. Os diretores podem incluir contas, usuários, funções, usuários federados ou. Serviços da AWS

Para permitir o acesso entre contas, é possível especificar uma conta inteira ou as entidades do IAM em outra conta como a entidade principal em uma política baseada em recursos. Consulte mais informações em [Acesso a recursos entre contas no IAM](#) no Guia do usuário do IAM.

Ações de políticas para o Amazon EMR no EKS

Compatível com ações de políticas: sim

Os administradores podem usar políticas AWS JSON para especificar quem tem acesso ao quê. Ou seja, qual entidade principal pode executar ações em quais recursos e em que condições.

O elemento `Action` de uma política JSON descreve as ações que podem ser usadas para permitir ou negar acesso em uma política. Incluem ações em uma política para conceder permissões para executar a operação associada.

Para visualizar uma lista de ações do Amazon EMR no EKS, consulte [Ações, recursos e chaves de condição para o Amazon EMR no EKS](#) na Referência de autorização do serviço.

As ações de política no Amazon EMR no EKS usam o seguinte prefixo antes da ação:

```
emr-containers
```

Para especificar várias ações em uma única declaração, separe-as com vírgulas.

```
"Action": [  
    "emr-containers:action1",  
    "emr-containers:action2"  
]
```

Para visualizar exemplos de políticas baseadas em identidade do Amazon EMR no EKS, consulte [Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS](#).

Recursos de políticas para o Amazon EMR no EKS

Compatível com recursos de políticas: sim

Os administradores podem usar políticas AWS JSON para especificar quem tem acesso ao quê. Ou seja, qual entidade principal pode executar ações em quais recursos e em que condições.

O elemento de política JSON `Resource` especifica o objeto ou os objetos aos quais a ação se aplica. Como prática recomendada, especifique um recurso usando seu [nome do recurso da Amazon \(ARN\)](#). Para ações que não oferecem compatibilidade com permissões em nível de recurso, use um curinga (*) para indicar que a instrução se aplica a todos os recursos.

```
"Resource": "*" 
```

Para ver uma lista dos tipos de recursos do Amazon EMR no EKS e seus ARNs, consulte [Recursos definidos pelo Amazon EMR no EKS na Referência](#) de autorização de serviço. Para aprender com quais ações você pode especificar o ARN de cada recurso, consulte [Ações, recursos e chaves de condição para o Amazon EMR no EKS](#).

Para visualizar exemplos de políticas baseadas em identidade do Amazon EMR no EKS, consulte [Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS](#).

Chaves de condição de políticas para o Amazon EMR no EKS

Compatível com chaves de condição de política específicas de serviço: sim

Os administradores podem usar políticas AWS JSON para especificar quem tem acesso ao quê. Ou seja, qual entidade principal pode executar ações em quais recursos e em que condições.

O elemento `Condition` especifica quando as instruções são executadas com base em critérios definidos. É possível criar expressões condicionais que usem [agentes de condição](#), como “igual a” ou “menor que”, para fazer a condição da política corresponder aos valores na solicitação. Para ver todas as chaves de condição AWS globais, consulte as [chaves de contexto de condição AWS global](#) no Guia do usuário do IAM.

Para visualizar uma lista de chaves de condição do Amazon EMR no EKS e aprender quais ações e recursos você pode usar uma chave de condição, consulte [Ações, recursos e chaves de condição para o Amazon EMR no EKS](#) na Referência de autorização do serviço.

Para visualizar exemplos de políticas baseadas em identidade do Amazon EMR no EKS, consulte [Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS](#).

Listas de controle de acesso (ACLs) no Amazon EMR no EKS

Suportes ACLs: Não

As listas de controle de acesso (ACLs) controlam quais diretores (membros da conta, usuários ou funções) têm permissões para acessar um recurso. ACLs são semelhantes às políticas baseadas em recursos, embora não usem o formato de documento de política JSON.

Controle de acesso por atributo (ABAC) com o Amazon EMR no EKS

Oferece compatibilidade com ABAC (tags em políticas)	Sim

O controle de acesso por atributo (ABAC) é uma estratégia de autorização que define permissões com base em atributos chamados de tags. Você pode anexar tags a entidades e AWS recursos do IAM e, em seguida, criar políticas ABAC para permitir operações quando a tag do diretor corresponder à tag no recurso.

Para controlar o acesso baseado em tags, forneça informações sobre as tags no [elemento de condição](#) de uma política usando as `aws:ResourceTag/key-name`, `aws:RequestTag/key-name` ou chaves de condição `aws:TagKeys`.

Se um serviço for compatível com as três chaves de condição para cada tipo de recurso, o valor será Sim para o serviço. Se um serviço for compatível com as três chaves de condição somente para alguns tipos de recursos, o valor será Parcial

Para saber mais sobre o ABAC, consulte [Definir permissões com autorização do ABAC](#) no Guia do usuário do IAM. Para visualizar um tutorial com etapas para configurar o ABAC, consulte [Usar controle de acesso por atributo \(ABAC\)](#) no Guia do usuário do IAM.

Uso de credencial temporária com o Amazon EMR no EKS

Compatível com credenciais temporárias: sim

As credenciais temporárias fornecem acesso de curto prazo aos AWS recursos e são criadas automaticamente quando você usa a federação ou troca de funções. AWS recomenda que você gere

credenciais temporárias dinamicamente em vez de usar chaves de acesso de longo prazo. Para ter mais informações, consulte [Credenciais de segurança temporárias no IAM](#) e [Serviços da Serviços da AWS que funcionam com o IAM](#) no Guia do usuário do IAM.

Permissões de entidades principais entre serviços para o Amazon EMR no EKS

Compatibilidade com o recurso de encaminhamento de sessões de acesso (FAS): sim

As sessões de acesso direto (FAS) usam as permissões do principal chamando um AWS service (Serviço da AWS), combinadas com a solicitação AWS service (Serviço da AWS) de fazer solicitações aos serviços posteriores. Para obter detalhes da política ao fazer solicitações de FAS, consulte [Sessões de acesso direto](#).

Perfis de serviço para o Amazon EMR no EKS

Oferece suporte a perfis de serviço	Não

Perfis vinculados ao serviço para o Amazon EMR no EKS

Oferece suporte a perfis vinculados ao serviço	Sim

Para obter detalhes sobre como criar ou gerenciar perfis vinculados a serviços, consulte [Serviços da AWS que funcionam com o IAM](#). Encontre um serviço na tabela que inclua um Yes na coluna Perfil vinculado ao serviço. Escolha o link Sim para visualizar a documentação do perfil vinculado a serviço desse serviço.

Uso de perfis vinculados ao serviço para o Amazon EMR no EKS

O Amazon EMR no EKS usa funções vinculadas a [serviços AWS Identity and Access Management](#) (IAM). Um perfil vinculado ao serviço é um tipo exclusivo de perfil do IAM vinculado diretamente ao Amazon EMR no EKS. As funções vinculadas ao serviço são predefinidas pelo Amazon EMR no EKS e incluem todas as permissões que o serviço exige para chamar outros AWS serviços em seu nome.

Um perfil vinculado ao serviço facilita a configuração do Amazon EMR no EKS porque você não precisa adicionar manualmente as permissões necessárias. O Amazon EMR no EKS define as permissões dos perfis vinculados ao serviço e, a menos que definido de outra forma, somente

o Amazon EMR no EKS pode assumir os perfis. As permissões definidas incluem a política de confiança e a política de permissões, que não pode ser anexada a nenhuma outra entidade do IAM.

Um perfil vinculado ao serviço poderá ser excluído somente após excluir seus atributos relacionados. Isso protege os recursos do Amazon EMR no EKS, pois você não pode remover inadvertidamente a permissão de acesso aos recursos.

Para obter informações sobre outros serviços compatíveis com perfis vinculados a serviços, consulte [Serviços da AWS compatíveis com o IAM](#) e procure os serviços que contenham Sim na coluna Service-Linked Role. Escolha um Sim com um link para visualizar a documentação do perfil vinculado para esse serviço.

Permissões de perfis vinculados ao serviço para o Amazon EMR no EKS

O Amazon EMR no EKS usa a função vinculada ao serviço chamada.
AWSServiceRoleForAmazonEMRContainers

O perfil vinculado ao serviço AWSServiceRoleForAmazonEMRContainers confia nos seguintes serviços para aceitar o perfil:

- `emr-containers.amazonaws.com`

A política de permissões de perfil AmazonEMRContainersServiceRolePolicy permite que o Amazon EMR no EKS conclua um conjunto de ações nos recursos especificados, como demonstra a instrução de política apresentada a seguir.

Note

O conteúdo da política gerenciada muda, então a política mostrada aqui pode ser out-of-date. Veja a maior parte da documentação sobre up-to-date políticas na [Amazon EMRContainers ServiceRolePolicy](#) no Guia de referência de políticas AWS gerenciadas.

JSON

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

```

"Effect": "Allow",
"Action": [
    "eks:DescribeCluster",
    "eks:ListNodeGroups",
    "eks:DescribeNodeGroup",
    "ec2:DescribeRouteTables",
    "ec2:DescribeSubnets",
    "ec2:DescribeSecurityGroups",
    "elasticloadbalancing:DescribeInstanceHealth",
    "elasticloadbalancing:DescribeLoadBalancers",
    "elasticloadbalancing:DescribeTargetGroups",
    "elasticloadbalancing:DescribeTargetHealth",
    "eks:ListPodIdentityAssociations",
    "eks:DescribePodIdentityAssociation"
],
"Resource": [
    "*"
],
"Sid": "AllowEKSDescribeclass"
},
{
    "Effect": "Allow",
    "Action": [
        "acm:ImportCertificate",
        "acm:AddTagsToCertificate"
    ],
    "Resource": [
        "*"
    ],
    "Condition": {
        "StringEquals": {
            "aws:RequestTag/emr-container:managed-certificate": "true"
        }
    },
    "Sid": "AllowACMImportcertificate"
},
{
    "Effect": "Allow",
    "Action": [
        "acm:DeleteCertificate"
    ],
    "Resource": [
        "*"
    ],

```

```
    "Condition": {
      "StringEquals": {
        "aws:ResourceTag/emr-container:endpoint:managed-certificate": "true"
      }
    },
    "Sid": "AllowACMDeletecertificate"
  }
]
```

Você deve configurar permissões para que uma entidade do IAM (por exemplo, um usuário, grupo ou função) crie, edite ou exclua um perfil vinculado a serviço. Para saber mais, consulte [Permissões de Função Vinculadas ao Serviço](#) no Guia do Usuário do IAM.

Criação de um perfil vinculado ao serviço para o Amazon EMR no EKS

Não é necessário criar manualmente um perfil vinculado ao serviço. Ao criar um cluster virtual, o Amazon EMR no EKS cria o perfil vinculado ao serviço para você.

Se excluir esse perfil vinculado ao serviço e precisar criá-lo novamente, será possível usar esse mesmo processo para recriar o perfil em sua conta. Ao criar um cluster virtual, o Amazon EMR no EKS cria o perfil vinculado ao serviço para você novamente.

Você também pode usar o console do IAM para criar um perfil vinculado ao serviço com o caso de uso do Amazon EMR no EKS. Na AWS CLI ou na AWS API, crie uma função vinculada ao serviço com o nome do `emr-containers.amazonaws.com` serviço. Para obter mais informações, consulte [Criar uma função vinculada ao serviço](#) no Guia do usuário do IAM. Se você excluir essa função vinculada ao serviço, será possível usar esse mesmo processo para criar a função novamente.

Edição de um perfil vinculado ao serviço para o Amazon EMR no EKS

O Amazon EMR no EKS não permite editar o perfil vinculado ao serviço

`AWSServiceRoleForAmazonEMRContainers`. Depois que criar um perfil vinculado ao serviço, você não poderá alterar o nome do perfil, pois várias entidades podem fazer referência a ele. No entanto, será possível editar a descrição do perfil usando o IAM. Para saber mais, consulte [Editar uma função vinculada a serviço](#) no Guia do usuário do IAM.

Exclusão de um perfil vinculado ao serviço do Amazon EMR no EKS

Se você não precisar mais usar um recurso ou serviço que requer um perfil vinculado ao serviço, é recomendável excluí-lo. Dessa forma, você não tem uma entidade não utilizada que não seja monitorada ativamente ou mantida. No entanto, você deve limpar os recursos de seu perfil vinculado ao serviço antes de excluí-lo manualmente.

Note

Se o serviço Amazon EMR no EKS estiver usando o perfil quando você tentar excluir os recursos, a exclusão poderá falhar. Se isso acontecer, espere alguns minutos e tente a operação novamente.

Excluir recursos do Amazon EMR no EKS usados pelos
AWSServiceRoleForAmazonEMRContainers

1. Abra o console do Amazon EMR.
2. Escolha um cluster virtual.
3. Na página `Virtual Cluster`, escolha `Excluir`.
4. Repita este procedimento para quaisquer outros clusters virtuais em sua conta.

Como excluir manualmente o perfil vinculado ao serviço usando o IAM

Use o console do IAM AWS CLI, o ou a AWS API para excluir a função `AWSServiceRoleForAmazonEMRContainers` vinculada ao serviço. Para saber mais, consulte [Excluir um perfil vinculado ao serviço](#) no Guia do usuário do IAM.

Regiões com suporte para perfis vinculados ao serviço do Amazon EMR no EKS

O Amazon EMR no EKS oferece suporte ao uso de perfis vinculados ao serviço em todas as regiões nas quais o serviço está disponível. Para obter mais informações, consulte [Cotas e endpoints de serviço do Amazon EMR no EKS](#).

Políticas gerenciadas para o Amazon EMR no EKS

Veja detalhes sobre as atualizações das políticas AWS gerenciadas do Amazon EMR no EKS desde 1º de março de 2021.

Alteração	Descrição	Data
AmazonEMRContainersServiceRolePolicy - Adicionadas permissões de leitura para listar associações de identidade de pods do EKS em um cluster e outra permissão de leitura para retornar informações descritivas sobre associações de identidade de pods em um cluster. Para obter mais informações, consulte Amazon EMRContainers ServiceRolePolicy .	As seguintes permissões são adicionadas à política: <code>eks:ListPodIdentityAssociations</code> , <code>eks:DescribePodIdentityAssociation</code> .	3 de fevereiro de 2023
AmazonEMRContainersServiceRolePolicy : permissões adicionadas para descrever e listar grupos de nós do Amazon EKS, descrever grupos de destino do balanceador de carga e descrever a integridade do destino do balanceador de carga.	As seguintes permissões são adicionadas à política: <code>eks:ListNodeGroups</code> , <code>eks:DescribeNodeGroup</code> , <code>elasticloadbalancing:DescribeTargetGroups</code> e <code>elasticloadbalancing:DescribeTargetHealth</code> .	13 de março de 2023
AmazonEMRContainersServiceRolePolicy - Permissões adicionadas para importar e excluir certificados em AWS Certificate Manager.	As seguintes permissões são adicionadas à política: <code>acm:ImportCertificate</code> , <code>acm:AddTagsToCertificate</code> e <code>acm>DeleteCertificate</code> .	3 de dezembro de 2021

Alteração	Descrição	Data
O Amazon EMR no EKS começou a rastrear alterações	O Amazon EMR no EKS começou a monitorar as mudanças em suas políticas AWS gerenciadas.	1.º de março de 2021

Uso de perfis de execução de trabalho com o Amazon EMR no EKS

Para usar o comando `StartJobRun` para enviar uma execução de trabalho em um cluster do EKS, primeiro é necessário integrar um perfil de execução de trabalho para ser usado com um cluster virtual. Para obter mais informações, consulte [Criação de um perfil de execução de trabalho](#) em [Configuração do Amazon EMR no EKS](#). Você também pode seguir as instruções na seção [Create IAM Role for job execution](#) do Amazon EMR on EKS Workshop.

As permissões apresentadas a seguir devem ser inclusas na política de confiança para o perfil de execução de trabalho.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "sts:AssumeRoleWithWebIdentity"
      ],
      "Resource": "*",
      "Condition": {
        "StringLike": {
          "aws:userid": "system:serviceaccount:NAMESPACE:emr-containers-sa-*-*-*AWS_ACCOUNT_ID-BASE36_ENCODED_ROLE_NAME"
        }
      },
      "Sid": "AllowSTSAssumerolewithwebidentity"
    }
  ]
}
```


A política de confiança no exemplo anterior concede permissões somente para uma conta de serviço do Kubernetes gerenciada pelo Amazon EMR com um nome que corresponda ao padrão `emr-containers-sa-*-*-AWS_ACCOUNT_ID-BASE36_ENCODED_ROLE_NAME`. As contas de serviço com esse padrão serão criadas automaticamente no envio do trabalho e terão como escopo o namespace no qual você envia o trabalho. Esta política de confiança permite que estas contas de serviço assumam o perfil de execução e obtenham as credenciais temporárias para o perfil de execução. As contas de serviço de um cluster diferente do Amazon EKS ou de um namespace diferente no mesmo cluster do EKS estão impedidas de assumir o perfil de execução.

Você pode executar o comando apresentado a seguir para atualizar automaticamente a política de confiança no formato fornecido acima.

```
aws emr-containers update-role-trust-policy \  
  --cluster-name cluster \  
  --namespace namespace \  
  --role-name iam_role_name_for_job_execution
```

Controle do acesso ao perfil de execução

Um administrador do cluster do Amazon EKS pode criar um cluster virtual multilocatário do Amazon EMR no EKS ao qual um administrador do IAM pode adicionar diversos perfis de execução. Como os locatários não confiáveis podem usar esses perfis de execução para enviar trabalhos que executam códigos arbitrários, você pode desejar restringir esses locatários para que eles não possam executar códigos que concedem as permissões atribuídas a um ou mais desses perfis de execução. Para restringir a política do IAM anexada a uma identidade do IAM, o administrador do IAM pode usar a chave de condição opcional `emr-containers:ExecutionRoleArn` do nome do recurso da Amazon (ARN). Essa condição aceita uma lista de funções de execução ARNs que têm permissões para o cluster virtual, conforme demonstra a política de permissões a seguir.

JSON

```
{  
  "Version": "2012-10-17",  
  "Statement": [  
    {  
      "Effect": "Allow",  
      "Action": [  
        "emr-containers:StartJobRun"  
      ],  
    },  
  ],  
}
```

```

    "Resource": [
      "arn:aws:emr-containers:*:*/virtualclusters/VIRTUAL_CLUSTER_ID"
    ],
    "Condition": {
      "ArnEquals": {
        "emr-containers:ExecutionRoleArn": [
          "arn:aws:iam:*:role/execution_role_name_1",
          "arn:aws:iam:*:role/execution_role_name_2"
        ]
      }
    },
    "Sid": "AllowEMRCONTAINERSStartjobrun"
  }
}

```

Se desejar permitir todos os perfis de execução que começam com um prefixo específico, como MyRole, você poderá substituir o operador de condição ArnEquals pelo operador ArnLike, e poderá substituir o valor de execution_role_arn na condição por um caractere curinga *. Por exemplo, .arn:aws:iam:*:**AWS_ACCOUNT_ID**:role/MyRole*. Todas as outras [chaves de condição de ARN](#) também são compatíveis.

Note

Com o Amazon EMR no EKS, não é possível conceder permissões para perfis de execução com base em etiquetas ou atributos. O Amazon EMR no EKS não oferece suporte ao controle de acesso por etiqueta (TBAC) ou ao controle de acesso por atributo (ABAC) para perfis de execução.

Exemplos de políticas baseadas em identidade para o Amazon EMR no EKS

Por padrão, os usuários e os perfis não têm permissão para criar ou modificar os recursos do Amazon EMR no EKS. Para conceder permissão aos usuários para executar ações nos recursos que eles precisam, um administrador do IAM pode criar políticas do IAM.

Para aprender a criar uma política baseada em identidade do IAM ao usar esses documentos de política em JSON de exemplo, consulte [Criar políticas do IAM \(console\)](#) no Guia do usuário do IAM.

Para obter detalhes sobre ações e tipos de recursos definidos pelo Amazon EMR no EKS, incluindo o formato de cada um dos ARNs tipos de recursos, consulte [Ações, recursos e chaves de condição do Amazon EMR no EKS na Referência](#) de autorização de serviço.

Tópicos

- [Práticas recomendadas de política](#)
- [Uso do console do Amazon EMR no EKS](#)
- [Permitir que os usuários visualizem suas próprias permissões](#)

Práticas recomendadas de política

As políticas baseadas em identidade determinam se alguém pode criar, acessar ou excluir recursos do Amazon EMR no EKS em sua conta. Essas ações podem incorrer em custos para sua Conta da AWS. Ao criar ou editar políticas baseadas em identidade, siga estas diretrizes e recomendações:

- Comece com as políticas AWS gerenciadas e avance para as permissões de privilégios mínimos — Para começar a conceder permissões aos seus usuários e cargas de trabalho, use as políticas AWS gerenciadas que concedem permissões para muitos casos de uso comuns. Eles estão disponíveis no seu Conta da AWS. Recomendamos que você reduza ainda mais as permissões definindo políticas gerenciadas pelo AWS cliente que sejam específicas para seus casos de uso. Para saber mais, consulte [Políticas gerenciadas pela AWS](#) ou [Políticas gerenciadas pela AWS para funções de trabalho](#) no Guia do usuário do IAM.
- Aplique permissões de privilégio mínimo: ao definir permissões com as políticas do IAM, conceda apenas as permissões necessárias para executar uma tarefa. Você faz isso definindo as ações que podem ser executadas em recursos específicos sob condições específicas, também conhecidas como permissões de privilégio mínimo. Para saber mais sobre como usar o IAM para aplicar permissões, consulte [Políticas e permissões no IAM](#) no Guia do usuário do IAM.
- Use condições nas políticas do IAM para restringir ainda mais o acesso: é possível adicionar uma condição às políticas para limitar o acesso a ações e recursos. Por exemplo, é possível escrever uma condição de política para especificar que todas as solicitações devem ser enviadas usando SSL. Você também pode usar condições para conceder acesso às ações de serviço se elas forem usadas por meio de uma ação específica AWS service (Serviço da AWS), como CloudFormation. Para saber mais, consulte [Elementos da política JSON do IAM: condição](#) no Guia do usuário do IAM.
- Use o IAM Access Analyzer para validar suas políticas do IAM a fim de garantir permissões seguras e funcionais: o IAM Access Analyzer valida as políticas novas e existentes para que elas

sigam a linguagem de política do IAM (JSON) e as práticas recomendadas do IAM. O IAM Access Analyzer oferece mais de cem verificações de política e recomendações práticas para ajudar a criar políticas seguras e funcionais. Para saber mais, consulte [Validação de políticas do IAM Access Analyzer](#) no Guia do Usuário do IAM.

- Exigir autenticação multifator (MFA) — Se você tiver um cenário que exija usuários do IAM ou um usuário root, ative Conta da AWS a MFA para obter segurança adicional. Para exigir MFA quando as operações de API forem chamadas, adicione condições de MFA às suas políticas. Para saber mais, consulte [Configuração de acesso à API protegido por MFA](#) no Guia do Usuário do IAM.

Para saber mais sobre as práticas recomendadas do IAM, consulte [Práticas recomendadas de segurança no IAM](#) no Guia do usuário do IAM.

Uso do console do Amazon EMR no EKS

Para acessar o console do Amazon EMR no EKS, você deve ter um conjunto mínimo de permissões. Essas permissões devem permitir que você liste e visualize detalhes sobre recursos do Amazon EMR no EKS em sua Conta da AWS. Caso crie uma política baseada em identidade mais restritiva que as permissões mínimas necessárias, o console não funcionará como pretendido para entidades (usuários ou perfis) com essa política.

Você não precisa permitir permissões mínimas do console para usuários que estão fazendo chamadas somente para a API AWS CLI ou para a AWS API. Em vez disso, permita o acesso somente a ações que correspondam à operação de API que estiverem tentando executar.

Para garantir que usuários e funções ainda possam usar o Amazon EMR no console EKS, anexe também o Amazon EMR no EKS ConsoleAccess ou a política ReadOnly AWS gerenciada às entidades. Para obter informações, consulte [Adicionar permissões a um usuário](#) no Guia do usuário do IAM.

Permitir que os usuários visualizem suas próprias permissões

Este exemplo mostra como criar uma política que permita que os usuários do IAM visualizem as políticas gerenciadas e em linha anexadas a sua identidade de usuário. Essa política inclui permissões para concluir essa ação no console ou programaticamente usando a API AWS CLI ou AWS .

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

```

    "Statement": [
      {
        "Sid": "ViewOwnUserInfo",
        "Effect": "Allow",
        "Action": [
          "iam:GetUserPolicy",
          "iam:ListGroupsForUser",
          "iam:ListAttachedUserPolicies",
          "iam:ListUserPolicies",
          "iam:GetUser"
        ],
        "Resource": ["arn:aws:iam::*:user/${aws:username}"]
      },
      {
        "Sid": "NavigateInConsole",
        "Effect": "Allow",
        "Action": [
          "iam:GetGroupPolicy",
          "iam:GetPolicyVersion",
          "iam:GetPolicy",
          "iam:ListAttachedGroupPolicies",
          "iam:ListGroupPolicies",
          "iam:ListPolicyVersions",
          "iam:ListPolicies",
          "iam:ListUsers"
        ],
        "Resource": "*"
      }
    ]
  }
}

```

Políticas para controle de acesso baseado em etiquetas

É possível aplicar condições em sua política baseada em identidade para controlar o acesso a clusters virtuais e execuções de trabalhos com base em etiquetas. Para obter mais informações sobre marcação, consulte [Marcação de recursos do Amazon EMR no EKS](#).

Os exemplos a seguir demonstram diferentes cenários e maneiras de usar operadores de condição com chaves de condição do Amazon EMR no EKS. Estas instruções de política do IAM são destinadas somente para fins de demonstração e não devem ser usadas em ambientes de produção.

Há várias maneiras de combinar declarações de políticas para conceder e negar permissões de acordo com seus requisitos. Para obter mais informações sobre como planejar e testar políticas do IAM, consulte o [Guia do usuário do IAM](#).

Important

Recusar, explicitamente, permissões para ações de uso de tags é uma consideração importante. Isso evita que os usuários façam a marcação de um recurso e, assim, concedam a si mesmos permissões que você não pretendia conceder. Se as ações de marcação de um recurso não forem negadas, um usuário poderá modificar as etiquetas e driblar a intenção das políticas baseadas em etiquetas. Para obter um exemplo de política que nega ações de marcação, consulte [Negação de acesso para adição ou remoção de etiquetas](#).

Os exemplos abaixo demonstram políticas de permissões baseadas em identidade usadas para controlar as ações que são permitidas com clusters virtuais do Amazon EMR no EKS.

Ações permitidas somente em recursos com valores de etiquetas específicos

No exemplo de política a seguir, o operador de StringEquals condição tenta combinar dev com o valor do departamento de tag. Se a etiqueta “Department” não tiver sido adicionada ao cluster virtual ou não contiver o valor “dev”, a política não se aplicará e as ações não serão permitidas por esta política. Se nenhuma outra instrução de política permitir as ações, o usuário poderá trabalhar somente com clusters virtuais que tenham essa etiqueta com este valor.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "emr-containers:DescribeVirtualCluster"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringEquals": {
```

```

        "aws:ResourceTag/department": "dev"
      }
    },
    "Sid": "AllowEMRCONTAINERDescribevirtualcluster"
  }
]
}

```

Você também pode especificar vários valores de tag usando um operador de condição. Por exemplo, para permitir ações em clusters virtuais nos quais a etiqueta department contém o valor dev ou test, você pode substituir o bloco condicional no exemplo anterior pelo apresentado a seguir.

```

"Condition": {
  "StringEquals": {
    "aws:ResourceTag/department": ["dev", "test"]
  }
}

```

Marcação obrigatória na criação de um recurso

No exemplo abaixo, a etiqueta precisa ser aplicada ao criar o cluster virtual.

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "emr-containers:CreateVirtualCluster"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringEquals": {
          "aws:RequestTag/department": "dev"
        }
      }
    },
    {
      "Sid": "AllowEMRCONTAINERSCreatevirtualcluster"
    }
  ]
}

```

```
}
]
}
```

A instrução de política apresentada a seguir permite que um usuário crie um cluster virtual somente se o cluster tiver uma etiqueta `department`, que pode conter qualquer valor.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "emr-containers:CreateVirtualCluster"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "Null": {
          "aws:RequestTag/department": "false"
        }
      },
      "Sid": "AllowEMRCONTAINERSCreatevirtualcluster"
    }
  ]
}
```

Negação de acesso para adição ou remoção de etiquetas

O efeito desta política é negar a um usuário a permissão para adicionar ou remover quaisquer etiquetas em clusters virtuais que estejam marcados com uma etiqueta `department` que contenha o valor `dev`.

JSON

```
{
```



```
"Version": "2012-10-17",
"Statement": [
  {
    "Effect": "Deny",
    "Action": [
      "emr-containers:TagResource",
      "emr-containers:UntagResource"
    ],
    "Resource": [
      "*"
    ],
    "Condition": {
      "StringNotEquals": {
        "aws:ResourceTag/department": "dev"
      }
    },
    "Sid": "AllowEMRCONTAINERSTagresource"
  }
]
```

Solução de problemas de identidade e acesso do Amazon EMR no EKS

Use as informações apresentadas a seguir para ajudar a diagnosticar e corrigir problemas comuns que você possa encontrar ao trabalhar com o Amazon EMR no EKS e com o IAM.

Tópicos

- [Não tenho autorização para executar uma ação no Amazon EMR no EKS](#)
- [Não estou autorizado a realizar iam: PassRole](#)
- [Quero permitir que pessoas fora da minha AWS conta acessem meus recursos do Amazon EMR no EKS](#)

Não tenho autorização para executar uma ação no Amazon EMR no EKS

Se isso Console de gerenciamento da AWS indicar que você não está autorizado a realizar uma ação, entre em contato com o administrador para obter ajuda. O administrador é a pessoa que forneceu o seu nome de usuário e senha.

O erro do exemplo a seguir ocorre quando o usuário `mateojackson` tenta usar o console para visualizar detalhes sobre um recurso do *my-example-widget* fictício, mas não tem as permissões fictícias do `emr-containers:GetWidget`.

```
User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform: emr-containers:GetWidget on resource: my-example-widget
```

Neste caso, Mateo pede ao administrador para atualizar suas políticas e permitir o acesso ao recurso *my-example-widget* usando a ação `emr-containers:GetWidget`.

Não estou autorizado a realizar `iam:PassRole`

Se você receber uma mensagem de erro informando que não tem autorização para executar a ação `iam:PassRole`, suas políticas devem ser atualizadas para permitir a transmissão de um perfil ao Amazon EMR no EKS.

Alguns Serviços da AWS permitem que você passe uma função existente para esse serviço em vez de criar uma nova função de serviço ou uma função vinculada ao serviço. Para fazer isso, é preciso ter permissões para passar o perfil para o serviço.

O erro exemplificado a seguir ocorre quando uma usuária do IAM chamada `marymajor` tenta usar o console para executar uma ação no Amazon EMR no EKS. No entanto, a ação exige que o serviço tenha permissões concedidas por um perfil de serviço. Mary não tem permissões para passar o perfil para o serviço.

```
User: arn:aws:iam::123456789012:user/marymajor is not authorized to perform: iam:PassRole
```

Nesse caso, as políticas de Mary devem ser atualizadas para permitir que ela realize a ação `iam:PassRole`.

Se precisar de ajuda, entre em contato com seu AWS administrador. Seu administrador é a pessoa que forneceu suas credenciais de login.

Quero permitir que pessoas fora da minha AWS conta acessem meus recursos do Amazon EMR no EKS

É possível criar um perfil que os usuários de outras contas ou pessoas fora da organização podem usar para acessar seus recursos. É possível especificar quem é confiável para assumir o perfil. Para

serviços que oferecem suporte a políticas baseadas em recursos ou listas de controle de acesso (ACLs), você pode usar essas políticas para conceder às pessoas acesso aos seus recursos.

Para saber mais, consulte:

- Para saber se o Amazon EMR no EKS oferece suporte a esses recursos, consulte [Como o Amazon EMR no EKS funciona com o IAM](#).
- Para saber como fornecer acesso aos seus recursos em todos os Contas da AWS que você possui, consulte Como [fornecer acesso a um usuário do IAM em outro Conta da AWS que você possui](#) no Guia do usuário do IAM.
- Para saber como fornecer acesso aos seus recursos a terceiros Contas da AWS, consulte Como [fornecer acesso Contas da AWS a terceiros](#) no Guia do usuário do IAM.
- Para saber como conceder acesso por meio da federação de identidades, consulte [Conceder acesso a usuários autenticados externamente \(federação de identidades\)](#) no Guia do usuário do IAM.
- Para conhecer a diferença entre perfis e políticas baseadas em recurso para acesso entre contas, consulte [Acesso a recursos entre contas no IAM](#) no Guia do usuário do IAM.

Usando o Amazon EMR no EKS com AWS Lake Formation para controle de acesso refinado

Com o Amazon EMR versão 7.7 e superior, você pode aproveitar o AWS Lake Formation para aplicar controles de acesso refinados nas tabelas do AWS Glue Data Catalog que são apoiadas por buckets do Amazon S3. Esse recurso permite configurar controles de acesso em nível de tabela, linha, coluna e célula para consultas de leitura em Trabalhos Spark do Amazon EMR no EKS.


Tópicos

- [Como o Amazon EMR no EKS funciona com AWS o Lake Formation](#)
- [Habilitar o Lake Formation com o Amazon EMR no EKS](#)
- [Considerações e limitações](#)
- [Solução de problemas](#)

Como o Amazon EMR no EKS funciona com AWS o Lake Formation

O uso do Amazon EMR no EKS com o Lake Formation permite aplicar uma camada de permissões em cada trabalho do Spark para aplicar o controle de permissões do Lake Formation quando o Amazon EMR no EKS executa trabalhos. O Amazon EMR on EKS usa [perfis de recursos do Spark](#) para criar dois perfis para executar trabalhos de forma efetiva. O perfil do usuário executa o código fornecido pelo usuário, enquanto o perfil do sistema impõe as políticas do Lake Formation. Cada trabalho habilitado para o Lake Formation utiliza dois drivers do Spark, um para o perfil do usuário e outro para o perfil do sistema. Para obter mais informações, consulte [O que é o AWS Lake Formation](#).

Veja a seguir uma visão geral de alto nível sobre como o Amazon EMR no EKS obtém acesso aos dados protegidos pelas políticas de segurança do Lake Formation.



As etapas a seguir descrevem este processo:

1. Um usuário envia um Spark Job para um Amazon EMR habilitado para AWS Lake Formation no cluster virtual EKS.
2. O serviço Amazon EMR on EKS configura o driver do usuário e executa o trabalho no perfil do usuário. O Driver do usuário executa uma versão simplificada do Spark que não tem capacidade para iniciar tarefas, solicitar executores, acessar o Amazon S3 ou o Catálogo de dados do Glue. Ele apenas cria um plano de trabalho.
3. O serviço Amazon EMR no EKS configura um segundo driver chamado driver do sistema e o executa no perfil do sistema (com uma identidade privilegiada). O Amazon EKS configura um canal TLS criptografado entre os dois drivers para comunicação. O driver do usuário usa o canal para enviar os planos de trabalho ao driver do sistema. O driver do sistema não executa o código enviado pelo usuário. Ele executa o Spark completo e se comunica com o Amazon S3 e com o Catálogo de dados para acesso aos dados. Ele solicita executores e compila o plano de trabalho em uma sequência de estágios de execução.
4. O serviço Amazon EMR no EKS executa as etapas nos executores. O código do usuário em qualquer estágio é executado exclusivamente nos executores do perfil do usuário.
5. Os estágios que lêem dados das tabelas do Catálogo de dados protegidas pelo Lake Formation ou que aplicam filtros de segurança são delegados aos executores do sistema.

Habilitar o Lake Formation com o Amazon EMR no EKS

Com o Amazon EMR versão 7.7 e superior, você pode aproveitar o AWS Lake Formation para aplicar controles de acesso refinados nas tabelas do catálogo de dados que são apoiadas pelo Amazon S3. Esse recurso permite configurar controles de acesso em nível de tabela, linha, coluna e célula para consultas de leitura em Trabalhos Spark do Amazon EMR no EKS.

Esta seção aborda como criar uma configuração de segurança e configurar o Lake Formation para funcionar com o Amazon EMR. Ele também descreve como criar um cluster virtual com a configuração de segurança que você criou para o Lake Formation. Essas seções devem ser concluídas em sequência.

Etapa 1: Configurar permissões em nível de coluna, linha ou célula com base no Lake Formation

Primeiro, para aplicar permissões em nível de linha e coluna com o Lake Formation, o administrador do data lake do Lake Formation deve definir a tag de LakeFormationAuthorizedCallersessão. O Lake Formation usa essa etiqueta de sessão para autorizar os chamadores e fornecer acesso ao data lake.

Navegue até o console do AWS Lake Formation e selecione a opção Configurações de integração de aplicativos na seção Administração na barra lateral. Em seguida, marque a caixa Permitir que mecanismos externos filtrem dados em locais do Amazon S3 registrados no Lake Formation. Adicione a AWS conta em IDs que os Spark Jobs seriam executados e os valores da tag Session.

Application integration settings [Learn more](#)

Application integration settings

Use the options below to control which third-party engines are allowed to read and filter data in Amazon S3 locations registered with Lake Formation.

☒ **Allow external engines to filter data in Amazon S3 locations registered with Lake Formation**
Check this box to allow third-party engines to access data in Amazon S3 locations that are registered with Lake Formation.

Session tag values
Enter one or more strings that match the LakeFormationAuthorizedCaller session tag defined for third-party engines.

Clear all

EMR on EKS Engine X

Enter one or several string values separated by comma.

AWS account IDs
Enter the external AWS account IDs from where third-party engines are allowed to access locations registered with Lake Formation.

Clear all

012345678901 X
Account

Enter one or more AWS account IDs. Press enter after each ID.

☐ **Allow external engines to access data in Amazon S3 locations with full table access**
When you enable this option, Lake Formation will return credentials to the integrated application directly without IAM session tag validation.

Cancel Save

Observe que a tag de LakeFormationAuthorizedCallersessão passada aqui é passada SecurityConfigurationposteriormente quando você configura as funções do IAM, na seção 3.

Etapa 2: Configurar permissões de RBAC do EKS

Em segundo lugar, você configura permissões para controle de acesso baseado em perfil.

Fornecer permissões do cluster do EKS ao serviço Amazon EMR no EKS

O serviço Amazon EMR no EKS deve ter permissões de perfil de cluster do EKS para que possa criar permissões entre namespaces para que o driver do sistema execute executores de usuário no namespace do usuário.

Criar perfil de cluster

Este exemplo define permissões para um conjunto de recursos.

```
vim emr-containers-cluster-role.yaml
---
apiVersion: rbac.authorization.k8s.io/v1
kind: ClusterRole
metadata:
  name: emr-containers
rules:
  - apiGroups: [""]
    resources: ["namespaces"]
    verbs: ["get"]
  - apiGroups: [""]
    resources: ["serviceaccounts", "services", "configmaps", "events", "pods", "pods/
log"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
  - apiGroups: [""]
    resources: ["secrets"]
    verbs: ["create", "patch", "delete", "watch"]
  - apiGroups: ["apps"]
    resources: ["statefulsets", "deployments"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete", "annotate",
"patch", "label"]
  - apiGroups: ["batch"]
    resources: ["jobs"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete", "annotate",
"patch", "label"]
  - apiGroups: ["extensions", "networking.k8s.io"]
    resources: ["ingresses"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete", "annotate",
"patch", "label"]
  - apiGroups: ["rbac.authorization.k8s.io"]
    resources: ["clusterroles", "clusterrolebindings", "roles", "rolebindings"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
  - apiGroups: [""]
    resources: ["persistentvolumeclaims"]
    verbs: ["get", "list", "watch", "describe", "create", "edit", "delete",
"deletecollection", "annotate", "patch", "label"]
  - apiGroups: ["kyverno.io"]
    resources: ["clusterpolicies"]
```

```
verbs: ["create", "delete"]
---
```

```
kubectl apply -f emr-containers-cluster-role.yaml
```

Criar vinculações de perfis de cluster

```
vim emr-containers-cluster-role-binding.yaml
---
apiVersion: rbac.authorization.k8s.io/v1
kind: ClusterRoleBinding
metadata:
  name: emr-containers
subjects:
- kind: User
  name: emr-containers
  apiGroup: rbac.authorization.k8s.io
roleRef:
  kind: ClusterRole
  name: emr-containers
  apiGroup: rbac.authorization.k8s.io
---
```

```
kubectl apply -f emr-containers-cluster-role-binding.yaml
```

Fornecer acesso ao namespace ao serviço Amazon EMR no EKS

Crie dois namespaces do Kubernetes, um para o driver e executores do usuário e outro para o driver e executores do sistema, e habilite o acesso ao serviço Amazon EMR no EKS para enviar trabalhos nos namespaces do usuário e do sistema. Siga o guia existente para fornecer acesso a cada namespace, disponível em [Habilitar acesso ao cluster usando aws-auth](#).

Etapa 3: Configurar perfis do IAM para componentes de perfil de usuário e sistema

Em terceiro lugar, você define perfis para componentes específicos. Um trabalho Spark habilitado para o Lake Formation tem dois componentes: usuário e sistema. O driver e os executores do usuário são executados no namespace do usuário e estão vinculados ao JobExecutionRole que é passado na API. StartJobRun O driver e os executores do sistema são executados no namespace System e estão vinculados à função. QueryEngine

Configurar o perfil do mecanismo de consulta

A QueryEngine função está vinculada aos componentes do System Space e teria permissões para assumir a tag JobExecutionRolewith LakeFormationAuthorizedCallerSession. A Política de permissões do IAM do perfil do Mecanismo de consulta é a seguinte:

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "AssumeJobRoleWithSessionTagAccessForSystemDriver",
      "Effect": "Allow",
      "Action": [
        "sts:AssumeRole",
        "sts:TagSession"
      ],
      "Resource": [
        "arn:aws:iam::*:role/JobExecutionRole"
      ],
      "Condition": {
        "StringLike": {
          "aws:RequestTag/LakeFormationAuthorizedCaller": "EMR on EKS Engine"
        }
      }
    },
    {
      "Sid": "AssumeJobRoleWithSessionTagAccessForSystemExecutor",
      "Effect": "Allow",
      "Action": [
        "sts:AssumeRole"
      ],
      "Resource": [
        "arn:aws:iam::*:role/JobExecutionRole"
      ]
    },
    {
      "Sid": "CreateCertificateAccessForTLS",
      "Effect": "Allow",
      "Action": [
        "emr-containers:CreateCertificate"
      ],
    }
  ]
}
```

```

    "Resource": [
      "*"
    ]
  }
]
}

```

Configure a política de confiança do perfil do Mecanismo de consulta para confiar no namespace do sistema Kubernetes.

```

aws emr-containers update-role-trust-policy \
  --cluster-name eks cluster \
  --namespace eks system namespace \
  --role-name query_engine_iam_role_name

```

Para obter mais informações, consulte [Atualizar a política de confiança de perfis](#).

Configurar o perfil de execução do trabalho

As permissões do Lake Formation controlam o acesso aos recursos do AWS Glue Data Catalog, aos locais do Amazon S3 e aos dados subjacentes nesses locais. As permissões do IAM controlam o acesso ao Lake Formation, ao AWS Glue APIs e aos recursos. Embora você possa ter a permissão do Lake Formation para acessar uma tabela no Catálogo de dados (SELECT), a operação falhará se você não tiver a permissão do IAM em operações de API `glue:Get*`.

Política de permissões do IAM de JobExecutionRole: A JobExecutionfunção deve ter as declarações de política em sua política de permissões.

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "GlueCatalogAccess",
      "Effect": "Allow",
      "Action": [
        "glue:Get*",
        "glue:Create*",

```

```

        "glue:Update*"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Sid": "LakeFormationAccess",
      "Effect": "Allow",
      "Action": [
        "lakeformation:GetDataAccess"
      ],
      "Resource": [
        "*"
      ]
    },
    {
      "Sid": "CreateCertificateAccessForTLS",
      "Effect": "Allow",
      "Action": [
        "emr-containers:CreateCertificate"
      ],
      "Resource": [
        "*"
      ]
    }
  ]
}

```

Política de confiança do IAM para JobExecutionRole:

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Sid": "TrustQueryEngineRoleForSystemDriver",
      "Effect": "Allow",
      "Action": [
        "sts:AssumeRole",
        "sts:TagSession"
      ]
    }
  ]
}

```

```

    ],
    "Resource": [
      "arn:aws:iam::*:role/QueryExecutionRole"
    ],
    "Condition": {
      "StringLike": {
        "aws:RequestTag/LakeFormationAuthorizedCaller": "EMR on EKS Engine"
      }
    }
  },
  {
    "Sid": "TrustQueryEngineRoleForSystemExecutor",
    "Effect": "Allow",
    "Action": [
      "sts:AssumeRole"
    ],
    "Resource": [
      "arn:aws:iam::*:role/QueryEngineRole"
    ]
  }
]
}

```

Configure a política de confiança do Perfil de execução de trabalho para confiar no namespace de usuário do Kubernetes:

```

aws emr-containers update-role-trust-policy \
  --cluster-name eks cluster \
  --namespace eks User namespace \
  --role-name job_execution_role_name

```

Para obter mais informações, consulte [Atualizar a política de confiança do perfil de execução do trabalho](#).

Etapa 4: Definir a configuração de segurança

Para executar um trabalho habilitado para o Lake Formation, você deve criar uma configuração de segurança.

```

aws emr-containers create-security-configuration \
  --name 'security-configuration-name' \

```

```
--security-configuration '{
  "authorizationConfiguration": {
    "lakeFormationConfiguration": {
      "authorizedSessionTagValue": "SessionTag configured in LakeFormation",
      "secureNamespaceInfo": {
        "clusterId": "eks-cluster-name",
        "namespace": "system-namespace-name"
      },
      "queryEngineRoleArn": "query-engine-IAM-role-ARN"
    }
  }
}'
```

Certifique-se de que a etiqueta de sessão passada no campo `authorizedSessionTagValue` possa autorizar o Lake Formation. Defina o valor como aquele configurado no Lake Formation, em [Etapa 1: Configurar permissões em nível de coluna, linha ou célula com base no Lake Formation](#).

Etapa 5: Criar um cluster virtual

Crie um cluster virtual do Amazon EMR no EKS com uma configuração de segurança.

```
aws emr-containers create-virtual-cluster \
--name my-lf-enabled-vc \
--container-provider '{
  "id": "eks-cluster",
  "type": "EKS",
  "info": {
    "eksInfo": {
      "namespace": "user-namespace"
    }
  }
}' \
--security-configuration-id SecurityConfiguraionId
```

Certifique-se de que o `SecurityConfigurationID` da etapa anterior seja passado, para que a configuração de autorização do Lake Formation seja aplicada a todos os trabalhos em execução no cluster virtual. Para obter mais informações, consulte [Registrar o cluster do Amazon EKS no Amazon EMR](#).

Etapa 6: Enviar um Job no FGAC Enabled VirtualCluster

O processo de envio de trabalhos é o mesmo para trabalhos pertencentes ou não ao Lake Formation. Para obter mais informações, consulte [Enviar uma execução de trabalho com o StartJobRun](#).

O driver Spark, o executor e os registros de eventos do driver do sistema são armazenados no bucket S3 da conta de AWS serviço para depuração. Recomendamos configurar uma chave KMS gerenciada pelo cliente no Job Run para criptografar todos os registros armazenados no service bucket. AWS Para obter mais informações sobre como habilitar a criptografia de logs, consulte [Criptografar logs do Amazon EMR no EKS](#).

Considerações e limitações

Observe as seguintes considerações e limitações ao usar o Lake Formation com o Amazon EMR no EKS:

- O Amazon EMR no EKS oferece suporte ao controle de acesso refinado por meio do Lake Formation apenas para os formatos de tabela Apache Hive, tabela do Iceberg, Apache Hudi e Delta. Os formatos do Apache Hive incluem Parquet, ORC e xSV.
- `DynamicResourceAllocation` está habilitado por padrão e `DynamicResourceAllocation` não pode ser desabilitado para trabalhos do Lake Formation. Como o valor padrão da configuração `spark.dynamicAllocation.maxExecutors` do DRA é infinito, configure um valor adequado com base na sua workload.
- Trabalhos habilitados para Lake Formation não são compatíveis com o uso de imagens personalizadas do EMR no EKS no driver do sistema e nos executores do sistema.
- Você só pode usar o Lake Formation com trabalhos do Spark.
- O EMR no EKS with Lake Formation oferece suporte apenas a uma única sessão do Spark durante todo o trabalho.
- O EMR no EKS com Lake Formation só oferece suporte a consultas de tabelas entre contas compartilhadas por meio de links de recursos.
- As seguintes opções não são compatíveis:
 - Conjuntos de dados distribuídos resilientes (RDD)
 - Streaming do Spark
 - Gravação com as permissões concedidas pelo Lake Formation
 - Controle de acesso para colunas aninhadas

- O EMR no EKS bloqueia funcionalidades que podem prejudicar o isolamento completo do driver do sistema, incluindo as seguintes:
 - UDTs, Hive UDFs e qualquer função definida pelo usuário que envolva classes personalizadas
 - Fontes de dados personalizadas
 - Fornecimento de JARs adicionais para o comando `ANALYZE TABLE` da extensão, conector ou metastore do Spark
- Para impor controles de acesso, `EXPLAIN PLAN` e operações de DDL, como `DESCRIBE TABLE`, não expõem informações restritas.
- O Amazon EMR no EKS restringe o acesso aos logs do driver do sistema Spark em trabalhos habilitados para o Lake Formation. Como o driver do sistema é executado com mais acesso, os eventos e logs que o driver do sistema gera podem incluir informações confidenciais. Para evitar que usuários ou códigos não autorizados acessem esses dados confidenciais, o EMR no EKS desabilitou o acesso aos logs do driver do sistema. Para solucionar problemas, entre em contato com AWS o suporte.
- Se você tiver registrado um local de tabela com o Lake Formation, o caminho de acesso aos dados passa pelas credenciais armazenadas no Lake Formation, independentemente da permissão do IAM para o perfil de execução de tarefas do EMR no EKS. Se você configurar incorretamente o perfil registrado com a localização da tabela, os trabalhos enviados que usam o perfil com a permissão do IAM para o S3 na localização da tabela falharão.
- Gravar em uma tabela do Lake Formation usa a permissão do IAM em vez das permissões concedidas pelo Lake Formation. Se o perfil de execução do trabalho tiver as permissões necessárias do S3, será possível usá-lo para executar operações de gravação.

Observe estas considerações e limitações ao usar o Apache Iceberg:

- Você só pode usar o Apache Iceberg com o catálogo de sessões e não com catálogos nomeados arbitrariamente.
- As tabelas do Iceberg registradas no Lake Formation oferecem suporte apenas às tabelas de metadados `history`, `metadata_log_entries`, `snapshots`, `files`, `manifests` e `refs`. O Amazon EMR oculta as colunas que podem conter dados confidenciais, como `partitions`, `path` e `summaries`. Essa limitação não se aplica às tabelas do Iceberg que não estão registradas no Lake Formation.
- As tabelas que você não registra no Lake Formation oferecem suporte a todos os procedimentos armazenados do Iceberg. Os procedimentos `register_table` e `migrate` não são compatíveis com nenhuma tabela.

- Recomendamos que você use o Iceberg DataFrameWriter V2 em vez do V1.

Para obter mais informações, consulte [Noções básicas sobre os conceitos e a terminologia do Amazon EMR no EKS](#) e [Habilitar acesso ao cluster para o Amazon EMR no EKS](#).

Aviso legal para administradores de dados

Note

Ao conceder acesso aos recursos do Lake Formation a um perfil do IAM para o EMR no EKS, você deve garantir que o administrador ou operador do cluster do EMR seja um administrador confiável. Isso é particularmente relevante para os recursos do Lake Formation que são compartilhados entre várias organizações e AWS contas.

Responsabilidades dos administradores do EKS

- O namespace `System` deve ser protegido. Nenhum usuário, recurso, entidade ou ferramenta teria permissão para ter quaisquer permissões de RBAC do Kubernetes sobre os recursos do Kubernetes no namespace `System`.
- Nenhum usuário, recurso ou entidade, exceto o serviço EMR no EKS, deve ter acesso a `CREATE` para `POD`, `CONFIG_MAP` e `SECRET` no namespace `User`.
- `Drivers System` e `executores System` contêm dados sensíveis. Portanto, eventos Spark, logs de driver Spark e logs de executor Spark no namespace `System` não devem ser encaminhados para sistemas externos de armazenamento de logs.

Solução de problemas

Registro em log

O EMR no EKS usa perfis de recursos do Spark para dividir a execução do trabalho. O Amazon EMR no EKS usa o perfil do usuário para executar o código fornecido, enquanto o perfil do sistema impõe as políticas do Lake Formation. Você pode acessar os registros dos contêineres executados como perfil de usuário configurando a `StartJobRun` solicitação com [MonitoringConfiguration](#).

Servidor de histórico do Spark

O Spark History Server têm todos os eventos do Spark gerados no perfil do usuário e os eventos editados gerados pelo driver do sistema. Você pode ver todos os contêineres dos drivers do usuário e do sistema na guia Executores. No entanto, os links de logs estão disponíveis somente para o perfil do usuário.

O trabalho falhou com permissões insuficientes do Lake Formation

Certifique-se de que o perfil de execução de trabalho tenha permissões para executar SELECT e DESCRIBE na tabela que você está acessando.

Falha na execução do trabalho com RDD

No momento, o EMR no EKS não oferece suporte a operações de conjunto de dados resilientes distribuídos (RDD) em trabalhos habilitados para o Lake Formation.

Não é possível acessar arquivos de dados no Amazon S3

Certifique-se de ter registrado a localização do data lake no Lake Formation.

Exceção de validação de segurança

O EMR no EKS detectou um erro de validação de segurança. Entre em contato com o AWS suporte para obter assistência.

Compartilhando o catálogo de dados e tabelas do AWS Glue entre contas

Você pode compartilhar bancos de dados e tabelas entre contas e ainda usar o Lake Formation. Para obter mais informações, consulte [Compartilhamento de dados entre contas no Lake Formation](#) e [Como faço para compartilhar o catálogo de dados e tabelas do AWS Glue entre contas usando o AWS Lake Formation?](#) .

Erro de inicialização do Iceberg Job que não configura a região AWS

A mensagem é a seguinte:

```
25/02/25 13:33:19 ERROR SparkFGACExceptionSanitizer: Client received error with id =  
b921f9e6-f655-491f-b8bd-b2842cdc20c7,  
reason = IllegalArgumentException, message = Cannot initialize
```

```
LakeFormationAwsClientFactory, please set client.region to a valid aws region
```

Certifique-se de que a configuração do Spark `spark.sql.catalog.catalog_name.client.region` esteja definida como uma região válida.

Lançamento de empregos no Iceberg SparkUnsupportedOperationException

A mensagem é a seguinte:

```
25/02/25 13:53:15 ERROR SparkFGACEExceptionSanitizer: Client received error with id =
  921fef42-0800-448b-bef5-d283d1278ce0,
reason = SparkUnsupportedOperationException, message = Either glue.id or glue.account-
id is set with non-default account.
Cross account access with fine-grained access control is only supported with AWS
Resource Access Manager.
```

Certifique-se de que a configuração do Spark `spark.sql.catalog.catalog_name.glue.account-id` esteja definida como um ID de conta válido.

Falha no trabalho Iceberg com “403 Acesso negado” durante a operação MERGE

A mensagem é a seguinte:

```
software.amazon.awssdk.services.s3.model.S3Exception: Access Denied (Service: S3,
  Status Code: 403,
...
  at
software.amazon.awssdk.services.s3.DefaultS3Client.deleteObject(DefaultS3Client.java:3365)
  at org.apache.iceberg.aws.s3.S3FileIO.deleteFile(S3FileIO.java:162)
  at org.apache.iceberg.io.FileIO.deleteFile(FileIO.java:86)
  at
org.apache.iceberg.io.RollingFileWriter.closeCurrentWriter(RollingFileWriter.java:129)
```

Desabilite as operações de exclusão do S3 no Spark adicionando a seguinte propriedade. `--conf spark.sql.catalog.s3-table-name.s3.delete-enabled=false`.

Registro em log e monitoramento

Para detectar incidentes, receber alertas quando incidentes ocorrerem e responder a eles, use estas opções com o Amazon EMR no EKS:

- Monitore o Amazon EMR no EKS com AWS CloudTrail - [AWS CloudTrail](#) fornece um registro das ações realizadas por um usuário, função ou AWS serviço no Amazon EMR no EKS. Ele captura as chamadas do console do Amazon EMR e as chamadas de código para as operações de API do Amazon EMR no EKS como eventos. Dessa forma, você pode determinar a solicitação feita ao Amazon EMR no EKS, o endereço IP do qual a solicitação foi feita, quem fez a solicitação, quando ela foi feita e detalhes adicionais. Para obter mais informações, consulte [Registro do Amazon EMR em chamadas de API EKS usando AWS CloudTrail](#).
- Use CloudWatch Events with Amazon EMR on EKS - CloudWatch Events fornece um fluxo quase em tempo real de eventos do sistema que descrevem mudanças nos AWS recursos. CloudWatch Os eventos ficam cientes das mudanças operacionais à medida que elas ocorrem, respondem a elas e tomam medidas corretivas conforme necessário, enviando mensagens para responder ao ambiente, ativando funções, fazendo alterações e capturando informações de estado. Para usar CloudWatch Eventos com o Amazon EMR no EKS, crie uma regra que seja acionada em uma chamada de API do Amazon EMR no EKS via. CloudTrail Para obter mais informações, consulte [Monitore trabalhos com a Amazon CloudWatch Events](#).

Criptografar logs do Amazon EMR no EKS com armazenamento gerenciado

As seções a seguir mostram como configurar a criptografia para logs.

Habilitar criptografia

Para criptografar logs no armazenamento gerenciado com sua própria chave do KMS, use a configuração a seguir ao enviar uma execução de trabalho.

```
"monitoringConfiguration": {
  "managedLogs": {
    "allowAWSToRetainLogs": "ENABLED",
    "encryptionKeyArn": "KMS key arn"
  },
  "persistentAppUI": "ENABLED"
}
```

A `allowAWSToRetainLogs` configuração permite AWS reter os registros do namespace do sistema ao executar um trabalho usando o FGAC nativo. A `persistentAppUI` configuração permite AWS salvar registros de eventos que são usados para gerar a interface do usuário do Spark.

encryptionKeyArn é usado para especificar o ARN da chave do KMS que você deseja usar para criptografar os log armazenados pela AWS.

Permissões necessárias para criptografia de logs

O usuário que envia o trabalho ou visualiza a IU do Spark deve ter permissão para as ações `kms:DescribeKey`, `kms:GenerateDataKey` e `kms:Decrypt` para a chave de criptografia. Essas permissões são usadas para verificar a validade da chave e confirmar que o usuário possui as permissões necessárias para ler e gravar logs criptografados com a chave do KMS. Se o usuário que envia o trabalho não tiver as permissões necessárias, o Amazon EMR no EKS rejeitará o envio da execução do trabalho.

Exemplo de política do IAM para a função usada para chamar `StartJobRun`

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Action": [
        "emr-containers:StartJobRun"
      ],
      "Resource": [
        "*"
      ],
      "Effect": "Allow",
      "Sid": "AllowEMRCONTAINERSStartjobrun"
    },
    {
      "Action": [
        "kms:DescribeKey",
        "kms:Decrypt",
        "kms:GenerateDataKey"
      ],
      "Resource": [
        "arn:aws:kms:*:*:key/key-id"
      ],
      "Effect": "Allow",
      "Sid": "AllowKMSDescribekey"
    }
  ]
}
```

```
}
```

Você também deve configurar a chave do KMS para permitir as entidades principais `elasticmapreduce.amazonaws.com` e `elasticmapreduce.amazonaws.com` para `kms:GenerateDataKey` e `kms:Decrypt`. Isso permite que o EMR leia e grave logs criptografados com a chave do KMS no armazenamento gerenciado.

Exemplo de política de chave do KMS

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kms:DescribeKey"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringLike": {
          "kms:viaService": "emr-containers.*.amazonaws.com"
        }
      },
      "Sid": "AllowKMSDescribekey"
    },
    {
      "Effect": "Allow",
      "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey"
      ],
      "Resource": [
        "*"
      ],
      "Condition": {
        "StringLike": {
```

```

        "kms:viaService": "emr-containers.*.amazonaws.com",
        "kms:EncryptionContext:aws:emr-containers:virtualClusterId": "virtual
cluster id"
    },
    },
    "Sid": "AllowKMSDecryptGenerate"
},
{
    "Effect": "Allow",
    "Action": [
        "kms:Decrypt",
        "kms:GenerateDataKey"
    ],
    "Resource": [
        "*"
    ],
    "Condition": {
        "StringLike": {
            "kms:EncryptionContext:aws:emr-containers:virtualClusterId": "virtual
cluster id"
        },
        "ArnLike": {
            "aws:SourceArn": "arn:aws:emr-containers:*:*:/
virtualclusters/virtual_cluster_id"
        }
    },
    "Sid": "AllowKMSDecryptService"
}
]
}

```

Como práticas recomendadas de segurança, recomendamos que você adicione as condições `kms:EncryptionContext`, `kms:viaService` e `aws:SourceArn`. Essas condições ajudam a garantir que a chave seja usada somente pelo Amazon EMR no EKS e usada exclusivamente para logs gerados a partir de trabalhos executados em um cluster virtual específico.

Registro do Amazon EMR em chamadas de API EKS usando AWS CloudTrail

O Amazon EMR no EKS é integrado com AWS CloudTrail, um serviço que fornece um registro das ações realizadas por um usuário, função ou AWS serviço no Amazon EMR no EKS. CloudTrail

captura todas as chamadas de API para o Amazon EMR no EKS como eventos. As chamadas capturadas incluem as chamadas do console do Amazon EMR no EKS e as chamadas de código para as operações de API do Amazon EMR no EKS. Se você criar uma trilha, poderá habilitar a entrega contínua de CloudTrail eventos para um bucket do Amazon S3, incluindo eventos para o Amazon EMR no EKS. Se você não configurar uma trilha, ainda poderá ver os eventos mais recentes no CloudTrail console no Histórico de eventos. Usando as informações coletadas por CloudTrail, você pode determinar a solicitação que foi feita ao Amazon EMR no EKS, o endereço IP a partir do qual a solicitação foi feita, quem fez a solicitação, quando ela foi feita e detalhes adicionais.

Para saber mais sobre isso CloudTrail, consulte o [Guia AWS CloudTrail do usuário](#).

Informações sobre o Amazon EMR sobre EKS em CloudTrail

CloudTrail é ativado em sua AWS conta quando você cria a conta. Quando a atividade ocorre no Amazon EMR no EKS, essa atividade é registrada em um CloudTrail evento junto com outros eventos de AWS serviço no histórico de eventos. Você pode visualizar, pesquisar e baixar eventos recentes em sua AWS conta. Para obter mais informações, consulte [Visualização de eventos com histórico de CloudTrail eventos](#).

Para um registro contínuo dos eventos em sua AWS conta, incluindo eventos do Amazon EMR no EKS, crie uma trilha. Uma trilha permite CloudTrail entregar arquivos de log para um bucket do Amazon S3. Por padrão, quando você cria uma trilha no console, a trilha se aplica a todas as AWS regiões. A trilha registra eventos de todas as regiões na AWS partição e entrega os arquivos de log ao bucket do Amazon S3 que você especificar. Além disso, você pode configurar outros AWS serviços para analisar e agir com base nos dados de eventos coletados nos CloudTrail registros. Para saber mais, consulte:

- [Visão geral da criação de uma trilha](#)
- [CloudTrail serviços e integrações suportados](#)
- [Configurando notificações do Amazon SNS para CloudTrail](#)
- [Recebendo arquivos de CloudTrail log de várias regiões](#) e [Recebendo arquivos de CloudTrail log de várias contas](#)

Todas as ações do Amazon EMR no EKS são registradas CloudTrail e documentadas na documentação da API Amazon [EMR](#) on EKS. Por exemplo, chamadas para o `CreateVirtualCluster` `StartJobRun` e `ListJobRuns` as ações geram entradas nos arquivos de CloudTrail log.

Cada entrada de log ou evento contém informações sobre quem gerou a solicitação. As informações de identidade ajudam a determinar o seguinte:

- Se a solicitação foi feita com credenciais de usuário root ou AWS Identity and Access Management (IAM).
- Se a solicitação foi feita com credenciais de segurança temporárias de um perfil ou de um usuário federado.
- Se a solicitação foi feita por outro AWS serviço.

Para obter mais informações, consulte o [elemento Identidade CloudTrail do usuário](#).

Noções básicas sobre entradas de arquivos de log do Amazon EMR no EKS

Uma trilha é uma configuração que permite a entrega de eventos como arquivos de log para um bucket do Amazon S3 que você especificar. CloudTrail os arquivos de log contêm uma ou mais entradas de log. Um evento representa uma única solicitação de qualquer fonte e inclui informações sobre a ação solicitada, a data e a hora da ação, os parâmetros da solicitação e assim por diante. CloudTrail os arquivos de log não são um rastreamento de pilha ordenado das chamadas públicas de API, portanto, eles não aparecem em nenhuma ordem específica.

O exemplo a seguir mostra uma entrada de CloudTrail registro que demonstra a [ListJobRuns](#) ação.

```
{
  "eventVersion": "1.05",
  "userIdentity": {
    "type": "AssumedRole",
    "principalId": "AIDACKCEVSQ6C2EXAMPLE:admin",
    "arn": "arn:aws:sts::012345678910:assumed-role/Admin/admin",
    "accountId": "012345678910",
    "accessKeyId": "AKIAIOSFODNN7EXAMPLE",
    "sessionContext": {
      "sessionIssuer": {
        "type": "Role",
        "principalId": "AIDACKCEVSQ6C2EXAMPLE",
        "arn": "arn:aws:iam::012345678910:role/Admin",
        "accountId": "012345678910",
        "userName": "Admin"
      },
      "webIdFederationData": {},
      "attributes": {
        "mfaAuthenticated": "false",
```



```

        "creationDate": "2020-11-04T21:49:36Z"
    }
}
},
"eventTime": "2020-11-04T21:52:58Z",
"eventSource": "emr-containers.amazonaws.com",
"eventName": "ListJobRuns",
"awsRegion": "us-east-1",
"sourceIPAddress": "203.0.113.1",
"userAgent": "aws-cli/1.11.167 Python/2.7.10 Darwin/16.7.0 botocore/1.7.25",
"requestParameters": {
    "virtualClusterId": "1K48XXXXXXHCB"
},
"responseElements": null,
"requestID": "890b8639-e51f-11e7-b038-EXAMPLE",
"eventID": "874f89fa-70fc-4798-bc00-EXAMPLE",
"readOnly": true,
"eventType": "AwsApiCall",
"recipientAccountId": "012345678910"
}

```

Uso do Amazon S3 Access Grants com o Amazon EMR no EKS

Visão geral do S3 Access Grants para o Amazon EMR no EKS

Com as versões 6.15.0 e superiores do Amazon EMR, o Amazon S3 Access Grants fornece uma solução de controle de acesso escalável que você pode usar para aumentar o acesso aos seus dados do Amazon S3 no Amazon EMR no EKS. Se você tiver uma configuração de permissão complexa ou grande para os dados do S3, poderá usar a funcionalidade Access Grants para escalar as permissões de dados do S3 para usuários, perfis e aplicações.

Use o S3 Access Grants para aumentar o acesso aos dados do Amazon S3 além das permissões concedidas pelo perfil de runtime ou pelos perfis do IAM que estão anexados às identidades com acesso ao seu cluster do Amazon EMR no EKS.

Para obter mais informações, consulte [Managing access with S3 Access Grants for Amazon EMR](#) no Guia de gerenciamento do Amazon EMR e [Gerenciar o acesso com o S3 Access Grants](#) no Guia do usuário do Amazon Simple Storage Service.

Esta página descreve os requisitos para executar um trabalho do Spark no Amazon EMR no EKS com a integração do S3 Access Grants. Com o Amazon EMR no EKS, o S3 Access Grants

exige uma declaração adicional de política do IAM no perfil de execução do seu trabalho e uma configuração adicional de substituição da API `StartJobRun`. Para ver as etapas de configuração do S3 Access Grants com outras implantações do Amazon EMR, consulte a seguinte documentação:

- [Using S3 Access Grants with Amazon EMR](#)
- [Using S3 Access Grants with EMR Serverless](#)

Execução de um cluster do Amazon EMR no EKS com o S3 Access Grants para gerenciamento de dados

Você pode habilitar o S3 Access Grants no Amazon EMR no EKS e executar um trabalho do Spark. Quando sua aplicação solicita dados do S3, o Amazon S3 fornece credenciais temporárias que têm como escopo o bucket, prefixo ou objeto específico.

1. Configure um perfil de execução de trabalhos para o cluster do Amazon EMR no EKS. Inclua as permissões do IAM necessárias para executar os trabalhos do Spark, `s3:GetDataAccess` e `s3:GetAccessGrantsInstanceForPrefix`:

```
{
  "Effect": "Allow",
  "Action": [
    "s3:GetDataAccess",
    "s3:GetAccessGrantsInstanceForPrefix"
  ],
  "Resource": [
    //LIST ALL INSTANCE ARNS THAT THE ROLE IS ALLOWED TO QUERY
    "arn:aws_partition:s3:Region:account-id1:access-grants/default",
    "arn:aws_partition:s3:Region:account-id2:access-grants/default"
  ]
}
```

Note

Se você especificar perfis do IAM para a execução de trabalhos que tenham permissões adicionais de acesso direto ao S3, os usuários poderão acessar os dados independentemente das permissões definidas no S3 Access Grants.

2. Envie um trabalho para o cluster do Amazon EMR no EKS com um rótulo de versão 6.15 ou superior do Amazon EMR e a classificação `emrfs-site`, conforme mostra o exemplo a seguir. Substitua os valores em *red text* pelos valores apropriados ao seu cenário de uso.

```
{
  "name": "myjob",
  "virtualClusterId": "123456",
  "executionRoleArn": "iam_role_name_for_job_execution",
  "releaseLabel": "emr-7.12.0-latest",
  "jobDriver": {
    "sparkSubmitJobDriver": {
      "entryPoint": "entryPoint_location",
      "entryPointArguments": ["argument1", "argument2"],
      "sparkSubmitParameters": "--class main_class"
    }
  },
  "configurationOverrides": {
    "applicationConfiguration": [
      {
        "classification": "emrfs-site",
        "properties": {
          "fs.s3.s3AccessGrants.enabled": "true",
          "fs.s3.s3AccessGrants.fallbackToIAM": "false"
        }
      }
    ]
  }
}
```

Considerações sobre o S3 Access Grants com o Amazon EMR no EKS

Para obter informações importantes sobre suporte, compatibilidade e comportamento ao usar o Amazon S3 Access Grants com o Amazon EMR no EKS, consulte [Considerações sobre o S3 Access Grants com o Amazon EMR](#) no Guia de gerenciamento do Amazon EMR.

Validação de conformidade para o Amazon EMR no EKS

Audidores terceirizados avaliam a segurança e a conformidade do Amazon EMR no EKS como parte de AWS vários programas de conformidade. Isso inclui SOC, PCI, FedRAMP, HIPAA e outros.

Resiliência no Amazon EMR no EKS

A infraestrutura AWS global é construída em torno de AWS regiões e zonas de disponibilidade. AWS As regiões fornecem várias zonas de disponibilidade fisicamente separadas e isoladas, conectadas a redes de baixa latência, alta taxa de transferência e alta redundância. Com as zonas de disponibilidade, é possível projetar e operar aplicações e bancos de dados que automaticamente executam o failover entre as zonas sem interrupção. As zonas de disponibilidade são altamente disponíveis, tolerantes a falhas e escaláveis que uma ou várias infraestruturas de data center tradicionais.

Para obter mais informações sobre AWS regiões e zonas de disponibilidade, consulte [Infraestrutura AWS global](#).

Além da infraestrutura AWS global, o Amazon EMR no EKS oferece integração com o Amazon S3 por meio do EMRFS para ajudar a suportar suas necessidades de resiliência e backup de dados.

Segurança da infraestrutura no Amazon EMR no EKS

Como um serviço gerenciado, o Amazon EMR é protegido pela segurança de rede AWS global. Para obter informações sobre serviços AWS de segurança e como AWS proteger a infraestrutura, consulte [AWS Cloud Security](#). Para projetar seu AWS ambiente usando as melhores práticas de segurança de infraestrutura, consulte [Proteção](#) de infraestrutura no Security Pillar AWS Well-Architected Framework.

Você usa chamadas de API AWS publicadas para acessar o Amazon EMR pela rede. Os clientes devem oferecer compatibilidade com:

- Transport Layer Security (TLS). Exigimos TLS 1.2 e recomendamos TLS 1.3.
- Conjuntos de criptografia com perfect forward secrecy (PFS) como DHE (Ephemeral Diffie-Hellman) ou ECDHE (Ephemeral Elliptic Curve Diffie-Hellman). A maioria dos sistemas modernos, como Java 7 e versões posteriores, comporta esses modos.

Análise de configuração e vulnerabilidade

AWS lida com tarefas básicas de segurança, como sistema operacional (SO) convidado e aplicação de patches em bancos de dados, configuração de firewall e recuperação de desastres. Esses procedimentos foram revisados e certificados por terceiros certificados. Para obter mais detalhes, consulte os seguintes recursos da :

- [Validação de conformidade para o Amazon EMR no EKS](#)
- [Modelo de responsabilidade compartilhada](#)
- [Amazon Web Services: visão geral do processo de segurança](#) (whitepaper)

Conexão com o Amazon EMR no EKS usando um endpoint da VPC de interface

Você pode se conectar diretamente ao Amazon EMR no EKS usando [endpoints de interface VPC \(AWS PrivateLink\) em sua Virtual Private Cloud \(VPC\)](#) em vez de se conectar pela Internet. Quando você usa uma interface VPC endpoint, a comunicação entre sua VPC e o Amazon EMR no EKS é conduzida inteiramente dentro da rede. AWS Cada VPC endpoint é representado por uma ou mais [interfaces de rede elástica \(ENIs\)](#) com endereços IP privados em suas sub-redes VPC.

A interface VPC endpoint conecta sua VPC diretamente ao Amazon EMR no EKS sem um gateway de internet, dispositivo NAT, conexão VPN ou conexão Direct Connect. AWS As instâncias em sua VPC não precisam de endereços IP públicos para se comunicarem com a API do Amazon EMR no EKS.

Você pode criar uma interface VPC endpoint para se conectar ao Amazon EMR no EKS usando os Console de gerenciamento da AWS comandos or (). AWS Command Line Interface AWS CLI Para obter mais informações, consulte [Criação de um endpoint de interface](#).

Após criar um endpoint da VPC de interface, se você habilitar nomes de host DNS privados para o endpoint, o endpoint padrão do Amazon EMR no EKS será resolvido para seu endpoint da VPC. O endpoint de nome de serviço padrão para o Amazon EMR no EKS estará no formato a seguir.

```
emr-containers.Region.amazonaws.com
```

Se você não habilitar nomes de host DNS privados, a Amazon VPC fornecerá um nome de endpoint DNS que poderá ser usado no formato a seguir.

```
VPC_Endpoint_ID.emr-containers.Region.vpce.amazonaws.com
```

Para obter mais informações, consulte [Interface VPC Endpoints \(AWS PrivateLink\)](#) no Guia do usuário da Amazon VPC. O Amazon EMR no EKS oferece suporte a chamadas para todas as [ações de API](#) dentro da sua VPC.

Você pode anexar políticas de endpoint da VPC a um endpoint da VPC para controlar o acesso de entidades principais do IAM. Também é possível associar grupos de segurança a um VPC endpoint para controlar o acesso de entrada e saída com base na origem e no destino do tráfego de rede, como um intervalo de endereços IP. Para obter mais informações, consulte [Controlar o acesso a serviços com endpoints da VPC](#).

Criação de uma política de endpoint da VPC para o Amazon EMR no EKS

É possível criar uma política para endpoints da Amazon VPC para o Amazon EMR no EKS com a finalidade de especificar o seguinte:

- O principal que pode ou não executar ações
- As ações que podem ser executadas
- Os recursos nos quais as ações podem ser executadas

Para obter mais informações, consulte [Controlling Access to Services with VPC Endpoints](#) no Guia do usuário da Amazon VPC.

Exemplo Política de VPC Endpoint para negar todo o acesso de uma conta especificada AWS

A política de VPC endpoint a seguir nega à AWS conta **123456789012** todo o acesso aos recursos que usam o endpoint.

```
{
  "Statement": [
    {
      "Action": "*",
      "Effect": "Allow",
      "Resource": "*",
      "Principal": "*"
    },
    {
      "Action": "*",
      "Effect": "Deny",
      "Resource": "*",
      "Principal": {
        "AWS": [
          "123456789012"
        ]
      }
    }
  ]
}
```

```

    }
  ]
}
```

Exemplo Política de endpoint da VPC para permitir o acesso à VPC somente a uma entidade principal do IAM (usuário) especificada

A política de VPC endpoint a seguir permite acesso total somente ao usuário *lijuan* do IAM na conta. AWS *123456789012* Todos os outros principais IAM têm acesso negado usando o endpoint.

```

{
  "Statement": [
    {
      "Action": "*",
      "Effect": "Allow",
      "Resource": "*",
      "Principal": {
        "AWS": [
          "arn:aws:iam::123456789012:user/lijuan"
        ]
      }
    }
  ]
}
```

Exemplo Política de endpoint da VPC para permitir operações somente leitura do Amazon EMR no EKS

A política de VPC endpoint a seguir permite que somente *123456789012* a AWS conta execute as ações especificadas do Amazon EMR no EKS.

As ações especificadas fornecem o equivalente ao acesso somente leitura para o Amazon EMR no EKS. Todas as outras ações na VPC serão negadas para a conta especificada. Todas as outras contas terão acesso negado. Para obter uma lista de ações do Amazon EMR no EKS, consulte [Ações, recursos e chaves de condição para o Amazon EMR no EKS](#).

```

{
  "Statement": [
    {
      "Action": [
        "emr-containers:DescribeJobRun",

```

```

        "emr-containers:DescribeVirtualCluster",
        "emr-containers:ListJobRuns",
        "emr-containers:ListTagsForResource",
        "emr-containers:ListVirtualClusters"
    ],
    "Effect": "Allow",
    "Resource": "*",
    "Principal": {
        "AWS": [
            "123456789012"
        ]
    }
}
]
}

```

Exemplo Política de endpoint da VPC com negação de acesso a um cluster virtual especificado

A política de VPC endpoint a seguir permite acesso total a todas as contas e entidades principais, mas nega qualquer acesso da AWS conta **123456789012** às ações executadas no cluster virtual com o ID do cluster. **A1B2CD34EF5G** Outras ações do Amazon EMR no EKS que não oferecem suporte a permissões em nível de recurso para clusters virtuais ainda são permitidas. Para obter uma lista de ações do Amazon EMR no EKS e seus tipos de recursos correspondentes, consulte [Ações, recursos e chaves de condição para o Amazon EMR no EKS](#) no Guia do usuário do AWS Identity and Access Management .

```

{
  "Statement": [
    {
      "Action": "*",
      "Effect": "Allow",
      "Resource": "*",
      "Principal": "*"
    },
    {
      "Action": "*",
      "Effect": "Deny",
      "Resource": "arn:aws:emr-containers:us-west-2:123456789012:/virtualclusters/A1B2CD34EF5G",
      "Principal": {
        "AWS": [
          "123456789012"
        ]
      }
    }
  ]
}

```



```
}  
  ]  
    }  
      }  
        ]
```

Configuração do acesso entre contas para o Amazon EMR no EKS

Você pode configurar o acesso entre contas para o Amazon EMR no EKS. O acesso entre contas permite que os usuários de uma AWS conta executem o Amazon EMR em trabalhos do EKS e acessem os dados subjacentes que pertencem a AWS outra conta.

Pré-requisitos

Para configurar o acesso entre contas para o Amazon EMR no EKS, você concluirá as tarefas enquanto estiver conectado às seguintes AWS contas:

- AccountA- Uma AWS conta em que você criou um cluster virtual do Amazon EMR no EKS registrando o Amazon EMR com um namespace em um cluster EKS.
- AccountB- Uma AWS conta que contém um bucket do Amazon S3 ou uma tabela do DynamoDB que você deseja que suas tarefas do Amazon EMR no EKS acessem.

Você deve ter o seguinte em mãos em suas AWS contas antes de configurar o acesso entre contas:

- Um cluster virtual do Amazon EMR no EKS na AccountA em que deseja executar trabalhos.
- Um perfil de execução de trabalho na AccountA que tem as permissões obrigatórias para executar trabalhos no cluster virtual. Para obter mais informações, consulte [Criação de um perfil de execução de trabalho](#) e [Uso de perfis de execução de trabalho com o Amazon EMR no EKS](#).

Como acessar um bucket do Amazon S3 ou uma tabela do DynamoDB entre contas

Para configurar o acesso entre contas do Amazon EMR no EKS, conclua as etapas apresentadas a seguir.

1. Crie um bucket do Amazon S3, cross-account-bucket, na AccountB. Para mais informações, consulte [Criar um bucket](#). Se desejar ter acesso entre contas para o DynamoDB,

you can also create a table in the AccountB DynamoDB. For more information, consult [Creating a DynamoDB table](#).

2. Create an IAM Cross-Account-Role-B in the AccountB that can access the cross-account-bucket.
 1. Log in to the IAM console.
 2. Choose Profiles and create a new profile: Cross-Account-Role-B. For more information about how to create IAM profiles, consult [Creating IAM profiles](#) in the IAM user guide.
 3. Create an IAM policy that specifies permissions for Cross-Account-Role-B to access the cross-account-bucket S3 bucket, as demonstrated by the policy instruction to follow. Then, attach the IAM policy to Cross-Account-Role-B. For more information, consult [Creating a New Policy](#) in the IAM user guide.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "s3:*"
      ],
      "Resource": [
        "arn:aws:s3:::cross-account-bucket",
        "arn:aws:s3:::cross-account-bucket/*"
      ],
      "Sid": "AllowS3"
    }
  ]
}
```

If access to the DynamoDB is necessary, create an IAM policy that specifies access permissions to the DynamoDB table between accounts. Then, attach the IAM policy to Cross-Account-Role-B. For more information, consult [Creating a table in DynamoDB](#) in the IAM user guide.

Next, a policy of access to a table in the DynamoDB, CrossAccountTable.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "dynamodb:*"
      ],
      "Resource": [
        "arn:aws:dynamodb:us-east-1:*:table/CrossAccountTable"
      ],
      "Sid": "AllowDYNAMODB"
    }
  ]
}
```

3. Edite a relação de confiança para o perfil Cross-Account-Role-B.

1. Para configurar a relação de confiança para o perfil, escolha a guia Relações de confiança no console do IAM para o perfil criado na Etapa 2: Cross-Account-Role-B.
2. Selecione Editar relação de confiança.
3. Adicione o documento de política a seguir, que permite que Job-Execution-Role-A na AccountA assumo esse perfil Cross-Account-Role-B.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "sts:AssumeRole"
      ],
      "Resource": [
        "arn:aws:iam::*:role/Job-Execution-Role-A"
      ],
      "Sid": "AllowSTSAssumerole"
    }
  ]
}
```

```
}

```

4. Conceda que o Job-Execution-Role-A na AccountA tenha a permissão sts assume-role para assumir Cross-Account-Role-B.
 1. No console do IAM da AWS contaAccountA, selecioneJob-Execution-Role-A.
 2. Adicione a instrução de política a seguir ao Job-Execution-Role-A para permitir a ação AssumeRole no perfil Cross-Account-Role-B.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "sts:AssumeRole"
      ],
      "Resource": [
        "arn:aws:iam::*:role/Cross-Account-Role-B"
      ],
      "Sid": "AllowSTSAssumerole"
    }
  ]
}
```

5. Para obter acesso ao Amazon S3, defina os parâmetros spark-submit (spark conf) apresentados a seguir ao enviar o trabalho para o Amazon EMR no EKS.

Note

Por padrão, o EMRFS usa o perfil de execução do trabalho para acessar o bucket do S3 usando o trabalho. Entretanto, quando customAWSCredentialsProvider é definido como AssumeRoleAWSCredentialsProvider, o EMRFS usa o perfil correspondente que você especifica com ASSUME_ROLE_CREDENTIALS_ROLE_ARN em vez do Job-Execution-Role-A para obter acesso ao Amazon S3.

- --conf

```
spark.hadoop.fs.s3.customAWSCredentialsProvider=com.amazonaws.emr.AssumeRole
```

- `--conf spark.kubernetes.driverEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN=arn:aws:iam::AccountA:role/Cross-Account-Role-B \`
- `--conf spark.executorEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN=arn:aws:iam::AccountB:role/Cross-Account-Role-B \`

Note

Você deve definir `ASSUME_ROLE_CREDENTIALS_ROLE_ARN` para o env do executor e do driver na configuração de trabalho do Spark.

Para obter acesso entre contas do DynamoDB, você deve definir `--conf spark.dynamodb.customAWSCredentialsProvider=com.amazonaws.emr.AssumeRoleAWSCredentialsProvider`

6. Execute o trabalho do Amazon EMR no EKS com acesso entre contas, como demonstrado pelo exemplo a seguir.

```
aws emr-containers start-job-run \
--virtual-cluster-id 123456 \
--name myjob \
--execution-role-arn execution-role-arn \
--release-label emr-6.2.0-latest \
--job-driver '{"sparkSubmitJobDriver": {"entryPoint": "entryPoint_location",
"entryPointArguments": ["arguments_list"], "sparkSubmitParameters": "--class
<main_class> --conf spark.executor.instances=2 --conf spark.executor.memory=2G
--conf spark.executor.cores=2 --conf spark.driver.cores=1 --conf
spark.hadoop.fs.s3.customAWSCredentialsProvider=com.amazonaws.emr.AssumeRoleAWSCredentialsProvider
--conf
spark.kubernetes.driverEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN=arn:aws:iam::AccountB:role/Cross-Account-Role-B --conf
spark.executorEnv.ASSUME_ROLE_CREDENTIALS_ROLE_ARN=arn:aws:iam::AccountB:role/Cross-Account-Role-B"}} ' \
--configuration-overrides '{"applicationConfiguration": [{"classification":
"spark-defaults", "properties": {"spark.driver.memory": "2G"}}],
"monitoringConfiguration": {"cloudWatchMonitoringConfiguration":
{"logGroupName": "log_group_name", "logStreamNamePrefix": "log_stream_prefix"},
```

```
"persistentAppUI":"ENABLED",  "s3MonitoringConfiguration": {"logUri": "s3://  
my_s3_log_location" }}}
```

Marcação de recursos do Amazon EMR no EKS

Para ajudar no gerenciamento de recursos do Amazon EMR no EKS, você pode atribuir seus próprios metadados a cada recurso usando etiquetas. Este tópico fornece uma visão geral da função das etiquetas e mostra como você pode criá-las.

Tópicos

- [Conceitos Básicos de Tags](#)
- [Marcar seus recursos com tag](#)
- [Restrições de tag](#)
- [Trabalhe com tags usando o AWS CLI e o Amazon EMR na API EKS](#)

Conceitos Básicos de Tags

Uma tag é um rótulo que você atribui a um AWS recurso. Cada tag consiste de uma chave e um valor opcional, que podem ser definidos.

As tags permitem que você categorize seus AWS recursos por atributos como finalidade, proprietário ou ambiente. Caso possua muitos recursos do mesmo tipo, você pode identificar rapidamente um recurso específico com base nas tags atribuídas a ele. Por exemplo, é possível definir um conjunto de etiquetas para os clusters do Amazon EMR no EKS para ajudar a rastrear o proprietário e o nível da pilha de cada cluster. Recomendamos planejar um conjunto consistente de chaves de etiquetas para cada tipo de recurso. Você pode pesquisar e filtrar os recursos de acordo com as tags que adicionar.

Tags não são automaticamente atribuídas aos recursos. Após adicionar uma tag, você pode editar as chaves e os valores das tags ou removê-las de um recurso a qualquer momento. Caso exclua um recurso, todas as respectivas tags também serão excluídas.

As etiquetas não têm significado semântico para o Amazon EMR no EKS e são interpretadas estritamente como uma string de caracteres.

Um valor de tag pode ser uma string vazia, mas não nula. Uma chave de etiqueta não pode ser uma string vazia. Se você adicionar uma etiqueta que tenha a mesma chave de uma etiqueta existente nesse recurso, o novo valor substituirá o antigo.

Se você usa AWS Identity and Access Management (IAM), você pode controlar quais usuários em sua AWS conta têm permissão para gerenciar tags.

Para obter exemplos de políticas de controle de acesso por etiquetas, consulte [Políticas para controle de acesso baseado em etiquetas](#).

Marcar seus recursos com tag

Você pode etiquetar clusters virtuais e execuções de trabalhos novos ou existentes que estão em estados ativos. Os estados ativos para execuções de trabalhos incluem: PENDING, SUBMITTED, RUNNING e CANCEL_PENDING. Os estados ativos para clusters virtuais incluem: RUNNING, TERMINATING e ARRESTED. Para obter mais informações, consulte [Estados de execução de trabalho](#) e [Estados de um cluster virtual](#).

Quando um cluster virtual é encerrado, as etiquetas são limpas e não ficam mais acessíveis.

Se você estiver usando o Amazon EMR na API EKS AWS CLI, o ou um AWS SDK, poderá aplicar tags a novos recursos usando o parâmetro tags na ação relevante da API. Você também pode aplicar etiquetas aos recursos usando a ação da API TagResource.

Você pode usar algumas ações de criação de recursos para especificar etiquetas para um recurso quando ele for criado. Nesse caso, se as etiquetas não puderem ser aplicadas enquanto o recurso estiver sendo criado, ele não será criado. Esse mecanismo garante que os recursos que você pretende etiquetar na criação sejam criados com as etiquetas especificadas ou não sejam criados. Se você etiquetar os recursos no momento da criação, não precisará executar os scripts de marcação personalizados após a criação do recurso.

A tabela a seguir descreve os recursos do Amazon EMR no EKS que podem ser etiquetados.

Recurso	Compatível com tags	Compatível com a propagação de tags	Suporta marcação na criação (Amazon EMR na API EKS e AWS CLI SDK) AWS	API para criação (etiquetas podem ser adicionadas durante a criação)
Cluster virtual	Sim	Não. As etiquetas	Sim	CreateVirtualCluster

Recurso	Compatível com tags	Compatível com a propagação de tags	Suporta marcação na criação (Amazon EMR na API EKS e AWS CLI SDK) AWS	API para criação (etiquetas podem ser adicionadas durante a criação)
		associadas a um cluster virtual não se propagam para execuções de trabalhos enviadas a esse cluster virtual.		
Execuções de trabalhos	Sim	Não	Sim	StartJobRun

Restrições de tag

As restrições básicas a seguir se aplicam a tags:

- Número máximo de tags por recurso:- 50
- Em todos os recursos, cada chave de tag deve ser exclusiva e possuir apenas um valor.
- Comprimento máximo da chave:- 128 caracteres Unicode em UTF-8
- Comprimento máximo do valor:- 256 caracteres Unicode em UTF-8
- Se seu esquema de marcação for usado em vários AWS serviços e recursos, lembre-se de que outros serviços podem ter restrições quanto aos caracteres permitidos. Em geral, caracteres permitidos incluem letras, números, espaços representáveis em UTF-8 e os caracteres + - = . _ : / @.
- Chaves e valores de tags diferenciam maiúsculas de minúsculas.
- Um valor de tag pode ser uma string vazia, mas não nula. Uma chave de etiqueta não pode ser uma string vazia.

- Não use `aws:`, `AWS:` ou qualquer combinação de letras maiúsculas e minúsculas como prefixo para chaves ou valores. Eles são reservados apenas para AWS uso.

Trabalhe com tags usando o AWS CLI e o Amazon EMR na API EKS

Use os AWS CLI comandos a seguir ou o Amazon EMR nas operações da API EKS para adicionar, atualizar, listar e excluir as tags dos seus recursos.

Tarefa	AWS CLI	Ação API
Adicione ou substitua uma ou mais tags	tag-resource	TagResource
Lista de tags para um recurso	list-tags-for-resource	ListTagsForResource
Exclua uma ou mais tags	untag-resource	UntagResource

Os exemplos a seguir mostram como marcar ou desmarcar recursos usando o AWS CLI.

Exemplo 1: etiquetar um cluster virtual existente

O comando a seguir realiza a marcação de um cluster virtual existente.

```
aws emr-containers tag-resource --resource-arn resource_ARN --tags team=devs
```

Exemplo 2: remover a etiqueta de um cluster virtual existente

O comando a seguir exclui uma etiqueta de um cluster virtual existente.

```
aws emr-containers untag-resource --resource-arn resource_ARN --tag-keys tag_key
```

Exemplo 3: listar etiquetas para um recurso

O comando a seguir lista as tags associadas a um recurso existente.

```
aws emr-containers list-tags-for-resource --resource-arn resource_ARN
```

Solução de problemas para o Amazon EMR no EKS

Esta seção descreve como solucionar problemas com o Amazon EMR no EKS. Para obter informações sobre como solucionar problemas gerais com o Amazon EMR, consulte [Troubleshoot a cluster](#) no Guia de gerenciamento do Amazon EMR.

Tópicos

- [Solução de problemas de trabalhos que usam PersistentVolumeClaims \(PVC\)](#)
- [Solução de problemas de escalabilidade automática vertical do Amazon EMR no EKS](#)
- [Solução de problemas do operador do Spark do Amazon EMR no EKS](#)

Solução de problemas de trabalhos que usam PersistentVolumeClaims (PVC)

Se você precisar criar, listar ou excluir PersistentVolumeClaims (PVC) para um trabalho, mas não adicionar permissões de PVC aos contêineres emr-emr da função padrão do Kubernetes, o trabalho falhará quando você o enviar. Sem essas permissões, o perfil emr-containers não pode criar os perfis necessários para o driver do Spark ou para o cliente do Spark. Não é suficiente adicionar permissões ao driver do Spark ou aos perfis de clientes, conforme sugerido pelas mensagens de erro. O perfil primário emr-containers também deve incluir as permissões necessárias. Esta seção explica como adicionar as permissões necessárias ao perfil primário emr-containers.

Verificação

Para verificar se o perfil emr-containers tem ou não as permissões necessárias, defina a variável NAMESPACE com seu próprio valor e execute o seguinte comando:

```
export NAMESPACE=YOUR_VALUE
kubectl describe role emr-containers -n ${NAMESPACE}
```

Além disso, para verificar se os perfis do Spark e dos clientes têm as permissões necessárias, execute o seguinte comando:

```
kubectl describe role emr-containers-role-spark-driver -n ${NAMESPACE}
kubectl describe role emr-containers-role-spark-client -n ${NAMESPACE}
```

Se as permissões não existirem, prossiga com a aplicação de patch, como apresentado a seguir.

Patch

1. Se os trabalhos estiverem em execução no momento sem as permissões, interrompa-os.
2. Crie um arquivo chamado RBAC_Patch.py da seguinte forma:

```
import os
import subprocess as sp
import tempfile as temp
import json
import argparse
import uuid

def delete_if_exists(dictionary: dict, key: str):
    if dictionary.get(key, None) is not None:
        del dictionary[key]

def doTerminalCmd(cmd):
    with temp.TemporaryFile() as f:
        process = sp.Popen(cmd, stdout=f, stderr=f)
        process.wait()
        f.seek(0)
        msg = f.read().decode()
    return msg

def patchRole(roleName, namespace, extraRules, skipConfirmation=False):
    cmd = f"kubectl get role {roleName} -n {namespace} --output json".split(" ")
    msg = doTerminalCmd(cmd)
    if "(NotFound)" in msg and "Error" in msg:
        print(msg)
        return False
    role = json.loads(msg)
    rules = role["rules"]
    rulesToAssign = extraRules[::]
    passedRules = []
    for rule in rules:
        apiGroups = set(rule["apiGroups"])
        resources = set(rule["resources"])
        verbs = set(rule["verbs"])
        for extraRule in extraRules:
            passes = 0
            apiGroupsExtra = set(extraRule["apiGroups"])
```

```

        resourcesExtra = set(extraRule["resources"])
        verbsExtra = set(extraRule["verbs"])
        passes += len(apiGroupsExtra.intersection(apiGroups)) >=
len(apiGroupsExtra)
        passes += len(resourcesExtra.intersection(resources)) >=
len(resourcesExtra)
        passes += len(verbsExtra.intersection(verbs)) >= len(verbsExtra)
        if passes >= 3:
            if extraRule not in passedRules:
                passedRules.append(extraRule)
                if extraRule in rulesToAssign:
                    rulesToAssign.remove(extraRule)
            break
    prompt_text = "Apply Changes?"
    if len(rulesToAssign) == 0:
        print(f"The role {roleName} seems to already have the necessary
permissions!")
        prompt_text = "Proceed anyways?"
    for ruleToAssign in rulesToAssign:
        role["rules"].append(ruleToAssign)
    delete_if_exists(role, "creationTimestamp")
    delete_if_exists(role, "resourceVersion")
    delete_if_exists(role, "uid")
    new_role = json.dumps(role, indent=3)
    uid = uuid.uuid4()
    filename = f"Role-{roleName}-New_Permissions-{uid}-TemporaryFile.json"
    try:
        with open(filename, "w+") as f:
            f.write(new_role)
            f.flush()
        prompt = "y"
        if not skipConfirmation:
            prompt = input(
                doTerminalCmd(f"kubect1 diff -f {filename}".split(" ")) +
f"\n{prompt_text} y/n: "
            ).lower().strip()
            while prompt != "y" and prompt != "n":
                prompt = input("Please make a valid selection. y/n:
").lower().strip()
            if prompt == "y":
                print(doTerminalCmd(f"kubect1 apply -f {filename}".split(" ")))
    except Exception as e:
        print(e)
    os.remove(f"./{filename}")

```

```

if __name__ == '__main__':
    parser = argparse.ArgumentParser()
    parser.add_argument("-n", "--namespace",
                        help="Namespace of the Role. By default its the
VirtualCluster's namespace",
                        required=True,
                        dest="namespace"
                        )

    parser.add_argument("-p", "--no-prompt",
                        help="Applies the patches without asking first",
                        dest="no_prompt",
                        default=False,
                        action="store_true"
                        )

    args = parser.parse_args()

    emrRoleRules = [
        {
            "apiGroups": [""],
            "resources": ["persistentvolumeclaims"],
            "verbs": ["list", "create", "delete", "patch"]
        }
    ]

    driverRoleRules = [
        {
            "apiGroups": [""],
            "resources": ["persistentvolumeclaims"],
            "verbs": ["list", "create", "delete", "patch", "deletecollection"]
        },
        {
            "apiGroups": [""],
            "resources": ["services"],
            "verbs": ["get", "list", "describe", "create", "delete", "watch",
"deletecollection"]
        },
        {
            "apiGroups": [""],
            "resources": ["configmaps", "pods"],
            "verbs": ["deletecollection"]
        }
    ]

```

```

    ]

    clientRoleRules = [
        {
            "apiGroups": [""],
            "resources": ["persistentvolumeclaims"],
            "verbs": ["list", "create", "delete", "patch"]
        }
    ]

    patchRole("emr-containers", args.namespace, emrRoleRules, args.no_prompt)
    patchRole("emr-containers-role-spark-driver", args.namespace, driverRoleRules,
args.no_prompt)
    patchRole("emr-containers-role-spark-client", args.namespace, clientRoleRules,
args.no_prompt)

```

3. Execute o script do Python:

```
python3 RBAC_Patch.py -n ${NAMESPACE}
```

4. O comando “kubectl diff” apresentará as diferenças entre as permissões novas e as antigas. Pressione Y para aplicar patches ao perfil.

5. Verifique os três perfis com permissões adicionais, como o apresentado:

```
kubectl describe role -n ${NAMESPACE}
```

6. Execute o script do Python:

```
python3 RBAC_Patch.py -n ${NAMESPACE}
```

7. Após executar o comando, o comando “kubectl diff” apresentará as diferenças entre as permissões novas e as antigas. Pressione Y para aplicar patches ao perfil.

8. Verifique os três perfis com permissões adicionais:

```
kubectl describe role -n ${NAMESPACE}
```

9. Envie o trabalho novamente.

Aplicação manual de patches

Se a permissão requerida pela sua aplicação se aplicar a algo diferente das regras de PVC, você poderá adicionar manualmente as permissões do Kubernetes ao cluster virtual do Amazon EMR, conforme necessário.

Note

O perfil `emr-containers` é um perfil primário. Isso significa que ele deve fornecer todas as permissões necessárias antes que você possa alterar os perfis subjacentes do driver ou dos clientes.

1. Faça o download das permissões atuais em arquivos YAML ao executar os comandos abaixo:

```
kubectl get role -n ${NAMESPACE} emr-containers -o yaml >> emr-containers-role-patch.yaml
kubectl get role -n ${NAMESPACE} emr-containers-role-spark-driver -o yaml >> driver-role-patch.yaml
kubectl get role -n ${NAMESPACE} emr-containers-role-spark-client -o yaml >> client-role-patch.yaml
```

2. Com base na permissão requerida pela aplicação, edite cada arquivo e adicione regras adicionais, como as seguintes:

- `emr-containers-role-patch.yaml`

```
- apiGroups:
  - ""
  resources:
  - persistentvolumeclaims
  verbs:
  - list
  - create
  - delete
  - patch
```

- `driver-role-patch.yaml`

```
- apiGroups:
  - ""
  resources:
```



```

- persistentvolumeclaims
verbs:
- list
- create
- delete
- patch
- deletecollection
- apiGroups:
  - ""
resources:
- services
verbs:
- get
- list
- describe
- create
- delete
- watch
- deletecollection
- apiGroups:
  - ""
resources:
- configmaps
- pods
verbs:
- deletecollection

```

- client-role-patch.yaml

```

- apiGroups:
  - ""
resources:
- persistentvolumeclaims
verbs:
- list
- create
- delete
- patch

```

3. Remova os atributos a seguir em conjunto com os valores deles. Isso é necessário para aplicar a atualização.

- creationTimestamp
- resourceVersion

- uid

4. Por fim, execute a aplicação de patches:

```
kubectl apply -f emr-containers-role-patch.yaml
kubectl apply -f driver-role-patch.yaml
kubectl apply -f client-role-patch.yaml
```

Solução de problemas de escalabilidade automática vertical do Amazon EMR no EKS

Consulte as seções a seguir se você encontrar problemas ao configurar o operador de escalabilidade automática vertical do Amazon EMR no EKS em um cluster do Amazon EKS com o Operator Lifecycle Manager. Para obter mais informações, incluindo as etapas para concluir a instalação, consulte [Uso da escalabilidade automática vertical com trabalhos do Spark no Amazon EMR](#).

Erro 403 Forbidden

Se você seguiu as etapas em [Instalação do Operator Lifecycle Manager \(OLM\) no cluster do Amazon EKS](#), executou o comando `olm status` e ele retornou um erro 403 Forbidden, como o mostrado abaixo, pode ser que você não tenha obtido os tokens de autenticação para o repositório do Amazon ECR para o operador.

Para resolver esse problema, repita a etapa descrita em [Instalação do operador de escalabilidade automática vertical do Amazon EMR no EKS](#) para obter os tokens. Em seguida, tente instalar novamente.

```
Error: FATA[0002] Failed to run bundle: pull bundle image: error pulling image IMAGE.
error resolving name : unexpected status code [manifests latest]: 403 Forbidden
```

Namespace do Kubernetes não encontrado

Ao [configurar o operador de escalabilidade automática vertical do Amazon EMR no EKS](#) em um cluster do Amazon EKS, você poderá receber um erro `namespaces not found`, como o mostrado aqui:

```
FATA[0020] Failed to run bundle: create catalog: error creating catalog source:
namespaces "NAME" not found.
```

Se o namespace especificado não existir, o OLM não instalará o operador de escalabilidade automática vertical. Para resolver esse problema, use o comando apresentado a seguir para criar o namespace. Em seguida, tente instalar novamente.

```
kubectl create namespace NAME
```

Erro ao salvar as credenciais do Docker

Para [configurar a escalabilidade automática vertical](#), você deve autenticar e buscar as imagens do Docker relacionadas à escalabilidade automática vertical do Amazon EMR no EKS. Ao fazer isso, você poderá receber um erro como o seguinte se o Docker não estiver em execução:

```
aws ecr get-login-password \
  --region $REGION | docker login \
  --username AWS \
  --password-stdin $ACCOUNT_ID.dkr.ecr.$REGION.amazonaws.com

Error saving credentials: error storing credentials - err: exit status 1
out: 'Post "http://ipc/registry/credstore-updated": dial unix backend.sock: connect: no
such file or directory'
```

Para resolver esse problema, confirme se o Docker está em execução ou abra o Docker Desktop. Em seguida, tente salvar as credenciais novamente.

Solução de problemas do operador do Spark do Amazon EMR no EKS

Consulte as seções a seguir se você encontrar problemas com o operador do Spark do Amazon EMR no EKS. Para obter mais informações, incluindo as etapas para concluir a instalação, consulte [Execução de trabalhos do Spark com o operador do Spark](#).

Erro na instalação do chart do Helm

Se você seguiu as etapas em [Instalação do operador do Spark](#) e ele retornou um erro `INSTALLATION FAILED`, como o mostrado abaixo, ao tentar instalar ou verificar o chart do Helm, pode ser que você não tenha obtido os tokens de autenticação para o repositório do Amazon ECR para o operador.

Para resolver esse problema, repita a descrita etapa em [Instalação do operador do Spark](#) para autenticar seu cliente Helm para o registro do Amazon ECR. Em seguida, tente realizar a etapa de instalação novamente.

```
Error: INSTALLATION FAILED: Kubernetes cluster unreachable: the server has asked for
the client to provide credentials
```

UnsupportedFileSystemException: Não FileSystem para o esquema "s3"

Você pode encontrar a seguinte exceção no thread "principal":

```
org.apache.hadoop.fs.UnsupportedFileSystemException: No FileSystem for scheme "s3"
```

Se isso ocorrer, adicione as seguintes exceções à especificação SparkApplication:

```
hadoopConf:
  # EMRFS filesystem
  fs.s3.customAWSCredentialsProvider:
com.amazonaws.auth.WebIdentityTokenCredentialsProvider
  fs.s3.impl: com.amazon.ws.emr.hadoop.fs.EmrFileSystem
  fs.AbstractFileSystem.s3.impl: org.apache.hadoop.fs.s3.EMRFSDelegate
  fs.s3.buffer.dir: /mnt/s3
  fs.s3.getObject.initialSocketTimeoutMilliseconds: "2000"
  mapreduce.fileoutputcommitter.algorithm.version.emr_internal_use_only.EmrFileSystem:
"2"
  mapreduce.fileoutputcommitter.cleanup-
failures.ignored.emr_internal_use_only.EmrFileSystem: "true"
sparkConf:
  # Required for EMR Runtime
  spark.driver.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/hadoop-
aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/share/aws/
emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/security/conf:/
usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-glue-datacatalog-
spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-serde.jar:/usr/share/aws/
sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/hadoop/extrajars/*
  spark.driver.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-lzo/lib/
native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/native
  spark.executor.extraClassPath: /usr/lib/hadoop-lzo/lib/*:/usr/lib/hadoop/hadoop-
aws.jar:/usr/share/aws/aws-java-sdk/*:/usr/share/aws/emr/emrfs/conf:/usr/share/aws/
emr/emrfs/lib/*:/usr/share/aws/emr/emrfs/auxlib/*:/usr/share/aws/emr/security/conf:/
usr/share/aws/emr/security/lib/*:/usr/share/aws/hmclient/lib/aws-glue-datacatalog-
```

```
spark-client.jar:/usr/share/java/Hive-JSON-Serde/hive-openx-serde.jar:/usr/share/aws/  
sagemaker-spark-sdk/lib/sagemaker-spark-sdk.jar:/home/hadoop/extrajars/*  
spark.executor.extraLibraryPath: /usr/lib/hadoop/lib/native:/usr/lib/hadoop-lzo/lib/  
native:/docker/usr/lib/hadoop/lib/native:/docker/usr/lib/hadoop-lzo/lib/native
```

Cotas e endpoints de serviço do Amazon EMR no EKS

A seguir são apresentados os endpoints de serviço e as cotas de serviço para o Amazon EMR no EKS. Para se conectar programaticamente a um AWS serviço, você usa um endpoint. Além dos AWS endpoints padrão, alguns AWS serviços oferecem endpoints FIPS em regiões selecionadas. Para obter mais informações, consulte [Endpoints de serviço da AWS](#). As cotas de serviço, também chamadas de limites, correspondem ao número máximo de recursos ou operações de serviço para sua conta da AWS. Para obter mais informações, consulte as [Service Quotas do AWS](#).

Service endpoints

Região da AWS nome	Código	Endpoint	Protocolo
Leste dos EUA (Norte da Virgínia)	us-east-1	emr-containers.us-east-1.amazonaws.com	HTTPS
Leste dos EUA (Ohio)	us-east-2	emr-containers.us-east-2.amazonaws.com	HTTPS
Oeste dos EUA (N. da Califórnia)	us-west-1	emr-containers.us-west-1.amazonaws.com	HTTPS
Oeste dos EUA (Oregon)	us-west-2	emr-containers.us-west-2.amazonaws.com	HTTPS
Ásia-Pacífico (Tóquio)	ap-northeast-1	emr-containers.ap-northeast-1.amazonaws.com	HTTPS
Ásia-Pacífico (Seul)	ap-northeast-2	emr-containers.ap-northeast-2.amazonaws.com	HTTPS
Asia Pacific (Osaka)	ap-northeast-3	emr-containers.ap-northeast-3.amazonaws.com	HTTPS
Ásia-Pacífico (Mumbai)	ap-south-1	emr-containers.ap-south-1.amazonaws.com	HTTPS

Região da AWS nome	Código	Endpoint	Protocolo
Ásia-Pacífico (Hyderabad)	ap-south-2	emr-containers.ap-south-2.amazonaws.com	HTTPS
Ásia-Pacífico (Singapura)	ap-southeast-1	emr-containers.ap-southeast-1.amazonaws.com	HTTPS
Ásia-Pacífico (Sydney)	ap-southeast-2	emr-containers.ap-southeast-2.amazonaws.com	HTTPS
Ásia-Pacífico (Jacarta)	ap-southeast-3	emr-containers.ap-southeast-3.amazonaws.com	HTTPS
Ásia-Pacífico (Hong Kong)	ap-east-1	emr-containers.ap-east-1.amazonaws.com	HTTPS
África (Cidade do Cabo)	af-south-1	emr-containers.af-south-1.amazonaws.com	HTTPS
Canadá (Central)	ca-central-1	emr-containers.ca-central-1.amazonaws.com	HTTPS
China (Ningxia)	cn-northwest-1	emr-containers.cn-northwest-1.amazonaws.com.cn	HTTPS
China (Pequim)	cn-north-1	emr-containers.cn-north-1.amazonaws.com.cn	HTTPS
Europa (Frankfurt)	eu-central-1	emr-containers.eu-central-1.amazonaws.com	HTTPS
Europa (Zurique)	eu-central-2	emr-containers.eu-central-2.amazonaws.com	HTTPS
Europa (Irlanda)	eu-west-1	emr-containers.eu-west-1.amazonaws.com	HTTPS

Região da AWS nome	Código	Endpoint	Protocolo
Europa (Londres)	eu-west-2	emr-containers.eu-west-2.amazonaws.com	HTTPS
Europa (Paris)	eu-west-3	emr-containers.eu-west-3.amazonaws.com	HTTPS
Europa (Estocolmo)	eu-north-1	emr-containers.eu-north-1.amazonaws.com	HTTPS
Europa (Milão)	eu-south-1	emr-containers.eu-south-1.amazonaws.com	HTTPS
Europa (Espanha)	eu-south-2	emr-containers.eu-south-2.amazonaws.com	HTTPS
Israel (Tel Aviv)	il-central-1	emr-containers.il-central-1.amazonaws.com	HTTPS
América do Sul (São Paulo)	sa-east-1	emr-containers.sa-east-1.amazonaws.com	HTTPS
Oriente Médio (Emirados Árabes Unidos)	me-central-1	emr-containers.me-central-1.amazonaws.com	HTTPS
Oriente Médio (Bahrein)	me-south-1	emr-containers.me-south-1.amazonaws.com	HTTPS
AWS GovCloud (Leste dos EUA)	us-gov-east-1	emr-containers.us-gov-east-1.amazonaws.com	HTTPS
AWS GovCloud (Oeste dos EUA)	us-gov-west-1	emr-containers.us-gov-west-1.amazonaws.com	HTTPS

Cotas de serviço

O Amazon EMR no EKS limita as seguintes solicitações de API para cada AWS conta por região. Para obter mais informações sobre como a limitação é aplicada, consulte Limitação de [solicitações de API na](#) Amazon API Reference. EC2 Você pode solicitar um aumento nas cotas de limitação de API para sua AWS conta, seguindo o guia a seguir.

Ação da API	Capacidade máxima do bucket	Taxa de reabastecimento do bucket (por segundo)
CancelJobRun	25	1
CreateJobTemplate	25	1
CreateManagedEndpoint	25	1
CreateSecurityConfiguration	25	1
CreateVirtualCluster	25	1
DeleteJobTemplate	25	1
DeleteManagedEndpoint	25	1
DeleteVirtualCluster	25	1
DescribeJobRun	100	20
DescribeJobTemplate	25	1
DescribeManagedEndpoint	100	5
DescribeSecurityConfiguration	25	1
DescribeVirtualCluster	100	5
GetManagedEndpoint SessionCredentials	25	1
ListJobRuns	100	5

Ação da API	Capacidade máxima do bucket	Taxa de reabastecimento do bucket (por segundo)
ListJobTemplates	25	1
ListManagedEndpoints	25	1
ListSecurityConfigurations	25	1
ListVirtualClusters	100	5
StartJobRun	25	1
Throttle quota for all EMR on EKS API requests	200	20

Quando você cria sua AWS conta, definimos cotas padrão (também chamadas de limites) para seus AWS recursos por região. Se você tentar exceder a cota de um recurso, a solicitação falhará. Se isso acontecer, reduza o uso de recursos ou solicite um aumento de cota.

O console Service Quotas é um local central onde você pode visualizar e gerenciar suas cotas de AWS serviços e solicitar aumentos de cota para muitos dos recursos que você usa. Use as informações de cota fornecidas aqui para gerenciar sua AWS infraestrutura. Planeje a solicitação de aumentos das cotas com antecedência antes que sejam necessários.

Visualizar cotas e solicitar aumentos de cotas

Você pode visualizar suas cotas de serviço atuais para cada região usando o console do Service Quotas. Para obter instruções detalhadas, consulte [Visualizar cotas de serviço](#), no Guia do usuário do Service Quotas.

Você pode solicitar um aumento de cota no AWS Management Console ou usando a AWS CLI. As etapas estão detalhadas em [Solicitar um aumento de cota](#).

Versões do Amazon EMR no EKS

Uma versão do Amazon EMR corresponde a um conjunto de aplicações de código aberto do ecossistema de big data. Cada versão inclui diferentes aplicações, componentes e recursos de big data que você seleciona para que o Amazon EMR no EKS implante e configure ao executar seu trabalho.

A partir das versões 5.32.0 e 6.2.0 do Amazon EMR, é possível implantar o Amazon EMR no EKS. Essa opção de implantação não está disponível em versões de liberação anteriores do Amazon EMR. Você deve especificar uma versão de liberação com suporte ao enviar seu trabalho.

O Amazon EMR no EKS usa o seguinte formato de rótulo de versão: `emr-x.x.x-latest` ou `emr-x.x.x-yyyyymmdd` com uma data de versão específica. Por exemplo, `emr-7.12.0-latest` ou `emr-7.12.0-20210129`. Ao usar o sufixo `-latest`, você garante que sua versão do Amazon EMR sempre inclua as atualizações de segurança mais recentes.

Note

Para uma comparação entre o Amazon EMR no EKS e o Amazon EMR em execução, EC2 consulte o Amazon [EMR](#) no site. FAQs AWS

Tópicos

- [Amazon EMR nas versões EKS 7.12.0](#)
- [Amazon EMR nas versões EKS 7.11.0](#)
- [Amazon EMR nas versões do EKS 7.10.0](#)
- [Amazon EMR nas versões EKS 7.9.0](#)
- [Amazon EMR nas versões EKS 7.8.0](#)
- [Amazon EMR nas versões EKS 7.7.0](#)
- [Amazon EMR nas versões do EKS 7.6.0](#)
- [Amazon EMR nas versões do EKS 7.5.0](#)
- [Amazon EMR nas versões do EKS 7.4.0](#)
- [Versões 7.3.0 do Amazon EMR no EKS](#)
- [Versões 7.2.0 do Amazon EMR no EKS](#)
- [Versões 7.1.0 do Amazon EMR no EKS](#)

- [Versões 7.0.0 do Amazon EMR no EKS](#)
- [Versões 6.15.0 do Amazon EMR no EKS](#)
- [Versões 6.14.0 do Amazon EMR no EKS](#)
- [Versões 6.13.0 do Amazon EMR no EKS](#)
- [Versões 6.12.0 do Amazon EMR no EKS](#)
- [Versões 6.11.0 do Amazon EMR no EKS](#)
- [Versões 6.10.0 do Amazon EMR no EKS](#)
- [Versões 6.9.0 do Amazon EMR no EKS](#)
- [Versões 6.8.0 do Amazon EMR no EKS](#)
- [Versões 6.7.0 do Amazon EMR no EKS](#)
- [Versões 6.6.0 do Amazon EMR no EKS](#)
- [Versões 6.5.0 do Amazon EMR no EKS](#)
- [Versões 6.4.0 do Amazon EMR no EKS](#)
- [Versões 6.3.0 do Amazon EMR no EKS](#)
- [Versões 6.2.0 do Amazon EMR no EKS](#)
- [Versões 5.36.0 do Amazon EMR no EKS](#)
- [Versões 5.35.0 do Amazon EMR no EKS](#)
- [Versões 5.34.0 do Amazon EMR no EKS](#)
- [Versões 5.33.0 do Amazon EMR no EKS](#)
- [Versões 5.32.0 do Amazon EMR no EKS](#)

Amazon EMR nas versões EKS 7.12.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão 7.12.0 do Amazon EMR em geral, consulte [Amazon EMR 7.12.0 no Guia de lançamento do Amazon EMR](#).

Amazon EMR nas versões do EKS 7.12

As seguintes versões do Amazon EMR 7.12.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do EMR-7.12.0-xxxx para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As seguintes versões do Amazon EMR 7.12.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Flink.

- [emr-7.12.0-flink-latest](#)
- [emr-7.12.0-flink-20251111](#)

Spark releases

As seguintes versões do Amazon EMR 7.12.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Spark.

- [emr-7.12.0-mais recente](#)
- [emr-7.12.0-20251111](#)
- `emr-7.12.0-spark-rapids-latest`
- `emr-7.12.0-spark-rapids-20251111`
- `emr-7.12.0-java11-latest`
- `emr-7.12.0-java11-20251111`
- `emr-7.12.0-java8-latest`
- `emr-7.12.0-java8-20251111`
- `emr-7.12.0-spark-rapids-java8-latest`
- `emr-7.12.0-spark-rapids-java8-20251111`
- `notebook-spark/emr-7.12.0-latest`
- `notebook-spark/emr-7.12.0-20251111`
- `notebook-spark/emr-7.12.0-spark-rapids-latest`
- `notebook-spark/emr-7.12.0-spark-rapids-20251111`
- `notebook-spark/emr-7.12.0-java11-latest`
- `notebook-spark/emr-7.12.0-java11-20251111`
- `notebook-spark/emr-7.12.0-java8-latest`
- `notebook-spark/emr-7.12.0-java8-20251111`
- `notebook-spark/emr-7.12.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.12.0-spark-rapids-java8-20251111`
- `notebook-python/emr-7.12.0-latest`

- notebook-python/emr-7.12.0-20251111
- notebook-python/emr-7.12.0-spark-rapids-latest
- notebook-python/emr-7.12.0-spark-rapids-20251111
- notebook-python/emr-7.12.0-java11-latest
- notebook-python/emr-7.12.0-java11-20251111
- notebook-python/emr-7.12.0-java8-latest
- notebook-python/emr-7.12.0-java8-20251111
- notebook-python/emr-7.12.0-spark-rapids-java8-latest
- notebook-python/emr-7.12.0-spark-rapids-java8-20251111
- livy/emr-7.12.0-latest
- livy/emr-7.12.0-20251111
- livy/emr-7.12.0-java11-latest
- livy/emr-7.12.0-java11-20251111
- livy/emr-7.12.0-java8-latest
- livy/emr-7.12.0-java8-20251111

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.12.0:

- Aplicações compatíveis: AWS SDK para Java 2.35.5 and 1.12.792, Apache Spark 3.5.6-amzn-1, Apache Hudi 1.0.2-amzn-1, Apache Iceberg 1.10.0-amzn-0, Delta 3.3.2-amzn-1, Apache Spark RAPIDS 25.04.0-amzn-0, Apache Flink 1.20.0-amzn-6
- Componentes com suporte - emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg, spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRune](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.

Classificações	Descrições
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>jeg-config</code>	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
<code>jupyter-kernel-overrides</code>	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Alterações e recursos

Os seguintes recursos estão incluídos na versão 7.12.0 do Amazon EMR no EKS:

- Visualizações materializadas do Iceberg — A partir do EMR 7.12.0, o EMR Spark suporta a criação e o gerenciamento de visualizações materializadas do Iceberg (MV).
- Hudi Full Table Access — A partir do EMR 7.12.0, o EMR agora oferece suporte ao controle de Full Table Access (FTA) para o Apache Hudi no Apache Spark com base em suas políticas definidas no Lake Formation. Esse recurso permite operações de leitura e gravação de suas tarefas do Amazon EMR Spark em tabelas registradas do Lake Formation quando a função de trabalho tem acesso total à tabela.
- Atualização da versão Iceberg — O EMR 7.12.0 é compatível com o Apache Iceberg versão 1.10.
- Registro para cargas de trabalho interativas do Livy — A partir do EMR 7.12.0, o EMR oferece suporte a registros extensivos dos principais componentes do sistema para melhorar a solução de problemas de falhas de trabalho do Livy Spark. Esse recurso fornecerá ao serviço de EMR acesso a Livy e SecretAgent registros adicionais para simplificar a solução de problemas.

emr-7.12.0-mais recente

Notas de versão: a versão `emr-7.12.0-latest` direciona para `emr-7.12.0-20251111`, no momento.

Regiões: `emr-7.12.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.12.0:latest`.

emr-7.12.0-20251111

Notas de lançamento: `emr-7.12.0-20251111` foi lançado em novembro de 2025. Esta é a versão inicial do Amazon EMR 7.12.0 (Spark).

Regiões: `emr-7.12.0-20251111` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.12.0-20251111`.

emr-7.12.0-flink-latest

Notas de versão: `emr-7.12.0-flink-latest` direciona para `emr-7.12.0-flink-20251111` no momento.

Regiões: `emr-7.12.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.12.0-flink:latest`.

emr-7.12.0-flink-20251111

Notas de lançamento: `7.12.0-flink-20251111` foi lançado em novembro de 2025. Esta é a versão inicial do Amazon EMR 7.12.0 (Flink).

Regiões: `emr-7.12.0-flink-20251111` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.12.0-flink:20251111`.

Amazon EMR nas versões EKS 7.11.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão 7.11.0 do Amazon EMR em geral, consulte Amazon EMR 7.11.0 no Guia de lançamento do Amazon [EMR](#).

Amazon EMR nas versões do EKS 7.11

As seguintes versões do Amazon EMR 7.11.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `EMR-7.11.0-xxxx` para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As seguintes versões do Amazon EMR 7.11.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Flink.

- [emr-7.11.0-flink-latest](#)

- [emr-7.11.0-flink-20251020](#)

Spark releases

As seguintes versões do Amazon EMR 7.11.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Spark.

- [emr-7.11.0-mais recente](#)
- [emr-7.11.0-20251020](#)
- `emr-7.11.0-spark-rapids-latest`
- `emr-7.11.0-spark-rapids-20251020`
- `emr-7.11.0-java11-latest`
- `emr-7.11.0-java11-20251020`
- `emr-7.11.0-java8-latest`
- `emr-7.11.0-java8-20251020`
- `emr-7.11.0-spark-rapids-java8-latest`
- `emr-7.11.0-spark-rapids-java8-20251020`
- `notebook-spark/emr-7.11.0-latest`
- `notebook-spark/emr-7.11.0-20251020`
- `notebook-spark/emr-7.11.0-spark-rapids-latest`
- `notebook-spark/emr-7.11.0-spark-rapids-20251020`
- `notebook-spark/emr-7.11.0-java11-latest`
- `notebook-spark/emr-7.11.0-java11-20251020`
- `notebook-spark/emr-7.11.0-java8-latest`
- `notebook-spark/emr-7.11.0-java8-20251020`
- `notebook-spark/emr-7.11.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.11.0-spark-rapids-java8-20251020`
- `notebook-python/emr-7.11.0-latest`
- `notebook-python/emr-7.11.0-20251020`
- `notebook-python/emr-7.11.0-spark-rapids-latest`
- `notebook-python/emr-7.11.0-spark-rapids-20251020`
- `notebook-python/emr-7.11.0-java11-latest`

- `notebook-python/emr-7.11.0-java11-20251020`
- `notebook-python/emr-7.11.0-java8-latest`
- `notebook-python/emr-7.11.0-java8-20251020`
- `notebook-python/emr-7.11.0-spark-rapids-java8-latest`
- `notebook-python/emr-7.11.0-spark-rapids-java8-20251020`
- `livy/emr-7.11.0-latest`
- `livy/emr-7.11.0-20251020`
- `livy/emr-7.11.0-java11-latest`
- `livy/emr-7.11.0-java11-20251020`
- `livy/emr-7.11.0-java8-latest`
- `livy/emr-7.11.0-java8-20251020`

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.11.0:

- Aplicações compatíveis: AWS SDK para Java 2.35.5 and 1.12.792, Apache Spark 3.5.6-amzn-0, Apache Hudi 1.0.2-amzn-0, Apache Iceberg 1.9.1-amzn-0, Delta 3.3.2-amzn-0, Apache Spark RAPIDS 25.04.0-amzn-0, Apache Flink 1.20.0-amzn-5
- Componentes com suporte - `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg`, `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRune](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.

Classificações	Descrições
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>jeg-config</code>	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
<code>jupyter-kernel-overrides</code>	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Alterações e recursos

As seguintes alterações estão incluídas na versão 7.11.0 do Amazon EMR no EKS:

O Amazon EMR no EKS agora oferece suporte à integração com o SageMaker Unified Studio por meio de uma solução gerenciada da Livy, incluindo:

- Sessões gerenciadas: novo tipo de recurso de sessão interativa que fornece um endpoint HTTPS personalizado para executar sessões do Spark em seu cluster EKS por meio do Unified Studio SageMaker
- Integração com Lake Formation: suporta controle de acesso a dados com dois modos: a) Controle de acesso refinado b) Acesso total à tabela (modo de compatibilidade)
- Gerenciamento de identidade: opções flexíveis de autenticação a) Controle de acesso baseado em funções do IAM b) controle de acesso baseado.
- Sessões em segundo plano do usuário com integração: suporta cargas de trabalho de longa duração do Spark para continuar em execução mesmo depois que os usuários se desconectarem do SageMaker Unified Studio, oferecendo suporte a sessões de até 90 dias

emr-7.11.0-mais recente

Notas de versão: a versão `emr-7.11.0-latest` direciona para `emr-7.11.0-20251020`, no momento.

Regiões: `emr-7.11.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.11.0:latest`.

emr-7.11.0-20251020

Notas de lançamento: `emr-7.11.0-20251020` foi lançado em novembro de 2025. Esta é a versão inicial do Amazon EMR 7.11.0 (Spark).

Regiões: `emr-emr-7.11.0-20251020` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.11.0-20251020`.

emr-7.11.0-flink-latest

Notas de versão: `emr-7.11.0-flink-latest` direciona para `emr-7.11.0-flink-20251020` no momento.

Regiões: `emr-7.11.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.11.0-flink:latest`.

`emr-7.11.0-flink-20251020`

Notas de lançamento: `7.11.0-flink-20251020` foi lançado em novembro de 2025. Esta é a versão inicial do Amazon EMR 7.11.0 (Flink).

Regiões: `emr-7.11.0-flink-20251020` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.11.0-flink:20251020`.

Amazon EMR nas versões do EKS 7.10.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.10.0 em geral, consulte Amazon EMR 7.10.0 no Guia de lançamento do Amazon [EMR](#).

Amazon EMR nas versões do EKS 7.10

As seguintes versões do Amazon EMR 7.10.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `EMR-7.10.0-xxxx` para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As seguintes versões do Amazon EMR 7.10.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Flink.

- [emr-7.10.0-flink-latest](#)
- [emr-7.10.0-flink-20250801](#)

Spark releases

As seguintes versões do Amazon EMR 7.10.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Spark.

- [emr-7.10.0-mais recente](#)
- [emr-7.10.0-20250801](#)
- `emr-7.10.0-spark-rapids-latest`
- `emr-7.10.0-spark-rapids-20250801`
- `emr-7.10.0-java11-latest`
- `emr-7.10.0-java11-20250801`
- `emr-7.10.0-java8-latest`
- `emr-7.10.0-java8-20250801`
- `emr-7.10.0-spark-rapids-java8-latest`
- `emr-7.10.0-spark-rapids-java8-20250801`
- `notebook-spark/emr-7.10.0-latest`
- `notebook-spark/emr-7.10.0-20250801`
- `notebook-spark/emr-7.10.0-spark-rapids-latest`
- `notebook-spark/emr-7.10.0-spark-rapids-20250801`
- `notebook-spark/emr-7.10.0-java11-latest`
- `notebook-spark/emr-7.10.0-java11-20250801`
- `notebook-spark/emr-7.10.0-java8-latest`
- `notebook-spark/emr-7.10.0-java8-20250801`
- `notebook-spark/emr-7.10.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.10.0-spark-rapids-java8-20250801`
- `notebook-python/emr-7.10.0-latest`
- `notebook-python/emr-7.10.0-20250801`
- `notebook-python/emr-7.10.0-spark-rapids-latest`
- `notebook-python/emr-7.10.0-spark-rapids-20250801`
- `notebook-python/emr-7.10.0-java11-latest`

- notebook-python/emr-7.10.0-java11-20250801
- notebook-python/emr-7.10.0-java8-latest
- notebook-python/emr-7.10.0-java8-20250801
- notebook-python/emr-7.10.0-spark-rapids-java8-latest
- notebook-python/emr-7.10.0-spark-rapids-java8-20250801
- livy/emr-7.10.0-latest
- livy/emr-7.10.0-20250801
- livy/emr-7.10.0-java11-latest
- livy/emr-7.10.0-java11-20250801
- livy/emr-7.10.0-java8-latest
- livy/emr-7.10.0-java8-20250801

Notas da versão

Notas de versão do Amazon EMR no EKS 7.10.0:

- Aplicações compatíveis: AWS SDK para Java 2.31.48 and 1.12.782, Apache Spark 3.5.5-amzn-1, Apache Hudi 0.15.0-amzn-7, Apache Iceberg 1.8.1-amzn-0, Delta 3.3.0-amzn-2, Apache Spark RAPIDS 25.04.0-amzn-0, Apache Flink 1.20.0-amzn-4, Flink Kubernetes Operator 1.10.0-amzn-4
- Componentes com suporte - emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg, spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRune](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Altera os valores no arquivo metrics.properties do Spark.

Classificações	Descrições
spark-defaults	Altera os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j2	Altera os valores no arquivo log4j2.properties do Spark.
emr-job-submitter	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo jupyter_enterprise_gateway_config.py do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como spark-hive-site.xml. Para obter mais informações, consulte [Configure Applications](#).

Alterações e recursos

Os recursos a seguir estão incluídos na versão 7.10.0 do Amazon EMR no EKS:

- Sistema de arquivos S3A: a partir da versão 7.10.0, o sistema de arquivos S3A substituiu o EMRFS como conector do EMR S3 padrão. Para obter mais informações, consulte [Sistema de arquivos do EMR \(EMRFS\)](#).

emr-7.10.0-mais recente

Notas de versão: a versão `emr-7.10.0-latest` direciona para `emr-7.10.0-20250801`, no momento.

Regiões: `emr-7.10.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.10.0:latest`.

emr-7.10.0-20250801

Notas de versão: `emr-7.10.0-20250801` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.10.0 (Spark).

Regiões: `emr-emr-7.10.0-20250801` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.10.0-20250801`.

emr-7.10.0-flink-latest

Notas de versão: `emr-7.10.0-flink-latest` direciona para `emr-7.10.0-flink-20250801` no momento.

Regiões: `emr-7.10.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.10.0-flink:latest`.

emr-7.10.0-flink-20250801

Notas de versão: `7.10.0-flink-20250801` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.10.0 (Flink).

Regiões: `emr-7.10.0-flink-20250801` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.10.0-flink:20250801`.

Amazon EMR nas versões EKS 7.9.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.9.0 em geral, consulte Amazon EMR 7.9.0 no Guia de lançamento do Amazon [EMR](#).

Amazon EMR nas versões do EKS 7.9

As seguintes versões do Amazon EMR 7.9.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do EMR-7.9.0-xxxx para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As seguintes versões do Amazon EMR 7.9.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Flink.

- [emr-7.9.0-flink-latest](#)
- [emr-7.9.0-flink-20250425](#)

Spark releases

As seguintes versões do Amazon EMR 7.9.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Spark.

- [emr-7.9.0-mais recente](#)
- [emr-7.9.0-20250425](#)
- `emr-7.9.0-spark-rapids-latest`
- `emr-7.9.0-spark-rapids-20250425`
- `emr-7.9.0-java11-latest`
- `emr-7.9.0-java11-20250425`
- `emr-7.9.0-java8-latest`
- `emr-7.9.0-java8-20250425`
- `emr-7.9.0-spark-rapids-java8-latest`

- `emr-7.9.0-spark-rapids-java8-20250425`
- `notebook-spark/emr-7.9.0-latest`
- `notebook-spark/emr-7.9.0-20250425`
- `notebook-spark/emr-7.9.0-spark-rapids-latest`
- `notebook-spark/emr-7.9.0-spark-rapids-20250425`
- `notebook-spark/emr-7.9.0-java11-latest`
- `notebook-spark/emr-7.9.0-java11-20250425`
- `notebook-spark/emr-7.9.0-java8-latest`
- `notebook-spark/emr-7.9.0-java8-20250425`
- `notebook-spark/emr-7.9.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.9.0-spark-rapids-java8-20250425`
- `notebook-python/emr-7.9.0-latest`
- `notebook-python/emr-7.9.0-20250425`
- `notebook-python/emr-7.9.0-spark-rapids-latest`
- `notebook-python/emr-7.9.0-spark-rapids-20250425`
- `notebook-python/emr-7.9.0-java11-latest`
- `notebook-python/emr-7.9.0-java11-20250425`
- `notebook-python/emr-7.9.0-java8-latest`
- `notebook-python/emr-7.9.0-java8-20250425`
- `notebook-python/emr-7.9.0-spark-rapids-java8-latest`
- `notebook-python/emr-7.9.0-spark-rapids-java8-20250425`
- `livy/emr-7.9.0-latest`
- `livy/emr-7.9.0-20250425`
- `livy/emr-7.9.0-java11-latest`
- `livy/emr-7.9.0-java11-20250425`
- `livy/emr-7.9.0-java8-latest`
- `livy/emr-7.9.0-java8-20250425`

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.9.0

- Aplicações compatíveis: AWS SDK para Java 2.31.16 and 1.12.782, Apache Spark 3.5.5, Apache Hudi 0.15.0-amzn-6, Apache Iceberg 1.7.1-amzn-2, Delta 3.3.0-amzn-1, Apache Spark RAPIDS 25.02.1-amzn-0, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.20.0-amzn-3, Flink Operator 1.10.0-amzn-3
- Componentes com suporte - `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg`, `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Alterações

As alterações a seguir estão incluídas na versão 7.9.0 do Amazon EMR no EKS:

- Nenhuma alteração na versão.

emr-7.9.0-mais recente

Notas de versão: a versão `emr-7.9.0-latest` direciona para `emr-7.9.0-20250425`, no momento.

Regiões: `emr-7.9.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.9.0:latest`.

emr-7.9.0-20250425

Notas de versão: `emr-7.9.0-20250425` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.9.0 (Spark).

Regiões: `emr-emr-7.9.0-20250425` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.9.0-20250425`.

`emr-7.9.0-flink-latest`

Notas de versão: `emr-7.9.0-flink-latest` direciona para `emr-7.9.0-flink-20250425` no momento.

Regiões: `emr-7.9.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.9.0-flink:latest`.

`emr-7.9.0-flink-20250425`

Notas de versão: `7.9.0-flink-20250425` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.9.0 (Flink).

Regiões: `emr-7.9.0-flink-20250425` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.9.0-flink:20250425`.

Amazon EMR nas versões EKS 7.8.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.8.0 em geral, consulte Amazon EMR 7.8.0 no Guia de lançamento do Amazon [EMR](#).

Amazon EMR nas versões do EKS 7.8

As seguintes versões do Amazon EMR 7.8.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `EMR-7.8.0-xxxx` para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As seguintes versões do Amazon EMR 7.8.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Flink.

- [emr-7.8.0-flink-mais recente](#)
- [emr-7.8.0-flink-20250228](#)

Spark releases

As seguintes versões do Amazon EMR 7.8.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Spark.

- [emr-7.8.0-mais recente](#)
- [emr-7.8.0-20250228](#)
- `emr-7.8.0-spark-rapids-latest`
- `emr-7.8.0-spark-rapids-20250228`
- `emr-7.8.0-java11-latest`
- `emr-7.8.0-java11-20250228`
- `emr-7.8.0-java8-latest`
- `emr-7.8.0-java8-20250228`
- `emr-7.8.0-spark-rapids-java8-latest`
- `emr-7.8.0-spark-rapids-java8-20250228`
- `notebook-spark/emr-7.8.0-latest`
- `notebook-spark/emr-7.8.0-20250228`
- `notebook-spark/emr-7.8.0-spark-rapids-latest`
- `notebook-spark/emr-7.8.0-spark-rapids-20250228`
- `notebook-spark/emr-7.8.0-java11-latest`
- `notebook-spark/emr-7.8.0-java11-20250228`
- `notebook-spark/emr-7.8.0-java8-latest`
- `notebook-spark/emr-7.8.0-java8-20250228`
- `notebook-spark/emr-7.8.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.8.0-spark-rapids-java8-20250228`
- `notebook-python/emr-7.8.0-latest`
- `notebook-python/emr-7.8.0-20250228`
- `notebook-python/emr-7.8.0-spark-rapids-latest`

- notebook-python/emr-7.8.0-spark-rapids-20250228
- notebook-python/emr-7.8.0-java11-latest
- notebook-python/emr-7.8.0-java11-20250228
- notebook-python/emr-7.8.0-java8-latest
- notebook-python/emr-7.8.0-java8-20250228
- notebook-python/emr-7.8.0-spark-rapids-java8-latest
- notebook-python/emr-7.8.0-spark-rapids-java8-20250228
- livy/emr-7.8.0-latest
- livy/emr-7.8.0-20250228
- livy/emr-7.8.0-java11-latest
- livy/emr-7.8.0-java11-20250228
- livy/emr-7.8.0-java8-latest
- livy/emr-7.8.0-java8-20250228

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.8.0

- Aplicações compatíveis: AWS SDK para Java 2.29.52 and 1.12.780, Apache Spark 3.5.4, Apache Hudi 0.15.0-amzn-5, Apache Iceberg 1.7.1-amzn-1, Delta 3.3.0-amzn-0, Apache Spark RAPIDS 24.12.0-amzn-0, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.20.0-amzn-2, Flink Operator 1.10.0-amzn-2
- Componentes com suporte - emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg, spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRune](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.

Classificações	Descrições
spark-metrics	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
spark-defaults	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
spark-log4j2	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
emr-job-submitter	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Alterações

As alterações a seguir estão incluídas na versão 7.8.0 do Amazon EMR no EKS:

- Recursos nativos do FGAC, incluindo:
 - Suporte do Iceberg para executar trabalhos que realizam ações em tabelas que não são do Lake Formation em um cluster virtual de controle de acesso refinado (FGAC). (Há um recurso alternativo para o IAM.)
 - Suporte para tabelas do S3
- Conexão com o Spark

emr-7.8.0-mais recente

Notas de versão: a versão `emr-7.8.0-latest` direciona para `emr-7.8.0-20250228`, no momento.

Regiões: `emr-7.8.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.8.0:latest`.

emr-7.8.0-20250228

Notas de versão: `emr-7.8.0-20250228` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.8.0 (Spark).

Regiões: `emr-emr-7.8.0-20250228` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.8.0-20250228`.

emr-7.8.0-flink-mais recente

Notas de versão: `emr-7.8.0-flink-latest` direciona para `emr-7.8.0-flink-20250228` no momento.

Regiões: `emr-7.8.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.8.0-flink:latest`.

emr-7.8.0-flink-20250228

Notas de versão: `7.8.0-flink-20250228` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.8.0 (Flink).

Regiões: `emr-7.8.0-flink-20250228` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.8.0-flink:20250228`.

Amazon EMR nas versões EKS 7.7.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.7.0 em geral, consulte Amazon EMR 7.7.0 no Guia de lançamento do Amazon [EMR](#).

Amazon EMR nas versões do EKS 7.7

As seguintes versões do Amazon EMR 7.7.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `EMR-7.7.0-xxxx` para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As seguintes versões do Amazon EMR 7.7.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Flink.

- [emr-7.7.0-flink-latest](#)
- [emr-7.7.0-flink-20250131](#)

Spark releases

As seguintes versões do Amazon EMR 7.7.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Spark.

- [emr-7.7.0-mais recente](#)
- [emr-7.7.0-20250131](#)

- `emr-7.7.0-spark-rapids-latest`
- `emr-7.7.0-spark-rapids-20250131`
- `emr-7.7.0-java11-latest`
- `emr-7.7.0-java11-20250131`
- `emr-7.7.0-java8-latest`
- `emr-7.7.0-java8-20250131`
- `emr-7.7.0-spark-rapids-java8-latest`
- `emr-7.7.0-spark-rapids-java8-20250131`
- `notebook-spark/emr-7.7.0-latest`
- `notebook-spark/emr-7.7.0-20250131`
- `notebook-spark/emr-7.7.0-spark-rapids-latest`
- `notebook-spark/emr-7.7.0-spark-rapids-20250131`
- `notebook-spark/emr-7.7.0-java11-latest`
- `notebook-spark/emr-7.7.0-java11-20250131`
- `notebook-spark/emr-7.7.0-java8-latest`
- `notebook-spark/emr-7.7.0-java8-20250131`
- `notebook-spark/emr-7.7.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.7.0-spark-rapids-java8-20250131`
- `notebook-python/emr-7.7.0-latest`
- `notebook-python/emr-7.7.0-20250131`
- `notebook-python/emr-7.7.0-spark-rapids-latest`
- `notebook-python/emr-7.7.0-spark-rapids-20250131`
- `notebook-python/emr-7.7.0-java11-latest`
- `notebook-python/emr-7.7.0-java11-20250131`
- `notebook-python/emr-7.7.0-java8-latest`
- `notebook-python/emr-7.7.0-java8-20250131`
- `notebook-python/emr-7.7.0-spark-rapids-java8-latest`
- `notebook-python/emr-7.7.0-spark-rapids-java8-20250131`
- `livy/emr-7.7.0-latest`

- `livy/emr-7.7.0-20250131`
- `livy/emr-7.7.0-java11-latest`
- `livy/emr-7.7.0-java11-20250131`
- `livy/emr-7.7.0-java8-latest`
- `livy/emr-7.7.0-java8-20250131`

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.7.0

- Aplicações compatíveis: AWS SDK para Java 2.29.25 and 1.12.779, Apache Spark 3.5.3-amzn-0, Apache Hudi 0.15.0-amzn-3, Apache Iceberg 1.6.1-amzn-2, Delta 3.2.1-amzn-1, Apache Spark RAPIDS 24.10.1-amzn-0, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.20.0-amzn-0, Flink Operator 1.10.0-amzn-0
- Componentes com suporte - `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg`, `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.

Classificações	Descrições
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>jeg-config</code>	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
<code>jupyter-kernel-overrides</code>	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Alterações

As alterações a seguir estão incluídas na versão 7.7.0 do Amazon EMR no EKS:

- A versão do Iceberg em uso a partir do EMR 7.7.0 não oferece mais suporte para Java 8. Além disso, o Iceberg está excluído das seguintes imagens Java 8: `emr-7.7.0-java8-latest` e `emr-7.7.0-spark-rapids-java8-latest`.

emr-7.7.0-mais recente

Notas de versão: a versão `emr-7.7.0-latest` direciona para `emr-7.7.0-20250131`, no momento.

Regiões: `emr-7.7.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.7.0:latest`.

emr-7.7.0-20250131

Notas de versão: `emr-7.7.0-20250131` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.7.0 (Spark).

Regiões: `emr-emr-7.7.0-20250131` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.7.0-20250131`.

emr-7.7.0-flink-latest

Notas de versão: `emr-7.7.0-flink-latest` direciona para `emr-7.7.0-flink-20250131` no momento.

Regiões: `emr-7.7.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.7.0-flink:latest`.

emr-7.7.0-flink-20250131

Notas de versão: `7.7.0-flink-20250131` foi lançado em fevereiro de 2025. Esta é a versão inicial do Amazon EMR 7.7.0 (Flink).

Regiões: `emr-7.7.0-flink-20250131` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.7.0-flink:20250131`.

Amazon EMR nas versões do EKS 7.6.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.6.0 em geral, consulte [Amazon EMR 7.6.0 no Guia de lançamento do Amazon EMR](#).

Amazon EMR nas versões do EKS 7.6

As seguintes versões do Amazon EMR 7.6.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do EMR-7.6.0-xxxx para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As seguintes versões do Amazon EMR 7.6.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Flink.

- [emr-7.6.0-flink-latest](#)
- [emr-7.6.0-flink-20241213](#)

Spark releases

As seguintes versões do Amazon EMR 7.6.0 estão disponíveis para o Amazon EMR no EKS quando você executa aplicativos Spark.

- [emr-7.6.0-mais recente](#)
- [emr-7.6.0-20241213](#)
- emr-7.6.0-spark-rapids-latest
- emr-7.6.0-spark-rapids-20241213
- emr-7.6.0-java11-latest
- emr-7.6.0-java11-20241213
- emr-7.6.0-java8-latest
- emr-7.6.0-java8-20241213
- emr-7.6.0-spark-rapids-java8-latest
- emr-7.6.0-spark-rapids-java8-20241213
- notebook-spark/emr-7.6.0-latest
- notebook-spark/emr-7.6.0-20241213
- notebook-spark/emr-7.6.0-spark-rapids-latest
- notebook-spark/emr-7.6.0-spark-rapids-20241213
- notebook-spark/emr-7.6.0-java11-latest
- notebook-spark/emr-7.6.0-java11-20241213

- `notebook-spark/emr-7.6.0-java8-latest`
- `notebook-spark/emr-7.6.0-java8-20241213`
- `notebook-spark/emr-7.6.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.6.0-spark-rapids-java8-20241213`
- `notebook-python/emr-7.6.0-latest`
- `notebook-python/emr-7.6.0-20241213`
- `notebook-python/emr-7.6.0-spark-rapids-latest`
- `notebook-python/emr-7.6.0-spark-rapids-20241213`
- `notebook-python/emr-7.6.0-java11-latest`
- `notebook-python/emr-7.6.0-java11-20241213`
- `notebook-python/emr-7.6.0-java8-latest`
- `notebook-python/emr-7.6.0-java8-20241213`
- `notebook-python/emr-7.6.0-spark-rapids-java8-latest`
- `notebook-python/emr-7.6.0-spark-rapids-java8-20241213`
- `livy/emr-7.6.0-latest`
- `livy/emr-7.6.0-20241213`
- `livy/emr-7.6.0-java11-latest`
- `livy/emr-7.6.0-java11-20241213`
- `livy/emr-7.6.0-java8-latest`
- `livy/emr-7.6.0-java8-20241213`

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.6.0

- Aplicações compatíveis: AWS SDK para Java 2.29.25 and 1.12.779, Apache Spark 3.5.3-amzn-0, Apache Hudi 0.15.0-amzn-3, Apache Iceberg 1.6.1-amzn-2, Delta 3.2.1-amzn-1, Apache Spark RAPIDS 24.10.1-amzn-0, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.20.0-amzn-0, Flink Operator 1.10.0-amzn-0
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>jeg-config</code>	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
<code>jupyter-kernel-overrides</code>	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos a seguir estão incluídos na versão 7.6.0 do Amazon EMR no EKS:

- Suporte de configuração de monitoramento para o operador do Apache Spark — A configuração de monitoramento permite que você configure facilmente o arquivamento de registros do seu aplicativo Spark e dos registros do operador no Amazon S3 ou na Amazon CloudWatch. Você pode escolher um ou os dois. Isso adiciona um sidecar do agente de log ao seu pod do operador Spark, driver e pods executores e, subsequentemente, encaminha os logs desses componentes para seus coletores configurados. Para mais informações, consulte [Usar a configuração de monitoramento para monitorar o operador Spark Kubernetes e os trabalhos Spark](#).

Alterações

As alterações a seguir estão incluídas na versão 7.6.0 do Amazon EMR no EKS:

- Nenhuma alteração na versão.

emr-7.6.0-mais recente

Notas de versão: a versão `emr-7.6.0-latest` direciona para `emr-7.6.0-20241213`, no momento.

Regiões: `emr-7.6.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.6.0:latest`.

emr-7.6.0-20241213

Notas de versão: `7.6.0-20241213` foi lançada em de janeiro de 2024. Esta é a versão inicial do Amazon EMR 7.6.0 (Spark).

Regiões: `emr-7.6.0-20241213` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.6.0:20241213`.

`emr-7.6.0-flink-latest`

Notas de versão: `emr-7.6.0-flink-latest` direciona para `emr-7.6.0-flink-20241213` no momento.

Regiões: `emr-7.6.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.6.0-flink:latest`.

`emr-7.6.0-flink-20241213`

Notas de versão: `7.6.0-flink-20241213` foi lançada em de janeiro de 2024. Esta é a versão inicial do Amazon EMR 7.6.0 (Flink).

Regiões: `emr-7.6.0-flink-20241213` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.6.0-flink:20241213`.

Amazon EMR nas versões do EKS 7.5.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.5.0 em geral, consulte Amazon EMR [7.5.0 no Guia de lançamento do Amazon EMR](#).

Amazon EMR nas versões do EKS 7.5

As seguintes versões do Amazon EMR 7.5.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `EMR-7.5.0-xxxx` para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.5.0

- Aplicações compatíveis: AWS SDK para Java 2.28.8 and 1.12.772, Apache Spark 3.5.2-amzn-1, Apache Hudi 0.15.0-amzn-1, Apache Iceberg 1.6.1-amzn-0, Delta 3.2.0-amzn-1, Apache Spark RAPIDS 24.08.1-amzn-1, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.19.1-amzn-1, Flink Operator 1.9.0-amzn-0
- Componentes com suporte: aws-sagemaker-spark-sdk, emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg e spark-kubernetes.

Amazon EMR nas versões do EKS 7.4.0

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.4.0 em geral, consulte [Amazon EMR 7.4.0 no Guia de lançamento do Amazon EMR](#).

Amazon EMR nas versões do EKS 7.4

As seguintes versões do Amazon EMR 7.4.0 estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do EMR-7.4.0-xxxx para ver mais detalhes, como a tag de imagem do contêiner relacionada.

Notas da versão

Notas de lançamento do Amazon EMR no EKS 7.4.0

- Aplicações compatíveis: AWS SDK para Java 2.25.70 and 1.12.772, Apache Spark 3.5.2-amzn-0, Apache Hudi 0.15.0-amzn-1, Apache Iceberg 1.6.1-amzn-0, Delta 3.2.0-amzn-1, Apache Spark RAPIDS 24.08.1-amzn-0, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.19.1-amzn-0, Flink Operator 1.9.0-amzn-1
- Componentes com suporte: aws-sagemaker-spark-sdk, emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg e spark-kubernetes.

Versões 7.3.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.3.0 em geral, consulte Amazon EMR [7.3.0 no Guia de lançamento do Amazon EMR](#).

Versões 7.3 do Amazon EMR no EKS

As versões 7.3.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do emr-7.3.0-XXXX para exibir mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As versões 7.3.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Flink.

- [emr-7.3.0-flink-latest](#)
- [emr-7.3.0-flink-29240920](#)

Spark releases

As versões 7.3.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Spark.

- [emr-7.3.0-latest](#)
- [emr-7.3.0-20240920](#)
- emr-7.3.0-spark-rapids-latest
- emr-7.3.0-spark-rapids-29240920
- emr-7.3.0-java11-latest
- emr-7.3.0-java11-29240920
- emr-7.3.0-java8-latest
- emr-7.3.0-java8-29240920
- emr-7.3.0-spark-rapids-java8-latest
- emr-7.3.0-spark-rapids-java8-29240920

- notebook-spark/emr-7.3.0-latest
- notebook-spark/emr-7.3.0-20240920
- notebook-spark/emr-7.3.0-spark-rapids-latest
- notebook-spark/emr-7.3.0-spark-rapids-29240920
- notebook-spark/emr-7.3.0-java11-latest
- notebook-spark/emr-7.3.0-java11-29240920
- notebook-spark/emr-7.3.0-java8-latest
- notebook-spark/emr-7.3.0-java8-29240920
- notebook-spark/emr-7.3.0-spark-rapids-java8-latest
- notebook-spark/emr-7.3.0-spark-rapids-java8-29240920
- notebook-python/emr-7.3.0-latest
- notebook-python/emr-7.3.0-20240920
- notebook-python/emr-7.3.0-spark-rapids-latest
- notebook-python/emr-7.3.0-spark-rapids-29240920
- notebook-python/emr-7.3.0-java11-latest
- notebook-python/emr-7.3.0-java11-29240920
- notebook-python/emr-7.3.0-java8-latest
- notebook-python/emr-7.3.0-java8-29240920
- notebook-python/emr-7.3.0-spark-rapids-java8-latest
- notebook-python/emr-7.3.0-spark-rapids-java8-29240920
- livy/emr-7.3.0-latest
- livy/emr-7.3.0-20240920
- livy/emr-7.3.0-java11-latest
- livy/emr-7.3.0-java11-29240920
- livy/emr-7.3.0-java8-latest
- livy/emr-7.3.0-java8-29240920

Notas da versão

Notas da versão 7.3.0 do Amazon EMR no EKS

- Aplicações compatíveis: AWS SDK para Java 2.25.70 and 1.12.747, Apache Spark 3.5.1-amzn-1, Apache Hudi 0.15.0-amzn-0, Apache Iceberg 1.5.2-amzn-0, Delta 3.2.0-amzn-0, Apache Spark RAPIDS 24.06.1-amzn-0, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.18.1-amzn-2, Flink Operator 1.9.0-amzn-0
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos a seguir estão incluídos na versão 7.3.0 do Amazon EMR no EKS.

- Atualizações de aplicações: o Amazon EMR no EKS agora inclui o [Flink Operator 1.9.0](#). Além de outros recursos, o Kubernetes do Flink agora permite definir cotas de CPU e memória para o escalador automático.
- Suporte do Apache Iceberg para o Apache Flink: o Apache Iceberg é um formato de tabelas analíticas enormes de código aberto e alta performance. Desde o Amazon EMR 7.3.0, você pode usar as tabelas do Apache Iceberg ao executar o Apache Flink no Amazon EMR no EKS. Para obter mais informações, consulte o artigo [Using Apache Iceberg with Amazon EMR on EKS](#) do Amazon EMR no EKS.
- Suporte do Delta Lake para Apache Flink: o Delta Lake é uma estrutura de camada de armazenamento para arquiteturas de lakehouse comumente desenvolvidas no Amazon S3. Com as versões 7.3.0 e superiores do Amazon EMR, você pode usar as tabelas do Delta ao executar o Apache Flink no Amazon EMR no EKS. Para obter mais informações, consulte [Using Delta Lake with Amazon EMR on EKS](#).

Alterações

As alterações a seguir estão incluídas na versão 7.3.0 do Amazon EMR no EKS.

- Com o Amazon EMR no EKS 7.3.0 e superior, o Apache Flink agora usa o runtime do Java 17 por padrão.

emr-7.3.0-latest

Notas de versão: a versão `emr-7.3.0-latest` direciona para `emr-7.3.0-20240920`, no momento.

Regiões: `emr-7.3.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.3.0:latest`.

emr-7.3.0-20240920

Notas da versão: `7.3.0-20240920` foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.3.0 (Spark).

Regiões: `emr-7.3.0-20240920` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.3.0:29240920`.

emr-7.3.0-flink-latest

Notas de versão: a versão `emr-7.3.0-flink-latest` direciona para `emr-7.3.0-flink-29240920`, no momento.

Regiões: `emr-7.3.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.3.0-flink:latest`.

emr-7.3.0-flink-29240920

Notas da versão: `7.3.0-flink-29240920` foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.3.0 (Flink).

Regiões: `emr-7.3.0-flink-29240920` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.3.0-flink:29240920`.

Versões 7.2.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.2.0 em geral, consulte Amazon EMR [7.2.0 no Guia de lançamento do Amazon EMR](#).

Versões 7.2 do Amazon EMR no EKS

As versões 7.2.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-7.2.0-XXXX` para exibir mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As versões 7.2.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Flink.

- [emr-7.2.0-flink-latest](#)
- [emr-7.2.0-flink-20240610](#)

Spark releases

As versões 7.2.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Spark.

- [emr-7.2.0-latest](#)
- [emr-7.2.0-20240610](#)
- `emr-7.2.0-spark-rapids-latest`
- `emr-7.2.0-spark-rapids-20240610`
- `emr-7.2.0-java11-latest`
- `emr-7.2.0-java11-20240610`
- `emr-7.2.0-java8-latest`
- `emr-7.2.0-java8-20240610`
- `emr-7.2.0-spark-rapids-java8-latest`

- `emr-7.2.0-spark-rapids-java8-20240610`
- `notebook-spark/emr-7.2.0-latest`
- `notebook-spark/emr-7.2.0-20240610`
- `notebook-spark/emr-7.2.0-spark-rapids-latest`
- `notebook-spark/emr-7.2.0-spark-rapids-20240610`
- `notebook-spark/emr-7.2.0-java11-latest`
- `notebook-spark/emr-7.2.0-java11-20240610`
- `notebook-spark/emr-7.2.0-java8-latest`
- `notebook-spark/emr-7.2.0-java8-20240610`
- `notebook-spark/emr-7.2.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.2.0-spark-rapids-java8-20240610`
- `notebook-python/emr-7.2.0-latest`
- `notebook-python/emr-7.2.0-20240610`
- `notebook-python/emr-7.2.0-spark-rapids-latest`
- `notebook-python/emr-7.2.0-spark-rapids-20240610`
- `notebook-python/emr-7.2.0-java11-latest`
- `notebook-python/emr-7.2.0-java11-20240610`
- `notebook-python/emr-7.2.0-java8-latest`
- `notebook-python/emr-7.2.0-java8-20240610`
- `notebook-python/emr-7.2.0-spark-rapids-java8-latest`
- `notebook-python/emr-7.2.0-spark-rapids-java8-20240610`
- `livy/emr-7.2.0-latest`
- `livy/emr-7.2.0-20240610`
- `livy/emr-7.2.0-java11-latest`
- `livy/emr-7.2.0-java11-20240610`
- `livy/emr-7.2.0-java8-latest`
- `livy/emr-7.2.0-java8-20240610`

Notas da versão

Notas da versão 7.2.0 do Amazon EMR no EKS

- Aplicações compatíveis: AWS SDK para Java 2.23.18 and 1.12.705, Apache Spark 3.5.1-amzn-1, Apache Hudi 0.14.1-amzn-0, Apache Iceberg 1.5.0-amzn-0, Delta 3.1.0, Apache Spark RAPIDS 24.02.0-amzn-1, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.18.1-amzn-0, Flink Operator 1.8.0-amzn-1
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos a seguir estão incluídos na versão 7.2.0 do Amazon EMR no EKS.

- **Atualizações da aplicação:** as atualizações da aplicação do Amazon EMR no EKS 7.2.0 incluem Spark 3.5.1, Flink 1.18.1 e [operador do Flink](#) 1.8.0.
- [Escalador automático para atualizações do Flink](#): a versão 7.2.0 usa a configuração de código aberto `job.autoscaler.restart.time-tracking.enabled` para permitir a estimativa do tempo de redimensionamento, para que você não precise mais atribuir valores empíricos manualmente ao reiniciar. Se você executar a versão 7.1.0 ou inferior, ainda poderá usar o ajuste de escala automático do Amazon EMR.
- [Integração do Apache Hudi com Apache Flink no Amazon EMR no EKS](#): essa versão adiciona uma integração entre o Apache Hudi e o Apache Flink, para que você possa usar o operador do Kubernetes do Flink ao executar trabalhos do Hudi. O Hudi permite usar operações em nível de registro que podem simplificar o gerenciamento de dados e o desenvolvimento do pipeline de dados.
- [Integração do Amazon S3 Express One Zone com o Amazon EMR no EKS](#): com a versão 7.2.0 e superior, você pode fazer upload de dados no S3 Express One Zone com o Amazon EMR no EKS. O S3 Express One Zone é uma classe de armazenamento de zona única e alta performance do Amazon S3 que oferece acesso consistente a dados de milissegundos de um dígito para a maioria das aplicações sensíveis à latência. Na hora da execução, o S3 Express One Zone oferece o

armazenamento de objetos na nuvem com a menor latência e a maior performance do Amazon S3.

- [Suporte para configurações padrão no operador do Spark](#): o operador do Spark no Amazon EKS agora oferece suporte às mesmas configurações padrão do modelo de início de execução de trabalhos no Amazon EMR no EKS para a versão 7.2.0 e posteriores. Isso significa que recursos como Amazon S3 e EMRFS não exigem mais configurações manuais no arquivo YAML.

emr-7.2.0-latest

Notas de versão: a versão `emr-7.2.0-latest` direciona para `emr-7.2.0-20240610`, no momento.

Regiões: `emr-7.2.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.2.0:latest`.

emr-7.2.0-20240610

Notas da versão: `7.2.0-20240610` foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.2.0 (Spark).

Regiões: `emr-7.2.0-20240610` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.2.0:20240610`.

emr-7.2.0-flink-latest

Notas de versão: a versão `emr-7.2.0-flink-latest` direciona para `emr-7.2.0-flink-20240610`, no momento.

Regiões: `emr-7.2.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.2.0-flink:latest`.

emr-7.2.0-flink-20240610

Notas da versão: `7.2.0-flink-20240610` foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.2.0 (Flink).

Regiões: `emr-7.2.0-flink-20240610` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.2.0-flink:20240610`.

Versões 7.1.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.1.0 em geral, consulte Amazon EMR [7.1.0 no Guia de lançamento do Amazon EMR](#).

Versões 7.1 do Amazon EMR no EKS

As versões 7.1.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-7.1.0-XXXX` para exibir mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As versões 7.1.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Flink.

- [emr-7.1.0-flink-latest](#)
- [emr-7.1.0-flink-20240321](#)

Spark releases

As versões 7.1.0 do Amazon EMR a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Spark.

- [emr-7.1.0-latest](#)
- [emr-7.1.0-20240321](#)
- `emr-7.1.0-spark-rapids-latest`
- `emr-7.1.0-spark-rapids-20240321`
- `emr-7.1.0-java11-latest`
- `emr-7.1.0-java11-20240321`

- `emr-7.1.0-java8-latest`
- `emr-7.1.0-java8-20240321`
- `emr-7.1.0-spark-rapids-java8-latest`
- `emr-7.1.0-spark-rapids-java8-20240321`
- `notebook-spark/emr-7.1.0-latest`
- `notebook-spark/emr-7.1.0-20240321`
- `notebook-spark/emr-7.1.0-spark-rapids-latest`
- `notebook-spark/emr-7.1.0-spark-rapids-20240321`
- `notebook-spark/emr-7.1.0-java11-latest`
- `notebook-spark/emr-7.1.0-java11-20240321`
- `notebook-spark/emr-7.1.0-java8-latest`
- `notebook-spark/emr-7.1.0-java8-20240321`
- `notebook-spark/emr-7.1.0-spark-rapids-java8-latest`
- `notebook-spark/emr-7.1.0-spark-rapids-java8-20240321`
- `notebook-python/emr-7.1.0-latest`
- `notebook-python/emr-7.1.0-20240321`
- `notebook-python/emr-7.1.0-spark-rapids-latest`
- `notebook-python/emr-7.1.0-spark-rapids-20240321`
- `notebook-python/emr-7.1.0-java11-latest`
- `notebook-python/emr-7.1.0-java11-20240321`
- `notebook-python/emr-7.1.0-java8-latest`
- `notebook-python/emr-7.1.0-java8-20240321`
- `notebook-python/emr-7.1.0-spark-rapids-java8-latest`
- `notebook-python/emr-7.1.0-spark-rapids-java8-20240321`
- `livy/emr-7.1.0-latest`
- `livy/emr-7.1.0-20240321`
- `livy/emr-7.1.0-java11-latest`
- `livy/emr-7.1.0-java11-20240321`
- `livy/emr-7.1.0-java8-latest`
- `livy/emr-7.1.0-java8-20240321`

Notas da versão

Notas da versão 7.1.0 do Amazon EMR no EKS

- Aplicações compatíveis: AWS SDK para Java 2.23.18 and 1.12.656, Apache Spark 3.5.0-amzn-1, Apache Hudi 0.14.1-amzn-0, Apache Iceberg 1.4.3-amzn-0, Delta 3.0.0, Apache Spark RAPIDS 23.10.0-amzn-1, Jupyter Enterprise Gateway 2.6.0, Apache Flink 1.18.1-amzn-0, Flink Operator 1.6.1-amzn-1
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j2</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos a seguir estão incluídos na versão 7.1.0 do Amazon EMR no EKS.

- [Suporte do Apache Livy para Amazon EMR no EKS](#): com o Amazon EMR no EKS nas versões 7.1.0 e superiores, você pode usar o Apache Livy em um cluster do Amazon EKS para criar uma interface REST do Apache Livy e enviar trabalhos do Spark ou trechos de código do Spark. Isso permite recuperar os resultados de forma síncrona e assíncrona, enquanto ainda aproveita os benefícios do Amazon EMR no EKS, como o runtime do Spark otimizado para Amazon EMR, endpoints do Livy habilitados por SSL e uma experiência de configuração programática.

emr-7.1.0-latest

Notas de versão: a versão `emr-7.1.0-latest` direciona para `emr-7.1.0-20240321`, no momento.

Regiões: `emr-7.1.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.1.0:latest`.

emr-7.1.0-20240321

Notas da versão: 7.1.0-20240321 foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.1.0 (Spark).

Regiões: `emr-7.1.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.1.0:20240321`.

emr-7.1.0-flink-latest

Notas de versão: a versão `emr-7.1.0-flink-latest` direciona para `emr-7.1.0-flink-20240321`, no momento.

Regiões: `emr-7.1.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.1.0-flink:latest`.

emr-7.1.0-flink-20240321

Notas da versão: 7.1.0-flink-20240321 foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.1.0 (Flink).

Regiões: `emr-7.1.0-flink-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.1.0-flink:20240321`.

Versões 7.0.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 7.0.0 em geral, consulte Amazon EMR [7.0.0 no Guia de lançamento do Amazon EMR](#).

Versões 7.0 do Amazon EMR no EKS

As versões 7.0.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do emr-7.0.0-XXXX para visualizar mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As versões 7.0.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Flink.

- [emr-7.0.0-flink-latest](#)
- [emr-7.0.0-flink-2024321](#)
- [emr-7.0.0-flink-20231211](#)

Spark releases

As versões 7.0.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Spark.

- [emr-7.0.0-latest](#)
- [emr-7.0.0-20231211](#)
- emr-7.0.0-spark-rapids-latest
- emr-7.0.0-spark-rapids-20231211
- emr-7.0.0-java11-latest
- emr-7.0.0-java11-20231211
- emr-7.0.0-java8-latest
- emr-7.0.0-java8-20231211
- emr-7.0.0-spark-rapids-java8-latest
- emr-7.0.0-spark-rapids-java8-20231211
- notebook-spark/emr-7.0.0-latest
- notebook-spark/emr-7.0.0-20231211
- notebook-spark/emr-7.0.0-spark-rapids-latest
- notebook-spark/emr-7.0.0-spark-rapids-20231211
- notebook-spark/emr-7.0.0-java11-latest

- notebook-spark/emr-7.0.0-java11-20231211
- notebook-spark/emr-7.0.0-java8-latest
- notebook-spark/emr-7.0.0-java8-20231211
- notebook-spark/emr-7.0.0-spark-rapids-java8-latest
- notebook-spark/emr-7.0.0-spark-rapids-java8-20231211
- notebook-python/emr-7.0.0-latest
- notebook-python/emr-7.0.0-20231211
- notebook-python/emr-7.0.0-spark-rapids-latest
- notebook-python/emr-7.0.0-spark-rapids-20231211
- notebook-python/emr-7.0.0-java11-latest
- notebook-python/emr-7.0.0-java11-20231211
- notebook-python/emr-7.0.0-java8-latest
- notebook-python/emr-7.0.0-java8-20231211
- notebook-python/emr-7.0.0-spark-rapids-java8-latest
- notebook-python/emr-7.0.0-spark-rapids-java8-20231211

Notas da versão

Notas da versão 7.0.0 do Amazon EMR no EKS

- Aplicações compatíveis: AWS SDK para Java 2.20.160-amzn-0 and 1.12.595, Apache Spark 3.5.0-amzn-0, Apache Flink 1.18.0-amzn-0, Flink Operator 1.6.1, Apache Hudi 0.14.0-amzn-1, Apache Iceberg 1.4.2-amzn-0, Delta 3.0.0, Apache Spark RAPIDS 23.10.0-amzn-0, Jupyter Enterprise Gateway 2.6.0
- Componentes com suporte: aws-sagemaker-spark-sdk, emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg e spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRune](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Altera os valores no arquivo metrics.properties do Spark.
spark-defaults	Altera os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Altera os valores no arquivo log4j2.properties do Spark.
emr-job-submitter	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo jupyter_enterprise_gateway_config.py do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os atributos apresentados a seguir estão inclusos na versão 7.0 do Amazon EMR no EKS.

- Atualizações da aplicação: as atualizações da aplicação Amazon EMR no EKS 7.0.0 incluem Spark 3.5, Flink 1.18 e [Flink Operator](#) 1.6.1.
- Ajuste automático de parâmetros do escalador automático do Flink: os parâmetros padrão que o escalador automático do Flink usa nos cálculos de ajuste de escala podem não ser o valor ideal para um determinado trabalho. A versão 7.0.0 do Amazon EMR no EKS usa tendências do histórico de métricas específicas capturadas para calcular o parâmetro ideal personalizado para o trabalho.

Alterações

A alterações a seguir estão inclusas na versão 7.0 do Amazon EMR no EKS.

- Amazon Linux 2023: com as versões 7.0.0 e superiores do Amazon EMR no EKS, todas as imagens de contêiner são baseadas no Amazon Linux 2023.
- O Spark usa o Java 17 como runtime padrão: o Spark da versão 7.0.0 do Amazon EMR no EKS usa o Java 17 como runtime padrão. Se precisar, você pode alternar para usar o Java 8 ou o Java 11 com o rótulo de versão correspondente, conforme fornecido na lista [Versões 7.0 do Amazon EMR no EKS](#).

emr-7.0.0-latest

Notas de versão: a versão `emr-7.0.0-latest` direciona para `emr-7.0.0-2024321`, no momento.

Regiões: `emr-7.0.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.0.0:latest`.

emr-7.0.0-2024321

Notas de versão: 7.0.0-2024321 foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-7.0.0-2024321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.0.0:2024321`.

emr-7.0.0-20231211

Notas da versão: 7.0.0-20231211 foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.0.0 (Spark).

Regiões: `emr-7.0.0-20231211` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.0.0:20231211`.

emr-7.0.0-flink-latest

Notas de versão: a versão `emr-7.0.0-flink-latest` direciona para `emr-7.0.0-flink-2024321`, no momento.

Regiões: `emr-7.0.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.0.0-flink:latest`.

emr-7.0.0-flink-2024321

Notas de versão: 7.0.0-flink-2024321 foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-7.0.0-flink-2024321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.0.0-flink:2024321`.

`emr-7.0.0-flink-20231211`

Notas da versão: `7.0.0-flink-20231211` foi lançada em dezembro de 2023. Esta é a versão inicial do Amazon EMR 7.0.0 (Flink).

Regiões: `emr-7.0.0-flink-20231211` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-7.0.0-flink:20231211`.

Versões 6.15.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão 6.15.0 do Amazon EMR em geral, consulte Amazon EMR 6.15.0 no Guia de lançamento do Amazon [EMR](#).

Versões 6.15 do Amazon EMR no EKS

As versões 6.15.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.15.0-XXXX` para visualizar mais detalhes, como a tag de imagem do contêiner relacionada.

Flink releases

As versões 6.15.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Flink.

- [emr-6.15.0-flink-latest](#)
- [emr-6.15.0-flink-20240105](#)
- [emr-6.15.0-flink-20231109](#)

Spark releases

As versões 6.15.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS ao executar aplicações do Spark.

- [emr-6.15.0-latest](#)
- [emr-6.15.0-20231109](#)
- `emr-6.15.0-spark-rapids-latest`
- `emr-6.15.0-spark-rapids-20231109`
- `emr-6.15.0-java11-latest`
- `emr-6.15.0-java11-20231109`
- `emr-6.15.0-java17-latest`
- `emr-6.15.0-java17-20231109`
- `emr-6.15.0-java17-al2023-latest`
- `emr-6.15.0-java17-al2023-20231109`
- `emr-6.15.0-spark-rapids-java17-latest`
- `emr-6.15.0-spark-rapids-java17-20231109`
- `emr-6.15.0-spark-rapids-java17-al2023-latest`
- `emr-6.15.0-spark-rapids-java17-al2023-20231109`
- `notebook-spark/emr-6.15.0-latest`
- `notebook-spark/emr-6.15.0-20231109`
- `notebook-spark/emr-6.15.0-spark-rapids-latest`
- `notebook-spark/emr-6.15.0-spark-rapids-20231109`
- `notebook-spark/emr-6.15.0-java11-latest`
- `notebook-spark/emr-6.15.0-java11-20231109`
- `notebook-spark/emr-6.15.0-java17-latest`
- `notebook-spark/emr-6.15.0-java17-20231109`
- `notebook-spark/emr-6.15.0-java17-al2023-latest`
- `notebook-spark/emr-6.15.0-java17-al2023-20231109`
- `notebook-python/emr-6.15.0-latest`
- `notebook-python/emr-6.15.0-20231109`
- `notebook-python/emr-6.15.0-spark-rapids-latest`
- `notebook-python/emr-6.15.0-spark-rapids-20231109`
- `notebook-python/emr-6.15.0-java11-latest`

- notebook-python/emr-6.15.0-java11-20231109
- notebook-python/emr-6.15.0-java17-latest
- notebook-python/emr-6.15.0-java17-20231109
- notebook-python/emr-6.15.0-java17-al2023-latest
- notebook-python/emr-6.15.0-java17-al2023-20231109

Notas da versão

Notas da versão 6.15.0 do Amazon EMR no EKS

- Aplicações compatíveis: AWS SDK para Java 1.12.569, Apache Spark 3.4.1-amzn-2, Apache Flink 1.17.1-amzn-1, Apache Hudi 0.14.0-amzn-0, Apache Iceberg 1.4.0-amzn-0, Delta 2.4.0, Apache Spark RAPIDS 23.08.01-amzn-0, Jupyter Enterprise Gateway 2.6.0
- Componentes com suporte: aws-sagemaker-spark-sdk, emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg e spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) e [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Altera os valores no arquivo metrics.properties do Spark.
spark-defaults	Altera os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.

Classificações	Descrições
<code>spark-log4j</code>	Altera os valores no arquivo <code>log4j2.properties</code> do Spark.
<code>emr-job-submitter</code>	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>jeg-config</code>	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
<code>jupyter-kernel-overrides</code>	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos apresentados a seguir estão inclusos na versão 6.15 do Amazon EMR no EKS.

- [Amazon EMR no EKS com Apache Flink](#): com a versão 6.15.0 do Amazon EMR no EKS você pode executar aplicações baseadas no Apache Flink com outros tipos de aplicações no mesmo cluster do Amazon EKS. Isso ajuda a melhorar a utilização de recursos e a simplificar o gerenciamento da infraestrutura. Você pode aproveitar as instâncias spot em uma aplicação do Flink com uma desativação tranquila e obter tempos de reinicialização mais rápidos com recuperação refinada e recuperação local de tarefas com o Amazon EBS. Os recursos de acessibilidade e monitoramento incluem a capacidade de iniciar um aplicativo Flink com jars armazenados no Amazon S3, acesso ao AWS Glue Data Catalog, monitoramento da integração com o Amazon S3 e a CloudWatch Amazon e rotação de registros de contêineres.

emr-6.15.0-latest

Notas de versão: a versão `emr-6.15.0-latest` direciona para `emr-6.15.0-20240105`, no momento.

Regiões: `emr-6.15.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.15.0:latest`.

emr-6.15.0-20240105

Notas de versão: `6.15.0-20240105` foi lançada em 17 de janeiro de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.15.0-20240105` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.15.0:20240105`.

emr-6.15.0-20231109

Notas da versão: `6.15.0-20231109` foi lançada em 17 de novembro de 2023. Esta é a versão inicial do Amazon EMR 6.15.0.

Regiões: `emr-6.15.0-20231109` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.15.0:20231109`.

emr-6.15.0-flink-latest

Notas de versão: a versão `emr-6.15.0-flink-latest` direciona para `emr-6.15.0-flink-20240105`, no momento.

Regiões: `emr-6.15.0-flink-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.15.0-flink:latest`.

emr-6.15.0-flink-20240105

Notas de versão: `6.15.0-flink-20240105` foi lançada em 17 de janeiro de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.15.0-flink-20240105` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.15.0-flink:20240105`.

emr-6.15.0-flink-20231109

Notas da versão: `6.15.0-flink-20231109` foi lançada em 17 de novembro de 2023. Esta é a versão inicial do Amazon EMR 6.15.0.

Regiões: `emr-6.15.0-flink-20231109` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.15.0-flink:20231109`.

Versões 6.14.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 6.14.0 em geral, consulte Amazon EMR 6.14.0 no Guia de lançamento do Amazon [EMR](#).

Versões 6.14 do Amazon EMR no EKS

As versões 6.14.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.14.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.14.0-latest](#)
- [emr-6.14.0-20231005](#)

- emr-6.14.0-spark-rapids-latest
- emr-6.14.0-spark-rapids-20231005
- emr-6.14.0-java11-latest
- emr-6.14.0-java11-20231005
- emr-6.14.0-java17-latest
- emr-6.14.0-java17-20231005
- emr-6.14.0-java17-al2023-latest
- emr-6.14.0-java17-al2023-20231005
- emr-6.14.0-spark-rapids-java17-latest
- emr-6.14.0-spark-rapids-java17-20231005
- emr-6.14.0-spark-rapids-java17-al2023-latest
- emr-6.14.0-spark-rapids-java17-al2023-20231005
- notebook-spark/emr-6.14.0-latest
- notebook-spark/emr-6.14.0-20231005
- notebook-spark/emr-6.14.0-spark-rapids-latest
- notebook-spark/emr-6.14.0-spark-rapids-20231005
- notebook-spark/emr-6.14.0-java11-latest
- notebook-spark/emr-6.14.0-java11-20231005
- notebook-spark/emr-6.14.0-java17-latest
- notebook-spark/emr-6.14.0-java17-20231005
- notebook-spark/emr-6.14.0-java17-al2023-latest
- notebook-spark/emr-6.14.0-java17-al2023-20231005
- notebook-python/emr-6.14.0-latest
- notebook-python/emr-6.14.0-20231005
- notebook-python/emr-6.14.0-spark-rapids-latest
- notebook-python/emr-6.14.0-spark-rapids-20231005
- notebook-python/emr-6.14.0-java11-latest
- notebook-python/emr-6.14.0-java11-20231005
- notebook-python/emr-6.14.0-java17-latest
- notebook-python/emr-6.14.0-java17-20231005

- notebook-python/emr-6.14.0-java17-al2023-latest
- notebook-python/emr-6.14.0-java17-al2023-20231005

Notas da versão

Notas da versão 6.14.0 do Amazon EMR no EKS

- Aplicativos compatíveis - AWS SDK para Java 1.12.543, Apache Spark 3.4.1-amzn-1, Apache Hudi 0.13.1-amzn-2, Apache Iceberg 1.3.0-amzn-0, Delta 2.4.0, Apache Spark RAPIDS 23.06.0-amzn-2, Jupyter Enterprise Gateway 2.7.0
- Componentes com suporte: aws-sagemaker-spark-sdk, emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg e spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Altera os valores no arquivo metrics.properties do Spark.
spark-defaults	Altera os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Altera os valores no arquivo log4j2.properties do Spark.
emr-job-submitter	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os atributos apresentados a seguir estão inclusos na versão 6.14 do Amazon EMR no EKS.

- Suporte ao [Apache Livy](#): o Amazon EMR no EKS agora oferece suporte ao Apache Livy com `spark-submit`.

emr-6.14.0-latest

Notas de versão: a versão `emr-6.14.0-latest` direciona para `emr-6.14.0-20231005`, no momento.

Regiões: `emr-6.14.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.14.0:latest`.

emr-6.14.0-20231005

Notas de versão: `6.14.0-20231005` foi liberada em 17 de outubro de 2023. Esta é a versão inicial do Amazon EMR 6.14.0.

Regiões: `emr-6.14.0-20231005` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.14.0:20231005`.

Versões 6.13.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 6.13.0 em geral, consulte [Amazon EMR 6.13.0 no Guia de lançamento do Amazon EMR](#).

Versões 6.13 do Amazon EMR no EKS

As versões 6.13.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.13.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.13.0-latest](#)
- [emr-6.13.0-20230814](#)
- `emr-6.13.0-spark-rapids-latest`
- `emr-6.13.0-spark-rapids-20230814`
- `emr-6.13.0-java11-latest`
- `emr-6.13.0-java11-20230814`
- `emr-6.13.0-java17-latest`
- `emr-6.13.0-java17-20230814`
- `emr-6.13.0-java17-al2023-latest`
- `emr-6.13.0-java17-al2023-20230814`
- `emr-6.13.0-spark-rapids-java17-latest`
- `emr-6.13.0-spark-rapids-java17-20230814`
- `emr-6.13.0-spark-rapids-java17-al2023-latest`
- `emr-6.13.0-spark-rapids-java17-al2023-20230814`
- `notebook-spark/emr-6.13.0-latest`

- notebook-spark/emr-6.13.0-20230814
- notebook-spark/emr-6.13.0-spark-rapids-latest
- notebook-spark/emr-6.13.0-spark-rapids-20230814
- notebook-spark/emr-6.13.0-java11-latest
- notebook-spark/emr-6.13.0-java11-20230814
- notebook-spark/emr-6.13.0-java17-latest
- notebook-spark/emr-6.13.0-java17-20230814
- notebook-spark/emr-6.13.0-java17-al2023-latest
- notebook-spark/emr-6.13.0-java17-al2023-20230814
- notebook-python/emr-6.13.0-latest
- notebook-python/emr-6.13.0-20230814
- notebook-python/emr-6.13.0-spark-rapids-latest
- notebook-python/emr-6.13.0-spark-rapids-20230814
- notebook-python/emr-6.13.0-java11-latest
- notebook-python/emr-6.13.0-java11-20230814
- notebook-python/emr-6.13.0-java17-latest
- notebook-python/emr-6.13.0-java17-20230814
- notebook-python/emr-6.13.0-java17-al2023-latest
- notebook-python/emr-6.13.0-java17-al2023-20230814

Notas da versão

Notas da versão 6.13.0 do Amazon EMR no EKS

- Aplicativos compatíveis - AWS SDK para Java 1.12.513, Apache Spark 3.4.1-amzn-0, Apache Hudi 0.13.1-amzn-0, Apache Iceberg 1.3.0-amzn-0, Delta 2.4.0, Apache Spark RAPIDS 23.06.0-amzn-1, Jupyter Enterprise Gateway 2.6.0.amzn
- Componentes com suporte: aws-sagemaker-spark-sdk, emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg e spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRune](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Altera os valores no arquivo metrics.properties do Spark.
spark-defaults	Altera os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Altera os valores no arquivo log4j2.properties do Spark.
emr-job-submitter	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo jupyter_enterprise_gateway_config.py do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos apresentados a seguir estão inclusos na versão 6.13 do Amazon EMR no EKS.

- Amazon Linux 2023 - Com o Amazon EMR no EKS 6.13 e superior, você pode iniciar o Spark com o AL2 023 como sistema operacional junto com o tempo de execução do Java 17. Para fazer isso, use o rótulo de versão `a12023` em seu nome. Por exemplo: `emr-6.13.0-java17-a12023-latest`. Recomendamos que você valide e execute testes de desempenho antes de mover suas cargas de trabalho de produção para AL2 023 e Java 17.
- [Amazon EMR no EKS com o Apache Flink](#) (pré-visualização pública): as versões 6.13 do Amazon EMR no EKS e versões superiores oferecem suporte ao Apache Flink, que está disponível em pré-visualização pública. Com este lançamento, você pode executar sua aplicação baseada no Apache Flink em conjunto com outros tipos de aplicações no mesmo cluster do Amazon EKS. Isso ajuda a melhorar a utilização de recursos e a simplificar o gerenciamento da infraestrutura. Se você já executa estruturas de big data no Amazon EKS, agora é possível permitir que o Amazon EMR automatize o provisionamento e o gerenciamento.

emr-6.13.0-latest

Notas de versão: a versão `emr-6.13.0-latest` direciona para `emr-6.13.0-20230814`, no momento.

Regiões: `emr-6.13.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.13.0:latest`.

emr-6.13.0-20230814

Notas de versão: `6.13.0-20230814` foi liberada em 7 de setembro de 2023. Esta é a versão inicial do Amazon EMR 6.13.0.

Regiões: `emr-6.13.0-20230814` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.13.0:20230814`.

Versões 6.12.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão 6.12.0 do Amazon EMR em geral, consulte [Amazon EMR 6.12.0 no Guia de lançamento do Amazon EMR](#).

Versões 6.12 do Amazon EMR no EKS

As versões 6.12.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.12.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.12.0-latest](#)
- [emr-6.12.0-20240321](#)
- [emr-6.12.0-20230701](#)
- `emr-6.12.0-spark-rapids-latest`
- `emr-6.12.0-spark-rapids-20230701`
- `emr-6.12.0-java11-latest`
- `emr-6.12.0-java11-20230701`
- `emr-6.12.0-java17-latest`
- `emr-6.12.0-java17-20230701`
- `emr-6.12.0-17-mais recente spark-rapids-java`
- `emr-6.12.0-17-20230701 spark-rapids-java`
- `notebook-spark/emr-6.12.0-latest`
- `notebook-spark/emr-6.12.0-20230701`
- `notebook-spark/emr-6.12.0-spark-rapids-latest`
- `notebook-spark/emr-6.12.0-spark-rapids-20230701`
- `notebook-python/emr-6.12.0-latest`
- `notebook-python/emr-6.12.0-20230701`

- notebook-python/emr-6.12.0- spark-rapids-latest
- notebook-python/emr-6.12.0-spark-rapids-20230701

Notas da versão

Notas da versão 6.12.0 do Amazon EMR no EKS

- Aplicativos compatíveis - AWS SDK para Java 1.12.490, Apache Spark 3.4.0-amzn-0, Apache Hudi 0.13.1-amzn-0, Apache Iceberg 1.3.0-amzn-0, Delta 2.4.0, Apache Spark RAPIDS 23.06.0-amzn-0, Jupyter Enterprise Gateway 2.6.0
- Componentes com suporte: aws-sagemaker-spark-sdk, emr-ddb, emr-goodies, emr-s3-select, emrfs, hadoop-client, hudi, hudi-spark, iceberg e spark-kubernetes.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Altera os valores no arquivo metrics.properties do Spark.
spark-defaults	Altera os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Altera os valores no arquivo log4j2.properties do Spark.
emr-job-submitter	Configuração para o pod de envio de trabalho .

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos apresentados a seguir estão inclusos na versão 6.12 do Amazon EMR no EKS.

- Java 17: com a versão 6.12 do Amazon EMR no EKS e versões superiores, é possível iniciar o Spark com o runtime do Java 17. Para fazer isso, transmita `emr-6.12.0-java17-latest` como uma etiqueta de versão. Recomendamos que você valide e execute testes de performance antes de mover as workloads de produção de versões anteriores da imagem do Java para a imagem do Java 17.

emr-6.12.0-latest

Notas de versão: a versão `emr-6.12.0-latest` direciona para `emr-6.12.0-20240321`, no momento.

Regiões: `emr-6.12.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.12.0:latest`.

emr-6.12.0-20240321

Notas de versão: 6.12.0-20240321 foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.12.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.12.0:20240321`.

emr-6.12.0-20230701

Notas de versão: 6.12.0-20230701 foi liberada em 1.º de julho de 2023. Esta é a versão inicial do Amazon EMR 6.12.0.

Regiões: `emr-6.12.0-20230701` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.12.0:20230701`.

Versões 6.11.0 do Amazon EMR no EKS

Esta página descreve a funcionalidade nova e atualizada do Amazon EMR que é específica para a implantação do Amazon EMR no EKS. Para obter detalhes sobre o Amazon EMR em execução na Amazon EC2 e sobre a versão do Amazon EMR 6.11.0 em geral, consulte Amazon EMR 6.11.0 no Guia de lançamento do Amazon [EMR](#).

Versões 6.11 do Amazon EMR no EKS

As versões 6.11.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.11.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.11.0-latest](#)
- [emr-6.11.0-20230905](#)
- [emr-6.11.0-20230509](#)

- `emr-6.11.0-spark-rapids-latest`
- `emr-6.11.0-spark-rapids-20230509`
- `emr-6.11.0-java11-latest`
- `emr-6.11.0-java11-20230509`
- `notebook-spark/emr-6.11.0-latest`
- `notebook-spark/emr-6.11.0-20230509`
- `notebook-python/emr-6.11.0-latest`
- `notebook-python/emr-6.11.0-20230509`

Notas da versão

Notas da versão 6.11.0 do Amazon EMR no EKS

- Aplicativos compatíveis - AWS SDK para Java 1.12.446, Apache Spark 3.3.2-amzn-0, Apache Hudi 0.13.0-amzn-0, Apache Iceberg 1.2.0-amzn-0, Delta 2.2.0, Apache Spark RAPIDS 23.02.0-amzn-0, Jupyter Enterprise Gateway 2.6.0
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.

Classificações	Descrições
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Altera os valores no arquivo log4j.properties do Spark.

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
jeg-config	Altera os valores no arquivo jupyter_enterprise_gateway_config.py do Jupyter Enterprise Gateway.
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como spark-hive-site.xml. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

Os recursos apresentados a seguir estão inclusos na versão 6.11 do Amazon EMR no EKS.

- [Imagem base do Amazon EMR no EKS na galeria pública do Amazon ECR](#): se você usar a funcionalidade [imagem personalizada](#), nossa imagem base fornecerá os arquivos em JARs, as configurações e as bibliotecas essenciais para a interação com o Amazon EMR no EKS. É possível encontrar a imagem base na [Galeria pública do Amazon ECR](#).
- [Alternância de log do contêiner do Spark](#): a versão 6.11 do Amazon EMR no EKS oferece suporte para a alternância de log do contêiner do Spark. É possível habilitar a funcionalidade com containerLogRotationConfiguration na operação MonitoringConfiguration da API StartJobRun. Você pode configurar rotationSize e maxFilestoKeep para especificar o

número e o tamanho dos arquivos de log que você deseja que o Amazon EMR no EKS mantenha nos pods do driver e do executor do Spark. Para obter mais informações, consulte [Uso da alternância de log do contêiner do Spark](#).

- Suporte ao Volcano no operador do Spark e no spark-submit: a versão 6.11 do Amazon EMR no EKS oferece suporte à execução de trabalhos do Spark com o Volcano como programador personalizado do Kubernetes no [operador do Spark](#) e no [spark-submit](#). É possível usar recursos como o agendamento coletivo, o gerenciamento de filas, a preempção e a programação de compartilhamento equitativo para obter alto throughput de programação e capacidade otimizada. Para obter mais informações, consulte [Uso do Volcano como um programador personalizado para Apache Spark no Amazon EMR no EKS](#).

emr-6.11.0-latest

Notas de versão: a versão `emr-6.11.0-latest` direciona para `emr-20230905`, no momento.

Regiões: `emr-6.11.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.11.0:latest`.

emr-6.11.0-20230905

Notas de versão: `6.11.0-20230905` foi lançada em 29 de setembro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.11.0-20230509` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.11.0:20230509`.

emr-6.11.0-20230509

Notas de versão: `6.11.0-20230509` foi liberada em 9 de maio de 2023. Esta é a versão inicial do Amazon EMR 6.11.0.

Regiões: `emr-6.11.0-20230509` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.11.0:20230509`.

Versões 6.10.0 do Amazon EMR no EKS

As versões 6.10.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.10.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.10.0-latest](#)
- [emr-6.10.0-20230905](#)
- [emr-6.10.0-20230624](#)
- [emr-6.10.0-20230421](#)
- [emr-6.10.0-20230403](#)
- [emr-6.10.0-20230220](#)
- `emr-6.10.0-spark-rapids-latest`
- `emr-6.10.0-spark-rapids-20230624`
- `emr-6.10.0-spark-rapids-20230220`
- `emr-6.10.0-java11-latest`
- `emr-6.10.0-java11-20230624`
- `emr-6.10.0-java11-20230220`
- `notebook-spark/emr-6.10.0-latest`
- `notebook-spark/emr-6.10.0-20230624`
- `notebook-spark/emr-6.10.0-20230220`
- `notebook-python/emr-6.10.0-latest`
- `notebook-python/emr-6.10.0-20230624`
- `notebook-python/emr-6.10.0-20230220`

Notas da versão 6.10.0 do Amazon EMR

- Aplicativos compatíveis - AWS SDK para Java 1.12.397, Spark 3.3.1-amzn-0, Hudi 0.12.2-amzn-0, Iceberg 1.1.0-amzn-0, Delta 2.2.0.
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte:

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Altera os valores no arquivo <code>log4j.properties</code> do Spark.

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>jeg-config</code>	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.
<code>jupyter-kernel-overrides</code>	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

- **Operador do Spark:** com a versão 6.10.0 do Amazon EMR no EKS e versões posteriores, é possível usar o operador do Kubernetes para Apache Spark ou o operador do Spark para implantar e gerenciar aplicações do Spark com o runtime de versão do Amazon EMR em seus próprios clusters do Amazon EKS. Para obter mais informações, consulte [Execução de trabalhos do Spark com o operador do Spark](#).
- **Java 11:** com a versão 6.10 do Amazon EMR no EKS e versões superiores, é possível iniciar o Spark com o runtime do Java 11. Para fazer isso, transmita `emr-6.10.0-java11-latest` como uma etiqueta de versão. Recomendamos que você valide e execute testes de performance antes de mover as workloads de produção da imagem do Java 8 para a imagem do Java 11.
- Para a integração do Amazon Redshift para Apache Spark, a versão 6.10.0 do Amazon EMR no EKS remove a dependência de `minimal-json.jar` e adiciona automaticamente os arquivos em JARs relacionados ao `spark-redshift` obrigatórios ao caminho de classe do executor para o Spark: `spark-redshift.jar`, `spark-avro.jar` e `RedshiftJDBC.jar`.

Alterações

- O confirmador otimizado para EMRFS S3 está habilitado por padrão para Parquet, ORC e formatos baseados em texto (incluindo CSV e JSON).

emr-6.10.0-latest

Notas de versão: a versão `emr-6.10.0-latest` direciona para `emr-6.10.0-20230905`, no momento.

Regiões: `emr-6.10.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.10.0:latest`.

emr-6.10.0-20230905

Notas de versão: 6.10.0-20230905 foi lançada em 29 de setembro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com pacotes do Amazon Linux atualizados recentemente e correções críticas.

Regiões: `emr-6.10.0-20230905` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.10.0:20230905`.

emr-6.10.0-20230624

Notas de versão: 6.10.0-20230624 foi liberada em 7 de julho de 2023. Em comparação com a versão anterior, esta versão foi atualizada com pacotes do Amazon Linux atualizados recentemente e correções críticas.

Regiões: `emr-6.10.0-20230624` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.10.0:20230624`.

emr-6.10.0-20230421

Notas de versão: 6.10.0-20230421 foi liberada em 28 de abril de 2023. Em comparação com a versão anterior, esta versão foi atualizada com pacotes do Amazon Linux atualizados recentemente e correções críticas.

Regiões: `emr-6.10.0-20230421` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.10.0:20230421`.

emr-6.10.0-20230403

Notas de versão: 6.10.0-20230403 foi liberada em 12 de abril de 2023. Em comparação com a versão anterior, esta versão foi atualizada com pacotes do Amazon Linux atualizados recentemente e correções críticas.

Regiões: `emr-6.10.0-20230403` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.10.0:20230403`.

emr-6.10.0-20230220

Notas de versão: `emr-6.10.0-20230220` foi liberada em 20 de fevereiro de 2023. Esta é a versão inicial do Amazon EMR 6.10.0.

Regiões: `emr-6.10.0-20230220` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.10.0:20230220`.

Versões 6.9.0 do Amazon EMR no EKS

As versões 6.9.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.9.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.9.0-latest](#)
- [emr-6.9.0-20230905](#)
- [emr-6.9.0-20230624](#)
- [emr-6.9.0-20221108](#)
- `emr-6.9.0-spark-rapids-latest`
- `emr-6.9.0-spark-rapids-20230624`
- `emr-6.9.0-spark-rapids-20221108`
- `notebook-spark/emr-6.9.0-latest`
- `notebook-spark/emr-6.9.0-20230624`
- `notebook-spark/emr-6.9.0-20221108`
- `notebook-python/emr-6.9.0-latest`
- `notebook-python/emr-6.9.0-20230624`
- `notebook-python/emr-6.9.0-20221108`

Notas da versão 6.9.0 do Amazon EMR

- Aplicativos suportados - AWS SDK para Java 1.12.331, Spark 3.3.0-amzn-1, Hudi 0.12.1-amzn-0, Iceberg 0.14.1-amzn-0, Delta 2.1.0.
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte:

Para uso com [StartJobRun](#) [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Alterar os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Alterar os valores no arquivo <code>log4j.properties</code> do Spark.

Para uso específico com [CreateManagedEndpoint](#) APIs:

Classificações	Descrições
<code>jeg-config</code>	Altera os valores no arquivo <code>jupyter_enterprise_gateway_config.py</code> do Jupyter Enterprise Gateway.

Classificações	Descrições
jupyter-kernel-overrides	Altera o valor da imagem do kernel no arquivo de um kernel do Jupyter especificado.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

- Nvidia RAPIDS Accelerator para Apache Spark - Amazon EMR no EKS para acelerar o Spark usando tipos de instância de unidade de processamento EC2 gráfico (GPU). Para usar a imagem do Spark com o RAPIDS Accelerator, especifique o rótulo de lançamento como `emr-6.9.0- spark-rapids-latest`. Acesse a [página de documentação](#) para saber mais.
- Conector Spark-Redshift: a integração do Amazon Redshift para Apache Spark está inclusa nas versões 6.9.0 e posteriores do Amazon EMR. Anteriormente uma ferramenta de código aberto, a integração nativa é um conector do Spark que você pode usar para criar aplicações do Apache Spark que realizam a leitura e a gravação de dados no Amazon Redshift e no Amazon Redshift sem servidor. Para obter mais informações, consulte [Uso da integração do Amazon Redshift para Apache Spark no Amazon EMR no EKS](#).
- Delta Lake: o [Delta Lake](#) é um formato de armazenamento de código aberto que possibilita o desenvolvimento de data lakes com consistência transacional, definição consistente de conjuntos de dados, alterações de evolução de esquema e suporte a mutações de dados. Acesse [Uso do Delta Lake](#) para saber mais.
- Modificar PySpark parâmetros - Os endpoints interativos agora oferecem suporte à modificação dos parâmetros do Spark associados às PySpark sessões no notebook EMR Studio Jupyter. Visite [Modificação dos parâmetros PySpark da sessão](#) para saber mais.

Problemas resolvidos

- Ao usar o conector DynamoDB com o Spark nas versões 6.6.0, 6.7.0 e 6.8.0 do Amazon EMR, todas as leituras da tabela retornam um resultado vazio, mesmo que a divisão de entrada faça referência a dados que não estão vazios. A versão 6.9.0 do Amazon EMR corrige esse problema.

- A versão 6.8.0 do Amazon EMR no EKS preenche incorretamente o hash de compilação nos metadados dos arquivos em Parquet gerados usando o [Apache Spark](#). Esse problema pode fazer com que as ferramentas que analisam a string de versão de metadados dos arquivos em Parquet gerados pela versão 6.8.0 do Amazon EMR no EKS apresentem falhas.

Problema conhecido

- Se você usar a integração do Amazon Redshift para Apache Spark e tiver um time, timetz, timestamp ou timestampz com precisão de microssegundos no formato Parquet, o conector arredondará os valores de tempo para o valor de milissegundo mais próximo. Como solução alternativa, use o parâmetro `unload_s3_format` do formato de descarregamento de texto.

emr-6.9.0-latest

Notas de versão: a versão `emr-6.9.0-latest` direciona para `emr-6.9.0-20230905`, no momento.

Regiões: `emr-6.9.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.9.0:latest`.

emr-6.9.0-20230905

Notas da versão: `emr-6.9.0-20230905`. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.9.0-20230905` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.9.0:20230905`.

emr-6.9.0-20230624

Notas de versão: `emr-6.9.0-20230624` foi liberada em 7 de julho de 2023.

Regiões: `emr-6.9.0-20230624` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.9.0:20230624`.

emr-6.9.0-20221108

Notas de versão: `emr-6.9.0-20221108` foi liberada em 8 de dezembro de 2022. Esta é a versão inicial do Amazon EMR 6.9.0.

Regiões: `emr-6.9.0-20221108` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.9.0:20221108`.

Versões 6.8.0 do Amazon EMR no EKS

As versões 6.8.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.8.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.8.0-latest](#)
- [emr-6.8.0-20230905](#)
- [emr-6.8.0-20230624](#)
- [emr-6.8.0-20221219](#)
- [emr-6.8.0-20220802](#)

Notas da versão 6.8.0 do Amazon EMR

- Aplicativos suportados - AWS SDK para Java 1.12.170, Spark 3.3.0-amzn-0, Hudi 0.11.1-amzn-0, Iceberg 0.14.0-amzn-0.
- Componentes com suporte: `aws-sagemaker-spark-sdk`, `emr-ddb`, `emr-goodies`, `emr-s3-select`, `emrfs`, `hadoop-client`, `hudi`, `hudi-spark`, `iceberg` e `spark-kubernetes`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.

Classificações	Descrições
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Alterar os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Alterar os valores no arquivo <code>log4j.properties</code> do Spark.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configure Applications](#).

Recursos notáveis

- Spark3.3.0: a versão 6.8 Amazon EMR no EKS inclui o Spark 3.3.0, que oferece suporte ao uso de rótulos seletores de nós separados para pods de executores e de drivers do Spark. Esses novos rótulos permitem que você defina os tipos de nós para os pods de driver e executor separadamente na StartJobRun API, sem usar modelos de pod.
- Propriedade do seletor do nó do driver: `spark.kubernetes.driver.node.selector.[labelKey]`
- Propriedade do seletor do nó do executor: `spark.kubernetes.executor.node.selector.[labelKey]`
- Mensagem aprimorada de falha de trabalho: esta versão apresenta as configurações `spark.stage.extraDetailsOnFetchFailures.enabled` e `spark.stage.extraDetailsOnFetchFailures.maxFailuresToInclude` para rastrear falhas de tarefas devido ao código do usuário. Esses detalhes serão usados para aprimorar a mensagem de falha exibida no log do driver quando um estágio é interrompido devido a uma falha na busca aleatória.

Nome da propriedade	Valor padrão	Significado	Desde a versão
<code>spark.stage.extraDetailsOnFailure.enabled</code>	false	Se definida como true, esta propriedade será usada para aprimorar a mensagem de falha do trabalho exibida no log do driver quando um estágio é interrompido devido a uma falha de busca aleatória. Por padrão, as últimas cinco falhas de tarefas causadas pelo código do usuário são rastreadas e a mensagem de erro de falha é anexada aos logs do driver. Para aumentar o número de falhas de tarefas com exceções de usuário a serem rastreadas, consulte a configuração <code>spark.stage.extraDetailsOnFailure.maxFailuresToInclude</code>.	emr-6.8

Nome da propriedade	Valor padrão	Significado	Desde a versão
<code>spark.stage.extraDetailsOnFetchFailures.maxFailuresToInclude</code>	5	Número de falhas de tarefas a serem rastreadas por estágio e por tentativa. Esta propriedade é usada para aprimorar a mensagem de falha do trabalho com exceções de usuário exibidas no log do driver quando um estágio é interrompido devido a uma falha de busca aleatória. Essa propriedade funciona somente se <code>Config spark.stage.extraDetailsOnFetchFailures.enabled</code> está definido como verdadeiro.	emr-6.8

Para obter mais informações, consulte a [documentação de configuração do Apache Spark](#).

Problema conhecido

- A versão 6.8.0 do Amazon EMR no EKS preenche incorretamente o hash de compilação nos metadados dos arquivos em Parquet gerados usando o [Apache Spark](#). Esse problema pode fazer com que as ferramentas que analisam a string de versão de metadados dos arquivos em Parquet gerados pela versão 6.8.0 do Amazon EMR no EKS apresentem falhas. Os clientes que analisam a string de versão dos metadados do Parquet e dependem do hash de compilação devem realizar a alteração para uma versão diferente do Amazon EMR e reescrever o arquivo.

Problema resolvido

- Funcionalidade de interrupção do kernel para kernels do PySpark: as workloads interativas em andamento que são acionadas pela execução de células em um caderno podem ser interrompidas usando a funcionalidade `Interrupt Kernel`. Uma correção foi introduzida para que esta funcionalidade funcione para kernels do PySpark. Isso também está disponível em código aberto em [Changes para lidar com interrupções no PySpark Kubernetes](#) Kernel #1115.

emr-6.8.0-latest

Notas de versão: a versão `emr-6.8.0-latest` direciona para `emr-6.8.0-20230624`, no momento.

Regiões: `emr-6.8.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.8.0:latest`.

emr-6.8.0-20230905

Notas de versão: `emr-6.8.0-20230905` foi lançada em 29 de setembro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.8.0-20230905` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.8.0:20230905`.

emr-6.8.0-20230624

Notas de versão: `emr-6.8.0-20230624` foi liberada em 7 de julho de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.8.0-20230624` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.8.0:20230624`.

emr-6.8.0-20221219

Notas de versão: `emr-6.8.0-20221219` foi liberada em 19 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.8.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.8.0:20221219`.

emr-6.8.0-20220802

Notas de versão: `emr-6.8.0-20220802` foi liberada em 27 de setembro de 2022. Esta é a versão inicial do Amazon EMR 6.8.0.

Regiões: `emr-6.8.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.8.0:20220802`.

Versões 6.7.0 do Amazon EMR no EKS

As versões 6.7.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.7.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.7.0-latest](#)
- [emr-6.7.0-20240321](#)
- [emr-6.7.0-20230624](#)
- [emr-6.7.0-20221219](#)
- [emr-6.7.0-20220630](#)

Notas da versão 6.7.0 do Amazon EMR

- Aplicações com suporte: Spark 3.2.1-amzn-0, Jupyter Enterprise Gateway 2.6, Hudi 0.11-amzn-0 e Iceberg 0.13.1.

- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Com a atualização para o JEG 2.6, o gerenciamento do kernel passou a ser assíncrono, o que significa que o JEG não bloqueia transações quando a inicialização do kernel está em andamento. Isso melhora muito a experiência do usuário ao fornecer o seguinte:
 - capacidade de executar comandos em cadernos que estão em execução no momento quando outras inicializações de kernel estão em andamento;
 - capacidade de iniciar vários kernels simultaneamente sem afetar os kernels que já estão em execução.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Altera os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Altera os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Altera os valores no arquivo <code>log4j.properties</code> do Spark.

As classificações de configuração permitem que você personalize aplicações. Elas geralmente correspondem a um arquivo XML de configuração da aplicação, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configuração de aplicações](#).

Problemas resolvidos

- A versão 6.7 do Amazon EMR no EKS corrige um problema na versão 6.6 relacionado ao uso da funcionalidade de modelos de pod do Apache Spark com endpoints interativos. O problema estava presente nas versões 6.4, 6.5 e 6.6 do Amazon EMR no EKS. No momento, você pode usar modelos de pod para definir como os pods de driver e de executores do Spark são iniciados ao usar endpoints interativos para executar analytics interativos.
- Nas versões anteriores do Amazon EMR no EKS, o Jupyter Enterprise Gateway bloqueava transações quando a inicialização do kernel estava em andamento, e isso impedia a execução de sessões de caderno que estavam em execução no momento. Agora, é possível executar comandos em cadernos em execução quando outras inicializações de kernel estiverem em andamento. Você também pode iniciar vários kernels simultaneamente sem o risco de perder a conectividade com os kernels que já estão em execução.

emr-6.7.0-latest

Notas de versão: a versão `emr-6.7.0-latest` direciona para `emr-6.7.0-20240321`, no momento.

Regiões: `emr-6.7.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.7.0:latest`.

emr-6.7.0-20240321

Notas de versão: `emr-6.7.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.7.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.7.0:20240321`.

emr-6.7.0-20230624

Notas de versão: `emr-6.7.0-20230624` foi liberada em 7 de julho de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.7.0-20230624` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.7.0:20230624`.

emr-6.7.0-20221219

Notas de versão: `emr-6.7.0-20221219` foi liberada em 19 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.7.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.7.0:20221219`.

emr-6.7.0-20220630

Notas de versão: `emr-6.7.0-20220630` foi liberada em 12 de julho de 2022. Esta é a versão inicial do Amazon EMR 6.7.0.

Regiões: `emr-6.7.0-20220630` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.7.0:20220630`.

Versões 6.6.0 do Amazon EMR no EKS

As versões 6.6.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.6.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.6.0-latest](#)
- [emr-6.6.0-20240321](#)
- [emr-6.6.0-20230624](#)

- [emr-6.6.0-20221219](#)
- [emr-6.6.0-20220411](#)

Notas da versão 6.6.0 do Amazon EMR

- Aplicações com suporte: Spark 3.2.0-amzn-0, Jupyter Enterprise Gateway (endpoints e pré-visualização pública), Hudi 0.10.1-amzn-0 e Iceberg 0.13.1.
- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Alterar os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Alterar os valores no arquivo <code>log4j.properties</code> do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configuração de aplicações](#).

Problema conhecido

- A funcionalidade do modelo de pod do Spark com endpoints interativos não funciona nas versões 6.4, 6.5 e 6.6 do Amazon EMR no EKS.

Problema resolvido

- Os logs de endpoint interativos são carregados no CloudWatch e no S3.

emr-6.6.0-latest

Notas de versão: a versão `emr-6.6.0-latest` direciona para `emr-6.6.0-20240321`, no momento.

Regiões: `emr-6.6.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.6.0:latest`.

emr-6.6.0-20240321

Notas de versão: `emr-6.6.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.6.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.6.0:20240321`.

emr-6.6.0-20230624

Notas de versão: `emr-6.6.0-20230624` foi liberada em 27 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.6.0-20230624` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.6.0:20230624`.

emr-6.6.0-20221219

Notas de versão: `emr-6.6.0-20221219` foi liberada em 27 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.6.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.6.0:20221219`.

emr-6.6.0-20220411

Notas de versão: `emr-6.6.0-20220411` foi liberada em 20 de maio de 2022. Esta é a versão inicial do Amazon EMR 6.6.0.

Regiões: `emr-6.6.0-20220411` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.6.0:20220411`.

Versões 6.5.0 do Amazon EMR no EKS

As versões 6.5.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.5.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.5.0-latest](#)
- [emr-6.5.0-20240321](#)
- [emr-6.5.0-20221219](#)
- [emr-6.5.0-20220802](#)
- [emr-6.5.0-20211119](#)

Notas da versão 6.5.0 do Amazon EMR

- Aplicações com suporte: Spark 3.1.2-amzn-1 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública).
- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.

- Classificações de configuração com suporte:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Alterar os valores no arquivo metrics.properties do Spark.
spark-defaults	Alterar os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Alterar os valores no arquivo log4j.properties do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como spark-hive-site.xml. Para obter mais informações, consulte [Configuração de aplicações](#).

Problema conhecido

- A funcionalidade do modelo de pod do Spark com endpoints interativos não funciona nas versões 6.4 e 6.5 do Amazon EMR no EKS.

emr-6.5.0-latest

Notas de versão: a versão `emr-6.5.0-latest` direciona para `emr-6.5.0-20240321`, no momento.

Regiões: `emr-6.5.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.5.0:latest`.

emr-6.5.0-20240321

Notas de versão: `emr-6.5.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.5.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.5.0:20240321`.

emr-6.5.0-20221219

Notas de versão: `emr-6.5.0-20221219` foi liberada em 19 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.5.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.5.0:20221219`.

emr-6.5.0-20220802

Notas de versão: `emr-6.5.0-20220802` foi liberada em 24 de agosto de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-6.5.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.5.0:20220802`.

emr-6.5.0-20211119

Notas de versão: `emr-6.5.0-20211119` foi liberada em 20 de janeiro de 2022. Esta é a versão inicial do Amazon EMR 6.5.0.

Regiões: `emr-6.5.0-20211119` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.5.0:20211119`.

Versões 6.4.0 do Amazon EMR no EKS

As versões 6.4.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.4.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.4.0-latest](#)
- [emr-6.4.0-20240321](#)
- [emr-6.4.0-20221219](#)
- [emr-6.4.0-20210830](#)

Notas da versão 6.4.0 do Amazon EMR

- Aplicações com suporte: Spark 3.1.2-amzn-0 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública).
- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Alterar os valores no arquivo <code>spark-defaults.conf</code> do Spark.

Classificações	Descrições
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Alterar os valores no arquivo log4j.properties do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como spark-hive-site.xml. Para obter mais informações, consulte [Configuração de aplicações](#).

Problema conhecido

- A funcionalidade do modelo de pod do Spark com endpoints interativos não funciona na versão 6.4 do Amazon EMR no EKS.

emr-6.4.0-latest

Notas de versão: a versão `emr-6.4.0-latest` direciona para `emr-6.4.0-20240321`, no momento.

Regiões: `emr-6.4.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.4.0:latest`.

emr-6.4.0-20240321

Notas de versão: `emr-6.4.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.4.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.4.0:20240321`.

emr-6.4.0-20221219

Notas de versão: `emr-6.4.0-20221219` foi liberada em 27 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux adicionados recentemente.

Regiões: `emr-6.4.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.4.0:20221219`.

emr-6.4.0-20210830

Notas de versão: `emr-6.4.0-20210830` foi liberada em 9 de dezembro de 2021. Esta é a versão inicial do Amazon EMR 6.4.0.

Regiões: `emr-6.4.0-20210830` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.4.0:20210830`.

Versões 6.3.0 do Amazon EMR no EKS

As versões 6.3.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.3.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.3.0-latest](#)
- [emr-6.3.0-20240321](#)
- [emr-6.3.0-20220802](#)
- [emr-6.3.0-20211008](#)
- [emr-6.3.0-20210802](#)
- [emr-6.3.0-20210429](#)

Notas da versão 6.3.0 do Amazon EMR

- Novos recursos: começando com o Amazon EMR 6.3.0 na série de versões 6.x, o Amazon EMR no EKS oferece suporte ao recurso de modelo de pod do Spark. Também é possível ativar o

recurso de alternância de log de eventos do Spark para o Amazon EMR no EKS. Para obter mais informações, consulte [Uso de modelos de pod](#) e [Uso da alternância de log de eventos do Spark](#).

- Aplicações com suporte: Spark 3.1.1-amzn-0 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública).
- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Alterar os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Alterar os valores no arquivo <code>log4j.properties</code> do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configuração de aplicações](#).

emr-6.3.0-latest

Notas de versão: a versão `emr-6.3.0-latest` direciona para `emr-6.3.0-20240321`, no momento.

Regiões: `emr-6.3.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.3.0:latest`.

`emr-6.3.0-20240321`

Notas de versão: `emr-6.3.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.3.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.3.0:20240321`.

`emr-6.3.0-20220802`

Notas de versão: `emr-6.3.0-20220802` foi liberada em 27 de setembro de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-6.3.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.3.0:20220802`.

`emr-6.3.0-20211008`

Notas de versão: `emr-6.3.0-20211008` foi liberada em 9 de dezembro de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-6.3.0-20211008` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.3.0:20211008`.

`emr-6.3.0-20210802`

Notas de versão: `emr-6.3.0-20210802` foi liberada em 2 de agosto de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-6.3.0-20210802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.3.0:20210802`.

`emr-6.3.0-20210429`

Notas de versão: `emr-6.3.0-20210429` foi liberada em 29 de abril de 2021. Esta é a versão inicial do Amazon EMR 6.3.0.

Regiões: `emr-6.3.0-20210429` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.3.0:20210429`.

Versões 6.2.0 do Amazon EMR no EKS

As versões 6.2.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-6.2.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-6.2.0-latest](#)
- [emr-6.2.0-20240321](#)
- [emr-6.2.0-20220802](#)
- [emr-6.2.0-20211008](#)
- [emr-6.2.0-20210802](#)
- [emr-6.2.0-20210615](#)
- [emr-6.2.0-20210129](#)
- [emr-6.2.0-20201218](#)
- [emr-6.2.0-20201201](#)

Notas da versão 6.2.0 do Amazon EMR

- Aplicações com suporte: Spark 3.0.1-amzn-0 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública).

- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Alterar os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Alterar os valores no arquivo <code>log4j.properties</code> do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configuração de aplicações](#).

emr-6.2.0-latest

Notas de versão: a versão `emr-6.2.0-latest` direciona para `emr-6.2.0-20240321`, no momento.

Regiões: `emr-6.2.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.2.0:20240321`.

emr-6.2.0-20240321

Notas de versão: `emr-6.2.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-6.2.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.2.0:20240321`.

emr-6.2.0-20220802

Notas de versão: `emr-6.2.0-20220802` foi liberada em 27 de setembro de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-6.2.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-6.2.0:20220802`.

emr-6.2.0-20211008

Notas de versão: `emr-6.2.0-20211008` foi liberada em 9 de dezembro de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-6.2.0-20211008` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-6.2.0:20211008`.

emr-6.2.0-20210802

Notas de versão: `emr-6.2.0-20210802` foi liberada em 2 de agosto de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-6.2.0-20210802` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-6.2.0:20210802`.

emr-6.2.0-20210615

Notas de versão: `emr-6.2.0-20210615` foi liberada em 15 de junho de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-6.2.0-20210615` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-6.2.0:20210615`.

emr-6.2.0-20210129

Notas de versão: `emr-6.2.0-20210129` foi liberada em 29 de janeiro de 2021. Em comparação com `emr-6.2.0-20201218`, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-6.2.0-20210129` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-6.2.0-20210129`.

emr-6.2.0-20201218

Notas de versão: `emr-6.2.0-20201218` foi liberada em 18 de dezembro de 2020. Em comparação com `emr-6.2.0-20201201`, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-6.2.0-20201218` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-6.2.0-20201218`.

emr-6.2.0-20201201

Notas de versão: `emr-6.2.0-20201201` foi liberada em 1.º de dezembro de 2020. Esta é a versão inicial do Amazon EMR 6.2.0.

Regiões: `emr-6.2.0-20201201` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-6.2.0-20201201`.

Versões 5.36.0 do Amazon EMR no EKS

As versões 5.36.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-5.36.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-5.36.0-latest](#)
- [emr-5.36.0-20240321](#)
- [emr-5.36.0-20221219](#)
- [emr-5.36.0-20220620](#)
- [emr-5.36.0-20220525](#)

Notas da versão 5.36.0 do Amazon EMR

- Os problemas de segurança do log4j2 foram corrigidos.
- Aplicações com suporte: Spark 2.4.8-amzn-2, Jupyter Enterprise Gateway (endpoints e pré-visualização pública; o kernel do Scala não tem suporte), livy-0.7.1 e fluentd-4.0.0.
- Componentes suportados - aws-hm-client, emr-ddb aws-sagemaker-spark-sdk, emr-goodies, emr-kinesis, kerberos-server.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.

Classificações	Descrições
spark-defaults	Alterar os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Alterar os valores no arquivo log4j.properties do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como spark-hive-site.xml. Para obter mais informações, consulte [Configuração de aplicações](#).

emr-5.36.0-latest

Notas de versão: a versão `emr-5.36.0-latest` direciona para `emr-5.36.0-20240321`, no momento.

Regiões: `emr-5.36.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.36.0:latest`.

emr-5.36.0-20240321

Notas de versão: `emr-5.36.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-5.36.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.36.0:20240321`.

emr-5.36.0-20221219

Notas de versão: `emr-5.36.0-20221219` foi liberada em 27 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.36.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.36.0:20221219`.

emr-5.36.0-20220620

Notas de versão: `emr-5.36.0-20220620` foi liberada em 27 de julho de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.36.0-20220620` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.36.0:20220620`.

emr-5.36.0-20220525

Notas de versão: `emr-5.36.0-20220525` foi liberada em 16 de junho de 2022. Esta é a versão inicial do Amazon EMR 5.36.0.

Regiões: `emr-5.36.0-20220525` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.36.0:20220525`.

Versões 5.35.0 do Amazon EMR no EKS

As versões 5.35.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-5.35.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-5.35.0-latest](#)
- [emr-5.35.0-20240321](#)
- [emr-5.35.0-20221219](#)

- [emr-5.35.0-20220802](#)
- [emr-5.35.0-20220307](#)

Notas da versão 5.35.0 do Amazon EMR

- Os problemas de segurança do log4j2 foram corrigidos.
- Aplicações com suporte: Spark 2.4.8-amzn-1, Hudi 0.9.0-amzn-2 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública; o kernel do Scala não tem suporte).
- Componentes suportados - aws-hm-client (conector Glue), emr-s3-select aws-sagemaker-spark-sdk, emrfs, emr-ddb, hudi-spark.
- Classificações de configuração com suporte:

Classificações	Descrições
core-site	Altera os valores no arquivo core-site.xml do Hadoop.
emrfs-site	Alterar as configurações do EMRFS.
spark-metrics	Alterar os valores no arquivo metrics.properties do Spark.
spark-defaults	Alterar os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Alterar os valores no arquivo log4j.properties do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como spark-hive-site.xml. Para obter mais informações, consulte [Configuração de aplicações](#).

emr-5.35.0-latest

Notas de versão: a versão `emr-5.35.0-latest` direciona para `emr-5.35.0-20240321`, no momento.

Regiões: `emr-5.35.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.35.0:latest`.

emr-5.35.0-20240321

Notas de versão: `emr-5.35.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-5.35.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.35.0:20240321`.

emr-5.35.0-20221219

Notas de versão: `emr-5.35.0-20221219` foi liberada em 27 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.35.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.35.0:20221219`.

emr-5.35.0-20220802

Notas de versão: `emr-5.35.0-20220802` foi liberada em 27 de setembro de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.35.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.35.0:20220802`.

emr-5.35.0-20220307

Notas de versão: `emr-5.35.0-20220307` foi liberada em 30 de março de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.35.0-20220307` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.35.0:20220307`.

Versões 5.34.0 do Amazon EMR no EKS

As versões 5.34.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-5.34.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-5.34.0-latest](#)
- [emr-5.34.0-20240321](#)
- [emr-5.34.0-20220802](#)

Notas da versão 5.34.0 do Amazon EMR

- Aplicações com suporte: Spark 2.4.8-amzn-0 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública; o kernel do Scala não tem suporte).
- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.

Classificações	Descrições
spark-metrics	Alterar os valores no arquivo metrics.properties do Spark.
spark-defaults	Alterar os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Alterar os valores no arquivo log4j.properties do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como spark-hive-site.xml. Para obter mais informações, consulte [Configuração de aplicações](#).

emr-5.34.0-latest

Notas de versão: a versão `emr-5.34.0-latest` direciona para `emr-5.34.0-20220802`, no momento.

Regiões: `emr-5.34.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.34.0:latest`.

emr-5.34.0-20240321

Notas de versão: `emr-5.34.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-5.34.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.34.0:20240321`.

emr-5.34.0-20220802

Notas de versão: `emr-5.34.0-20220802` foi liberada em 24 de agosto de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.34.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.34.0:20220802`.

emr-5.34.0-20211208

Notas de versão: `emr-5.34.0-20211208` foi liberada em 20 de janeiro de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.34.0-20211208` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.34.0:20211208`.

Versões 5.33.0 do Amazon EMR no EKS

As versões 5.33.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-5.33.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-5.33.0-latest](#)
- [emr-5.33.0-20240321](#)
- [emr-5.33.0-20221219](#)
- [emr-5.33.0-20220802](#)
- [emr-5.33.0-20211008](#)
- [emr-5.33.0-20210802](#)
- [emr-5.33.0-20210615](#)

- [emr-5.33.0-20210323](#)

Notas da versão 5.33.0 do Amazon EMR

- Novo recurso: começando com o Amazon EMR 5.33.0 na série de versões 5.x, o Amazon EMR no EKS oferece suporte ao recurso de modelo de pod do Spark. Para obter mais informações, consulte [Uso de modelos de pod](#).
- Aplicações com suporte: Spark 2.4.7-amzn-1 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública; o kernel do Scala não tem suporte).
- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.
<code>spark-defaults</code>	Alterar os valores no arquivo <code>spark-defaults.conf</code> do Spark.
<code>spark-env</code>	Alterar os valores no ambiente do Spark.
<code>spark-hive-site</code>	Altera os valores no arquivo <code>hive-site.xml</code> do Spark.
<code>spark-log4j</code>	Alterar os valores no arquivo <code>log4j.properties</code> do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como `spark-hive-site.xml`. Para obter mais informações, consulte [Configuração de aplicações](#).

emr-5.33.0-latest

Notas de versão: a versão `emr-5.33.0-latest` direciona para `emr-5.33.0-20240321`, no momento.

Regiões: `emr-5.33.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0:latest`.

emr-5.33.0-20240321

Notas de versão: `emr-5.33.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-5.33.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0:20240321`.

emr-5.33.0-20221219

Notas de versão: `emr-5.33.0-20221219` foi liberada em 19 de janeiro de 2023. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-5.33.0-20221219` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0:20221219`.

emr-5.33.0-20220802

Notas de versão: `emr-5.33.0-20220802` foi liberada em 24 de agosto de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.33.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0:20220802`.

emr-5.33.0-20211008

Notas de versão: `emr-5.33.0-20211008` foi liberada em 9 de dezembro de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.33.0-20211008` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0:20211008`.

emr-5.33.0-20210802

Notas de versão: `emr-5.33.0-20210802` foi liberada em 2 de agosto de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.33.0-20210802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0:20210802`.

emr-5.33.0-20210615

Notas de versão: `emr-5.33.0-20210615` foi liberada em 15 de junho de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.33.0-20210615` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0:20210615`.

emr-5.33.0-20210323

Notas de versão: `emr-5.33.0-20210323` foi liberada em 23 de março de 2021. Esta é a versão inicial do Amazon EMR 5.33.0.

Regiões: `emr-5.33.0-20210323` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.33.0-20210323`.

Versões 5.32.0 do Amazon EMR no EKS

As versões 5.32.0 do Amazon EMR apresentadas a seguir estão disponíveis para o Amazon EMR no EKS. Selecione uma versão específica do `emr-5.32.0-XXXX` para visualizar mais detalhes, como a etiqueta de imagem do contêiner relacionada.

- [emr-5.32.0-latest](#)
- [emr-5.32.0-20240321](#)
- [emr-5.32.0-20220802](#)
- [emr-5.32.0-20211008](#)
- [emr-5.32.0-20210802](#)
- [emr-5.32.0-20210615](#)
- [emr-5.32.0-20210129](#)
- [emr-5.32.0-20201218](#)
- [emr-5.32.0-20201201](#)

Notas da versão 5.32.0 do Amazon EMR

- Aplicações com suporte: Spark 2.4.7-amzn-0 e Jupyter Enterprise Gateway (endpoints e pré-visualização pública; o kernel do Scala não é compatível).
- Componentes com suporte: `aws-hm-client` (conector do Glue), `aws-sagemaker-spark-sdk`, `emr-s3-select`, `emrfs`, `emr-ddb` e `hudi-spark`.
- Classificações de configuração com suporte:

Classificações	Descrições
<code>core-site</code>	Altera os valores no arquivo <code>core-site.xml</code> do Hadoop.
<code>emrfs-site</code>	Alterar as configurações do EMRFS.
<code>spark-metrics</code>	Alterar os valores no arquivo <code>metrics.properties</code> do Spark.

Classificações	Descrições
spark-defaults	Alterar os valores no arquivo spark-defaults.conf do Spark.
spark-env	Alterar os valores no ambiente do Spark.
spark-hive-site	Altera os valores no arquivo hive-site.xml do Spark.
spark-log4j	Alterar os valores no arquivo log4j.properties do Spark.

As classificações de configuração permitem que você personalize aplicações. Eles geralmente correspondem a um arquivo XML de configuração do aplicativo, como spark-hive-site.xml. Para obter mais informações, consulte [Configuração de aplicações](#).

emr-5.32.0-latest

Notas de versão: a versão `emr-5.32.0-latest` direciona para `emr-5.32.0-20240321`, no momento.

Regiões: `emr-5.32.0-latest` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.32.0:latest`.

emr-5.32.0-20240321

Notas de versão: `emr-5.32.0-20240321` foi lançada em 11 de março de 2024. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente e com as correções críticas.

Regiões: `emr-5.32.0-20240321` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.32.0:20240321`.

emr-5.32.0-20220802

Notas de versão: `emr-5.32.0-20220802` foi liberada em 24 de agosto de 2022. Em comparação com a versão anterior, esta versão foi atualizada com os pacotes do Amazon Linux atualizados recentemente.

Regiões: `emr-5.32.0-20220802` está disponível em todas as regiões com suporte do Amazon EMR no EKS. Para obter mais informações, consulte [Endpoints de serviço do Amazon EMR no EKS](#).

Etiqueta da imagem do contêiner: `emr-5.32.0:20220802`.

emr-5.32.0-20211008

Notas de versão: `emr-5.32.0-20211008` foi liberada em 9 de dezembro de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.32.0-20211008` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-5.32.0:20211008`.

emr-5.32.0-20210802

Notas de versão: `emr-5.32.0-20210802` foi liberada em 2 de agosto de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.32.0-20210802` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-5.32.0:20210802`.

emr-5.32.0-20210615

Notas de versão: `emr-5.32.0-20210615` foi liberada em 15 de junho de 2021. Em comparação com a versão anterior, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.32.0-20210615` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-5.32.0:20210615`.

emr-5.32.0-20210129

Notas de versão: `emr-5.32.0-20210129` foi liberada em 29 de janeiro de 2021. Em comparação com `emr-5.32.0-20201218`, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.32.0-20210129` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-5.32.0-20210129`.

emr-5.32.0-20201218

Notas de versão: `5.32.0-20201218` foi liberada em 18 de dezembro de 2020. Em comparação com `5.32.0-20201201`, esta versão contém correções de problemas e atualizações de segurança.

Regiões: `emr-5.32.0-20201218` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-5.32.0-20201218`.

emr-5.32.0-20201201

Notas de versão: `5.32.0-20201201` foi liberada em 1.º de dezembro de 2020. Esta é a versão inicial do Amazon EMR 5.32.0.

Regiões: `5.32.0-20201201` está disponível nas seguintes regiões: Leste dos EUA (Norte da Virgínia), Oeste dos EUA (Oregon), Ásia-Pacífico (Tóquio), Europa (Irlanda) e América do Sul (São Paulo).

Etiqueta da imagem do contêiner: `emr-5.32.0-20201201`.

Histórico do documento

A tabela a seguir descreve as alterações importantes na documentação desde a última versão do Amazon EMR no EKS. Para obter mais informações sobre as atualizações desta documentação, você pode se tornar assinante de um feed RSS.

Alteração	Descrição	Data
Informações sobre a versão do EMR 7.12.0 adicionadas	Foram adicionadas informações de versão do EMR 7.12.0 com visualizações materializadas do Iceberg e acesso completo à tabela do Hudi	Novembro de 2025
Informações sobre a versão do EMR 7.11.0 adicionadas	Informações de versão do EMR 7.11.0 adicionadas com integração com o Unified Studio SageMaker	Novembro de 2025
Atualização de conteúdo	Políticas gerenciadas para o Amazon EMR no EKS – Permissões adicionais para AmazonEMRContainersServiceRolePolicy	3 de fevereiro de 2025
Nova versão	Amazon EMR nas versões do EKS 7.6.0	10 de janeiro de 2025
Nova versão	Amazon EMR nas versões do EKS 7.5.0	21 de novembro de 2024
Nova versão	Amazon EMR nas versões do EKS 7.4.0	13 de novembro de 2024
Nova versão	Versões 7.3.0 do Amazon EMR no EKS	16 de outubro de 2024
Nova versão	Versões 7.2.0 do Amazon EMR no EKS	25 de julho de 2024
Nova versão	Versões 7.1.0 do Amazon EMR no EKS	17 de abril de 2024
Nova versão	Versões 7.0.0 do Amazon EMR no EKS	22 de dezembro de 2023

Alteração	Descrição	Data
Nova versão	Versões 6.15.0 do Amazon EMR no EKS	17 de novembro de 2023
Nova versão	Versões 6.14.0 do Amazon EMR no EKS	17 de outubro de 2023
Atualização de conteúdo	Renomeação de “endpoints gerenciados” para endpoints interativos . Os endpoints interativos estão com disponibilidade geral .	29 de setembro de 2023
Nova versão	Versões 6.13.0 do Amazon EMR no EKS e documentos de pré-visualização pública para Execução de trabalhos do Flink com o Amazon EMR no EKS .	12 de setembro de 2023
Nova versão	Versões 6.12.0 do Amazon EMR no EKS	21 de julho de 2023
Novo conteúdo	Uso do Volcano como um programador personalizado para Apache Spark no Amazon EMR no EKS adicionado	13 de junho de 2023
Novo conteúdo	Uso do Volcano como um programador personalizado para Apache Spark no Amazon EMR no EKS adicionado	13 de junho de 2023
Novo conteúdo	Uso da alternância de log do contêiner do Spark adicionado	12 de junho de 2023
Atualização de conteúdo	Atualização da documentação de imagens personalizadas para a descoberta de informações sobre as imagens base na galeria pública do Amazon ECR.	8 de junho de 2023

Alteração	Descrição	Data
Nova versão	Versões 6.11.0 do Amazon EMR no EKS	8 de junho de 2023
Novo conteúdo	Adição de Execução de trabalhos do Spark com o operador do Spark e reorganização das seções de execuções de trabalhos em Execução de trabalhos do Spark com o Amazon EMR no EKS .	5 de junho de 2023
Novo conteúdo	Adição de duas seções: Uso da escalabilidade automática vertical com trabalhos do Spark no Amazon EMR e Uso de cadernos Jupyter de hospedagem própria .	4 de maio de 2023
Página para o histórico de documentos	Criação de uma página para o histórico de documentos para o Amazon EMR no EKS.	13 de março de 2023
Página para as políticas gerenciadas	Criação de uma página para as políticas gerenciadas para o Amazon EMR no EKS.	13 de março de 2023

As traduções são geradas por tradução automática. Em caso de conflito entre o conteúdo da tradução e da versão original em inglês, a versão em inglês prevalecerá.