



Panduan Pengguna

Application Auto Scaling



Application Auto Scaling: Panduan Pengguna

Copyright © 2024 Amazon Web Services, Inc. and/or its affiliates. All rights reserved.

Merek dagang dan tampilan dagang Amazon tidak boleh digunakan sehubungan dengan produk atau layanan apa pun yang bukan milik Amazon, dengan cara apa pun yang dapat menyebabkan kebingungan antara para pelanggan, atau dengan cara apa pun yang menghina atau mendiskreditkan Amazon. Semua merek dagang lain yang tidak dimiliki oleh Amazon merupakan kekayaan masing-masing pemiliknya, yang mungkin atau mungkin tidak berafiliasi, terkait dengan, atau disponsori oleh Amazon.

Table of Contents

Apa yang dimaksud dengan Application Auto Scaling?	1
Fitur Application Auto Scaling	2
Bekerja dengan Application Auto Scaling	2
Konsep	3
Pelajari selengkapnya	5
Layanan yang terintegrasi	6
Amazon AppStream 2.0	8
Peran terkait layanan	9
Pemimpin layanan	9
Mendaftarkan AppStream 2.0 armada sebagai target yang dapat diskalakan dengan Application Auto Scaling	9
Sumber daya terkait	10
Amazon Aurora	10
Peran terkait layanan	10
Pemimpin layanan	11
Mendaftarkan cluster Aurora DB sebagai target yang dapat diskalakan dengan Application Auto Scaling	11
Sumber daya terkait	12
Amazon Comprehend	12
Peran terkait layanan	12
Pemimpin layanan	13
Mendaftarkan Amazon Comprehend resource sebagai target yang dapat diskalakan dengan Application Auto Scaling	13
Sumber daya terkait	14
Amazon DynamoDB	15
Peran terkait layanan	15
Pemimpin layanan	15
Mendaftarkan sumber daya DynamoDB sebagai target yang dapat diskalakan dengan Application Auto Scaling	15
Sumber daya terkait	18
Amazon ECS	18
Peran terkait layanan	18
Pemimpin layanan	19

Mendaftarkan layanan ECS sebagai target yang dapat diskalakan dengan Application Auto Scaling	19
Sumber daya terkait	20
Amazon ElastiCache	20
Peran terkait layanan	21
Pemimpin layanan	21
Mendaftarkan grup replikasi ElastiCache (RedisOSS) sebagai target yang dapat diskalakan dengan Application Auto Scaling	21
Sumber daya terkait	23
Amazon Keyspaces (untuk Apache Cassandra)	23
Peran terkait layanan	23
Pemimpin layanan	23
Mendaftarkan tabel Amazon Keyspaces sebagai target yang dapat diskalakan dengan Application Auto Scaling	24
Sumber daya terkait	25
AWS Lambda	25
Peran terkait layanan	25
Pemimpin layanan	26
Mendaftarkan fungsi Lambda sebagai target yang dapat diskalakan dengan Application Auto Scaling	26
Sumber daya terkait	27
Arus yang Dikelola Amazon untuk Apache Kafka (MSK)	27
Peran terkait layanan	27
Pemimpin layanan	28
Mendaftarkan penyimpanan cluster MSK Amazon sebagai target yang dapat diskalakan dengan Application Auto Scaling	28
Sumber daya terkait	29
Amazon Neptune	29
Peran terkait layanan	29
Pemimpin layanan	30
Mendaftarkan cluster Neptunus sebagai target yang dapat diskalakan dengan Application Auto Scaling	30
Sumber daya terkait	31
Amazon SageMaker	31
Peran terkait layanan	31
Pemimpin layanan	32

Mendaftarkan varian SageMaker endpoint sebagai target yang dapat diskalakan dengan Application Auto Scaling	32
Mendaftarkan konkurensi titik akhir tanpa server yang disediakan sebagai target yang dapat diskalakan dengan Application Auto Scaling	33
Mendaftarkan komponen inferensi sebagai target yang dapat diskalakan dengan Application Auto Scaling	34
Sumber daya terkait	35
Armada Spot (Amazon EC2)	35
Peran terkait layanan	36
Pemimpin layanan	36
Mendaftarkan Armada Spot sebagai target yang dapat diskalakan dengan Application Auto Scaling	36
Sumber daya terkait	37
Amazon WorkSpaces	37
Peran terkait layanan	37
Pemimpin layanan	38
Mendaftarkan WorkSpaces pool sebagai target yang dapat diskalakan dengan Application Auto Scaling	38
Sumber daya khusus	39
Peran terkait layanan	39
Pemimpin layanan	39
Mendaftarkan sumber daya kustom sebagai target yang dapat diskalakan dengan Application Auto Scaling	40
Sumber daya terkait	41
Konfigurasikan penskalaan menggunakan AWS CloudFormation	42
Application Auto Scaling dan template AWS CloudFormation	42
Contoh cuplikan template	43
Pelajari lebih lanjut tentang AWS CloudFormation	43
Penskalaan terjadwal	44
Cara kerja penskalaan terjadwal	45
Cara kerjanya	45
Pertimbangan	45
Perintah yang umum digunakan	46
Sumber daya terkait	47
Batasan	47
Buat tindakan terjadwal	48

Buat tindakan terjadwal yang hanya terjadi sekali	48
Buat tindakan terjadwal yang berjalan pada interval berulang	50
Buat tindakan terjadwal yang berjalan pada jadwal berulang	51
Buat tindakan terjadwal satu kali yang menentukan zona waktu	51
Buat tindakan terjadwal berulang yang menentukan zona waktu	52
Jelaskan penskalaan terjadwal	53
Jelaskan aktivitas penskalaan untuk layanan	53
Jelaskan tindakan terjadwal untuk suatu layanan	55
Jelaskan tindakan terjadwal untuk target yang dapat diskalakan	57
Jadwalkan tindakan penskalaan berulang	58
Matikan penskalaan terjadwal	61
Hapus tindakan terjadwal	62
Kebijakan penskalaan pelacakan target	64
Cara kerja pelacakan target	65
Cara kerjanya	66
Pilih metrik	67
Tentukan nilai target	68
Tentukan periode cooldown	68
Pertimbangan	70
Beberapa kebijakan penskalaan	71
Perintah yang umum digunakan	72
Sumber daya terkait	72
Batasan	72
Buat kebijakan penskalaan pelacakan target	73
Langkah 1: Daftarkan target yang dapat diskalakan	73
Langkah 2: Buat kebijakan penskalaan pelacakan target	74
Langkah 3: Jelaskan kebijakan penskalaan pelacakan target	76
Hapus kebijakan penskalaan pelacakan target	78
Gunakan matematika metrik	79
Contoh: backlog antrian Amazon SQS per tugas	79
Batasan	84
Kebijakan penskalaan bertahap	85
Cara kerja penskalaan langkah	86
Cara kerjanya	87
Penyesuaian langkah	87
Jenis penyesuaian penskalaan	90

Periode pendinginan	91
Perintah yang umum digunakan	92
Pertimbangan	92
Sumber daya terkait	47
Akses konsol	93
Membuat kebijakan penskalaan langkah	93
Langkah 1: Daftarkan target yang dapat diskalakan	93
Langkah 2: Buat kebijakan penskalaan langkah	94
Langkah 3: Buat alarm yang memanggil kebijakan penskalaan	98
Mendeskripsikan kebijakan penskalaan langkah	99
Menghapus kebijakan penskalaan langkah	101
Tutorial: Konfigurasikan penskalaan otomatis untuk menangani beban kerja yang berat	102
Prasyarat	102
Langkah 1: Daftarkan target yang dapat diskalakan	103
Langkah 2: Siapkan tindakan terjadwal sesuai dengan kebutuhan Anda	104
Langkah 3: Tambahkan kebijakan penskalaan pelacakan target	108
Langkah 4: Langkah selanjutnya	110
Langkah 5: Bersihkan	111
Tangguhkan penskalaan	113
Aktivitas penskalaan	113
Menangguhkan dan melanjutkan aktivitas penskalaan	114
Melihat aktivitas penskalaan yang ditangguhkan	117
Melanjutkan aktivitas penskalaan	118
Aktivitas penskalaan	119
Cari aktivitas penskalaan berdasarkan target yang dapat diskalakan	119
Sertakan aktivitas yang tidak diskalakan	120
Kode alasan	122
Pemantauan	125
Monitor menggunakan CloudWatch	126
CloudWatch metrik untuk memantau penggunaan sumber daya	127
Metrik yang telah ditentukan sebelumnya untuk kebijakan penskalaan pelacakan target	138
AWS CloudTrail	141
Informasi Application Auto Scaling di CloudTrail	141
Memahami entri file log Application Auto Scaling	142
Sumber daya terkait	143

Amazon EventBridge	144
Peristiwa Application Auto Scaling	144
Dukungan penandaan	149
Contoh penandaan	149
Tag untuk keamanan	150
Kontrol akses ke tag	151
Keamanan	153
Perlindungan data	154
Identity and Access Management	155
Kontrol akses	155
Bagaimana Application Auto Scaling bekerja dengan IAM	156
AWS kebijakan terkelola	162
Peran terkait layanan	172
Contoh kebijakan berbasis identitas	178
Pemecahan Masalah	190
Validasi izin	191
AWS PrivateLink	193
Buat titik VPC akhir antarmuka	194
Buat kebijakan VPC endpoint	194
Ketangguhan	195
Keamanan infrastruktur	195
Validasi kepatuhan	196
Kuota	198
Riwayat dokumen	200
.....	ccxi

Apa yang dimaksud dengan Application Auto Scaling?

Application Auto Scaling adalah layanan web untuk pengembang dan administrator sistem yang membutuhkan solusi untuk secara otomatis menskalakan sumber daya mereka yang dapat diskalakan untuk layanan individual di luar Amazon. AWS EC2 Dengan Application Auto Scaling, Anda dapat mengonfigurasi penskalaan otomatis untuk sumber daya berikut: : AWS

- AppStream 2.0 armada
- Replika Aurora
- Klasifikasi dokumen dan titik akhir pengenal entitas Amazon Comprehend
- Tabel DynamoDB dan indeks sekunder global
- ECSLayanan Amazon
- ElastiCache (RedisOSS) cluster (grup replikasi)
- EMRCluster Amazon
- Tabel Amazon Keyspaces (untuk Apache Cassandra)
- Konkurensi terprovisi fungsi Lambda
- Amazon Managed Streaming untuk Apache Kafka MSK () penyimpanan broker
- Cluster Amazon Neptunus
- SageMaker varian titik akhir
- SageMaker komponen inferensi
- SageMaker Konkurensi yang disediakan tanpa server
- Permintaan Armada Spot
- Kolam Amazon WorkSpaces
- Sumber daya kustom yang disediakan oleh aplikasi atau layanan Anda sendiri. Untuk informasi selengkapnya, lihat [GitHubrepositori](#).

Untuk melihat ketersediaan regional untuk salah satu AWS layanan yang tercantum di atas, lihat [tabel Wilayah tabel](#) .

Untuk informasi tentang penskalaan armada EC2 instans Amazon menggunakan grup Auto Scaling, lihat Panduan Pengguna [Auto EC2 Scaling](#) Amazon.

Fitur Application Auto Scaling

Application Auto Scaling memungkinkan Anda untuk secara otomatis memperbesar skala sumber daya Anda sesuai dengan kondisi yang Anda tentukan.

- Penskalaan pelacakan target — Skala sumber daya berdasarkan nilai target untuk CloudWatch metrik tertentu.
- Penskalaan langkah — Skala sumber daya berdasarkan serangkaian penyesuaian penskalaan yang bervariasi berdasarkan ukuran pelanggaran alarm.
- Penskalaan terjadwal — Skala sumber daya hanya satu kali atau pada jadwal berulang.

Bekerja dengan Application Auto Scaling

Anda dapat mengonfigurasi penskalaan menggunakan antarmuka berikut tergantung pada sumber daya yang Anda skalakan:

- AWS Management Console— Menyediakan antarmuka web yang dapat Anda gunakan untuk mengkonfigurasi penskalaan. Jika Anda telah mendaftar untuk sebuah AWS akun, akses Application Auto Scaling dengan masuk ke akun. AWS Management Console Kemudian, buka konsol layanan untuk salah satu sumber daya yang tercantum dalam pendahuluan. Pastikan Anda membuka konsol Wilayah AWS sama dengan sumber daya yang ingin Anda gunakan.

 Note

Akses konsol tidak tersedia untuk semua sumber daya. Untuk informasi selengkapnya, lihat [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

- AWS Command Line Interface (AWS CLI) - Menyediakan perintah untuk serangkaian luas Layanan AWS, dan didukung pada Windows, macOS, dan Linux. Untuk memulai, lihat [AWS Command Line Interface](#). Untuk daftar perintah, lihat [application-autoscaling](#) di Command Reference.AWS CLI
- AWS Tools for Windows PowerShell— Menyediakan perintah untuk serangkaian AWS produk yang luas bagi mereka yang membuat skrip di PowerShell lingkungan. Untuk memulai, lihat [AWS Tools for Windows PowerShell Panduan Pengguna](#). Untuk informasi lebih lanjut, lihat [AWS Tools for PowerShell Referensi Cmdlet](#).

- AWS SDKs—Menyediakan API operasi khusus bahasa dan menangani banyak detail koneksi, seperti menghitung tanda tangan, menangani percobaan ulang permintaan, dan menangani kesalahan. Untuk informasi selengkapnya, lihat [Alat untuk Dibangun AWS](#).
- HTTPS API— Menyediakan API tindakan tingkat rendah yang Anda panggil menggunakan HTTPS permintaan. Untuk informasi selengkapnya, lihat Referensi [Application Auto Scaling API](#)
- AWS CloudFormation— Mendukung konfigurasi penskalaan menggunakan template. CloudFormation Untuk informasi selengkapnya, lihat [Konfigurasikan sumber daya Application Auto Scaling menggunakan AWS CloudFormation](#).

Untuk terhubung secara terprogram ke sebuah Layanan AWS, Anda menggunakan endpoint. .

Konsep Application Auto Scaling

Topik ini menjelaskan konsep-konsep kunci untuk membantu Anda mempelajari Application Auto Scaling dan mulai menggunakannya.

Target yang dapat diskalakan

Entitas yang Anda buat untuk menentukan sumber daya yang ingin Anda skalakan. Setiap target yang dapat diskalakan diidentifikasi secara unik oleh namespace layanan, ID sumber daya, dan dimensi yang dapat diskalakan, yang mewakili beberapa dimensi kapasitas layanan yang mendasarinya. Misalnya, layanan Amazon ECS mendukung penskalaan otomatis jumlah tugasnya, tabel DynamoDB mendukung penskalaan otomatis kapasitas baca dan tulis tabel dan indeks sekunder globalnya, dan klaster Aurora mendukung penskalaan jumlah replika.

Tip

Setiap target yang dapat diskalakan juga memiliki kapasitas minimum dan maksimum. Kebijakan penskalaan tidak akan pernah lebih tinggi atau lebih rendah dari kisaran minimum-maksimum. Anda dapat membuat out-of-band perubahan langsung ke sumber daya dasar yang berada di luar rentang ini, yang tidak diketahui Application Auto Scaling. Namun, kapan saja kebijakan penskalaan dipanggil atau `RegisterScalableTarget` API dipanggil, Application Auto Scaling mengambil kapasitas saat ini dan membandingkannya dengan kapasitas minimum dan maksimum. Jika berada di luar kisaran minimum-maksimum, maka kapasitas diperbarui untuk memenuhi minimum dan maksimum yang ditetapkan.

Penurunan skala

Ketika Application Auto Scaling secara otomatis mengurangi kapasitas untuk target yang dapat diskalakan, target yang dapat diskalakan akan masuk. Ketika kebijakan penskalaan ditetapkan, mereka tidak dapat menskalakan target yang dapat diskalakan lebih rendah dari kapasitas minimumnya.

Menskalakan ke luar

Ketika Application Auto Scaling secara otomatis meningkatkan kapasitas untuk target yang dapat diskalakan, target yang dapat diskalakan akan keluar. Ketika kebijakan penskalaan ditetapkan, mereka tidak dapat mengukur target yang dapat diskalakan lebih tinggi dari kapasitas maksimumnya.

Kebijakan penskalaan

Kebijakan penskalaan menginstruksikan Application Auto Scaling untuk melacak metrik tertentu. CloudWatch Kemudian, ini menentukan tindakan penskalaan apa yang harus diambil ketika metrik lebih tinggi atau lebih rendah dari nilai ambang tertentu. Misalnya, Anda mungkin ingin memperkecil skala jika penggunaan CPU di seluruh klaster Anda mulai meningkat, dan menskalakan saat CPU turun lagi.

Metrik yang digunakan untuk penskalaan otomatis diterbitkan oleh layanan target, tetapi Anda juga dapat mempublikasikan metrik Anda sendiri CloudWatch dan kemudian menggunakannya dengan kebijakan penskalaan.

Periode cooldown antara aktivitas penskalaan memungkinkan sumber daya stabil sebelum aktivitas penskalaan lainnya dimulai. Application Auto Scaling terus mengevaluasi metrik selama periode cooldown. Ketika periode cooldown berakhir, kebijakan penskalaan memulai aktivitas penskalaan lain jika diperlukan. Sementara periode cooldown berlaku, jika skala yang lebih besar diperlukan berdasarkan nilai metrik saat ini, kebijakan penskalaan segera keluar.

Tindakan terjadwal

Tindakan terjadwal secara otomatis menskalakan sumber daya pada tanggal dan waktu tertentu. Mereka bekerja dengan memodifikasi kapasitas minimum dan maksimum untuk target yang dapat diskalakan, dan oleh karena itu dapat digunakan untuk skala masuk dan keluar sesuai jadwal dengan menetapkan kapasitas minimum tinggi atau kapasitas maksimum rendah. Misalnya, Anda dapat menggunakan tindakan terjadwal untuk menskalakan aplikasi yang tidak mengkonsumsi sumber daya pada akhir pekan dengan mengurangi kapasitas pada hari Jumat dan meningkatkan kapasitas pada hari Senin berikutnya.

Anda juga dapat menggunakan tindakan terjadwal untuk mengoptimalkan nilai minimum dan maksimum dari waktu ke waktu untuk beradaptasi dengan situasi di mana lalu lintas yang lebih tinggi dari normal diharapkan, misalnya, kampanye pemasaran atau fluktuasi musiman. Melakukan hal ini dapat membantu Anda meningkatkan kinerja untuk saat-saat ketika Anda perlu skala lebih tinggi untuk peningkatan penggunaan, dan mengurangi biaya pada saat Anda menggunakan lebih sedikit sumber daya.

Pelajari selengkapnya

[Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#)— Bagian ini memperkenalkan Anda pada layanan yang dapat Anda skalakan dan membantu Anda mengatur penskalaan otomatis dengan mendaftarkan target yang dapat diskalakan. Ini juga menjelaskan setiap peran terkait layanan IAM yang dibuat Application Auto Scaling untuk mengakses sumber daya dalam layanan target.

[Kebijakan penskalaan pelacakan target untuk Application Auto Scaling](#)- Salah satu fitur utama Application Auto Scaling adalah kebijakan penskalaan pelacakan target. Pelajari cara kebijakan pelacakan target secara otomatis menyesuaikan kapasitas yang diinginkan untuk menjaga pemanfaatan pada tingkat konstan berdasarkan metrik dan nilai target yang dikonfigurasi. Misalnya, Anda dapat mengonfigurasi pelacakan target untuk menjaga penggunaan CPU rata-rata untuk Armada Spot Anda sebesar 50 persen. Application Auto Scaling kemudian meluncurkan atau menghentikan instans EC2 sesuai kebutuhan untuk menjaga pemanfaatan CPU agregat di semua server sebesar 50 persen.

Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling

Application Auto Scaling terintegrasi dengan AWS layanan lain sehingga Anda dapat menambahkan kemampuan penskalaan untuk memenuhi permintaan aplikasi Anda. Penskalaan otomatis adalah fitur opsional dari layanan yang dinonaktifkan secara default di hampir semua kasus.

Tabel berikut mencantumkan AWS layanan yang dapat Anda gunakan dengan Application Auto Scaling, termasuk informasi tentang metode yang didukung untuk mengonfigurasi penskalaan otomatis. Anda juga dapat menggunakan Application Auto Scaling dengan sumber daya khusus.

- Akses konsol — Anda dapat mengonfigurasi AWS layanan yang kompatibel untuk memulai penskalaan otomatis dengan mengonfigurasi kebijakan penskalaan di konsol layanan target.
- Akses CLI - Anda dapat mengonfigurasi AWS layanan yang kompatibel untuk memulai penskalaan otomatis menggunakan AWS CLI
- Akses SDK — Anda dapat mengonfigurasi AWS layanan yang kompatibel untuk memulai penskalaan otomatis menggunakan SDK AWS
- CloudFormation akses - Anda dapat mengonfigurasi AWS layanan yang kompatibel untuk memulai penskalaan otomatis menggunakan template AWS CloudFormation tumpukan. Untuk informasi selengkapnya, lihat [Konfigurasikan sumber daya Application Auto Scaling menggunakan AWS CloudFormation](#).

AWS layanan	Akses konsol ¹	Akses CLI	Akses SDK	CloudFormation akses
AppStream 2.0	Ya	Ya	Ya	Ya
Aurora	Ya	Ya	Ya	Ya

AWS layanan	Akses konsol ¹	Akses CLI	Akses SDK	CloudFormation akses
Amazon Comprehend	Tida			
Amazon DynamoDB				
Amazon ECS				
Amazon ElastiCache				
Amazon EMR				
Amazon Keyspaces				
Lambda	Tida			
Amazon MSK				

AWS layanan	Akses konsol ¹	Akses CLI	Akses SDK	CloudFormation akses
Amazon Neptunus	Tida	Ya	Ya	Ya
SageMaker	Ya	Ya	Ya	Ya
Armada Spot	Ya	Ya	Ya	Ya
WorkSpaces	Ya	Ya	Ya	Ya
Sumber daya khusus	Tida	Ya	Ya	Ya

¹ Akses konsol untuk mengonfigurasi kebijakan penskalaan. Sebagian besar layanan tidak mendukung konfigurasi penskalaan terjadwal dari konsol. Saat ini, hanya Amazon AppStream 2.0, ElastiCache, dan Spot Fleet yang menyediakan akses konsol untuk penskalaan terjadwal.

Amazon AppStream 2.0 dan Application Auto Scaling

Anda dapat menskalakan armada AppStream 2.0 menggunakan kebijakan penskalaan pelacak target, kebijakan penskalaan langkah, dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan AppStream 2.0 dengan Application Auto Scaling.

Peran terkait layanan dibuat untuk 2.0 AppStream

Peran terkait layanan berikut dibuat secara otomatis di dalam Akun AWS saat mendaftarkan sumber daya AppStream 2.0 sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- `AWSServiceRoleForApplicationAutoScaling_AppStreamFleet`

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- `appstream.application-autoscaling.amazonaws.com`

Mendaftarkan AppStream 2.0 armada sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk armada 2.0. AppStream Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengkonfigurasi penskalaan otomatis menggunakan konsol AppStream 2.0, maka AppStream 2.0 secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengkonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk armada AppStream 2.0. Contoh berikut mencatat kapasitas yang diinginkan dari armada yang disebut `sample-fleet`, dengan kapasitas minimum satu instance armada dan kapasitas maksimum lima instance armada.

```
aws application-autoscaling register-scalable-target \
--service-namespace appstream \
--scalable-dimension appstream:fleet:DesiredCapacity \
--resource-id fleet/sample-fleet \
--min-capacity 1 \
--max-capacity 5
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya AppStream 2.0 Anda dalam dokumentasi berikut:

[Auto Scaling Armada untuk AppStream 2.0](#) di Panduan Administrasi Amazon AppStream 2.0

Amazon Aurora dan Application Auto Scaling

Anda dapat menskalakan klaster DB Aurora menggunakan kebijakan penskalaan pelacakan target, kebijakan penskalaan langkah, dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Aurora dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk Aurora

[Peran terkait layanan](#) berikut dibuat secara otomatis di Akun AWS saat mendaftarkan sumber daya Aurora sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini

memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_RDSCluster

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- rds.application-autoscaling.amazonaws.com

Mendaftarkan cluster Aurora DB sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk klaster Aurora. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengonfigurasi penskalaan otomatis menggunakan konsol Aurora, maka Aurora secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk cluster Aurora. Contoh berikut mencatat jumlah Replika Aurora dalam sebuah cluster yang `my-db-cluster` disebut, dengan kapasitas minimum satu Replika Aurora dan kapasitas maksimum delapan Replika Aurora.

```
aws application-autoscaling register-scalable-target \
--service-namespace rds \
--scalable-dimension rds:cluster:ReadReplicaCount \
--resource-id cluster:my-db-cluster \
```

```
--min-capacity 1 \
--max-capacity 8
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya Aurora Anda dalam dokumentasi berikut:

[Menggunakan Auto Scaling Amazon Aurora dengan replika Aurora](#) di Panduan Pengguna Amazon RDS

Amazon Comprehend dan Application Auto Scaling

Anda dapat menskalakan klasifikasi dokumen Amazon Comprehend dan titik akhir pengenal entitas menggunakan kebijakan penskalaan pelacakan target dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Amazon Comprehend dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk Amazon Comprehend

[Peran terkait layanan](#) berikut dibuat secara otomatis di Akun AWS saat mendaftarkan sumber daya Amazon Comprehend sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_ComprehendEndpoint

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- comprehend.application-autoscaling.amazonaws.com

Mendaftarkan Amazon Comprehend resource sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk klasifikasi dokumen Amazon Comprehend atau titik akhir pengenal entitas. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Untuk mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk titik akhir klasifikasi dokumen. Contoh berikut mencatat jumlah unit inferensi yang diinginkan untuk digunakan oleh model untuk titik akhir pengklasifikasi dokumen menggunakan ARN titik akhir, dengan kapasitas minimum satu unit inferensi dan kapasitas maksimum tiga unit inferensi.

```
aws application-autoscaling register-scalable-target \
--service-namespace comprehend \
--scalable-dimension comprehend:document-classifier-endpoint:DesiredInferenceUnits \
--resource-id arn:aws:comprehend:us-west-2:123456789012:document-classifier-
endpoint/EXAMPLE \
--min-capacity 1 \
--max-capacity 3
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Panggil [register-scalable-target](#) perintah untuk titik akhir pengenal entitas. Contoh berikut mencatat jumlah unit inferensi yang diinginkan untuk digunakan oleh model untuk pengenal entitas menggunakan ARN titik akhir, dengan kapasitas minimum satu unit inferensi dan kapasitas maksimum tiga unit inferensi.

```
aws application-autoscaling register-scalable-target \  
--service-namespace comprehend \  
--scalable-dimension comprehend:entity-recognizer-endpoint:DesiredInferenceUnits \  
--resource-id arn:aws:comprehend:us-west-2:123456789012:entity-recognizer-  
endpoint/EXAMPLE \  
--min-capacity 1 \  
--max-capacity 3
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya Amazon Comprehend Anda dalam dokumentasi berikut:

[Penskalaan otomatis dengan titik akhir di Panduan Pengembang Amazon Comprehend](#)

Amazon DynamoDB dan Application Auto Scaling

Anda dapat menskalakan tabel DynamoDB dan indeks sekunder global menggunakan kebijakan penskalaan pelacakan target dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan DynamoDB dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk DynamoDB

Peran terkait layanan berikut dibuat secara otomatis di Akun AWS saat mendaftarkan sumber daya DynamoDB sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_DynamoDBTable

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- dynamodb.application-autoscaling.amazonaws.com

Mendaftarkan sumber daya DynamoDB sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk tabel DynamoDB atau indeks sekunder global. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengonfigurasi penskalaan otomatis menggunakan konsol DynamoDB, maka DynamoDB secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk kapasitas tulis tabel. Contoh berikut mencatat kapasitas tulis yang disediakan dari tabel yang disebut `my-table`, dengan kapasitas minimum lima unit kapasitas tulis dan kapasitas maksimum 10 unit kapasitas tulis.

```
aws application-autoscaling register-scalable-target \
--service-namespace dynamodb \
--scalable-dimension dynamodb:table:WriteCapacityUnits \
--resource-id table/my-table \
--min-capacity 5 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Panggil [register-scalable-target](#) perintah untuk kapasitas baca tabel. Contoh berikut mencatat kapasitas baca yang disediakan dari tabel yang disebut `my-table`, dengan kapasitas minimum lima unit kapasitas baca dan kapasitas maksimum 10 unit baca.

```
aws application-autoscaling register-scalable-target \
--service-namespace dynamodb \
--scalable-dimension dynamodb:table:ReadCapacityUnits \
--resource-id table/my-table \
--min-capacity 5 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Panggil [register-scalable-target](#) perintah untuk kapasitas tulis indeks sekunder global. Contoh berikut mencatat kapasitas tulis yang disediakan dari indeks sekunder global yang disebut my-table-index, dengan kapasitas minimum lima unit kapasitas tulis dan kapasitas maksimum 10 unit kapasitas tulis.

```
aws application-autoscaling register-scalable-target \
--service-namespace dynamodb \
--scalable-dimension dynamodb:index:WriteCapacityUnits \
--resource-id table/my-table/index/my-table-index \
--min-capacity 5 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Panggil [register-scalable-target](#) perintah untuk kapasitas baca indeks sekunder global. Contoh berikut mencatat kapasitas baca yang disediakan dari indeks sekunder global yang disebut my-table-index, dengan kapasitas minimum lima unit kapasitas baca dan kapasitas maksimum 10 unit kapasitas baca.

```
aws application-autoscaling register-scalable-target \
--service-namespace dynamodb \
--scalable-dimension dynamodb:index:ReadCapacityUnits \
--resource-id table/my-table/index/my-table-index \
--min-capacity 5 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya DynamoDB Anda dalam dokumentasi berikut:

- [Mengelola kapasitas throughput dengan DynamoDB Auto Scaling](#) di Panduan Pengembang Amazon DynamoDB
- [Mengevaluasi pengaturan penskalaan otomatis tabel Anda](#) di Panduan Pengembang Amazon DynamoDB
- [Cara menggunakan AWS CloudFormation untuk mengkonfigurasi auto scaling untuk tabel DynamoDB](#) dan indeks di Blog AWS

Amazon ECS dan Application Auto Scaling

Anda dapat menskalakan layanan ECS menggunakan kebijakan penskalaan pelacakan target, kebijakan penskalaan langkah, dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Amazon ECS dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk Amazon ECS

[Peran terkait layanan](#) berikut dibuat secara otomatis di Akun AWS saat mendaftarkan resource Amazon ECS sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- `AWSServiceRoleForApplicationAutoScaling_ECSService`

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- `ecs.application-autoscaling.amazonaws.com`

Mendaftarkan layanan ECS sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk layanan Amazon ECS. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengkonfigurasi penskalaan otomatis menggunakan konsol Amazon ECS, Amazon ECS secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengkonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk layanan Amazon ECS. Contoh berikut mendaftarkan target yang dapat diskalakan untuk layanan yang dipanggil `sample-app-service`, berjalan di default cluster, dengan jumlah tugas minimum satu tugas dan jumlah tugas maksimum 10 tugas.

```
aws application-autoscaling register-scalable-target \
--service-namespace ecs \
--scalable-dimension ecs:service:DesiredCount \
--resource-id service/default/sample-app-service \
--min-capacity 1 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

{

```
"ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya Amazon ECS Anda dalam dokumentasi berikut:

- [Penskalaan otomatis servis](#) di Panduan Pengembang Layanan Kontainer Elastis Amazon
- [Mengonfigurasi penskalaan otomatis servis](#) di Panduan Praktik Terbaik Amazon Elastic Container Service

 Note

Untuk petunjuk penangguhan proses penskalaan saat penerapan Amazon ECS sedang berlangsung, lihat dokumentasi berikut:

[Servis penskalaan dan penerapan otomatis](#) di Panduan Pengembang Layanan Amazon Elastic Container

ElastiCache (RedisOSS) dan Application Auto Scaling

Anda dapat menskalakan grup replikasi ElastiCache (RedisOSS) menggunakan kebijakan penskalaan pelacakan target dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda berintegrasi ElastiCache dengan Application Auto Scaling.

Peran terkait layanan dibuat untuk ElastiCache

Peran terkait layanan berikut dibuat secara otomatis di dalam Akun AWS saat mendaftarkan ElastiCache sumber daya sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_ElastiCacheRG

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- elasticache.application-autoscaling.amazonaws.com

Mendaftarkan grup replikasi ElastiCache (RedisOSS) sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk grup replikasi. ElastiCache Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengkonfigurasi penskalaan otomatis menggunakan ElastiCache konsol, maka ElastiCache secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengkonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah satu AWS SDKs, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk grup ElastiCache replikasi. Contoh berikut mendaftarkan jumlah kelompok node yang diinginkan untuk grup replikasi yang disebut `mycluster`, dengan kapasitas minimum satu dan kapasitas maksimum lima.

```
aws application-autoscaling register-scalable-target \
--service-namespace elasticache \
--scalable-dimension elasticache:replication-group:NodeGroups \
--resource-id replication-group/mycluster \
--min-capacity 1 \
--max-capacity 5
```

Jika berhasil, perintah ini mengembalikan target ARN yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Contoh berikut mencatat jumlah replika yang diinginkan per grup node untuk grup replikasi yang disebut *mycluster*, dengan kapasitas minimum 1 dan kapasitas maksimum 5.

```
aws application-autoscaling register-scalable-target \
--service-namespace elasticache \
--scalable-dimension elasticache:replication-group:Replicas \
--resource-id replication-group/mycluster \
--min-capacity 1 \
--max-capacity 5
```

Jika berhasil, perintah ini mengembalikan target ARN yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan ElastiCache sumber daya Anda dalam dokumentasi berikut:

[Cluster Auto Scaling ElastiCache \(RedisOSS\) di Panduan Pengguna Amazon ElastiCache \(Redis OSS\)](#)

Amazon Keyspaces (untuk Apache Cassandra) dan Application Auto Scaling

Anda dapat menskalakan tabel Amazon Keyspaces menggunakan kebijakan penskalaan pelacakan target dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Amazon Keyspaces dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk Amazon Keyspaces

[Peran terkait layanan](#) berikut dibuat secara otomatis di Akun AWS saat mendaftarkan resource Amazon Keyspaces sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_CassandraTable

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- cassandra.application-autoscaling.amazonaws.com

Mendaftarkan tabel Amazon Keyspaces sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk tabel Amazon Keyspaces. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengonfigurasi penskalaan otomatis menggunakan konsol Amazon Keyspaces, Amazon Keyspaces secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk tabel Amazon Keyspaces. Contoh berikut mencatat kapasitas tulis yang disediakan dari tabel yang disebut `mytable`, dengan kapasitas minimum lima unit kapasitas tulis dan kapasitas maksimum 10 unit kapasitas tulis.

```
aws application-autoscaling register-scalable-target \
--service-namespace cassandra \
--scalable-dimension cassandra:table:WriteCapacityUnits \
--resource-id keyspace/mykeyspace/table/mytable \
--min-capacity 5 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Contoh berikut mencatat kapasitas baca yang disediakan dari tabel yang disebut `mytable`, dengan kapasitas minimum lima unit kapasitas baca dan kapasitas maksimum 10 unit kapasitas baca.

```
aws application-autoscaling register-scalable-target \
--service-namespace cassandra \
```

```
--scalable-dimension cassandra:table:ReadCapacityUnits \
--resource-id keyspace/mykeyspace/table/mytable \
--min-capacity 5 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya Amazon Keyspaces Anda dalam dokumentasi berikut:

[Mengelola kapasitas throughput dengan penskalaan otomatis Amazon Keyspaces](#) di Amazon Keyspaces (untuk Apache Cassandra) Panduan Pengembang

AWS Lambda dan Application Auto Scaling

Anda dapat menskalakan AWS Lambda konkurensi yang disediakan menggunakan kebijakan penskalaan pelacakan target dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Lambda dengan Application Auto Scaling.

Peran terkait layanan dibuat untuk Lambda

[Peran terkait layanan](#) berikut dibuat secara otomatis di dalam Akun AWS saat mendaftarkan sumber daya Lambda sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun

Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_LambdaConcurrency

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- lambda.application-autoscaling.amazonaws.com

Mendaftarkan fungsi Lambda sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk fungsi Lambda. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Untuk mengkonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk fungsi Lambda. Contoh berikut mendaftarkan konkreensi yang disediakan untuk alias yang dipanggil BLUE untuk fungsi yang dipanggil my-function, dengan kapasitas minimum 0 dan kapasitas maksimum 100.

```
aws application-autoscaling register-scalable-target \
--service-namespace lambda \
--scalable-dimension lambda:function:ProvisionedConcurrency \
--resource-id function:my-function:BLUE \
--min-capacity 0 \
--max-capacity 100
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
    target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan fungsi Lambda Anda dalam dokumentasi berikut:

- [Mengkonfigurasi konkurensi yang disediakan dalam Panduan Pengembang AWS Lambda](#)
- [Menjadwalkan Lambda Provisioned Concurrency untuk penggunaan puncak berulang di Blog AWS](#)

Amazon Managed Streaming untuk Apache Kafka (MSK) dan Application Auto Scaling

Anda dapat meningkatkan skala penyimpanan klaster MSK Amazon menggunakan kebijakan penskalaan pelacakan target. Penskalaan berdasarkan kebijakan pelacakan target dinonaktifkan.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Amazon MSK dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk Amazon MSK

[Peran terkait layanan](#) berikut dibuat secara otomatis di Akun AWS saat mendaftarkan sumber daya MSK Amazon sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_KafkaCluster

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- kafka.application-autoscaling.amazonaws.com

Mendaftarkan penyimpanan cluster MSK Amazon sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan untuk ukuran volume penyimpanan per broker kluster MSK Amazon. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengonfigurasi penskalaan otomatis menggunakan konsol MSK Amazon, maka Amazon MSK secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk cluster MSK Amazon. Contoh berikut mencatat ukuran volume penyimpanan per broker dari cluster MSK Amazon, dengan kapasitas minimum 100 GiB dan kapasitas maksimum 800 GiB.

```
aws application-autoscaling register-scalable-target \
--service-namespace kafka \
--scalable-dimension kafka:broker-storage:VolumeSize \
--resource-id arn:aws:kafka:us-east-1:123456789012:cluster/demo-
cluster-1/6357e0b2-0e6a-4b86-a0b4-70df934c2e31-5 \
--min-capacity 100 \
--max-capacity 800
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
    target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

 Note

Ketika sebuah klaster Amazon MSK adalah target yang dapat diskalakan, skala di dinonaktifkan dan tidak dapat diaktifkan.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya MSK Amazon Anda dalam dokumentasi berikut:

[Penskalaan otomatis](#) dalam Panduan Pengembang Amazon Managed Streaming for Apache Kafka

Amazon Neptunus dan Application Auto Scaling

Anda dapat menskalakan klaster Neptunus menggunakan kebijakan penskalaan pelacakan target dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Neptunus dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk Neptunus

[Peran terkait layanan](#) berikut dibuat secara otomatis di dalam Akun AWS saat mendaftarkan sumber daya Neptunus sebagai target yang dapat diskalakan dengan Application Auto Scaling.

Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- AWSServiceRoleForApplicationAutoScaling_NeptuneCluster

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- neptune.application-autoscaling.amazonaws.com

Mendaftarkan cluster Neptunus sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk cluster Neptunus. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Untuk mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk cluster Neptunus. Contoh berikut mencatat kapasitas yang diinginkan dari sebuah cluster yang disebut *mycluster*, dengan kapasitas minimum satu dan kapasitas maksimum delapan.

```
aws application-autoscaling register-scalable-target \
--service-namespace neptune \
--scalable-dimension neptune:cluster:ReadReplicaCount \
--resource-id cluster:mycluster \
--min-capacity 1 \
--max-capacity 8
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
    target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya Neptunus Anda dalam dokumentasi berikut:

[Penskalaan otomatis jumlah replika di cluster DB Amazon Neptunus](#) di [Panduan Pengguna Neptunus](#)

Amazon SageMaker dan Application Auto Scaling

Anda dapat menskalakan varian SageMaker titik akhir, konkurensi yang disediakan untuk titik akhir tanpa server, dan komponen inferensi menggunakan kebijakan penskalaan pelacakan target, kebijakan penskalaan langkah, dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda berintegrasi SageMaker dengan Application Auto Scaling.

Peran terkait layanan dibuat untuk SageMaker

[Peran terkait layanan](#) berikut dibuat secara otomatis di dalam Akun AWS saat mendaftarkan SageMaker sumber daya sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- `AWSServiceRoleForApplicationAutoScaling_SageMakerEndpoint`

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- `sagemaker.application-autoscaling.amazonaws.com`

Mendaftarkan varian SageMaker endpoint sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk SageMaker model (varian). Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengonfigurasi penskalaan otomatis menggunakan SageMaker konsol, maka SageMaker secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil `register-scalable-target` perintah untuk varian produk. Contoh berikut mencatat jumlah instans yang diinginkan untuk varian produk yang disebut `my-variant`, berjalan pada `my-endpoint` titik akhir, dengan kapasitas minimum satu instance dan kapasitas maksimum delapan instance.

```
aws application-autoscaling register-scalable-target \
--service-namespace sagemaker \
--scalable-dimension sagemaker:variant:DesiredInstanceCount \
--resource-id endpoint/my-endpoint/variant/my-variant \
--min-capacity 1 \
--max-capacity 8
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
    target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Mendaftarkan konkurensi titik akhir tanpa server yang disediakan sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling juga memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk konkurensi titik akhir tanpa server yang disediakan.

Jika Anda mengonfigurasi penskalaan otomatis menggunakan SageMaker konsol, maka SageMaker secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika tidak, gunakan salah satu metode berikut untuk mendaftarkan target yang dapat diskalakan:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk varian produk. Contoh berikut mendaftarkan konkurensi yang disediakan untuk varian produk yang disebut `my-variant`, berjalan pada `my-endpoint` titik akhir, dengan kapasitas minimum satu dan kapasitas maksimum sepuluh.

```
aws application-autoscaling register-scaling-target \  
    --service-namespace sagemaker \  
    --scalable-dimension sagemaker:variant:DesiredProvisionedConcurrency \  
    --resource-id endpoint/my-endpoint/variant/my-variant \  
    --min-capacity 1 \  
    --max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
```

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Mendaftarkan komponen inferensi sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling juga memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk komponen inferensi.

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk komponen inferensi. Contoh berikut mencatat jumlah salinan yang diinginkan untuk komponen inferensi yang disebut `my-inference-component`, dengan kapasitas minimum nol salinan dan kapasitas maksimum tiga salinan.

```
aws application-autoscaling register-scalable-target \  
    --service-namespace sagemaker \  
    --scalable-dimension sagemaker:inference-component:DesiredCopyCount \  
    --resource-id inference-component/my-inference-component \  
    --min-capacity 0 \  
    --max-capacity 3
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan SageMaker sumber daya Anda di Panduan Pengembang Amazon SageMaker :

- [Secara otomatis menskalakan SageMaker model Amazon](#)
- [Secara otomatis menskalakan Konkurensi yang Disediakan untuk titik akhir tanpa server](#)
- [Menetapkan kebijakan penskalaan otomatis untuk penerapan titik akhir multi-model](#)
- [Skala otomatis titik akhir asinkron](#)

Note

Pada tahun 2023, SageMaker memperkenalkan kemampuan inferensi baru yang dibangun di atas titik akhir inferensi waktu nyata. Anda membuat SageMaker titik akhir dengan konfigurasi titik akhir yang mendefinisikan jenis instans dan jumlah instans awal untuk titik akhir. Kemudian, buat komponen inferensi, yang merupakan objek SageMaker hosting yang dapat Anda gunakan untuk menyebarkan model ke titik akhir. Untuk informasi tentang penskalaan komponen inferensi, [lihat Amazon SageMaker menambahkan kemampuan inferensi baru untuk membantu mengurangi biaya penerapan model dasar dan latensi](#) serta [Mengurangi biaya penerapan model rata-rata sebesar 50% menggunakan fitur terbaru Amazon di Blog. SageMaker AWS](#)

Armada Spot Amazon EC2 dan Application Auto Scaling

Anda dapat menskalakan Armada Spot menggunakan kebijakan penskalaan pelacakan target, kebijakan penskalaan langkah, dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan Armada Spot dengan Application Auto Scaling.

Peran terkait layanan dibuat untuk Armada Spot

Peran terkait layanan berikut dibuat secara otomatis di dalam Akun AWS saat mendaftarkan sumber daya Armada Spot sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- `AWSServiceRoleForApplicationAutoScaling_EC2SpotFleetRequest`

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- `ec2.application-autoscaling.amazonaws.com`

Mendaftarkan Armada Spot sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk Armada Spot. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengkonfigurasi penskalaan otomatis menggunakan konsol Spot Fleet, maka Spot Fleet secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengkonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil [register-scalable-target](#) perintah untuk Armada Spot. Contoh berikut mencatat kapasitas target Armada Spot menggunakan ID permintaannya, dengan kapasitas minimum dua instans dan kapasitas maksimum 10 instans.

```
aws application-autoscaling register-scalable-target \
--service-namespace ec2 \
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \
--resource-id spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-1cee4EXAMPLE \
--min-capacity 2 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan Armada Spot Anda di dokumentasi berikut:

[Penskalaan otomatis untuk Armada Spot](#) di Panduan Pengguna Amazon EC2

Amazon WorkSpaces dan Application Auto Scaling

Anda dapat menskalakan kumpulan WorkSpaces menggunakan kebijakan penskalaan pelacakan target, kebijakan penskalaan langkah, dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda berintegrasi WorkSpaces dengan Application Auto Scaling.

Peran terkait layanan dibuat untuk WorkSpaces

Application Auto Scaling secara otomatis membuat peran terkait layanan yang disebutkan `AWSRoleForApplicationAutoScaling_WorkSpacesPool` dalam nama Anda Akun AWS saat

Anda mendaftarkan WorkSpaces sumber daya sebagai target yang dapat diskalakan dengan Application Auto Scaling. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

Peran terkait layanan ini menggunakan kebijakan terkelola.

AWSApplicationAutoscalingWorkSpacesPoolPolicy Kebijakan ini memberikan izin Application Auto Scaling untuk memanggil WorkSpaces Amazon atas nama Anda. Untuk informasi selengkapnya, lihat [AWSApplicationAutoscalingWorkSpacesPoolPolicy](#) di Referensi Kebijakan AWS Terkelola.

Prinsip layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan mempercayai prinsip layanan berikut untuk mengambil peran:

- `workspaces.application-autoscaling.amazonaws.com`

Mendaftarkan WorkSpaces pool sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk. WorkSpaces Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Jika Anda mengonfigurasi penskalaan otomatis menggunakan WorkSpaces konsol, maka WorkSpaces secara otomatis mendaftarkan target yang dapat diskalakan untuk Anda.

Jika Anda ingin mengonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil `register-scalable-target` perintah untuk kumpulan WorkSpaces. Contoh berikut mencatat kapasitas target kumpulan WorkSpaces menggunakan ID permintaannya, dengan kapasitas minimum dua desktop virtual dan kapasitas maksimum sepuluh desktop virtual.

```
aws application-autoscaling register-scalable-target \
--service-namespace workspaces \
--resource-id workspacespool/wspool-abcdef012 \
--scalable-dimension workspaces:workspacespool:DesiredUserSessions \
```

```
--min-capacity 2 \
--max-capacity 10
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya khusus dan Application Auto Scaling

Anda dapat menskalakan sumber daya khusus menggunakan kebijakan penskalaan pelacakan target, kebijakan penskalaan langkah, dan penskalaan terjadwal.

Gunakan informasi berikut untuk membantu Anda mengintegrasikan sumber daya khusus dengan Application Auto Scaling.

Peran terkait layanan yang dibuat untuk sumber daya khusus

[Peran terkait layanan](#) berikut dibuat secara otomatis di Akun AWS saat mendaftarkan sumber daya kustom sebagai target yang dapat diskalakan dengan Application Auto Scaling. Peran ini memungkinkan Application Auto Scaling untuk melakukan operasi yang didukung dalam akun Anda. Untuk informasi selengkapnya, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

- `AWSServiceRoleForApplicationAutoScaling_CustomResource`

Prinsipal layanan yang digunakan oleh peran terkait layanan

Peran terkait layanan di bagian sebelumnya hanya dapat diasumsikan oleh kepala layanan yang diotorisasi oleh hubungan kepercayaan yang ditentukan untuk peran tersebut. Peran terkait layanan yang digunakan oleh Application Auto Scaling memberikan akses ke prinsipal layanan berikut:

- `custom-resource.application-autoscaling.amazonaws.com`

Mendaftarkan sumber daya kustom sebagai target yang dapat diskalakan dengan Application Auto Scaling

Application Auto Scaling memerlukan target yang dapat diskalakan sebelum Anda dapat membuat kebijakan penskalaan atau tindakan terjadwal untuk sumber daya kustom. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling. Target yang dapat diskalakan diidentifikasi secara unik dengan kombinasi ID sumber daya, dimensi yang dapat diskalakan, dan namespace.

Untuk mengkonfigurasi penskalaan otomatis menggunakan AWS CLI atau salah AWS satu SDK, Anda dapat menggunakan opsi berikut:

- AWS CLI:

Panggil `register-scalable-target` perintah untuk sumber daya khusus. Contoh berikut mendaftarkan sumber daya kustom sebagai target yang dapat diskalakan, dengan jumlah minimum yang diinginkan dari satu unit kapasitas dan jumlah maksimum yang diinginkan dari 10 unit kapasitas. `custom-resource-id.txt` file berisi string yang mengidentifikasi ID sumber daya, yang mewakili jalur ke sumber daya kustom melalui titik akhir Amazon API Gateway Anda.

```
aws application-autoscaling register-scalable-target \
--service-namespace custom-resource \
--scalable-dimension custom-resource:ResourceType:Property \
--resource-id file://~/custom-resource-id.txt \
--min-capacity 1 \
--max-capacity 10
```

Isi dari `custom-resource-id.txt`:

```
https://example.execute-api.us-west-2.amazonaws.com/prod/
scalableTargetDimensions/1-23456789
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"}
```

```
}
```

- AWS SDK:

Panggil [RegisterScalableTarget](#) operasi dan berikan `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity`, dan `MaxCapacity` sebagai parameter.

Sumber daya terkait

Jika Anda baru memulai Application Auto Scaling, Anda dapat menemukan informasi berguna tambahan tentang penskalaan sumber daya kustom Anda dalam dokumentasi berikut:

[GitHub repository](#)

Konfigurasikan sumber daya Application Auto Scaling menggunakan AWS CloudFormation

Application Auto Scaling terintegrasi dengan AWS CloudFormation, layanan yang membantu Anda memodelkan dan mengatur AWS sumber daya Anda sehingga Anda dapat menghabiskan lebih sedikit waktu untuk membuat dan mengelola sumber daya dan infrastruktur Anda. Anda membuat template yang menjelaskan semua AWS sumber daya yang Anda inginkan, dan menyediakan serta AWS CloudFormation mengonfigurasi sumber daya tersebut untuk Anda.

Bila Anda menggunakan AWS CloudFormation, Anda dapat menggunakan kembali template Anda untuk mengatur sumber daya Application Auto Scaling Anda secara konsisten dan berulang kali. Jelaskan sumber daya Anda sekali, lalu sediakan sumber daya yang sama berulang-ulang di beberapa Akun AWS dan Wilayah.

Application Auto Scaling dan template AWS CloudFormation

Untuk menyediakan dan mengonfigurasi sumber daya untuk Application Auto Scaling dan layanan terkait, Anda harus memahami AWS CloudFormation template. Templat adalah file teks dengan format JSON atau YAML. Template ini menjelaskan sumber daya yang ingin Anda sediakan di AWS CloudFormation tumpukan Anda. Jika Anda tidak terbiasa dengan JSON atau YAMM, Anda dapat menggunakan AWS CloudFormation Designer untuk membantu Anda memulai dengan template. AWS CloudFormation Untuk informasi selengkapnya, lihat [Apa itu AWS CloudFormation Designer?](#) di Panduan Pengguna AWS CloudFormation .

Saat Anda membuat template tumpukan untuk sumber daya Application Auto Scaling, Anda harus memberikan yang berikut:

- Namespace untuk layanan target (misalnya,**appstream**). Lihat [AWS::ApplicationAutoScaling::ScalableTarget](#) referensi untuk mendapatkan ruang nama layanan.
- Dimensi skalabel yang terkait dengan sumber daya target (misalnya,**appstream:fleet:DesiredCapacity**). Lihat [AWS::ApplicationAutoScaling::ScalableTarget](#) referensi untuk mendapatkan dimensi yang dapat diskalakan.
- ID sumber daya untuk sumber daya target (misalnya,**fleet/sample-fleet**). Lihat [AWS::ApplicationAutoScaling::ScalableTarget](#) referensi untuk informasi tentang sintaks dan contoh ID sumber daya tertentu.

- Peran terkait layanan untuk sumber daya target (misalnya,**arn:aws:iam::012345678910:role/aws-service-role/appstream.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_AppStreamFleet**). Lihat [Referensi peran terkait layanan ARN](#) tabel untuk mendapatkan ARN peran.

Untuk mempelajari lebih lanjut tentang sumber daya Application Auto Scaling, lihat referensi [Application Auto Scaling](#) di AWS CloudFormation Panduan Pengguna.

Contoh cuplikan template

Anda dapat menemukan contoh cuplikan untuk disertakan dalam AWS CloudFormation templat di bagian AWS CloudFormation Panduan Pengguna berikut:

- Untuk contoh kebijakan penskalaan dan tindakan terjadwal, lihat [Mengkonfigurasi sumber daya Application Auto Scaling dengan AWS CloudFormation](#)
- Untuk contoh kebijakan penskalaan lainnya, lihat [AWS::ApplicationAutoScaling::ScalingPolicy](#).

Pelajari lebih lanjut tentang AWS CloudFormation

Untuk mempelajari selengkapnya AWS CloudFormation, lihat sumber daya berikut:

- [AWS CloudFormation](#)
- [AWS CloudFormation Panduan Pengguna](#)
- [AWS CloudFormation Referensi API](#)
- [Panduan Pengguna Antarmuka Baris Perintah AWS CloudFormation](#)

Penskalaan terjadwal untuk Application Auto Scaling

Dengan penskalaan terjadwal, Anda dapat mengatur penskalaan otomatis untuk aplikasi berdasarkan perubahan beban yang dapat diprediksi dengan membuat tindakan terjadwal yang menambah atau mengurangi kapasitas pada waktu tertentu. Ini memungkinkan Anda menskalakan aplikasi secara proaktif agar sesuai dengan perubahan beban yang dapat diprediksi.

Misalnya, katakanlah Anda mengalami pola lalu lintas mingguan reguler di mana beban meningkat pertengahan minggu dan menurun menjelang akhir minggu. Anda dapat mengonfigurasi jadwal penskalaan di Application Auto Scaling yang sejajar dengan pola ini:

- Pada Rabu pagi, satu tindakan yang dijadwalkan meningkatkan kapasitas dengan meningkatkan kapasitas minimum yang ditetapkan sebelumnya dari target yang dapat diskalakan.
- Pada Jumat malam, tindakan terjadwal lainnya mengurangi kapasitas dengan mengurangi kapasitas maksimum yang ditetapkan sebelumnya dari target yang dapat diskalakan.

Tindakan penskalaan terjadwal ini memungkinkan Anda mengoptimalkan biaya dan kinerja. Aplikasi Anda memiliki kapasitas yang cukup untuk menangani puncak lalu lintas pertengahan minggu, tetapi tidak menyediakan kapasitas yang tidak dibutuhkan secara berlebihan di lain waktu.

Anda dapat menggunakan kebijakan penskalaan dan penskalaan terjadwal bersama-sama untuk mendapatkan manfaat dari pendekatan proaktif dan reaktif untuk penskalaan. Setelah tindakan penskalaan terjadwal berjalan, kebijakan penskalaan dapat terus membuat keputusan tentang apakah akan meningkatkan kapasitas skala lebih lanjut. Ini membantu memastikan bahwa Anda memiliki kapasitas yang cukup untuk menangani beban untuk aplikasi Anda. Meskipun aplikasi Anda menskalakan sesuai dengan permintaan, kapasitas saat ini harus berada di antara kapasitas minimum dan maksimum yang ditetapkan oleh tindakan terjadwal Anda.

Daftar Isi

- [Cara kerja penskalaan terjadwal untuk Application Auto Scaling](#)
- [Buat tindakan terjadwal untuk Application Auto Scaling menggunakan AWS CLI](#)
- [Jelaskan penskalaan terjadwal untuk Application Auto Scaling menggunakan AWS CLI](#)
- [Jadwalkan tindakan penskalaan berulang menggunakan Application Auto Scaling](#)
- [Matikan penskalaan terjadwal untuk target yang dapat diskalakan](#)
- [Menghapus tindakan terjadwal untuk Application Auto Scaling menggunakan AWS CLI](#)

Cara kerja penskalaan terjadwal untuk Application Auto Scaling

Topik ini menjelaskan cara kerja penskalaan terjadwal dan memperkenalkan pertimbangan utama yang perlu Anda pahami untuk menggunakannya secara efektif.

Daftar Isi

- [Cara kerjanya](#)
- [Pertimbangan](#)
- [Perintah yang umum digunakan untuk pembuatan, pengelolaan, dan penghapusan tindakan terjadwal](#)
- [Sumber daya terkait](#)
- [Batasan](#)

Cara kerjanya

Untuk menggunakan penskalaan terjadwal, buatlah tindakan terjadwal, yang memberi tahu Application Auto Scaling untuk melakukan aktivitas penskalaan pada waktu tertentu. Saat Anda membuat tindakan terjadwal, Anda menentukan target yang dapat diskalakan, waktu aktivitas penskalaan seharusnya terjadi, kapasitas minimum, dan kapasitas maksimum. Anda dapat membuat tindakan terjadwal yang berskala satu kali saja atau skala itu pada jadwal berulang.

Pada waktu yang ditentukan, Application Auto Scaling menskalakan berdasarkan nilai kapasitas baru, dengan membandingkan kapasitas saat ini dengan kapasitas minimum dan maksimum yang ditentukan.

- Jika kapasitas saat ini kurang dari kapasitas minimum yang ditentukan, Application Auto Scaling akan menskalakan naik (meningkatkan kapasitas) ke kapasitas minimum yang ditentukan.
- Jika kapasitas saat ini lebih besar daripada kapasitas maksimum yang ditentukan, Application Auto Scaling menskalakan turun (menurunkan kapasitas) ke kapasitas maksimum yang ditentukan.

Pertimbangan

Saat Anda membuat tindakan terjadwal, ingatlah hal berikut:

- Tindakan terjadwal menetapkan MinCapacity dan apa MaxCapacity yang ditentukan oleh tindakan terjadwal pada tanggal dan waktu yang ditentukan. Permintaan secara opsional hanya

dapat mencakup satu dari ukuran ini. Misalnya, Anda dapat membuat tindakan terjadwal hanya dengan kapasitas minimum yang ditentukan. Namun, dalam beberapa kasus, Anda harus memasukkan kedua ukuran untuk memastikan bahwa kapasitas minimum baru tidak lebih besar dari kapasitas maksimum, atau kapasitas maksimum baru tidak kurang dari kapasitas minimum.

- Secara default, jadwal berulang yang Anda tetapkan berada di Coordinated Universal Time (UTC). Anda dapat mengubah zona waktu agar sesuai dengan zona waktu lokal Anda atau zona waktu untuk bagian lain dari jaringan Anda. Saat Anda menentukan zona waktu yang mengamati waktu musim panas, tindakan secara otomatis menyesuaikan Daylight Saving Time (DST). Untuk informasi selengkapnya, lihat [Jadwalkan tindakan penskalaan berulang menggunakan Application Auto Scaling](#).
- Anda dapat mematikan sementara penskalaan terjadwal untuk target yang dapat diskalakan. Ini membantu Anda mencegah tindakan terjadwal agar tidak aktif tanpa harus menghapusnya. Anda kemudian dapat melanjutkan penskalaan terjadwal ketika Anda ingin menggunakan lagi. Untuk informasi selengkapnya, lihat [Menangguhkan dan melanjutkan penskalaan untuk Application Auto Scaling](#).
- Urutan di mana tindakan terjadwal dijalankan dijamin untuk target skalabel yang sama, tetapi tidak untuk tindakan terjadwal di seluruh target yang dapat diskalakan.
- Untuk menyelesaikan tindakan terjadwal dengan sukses, sumber daya yang ditentukan harus dalam status skalabel dalam layanan target. Jika tidak, permintaan gagal dan mengembalikan pesan kesalahan, misalnya, Resource Id [ActualResourceId] is not scalable. Reason: The status of all DB instances must be 'available' or 'incompatible-parameters'.
- Karena sifat terdistribusi dari Application Auto Scaling dan layanan target, penundaan antara waktu tindakan terjadwal dipicu dan waktu layanan target menghormati tindakan penskalaan mungkin beberapa detik. Karena tindakan terjadwal dijalankan dalam urutan yang sesuai dengan urutan ditentukannya tindakan, tindakan-tindakan terjadwal dengan waktu mulai yang berdekatan dapat memakan waktu lebih lama untuk dijalankan.

Perintah yang umum digunakan untuk pembuatan, pengelolaan, dan penghapusan tindakan terjadwal

Perintah yang umum digunakan untuk bekerja dengan penskalaan jadwal meliputi:

- [register-scalable-target](#)untuk mendaftarkan AWS atau menyesuaikan sumber daya sebagai target yang dapat diskalakan (sumber daya yang dapat diskalakan oleh Application Auto Scaling), dan untuk menangguhkan dan melanjutkan penskalaan.
- [put-scheduled-action](#)untuk menambah atau memodifikasi tindakan terjadwal untuk target skala yang ada.
- [describe-scaling-activities](#)untuk mengembalikan informasi tentang aktivitas penskalaan di suatu AWS Wilayah.
- [describe-scheduled-actions](#)untuk mengembalikan informasi tentang tindakan terjadwal di suatu AWS Wilayah.
- [delete-scheduled-action](#) untuk menghapus tindakan terjadwal.

Sumber daya terkait

Untuk contoh mendetail tentang penggunaan penskalaan terjadwal, lihat posting blog [Menjadwalkan Konkurensi yang AWS Lambda Disediakan untuk penggunaan puncak berulang](#) di Blog Komputasi. AWS

Untuk informasi tentang membuat tindakan terjadwal untuk grup Auto Scaling, lihat Penskalaan terjadwal untuk Penskalaan Otomatis Amazon EC2 di [Panduan Pengguna Auto Scaling Amazon EC2](#).

Batasan

Berikut ini adalah keterbatasan saat menggunakan penskalaan terjadwal:

- Nama-nama tindakan terjadwal harus unik per target yang dapat diskalakan.
- Application Auto Scaling tidak memberikan presisi tingkat kedua dalam ekspresi jadwal. Resolusi terbaik yang menggunakan ekspresi cron adalah 1 menit.
- Target yang dapat diskalakan tidak bisa menjadi klaster Amazon MSK. Penskalaan terjadwal tidak didukung untuk Amazon MSK.
- Akses konsol untuk melihat, menambah, memperbarui, atau menghapus tindakan terjadwal pada sumber daya yang dapat diskalakan bergantung pada sumber daya yang Anda gunakan. Untuk informasi selengkapnya, lihat [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

Buat tindakan terjadwal untuk Application Auto Scaling menggunakan AWS CLI

Contoh berikut menunjukkan cara membuat tindakan terjadwal menggunakan AWS CLI [put-scheduled-action](#) perintah. Saat menentukan kapasitas baru, Anda dapat menentukan kapasitas minimum, kapasitas maksimum, atau keduanya.

Contoh-contoh ini menggunakan target yang dapat diskalakan untuk beberapa layanan yang terintegrasi dengan Application Auto Scaling. Untuk menggunakan target skabel yang berbeda, tentukan namespace di, dimensi yang dapat diskalakan di `--service-namespace--scalable-dimension`, dan ID sumber dayanya di `--resource-id`

Saat menggunakan AWS CLI, ingatlah bahwa perintah Anda berjalan di Wilayah AWS konfigurasi untuk profil Anda. Jika Anda ingin menjalankan perintah di Wilayah yang berbeda, ubah Wilayah default untuk profil Anda, atau gunakan parameter `--region` bersama perintah tersebut.

Contoh

- [Buat tindakan terjadwal yang hanya terjadi sekali](#)
- [Buat tindakan terjadwal yang berjalan pada interval berulang](#)
- [Buat tindakan terjadwal yang berjalan pada jadwal berulang](#)
- [Buat tindakan terjadwal satu kali yang menentukan zona waktu](#)
- [Buat tindakan terjadwal berulang yang menentukan zona waktu](#)

Buat tindakan terjadwal yang hanya terjadi sekali

Untuk secara otomatis menskalakan target yang dapat diskalakan Anda hanya satu kali, pada tanggal dan waktu tertentu, gunakan opsi `--schedule` "at(*yyyy-mm-ddThh:mm:ss*)".

Example Contoh: Untuk menskalakan naik hanya satu kali

Berikut adalah contoh pembuatan tindakan terjadwal untuk melakukan penskalaan naik terhadap kapasitas pada tanggal dan waktu tertentu.

Pada tanggal dan waktu yang ditentukan untuk `--schedule` (pukul 22.00 UTC pada 31 Maret 2021), jika nilai yang ditentukan untuk `MinCapacity` melebihi kapasitas saat ini, Application Auto Scaling menskalakan naik ke `MinCapacity`.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action --service-namespace custom-resource \
--scalable-dimension custom-resource:ResourceType:Property \
--resource-id file://~/custom-resource-id.txt \
--scheduled-action-name scale-out \
--schedule "at(2021-03-31T22:00:00)" \
--scalable-target-action MinCapacity=3
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace custom-resource ^
--scalable-dimension custom-resource:ResourceType:Property ^
--resource-id file://~/custom-resource-id.txt ^
--scheduled-action-name scale-out ^
--schedule "at(2021-03-31T22:00:00)" ^
--scalable-target-action MinCapacity=3
```

Ketika tindakan terjadwal ini berjalan, jika kapasitas maksimum kurang dari nilai yang ditentukan untuk kapasitas minimum, Anda harus menentukan kapasitas minimum dan maksimum baru, dan bukan hanya kapasitas minimum.

Example Contoh: Untuk menskalakan turun hanya satu kali

Berikut adalah contoh pembuatan tindakan terjadwal untuk melakukan penskalaan turun terhadap kapasitas pada tanggal dan waktu tertentu.

Pada tanggal dan waktu yang ditentukan untuk **--schedule** (pukul 22.30 UTC pada 31 Maret 2021), jika nilai yang ditentukan untuk **MaxCapacity** berada di bawah kapasitas saat ini, Application Auto Scaling menskalakan turun ke **MaxCapacity**.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action --service-namespace custom-resource \
--scalable-dimension custom-resource:ResourceType:Property \
--resource-id file://~/custom-resource-id.txt \
--scheduled-action-name scale-in \
--schedule "at(2021-03-31T22:30:00)" \
--scalable-target-action MinCapacity=0,MaxCapacity=0
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace custom-resource ^
--scalable-dimension custom-resource:ResourceType:Property ^
```

```
--resource-id file://~/custom-resource-id.txt ^
--scheduled-action-name scale-in ^
--schedule "at(2021-03-31T22:30:00)" ^
--scalable-target-action MinCapacity=0,MaxCapacity=0
```

Buat tindakan terjadwal yang berjalan pada interval berulang

Untuk menjadwalkan penskalaan pada interval berulang, gunakan opsi `--schedule "rate(value unit)"`. Nilai harus berupa bilangan bulat positif. Unit dapat minute, minutes, hour, hours, day, atau days. Untuk informasi selengkapnya, lihat [Nilai ekspresi](#) di Panduan EventBridge Pengguna Amazon.

Berikut ini adalah contoh tindakan terjadwal yang menggunakan ekspresi rate.

Pada jadwal yang ditentukan (setiap 5 jam mulai tanggal 30 Januari 2021 pukul 12.00 UTC dan berakhir pada tanggal 31 Januari 2021 pukul 22.00 UTC), jika nilai yang ditentukan untuk `MinCapacity` berada di atas kapasitas saat ini, Application Auto Scaling menskalakan keluar ke `MinCapacity`. Jika nilai yang ditentukan untuk `MaxCapacity` berada di bawah kapasitas saat ini, Application Auto Scaling menskalakan kedalam ke `MaxCapacity`.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action --service-namespace ecs \
--scalable-dimension ecs:service:DesiredCount \
--resource-id service/my-cluster/my-service \
--scheduled-action-name my-recurring-action \
--schedule "rate(5 hours)" \
--start-time 2021-01-30T12:00:00 \
--end-time 2021-01-31T22:00:00 \
--scalable-target-action MinCapacity=3,MaxCapacity=10
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace ecs ^
--scalable-dimension ecs:service:DesiredCount ^
--resource-id service/my-cluster/my-service ^
--scheduled-action-name my-recurring-action ^
--schedule "rate(5 hours)" ^
--start-time 2021-01-30T12:00:00 ^
--end-time 2021-01-31T22:00:00 ^
--scalable-target-action MinCapacity=3,MaxCapacity=10
```

Buat tindakan terjadwal yang berjalan pada jadwal berulang

Untuk menjadwalkan penskalaan pada jadwal berulang, gunakan opsi `--schedule "cron(fields)"`. Untuk informasi selengkapnya, lihat [Jadwalkan tindakan penskalaan berulang menggunakan Application Auto Scaling](#).

Berikut ini adalah contoh tindakan terjadwal yang menggunakan ekspresi cron.

Pada jadwal yang ditentukan (setiap hari pukul 09.00 UTC), jika nilai yang ditentukan untuk `MinCapacity` berada di atas kapasitas saat ini, Application Auto Scaling menskalakan naik ke `MinCapacity`. Jika nilai yang ditentukan untuk `MaxCapacity` berada di bawah kapasitas saat ini, Application Auto Scaling menskalakan kedalam ke `MaxCapacity`.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action --service-namespace appstream \  
  --scalable-dimension appstream:fleet:DesiredCapacity \  
  --resource-id fleet/sample-fleet \  
  --scheduled-action-name my-recurring-action \  
  --schedule "cron(0 9 * * ? *)" \  
  --scalable-target-action MinCapacity=10,MaxCapacity=50
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace appstream ^  
  --scalable-dimension appstream:fleet:DesiredCapacity ^  
  --resource-id fleet/sample-fleet ^  
  --scheduled-action-name my-recurring-action ^  
  --schedule "cron(0 9 * * ? *)" ^  
  --scalable-target-action MinCapacity=10,MaxCapacity=50
```

Buat tindakan terjadwal satu kali yang menentukan zona waktu

Tindakan terjadwal diatur ke zona waktu UTC secara default. Untuk menentukan zona waktu yang berbeda, sertakan opsi `--timezone` dan tentukan nama resmi untuk zona waktu (misalnya `America/New_York`). Untuk informasi selengkapnya, lihat <https://www.joda.org/joda-time/timezones.html>, yang menyediakan informasi tentang zona waktu IANA yang didukung saat menelepon [put-scheduled-action](#).

Berikut adalah contoh yang menggunakan opsi `--timezone` saat membuat tindakan terjadwal untuk menskalakan kapasitas pada tanggal dan waktu tertentu.

Pada tanggal dan waktu yang ditentukan untuk --schedule (pukul 17.00 waktu setempat pada 31 Januari 2021), jika nilai yang ditentukan untuk MinCapacity melebihi kapasitas saat ini, Application Auto Scaling menskalakan naik ke MinCapacity. Jika nilai yang ditentukan untuk MaxCapacity berada di bawah kapasitas saat ini, Application Auto Scaling menskalakan kedalam ke MaxCapacity.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action --service-namespace comprehend \
--scalable-dimension comprehend:document-classifier-endpoint:DesiredInferenceUnits \
--resource-id arn:aws:comprehend:us-west-2:123456789012:document-classifier-endpoint/
EXAMPLE \
--scheduled-action-name my-one-time-action \
--schedule "at(2021-01-31T17:00:00)" --timezone "America/New_York" \
--scalable-target-action MinCapacity=1,MaxCapacity=3
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace comprehend ^
--scalable-dimension comprehend:document-classifier-endpoint:DesiredInferenceUnits ^
--resource-id arn:aws:comprehend:us-west-2:123456789012:document-classifier-endpoint/
EXAMPLE ^
--scheduled-action-name my-one-time-action ^
--schedule "at(2021-01-31T17:00:00)" --timezone "America/New_York" ^
--scalable-target-action MinCapacity=1,MaxCapacity=3
```

Buat tindakan terjadwal berulang yang menentukan zona waktu

Berikut adalah contoh yang menggunakan opsi --timezone saat membuat tindakan terjadwal berulang untuk menskalakan kapasitas. Untuk informasi selengkapnya, lihat [Jadwalkan tindakan penskalaan berulang menggunakan Application Auto Scaling](#).

Pada jadwal yang ditentukan (setiap Senin hingga Jumat pukul 18.00 waktu setempat), jika nilai yang ditentukan untuk MinCapacity berada di atas kapasitas saat ini, Application Auto Scaling menskalakan naik ke MinCapacity. Jika nilai yang ditentukan untuk MaxCapacity berada di bawah kapasitas saat ini, Application Auto Scaling menskalakan kedalam ke MaxCapacity.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action --service-namespace lambda \
```

```
--scalable-dimension lambda:function:ProvisionedConcurrency \
--resource-id function:my-function:BLUE \
--scheduled-action-name my-recurring-action \
--schedule "cron(0 18 ? * MON-FRI *)" --timezone "Etc/GMT+9" \
--scalable-target-action MinCapacity=10,MaxCapacity=50
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace Lambda ^
--scalable-dimension lambda:function:ProvisionedConcurrency ^
--resource-id function:my-function:BLUE ^
--scheduled-action-name my-recurring-action ^
--schedule "cron(0 18 ? * MON-FRI *)" --timezone "Etc/GMT+9" ^
--scalable-target-action MinCapacity=10,MaxCapacity=50
```

Jelaskan penskalaan terjadwal untuk Application Auto Scaling menggunakan AWS CLI

Contoh AWS CLI perintah ini menjelaskan aktivitas penskalaan dan tindakan terjadwal menggunakan sumber daya dari layanan yang terintegrasi dengan Application Auto Scaling. Untuk target skabel yang berbeda, tentukan namespace di `--service-namespace`, dimensi yang dapat diskalakan di `--scalable-dimension`, dan ID sumber dayanya di `--resource-id`.

Saat menggunakan AWS CLI, ingatlah bahwa perintah Anda berjalan di Wilayah AWS konfigurasi untuk profil Anda. Jika Anda ingin menjalankan perintah di Wilayah yang berbeda, ubah Wilayah default untuk profil Anda, atau gunakan parameter `--region` bersama perintah tersebut.

Contoh

- [Jelaskan aktivitas penskalaan untuk layanan](#)
- [Jelaskan tindakan terjadwal untuk suatu layanan](#)
- [Jelaskan tindakan terjadwal untuk target yang dapat diskalakan](#)

Jelaskan aktivitas penskalaan untuk layanan

Untuk melihat aktivitas penskalaan untuk semua target yang dapat diskalakan dalam namespace layanan tertentu, gunakan perintah tersebut. [describe-scaling-activities](#)

Contoh berikut mengambil aktivitas penskalaan yang terkait dengan namespace layanan dynamodb.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scaling-activities --service-namespace dynamodb
```

Windows

```
aws application-autoscaling describe-scaling-activities --service-namespace dynamodb
```

Output

Jika perintah berhasil, ia mengembalikan output yang mirip dengan berikut ini.

```
{
  "ScalingActivities": [
    {
      "ScalableDimension": "dynamodb:table:WriteCapacityUnits",
      "Description": "Setting write capacity units to 10.",
      "ResourceId": "table/my-table",
      "ActivityId": "4d1308c0-bbcf-4514-a673-b0220ae38547",
      "StartTime": 1561574415.086,
      "ServiceNamespace": "dynamodb",
      "EndTime": 1561574449.51,
      "Cause": "maximum capacity was set to 10",
      "StatusMessage": "Successfully set write capacity units to 10. Change successfully fulfilled by dynamodb.",
      "StatusCode": "Successful"
    },
    {
      "ScalableDimension": "dynamodb:table:WriteCapacityUnits",
      "Description": "Setting min capacity to 5 and max capacity to 10",
      "ResourceId": "table/my-table",
      "ActivityId": "f2b7847b-721d-4e01-8ef0-0c8d3bacc1c7",
      "StartTime": 1561574414.644,
      "ServiceNamespace": "dynamodb",
      "Cause": "scheduled action name my-second-scheduled-action was triggered",
      "StatusMessage": "Successfully set min capacity to 5 and max capacity to 10",
      "StatusCode": "Successful"
    },
    {
      "ScalableDimension": "dynamodb:table:WriteCapacityUnits",
      "Description": "Setting write capacity units to 15."
    }
  ]
}
```

```
"ResourceId": "table/my-table",
"ActivityId": "d8ea4de6-9eaa-499f-b466-2cc5e681ba8b",
"StartTime": 1561574108.904,
"ServiceNamespace": "dynamodb",
"EndTime": 1561574140.255,
"Cause": "minimum capacity was set to 15",
>StatusMessage": "Successfully set write capacity units to 15. Change successfully fulfilled by dynamodb.",
"StatusCode": "Successful"
},
{
"ScalableDimension": "dynamodb:table:WriteCapacityUnits",
>Description": "Setting min capacity to 15 and max capacity to 20",
"ResourceId": "table/my-table",
"ActivityId": "3250fd06-6940-4e8e-bb1f-d494db7554d2",
"StartTime": 1561574108.512,
"ServiceNamespace": "dynamodb",
"Cause": "scheduled action name my-first-scheduled-action was triggered",
>StatusMessage": "Successfully set min capacity to 15 and max capacity to 20",
"StatusCode": "Successful"
}
]
```

Untuk mengubah perintah ini sehingga mengambil aktivitas penskalaan hanya untuk satu target yang dapat diskalakan Anda, tambahkan opsi `--resource-id`.

Jelaskan tindakan terjadwal untuk suatu layanan

Untuk menjelaskan tindakan terjadwal untuk semua target yang dapat diskalakan dalam namespace layanan tertentu, gunakan perintah. [describe-scheduled-actions](#)

Contoh berikut mengambil tindakan terjadwal yang terkait dengan namespace layanan ec2.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scheduled-actions --service-namespace ec2
```

Windows

```
aws application-autoscaling describe-scheduled-actions --service-namespace ec2
```

Output

Jika perintah berhasil, ia mengembalikan output yang mirip dengan berikut ini.

```
{  
  "ScheduledActions": [  
    {  
      "ScheduledActionName": "my-one-time-action",  
      "ScheduledActionARN": "arn:aws:autoscaling:us-  
west-2:123456789012:scheduledAction:493a6261-fbb9-432d-855d-3c302c14bdb9:resource/ec2/  
spot-fleet-request/sfr-107dc873-0802-4402-a901-37294EXAMPLE:scheduledActionName/my-one-  
time-action",  
      "ServiceNamespace": "ec2",  
      "Schedule": "at(2021-01-31T17:00:00)",  
      "Timezone": "America/New_York",  
      "ResourceId": "spot-fleet-request/sfr-107dc873-0802-4402-  
a901-37294EXAMPLE",  
      "ScalableDimension": "ec2:spot-fleet-request:TargetCapacity",  
      "ScalableTargetAction": {  
        "MaxCapacity": 1  
      },  
      "CreationTime": 1607454792.331  
    },  
    {  
      "ScheduledActionName": "my-recurring-action",  
      "ScheduledActionARN": "arn:aws:autoscaling:us-  
west-2:123456789012:scheduledAction:493a6261-fbb9-432d-855d-3c302c14bdb9:resource/ec2/  
spot-fleet-request/sfr-107dc873-0802-4402-a901-37294EXAMPLE:scheduledActionName/my-  
recurring-action",  
      "ServiceNamespace": "ec2",  
      "Schedule": "rate(5 minutes)",  
      "ResourceId": "spot-fleet-request/sfr-107dc873-0802-4402-  
a901-37294EXAMPLE",  
      "ScalableDimension": "ec2:spot-fleet-request:TargetCapacity",  
      "StartTime": 1604059200.0,  
      "EndTime": 1612130400.0,  
      "ScalableTargetAction": {  
        "MinCapacity": 3,  
        "MaxCapacity": 10  
      },  
      "CreationTime": 1607454949.719  
    },  
    {  
      "ScheduledActionName": "my-one-time-action",  
    }  
  ]  
}
```

```
        "ScheduledActionARN": "arn:aws:autoscaling:us-west-2:123456789012:scheduledAction:4bce34c7-bb81-4ecf-b776-5c726efb1567:resource/ec2/spot-fleet-request/sfr-40edeb7b-9ae7-44be-bef2-5c4c8EXAMPLE:scheduledActionName/my-one-time-action",
        "ServiceNamespace": "ec2",
        "Schedule": "at(2020-12-08T9:36:00)",
        "Timezone": "America/New_York",
        "ResourceId": "spot-fleet-request/sfr-40edeb7b-9ae7-44be-bef2-5c4c8EXAMPLE",
        "ScalableDimension": "ec2:spot-fleet-request:TargetCapacity",
        "ScalableTargetAction": {
            "MinCapacity": 1,
            "MaxCapacity": 3
        },
        "CreationTime": 1607456031.391
    }
]
}
```

Jelaskan tindakan terjadwal untuk target yang dapat diskalakan

Untuk mengambil informasi tentang tindakan terjadwal untuk target terukur tertentu, tambahkan `--resource-id` opsi saat menjelaskan tindakan terjadwal menggunakan perintah. [describe-scheduled-actions](#)

Jika Anda menyertakan opsi `--scheduled-action-names` dan menentukan nama tindakan terjadwal sebagai nilainya, perintah mengembalikan hanya tindakan terjadwal yang namanya cocok, seperti yang ditunjukkan pada contoh berikut.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scheduled-actions --service-namespace ec2 \
--resource-id spot-fleet-request/sfr-40edeb7b-9ae7-44be-bef2-5c4c8EXAMPLE \
--scheduled-action-names my-one-time-action
```

Windows

```
aws application-autoscaling describe-scheduled-actions --service-namespace ec2 ^
--resource-id spot-fleet-request/sfr-40edeb7b-9ae7-44be-bef2-5c4c8EXAMPLE ^
--scheduled-action-names my-one-time-action
```

Output

Jika perintah berhasil, ia mengembalikan output yang mirip dengan berikut ini. Jika Anda memberikan lebih dari satu nilai untuk--scheduled-action-names, output mencakup semua tindakan terjadwal yang namanya cocok.

```
{  
    "ScheduledActions": [  
        {  
            "ScheduledActionName": "my-one-time-action",  
            "ScheduledActionARN": "arn:aws:autoscaling:us-  
west-2:123456789012:scheduledAction:4bce34c7-bb81-4ecf-b776-5c726efb1567:resource/ec2/  
spot-fleet-request/sfr-40edeb7b-9ae7-44be-bef2-5c4c8EXAMPLE:scheduledActionName/my-one-  
time-action",  
            "ServiceNamespace": "ec2",  
            "Schedule": "at(2020-12-08T9:36:00)",  
            "Timezone": "America/New_York",  
            "ResourceId": "spot-fleet-request/sfr-40edeb7b-9ae7-44be-  
bef2-5c4c8EXAMPLE",  
            "ScalableDimension": "ec2:spot-fleet-request:TargetCapacity",  
            "ScalableTargetAction": {  
                "MinCapacity": 1,  
                "MaxCapacity": 3  
            },  
            "CreationTime": 1607456031.391  
        }  
    ]  
}
```

Jadwalkan tindakan penskalaan berulang menggunakan Application Auto Scaling

Important

Untuk bantuan dengan ekspresi cron untuk Amazon EC2 Auto Scaling, lihat topik [Jadwal berulang di Panduan Pengguna Auto Scaling](#) Amazon EC2. Dengan Amazon EC2 Auto Scaling, Anda menggunakan sintaks cron tradisional alih-alih sintaks cron khusus yang digunakan Application Auto Scaling.

Anda dapat membuat tindakan terjadwal yang berjalan pada jadwal berulang menggunakan ekspresi cron.

Untuk membuat jadwal berulang, tentukan ekspresi cron dan zona waktu untuk menjelaskan kapan tindakan terjadwal itu akan berulang. Nilai zona waktu yang didukung adalah nama kanonik dari zona waktu IANA yang didukung oleh [Joda-Time](#) (seperti atau). Etc/GMT+9 Pacific/Tahiti Anda dapat secara opsional menentukan tanggal dan waktu untuk waktu mulai, waktu akhir, atau keduanya. Untuk contoh perintah yang menggunakan AWS CLI untuk membuat tindakan terjadwal, lihat [Buat tindakan terjadwal berulang yang menentukan zona waktu](#).

Format ekspresi cron yang didukung terdiri dari enam bidang yang dipisahkan oleh spasi putih: [Minutes] [Hours] [Day_of_month] [Month] [Day_of_week] [Year]. Misalnya, ekspresi cron 30 6 ? * MON * mengkonfigurasi tindakan terjadwal yang berulang setiap hari Senin pukul 6:30 pagi. Tanda bintang digunakan sebagai wildcard untuk mencocokkan semua nilai untuk bidang.

Untuk informasi selengkapnya tentang sintaks cron untuk tindakan terjadwal Application Auto Scaling, lihat [Referensi ekspresi cron di Panduan Pengguna Amazon EventBridge](#)

Saat Anda membuat jadwal berulang, pilih waktu mulai dan akhir Anda dengan hati-hati. Ingatlah hal-hal berikut ini:

- Jika Anda menentukan waktu mulai, Application Auto Scaling melakukan tindakan saat ini, dan kemudian melakukan tindakan berulang berdasarkan pengulangan yang ditentukan.
- Jika Anda menentukan waktu akhir, tindakan berhenti berulang setelah waktu ini. Application Auto Scaling tidak melacak nilai sebelumnya dan kembali ke nilai sebelumnya setelah waktu berakhir.
- Waktu mulai dan waktu berakhir harus diatur dalam UTC saat Anda menggunakan AWS CLI atau AWS SDK untuk membuat atau memperbarui tindakan terjadwal.

Contoh

Anda dapat merujuk ke tabel berikut saat membuat jadwal berulang untuk target Application Auto Scaling yang dapat diskalakan. Contoh berikut adalah sintaks yang benar untuk menggunakan Application Auto Scaling untuk membuat atau memperbarui tindakan terjadwal.

Menit	Jam	Hari dalam sebulan	Bulan	Hari dalam seminggu	Tahun	Arti
0	10	*	*	?	*	Jalankan pada pukul

Menit	Jam	Hari dalam sebulan	Bulan	Hari dalam seminggu	Tahun	Arti
						10:00 pagi (UTC) setiap hari
15	12	*	*	?	*	Jalankan pada pukul 12.15 (UTC) setiap hari
0	18	?	*	MON-FRI	*	Jalankan pada pukul 18.00 (UTC) setiap Senin hingga Jumat
0	8	1	*	?	*	Jalankan pukul 08.00 (UTC) pada hari pertama setiap bulan
0/15	*	*	*	?	*	Jalankan setiap 15 menit

Menit	Jam	Hari dalam sebulan	Bulan	Hari dalam seminggu	Tahun	Arti
0/10	*	?	*	MON-FRI	*	Jalankan setiap 10 menit Senin hingga Jumat
0/5	8-17	?	*	MON-FRI	*	Jalankan setiap 5 menit Senin hingga Jumat antara pukul 08.00 dan 17.55 (UTC)

Pengecualian

Anda juga dapat membuat ekspresi cron dengan nilai string yang berisi tujuh bidang. Dalam hal ini, Anda dapat menggunakan tiga bidang pertama untuk menentukan waktu kapan tindakan terjadwal harus dijalankan, termasuk detik. Ekspresi cron lengkap memiliki bidang yang dipisahkan spasi berikut: [Seconds] [Minutes] [Hours] [Day_of_month] [Month] [Day_of_week] [Year]. Namun, pendekatan ini tidak menjamin bahwa tindakan terjadwal akan berjalan pada detik yang tepat yang Anda tentukan. Selain itu, beberapa konsol layanan mungkin tidak mendukung bidang detik dalam ekspresi cron.

Matikan penskalaan terjadwal untuk target yang dapat diskalakan

Anda dapat mematikan sementara penskalaan terjadwal tanpa menghapus tindakan terjadwal. Untuk informasi selengkapnya, lihat [Menangguhkan dan melanjutkan penskalaan untuk Application Auto Scaling](#).

Untuk menangguhkan penskalaan terjadwal

Tangguhkan penskalaan terjadwal pada target yang dapat diskalakan dengan menggunakan [register-scalable-target](#) perintah dengan --suspended-state opsi, dan tentukan true sebagai nilai ScheduledScalingSuspended atribut, seperti yang ditunjukkan pada contoh berikut.

Linux, macOS, atau Unix

```
aws application-autoscaling register-scaling-target --service-namespace rds \
--scalable-dimension rds:cluster:ReadReplicaCount --resource-id cluster:my-db-cluster \
--suspended-state '{"ScheduledScalingSuspended": true}'
```

Windows

```
aws application-autoscaling register-scaling-target --service-namespace rds ^
--scalable-dimension rds:cluster:ReadReplicaCount --resource-id cluster:my-db-cluster
^
--suspended-state "{\"ScheduledScalingSuspended\": true}"
```

Output

Jika perintah berhasil, ia mengembalikan ARN dari target yang dapat diskalakan. Berikut ini adalah output contoh.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

Untuk melanjutkan penskalaan terjadwal

Untuk melanjutkan penskalaan terjadwal, jalankan register-scaling-target perintah lagi, tentukan false sebagai nilai untuk ScheduledScalingSuspended

Menghapus tindakan terjadwal untuk Application Auto Scaling menggunakan AWS CLI

Setelah selesai dengan tindakan terjadwal, Anda dapat menghapusnya.

Untuk menghapus tindakan terjadwal Anda

Gunakan perintah [delete-scheduled-action](#). Jika berhasil, perintah ini tidak mengembalikan output apa pun.

Linux, macOS, atau Unix

```
aws application-autoscaling delete-scheduled-action \
--service-namespace ec2 \
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \
--resource-id spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-37294EXAMPLE \
--scheduled-action-name my-recurring-action
```

Windows

```
aws application-autoscaling delete-scheduled-action ^
--service-namespace ec2 ^
--scalable-dimension ec2:spot-fleet-request:TargetCapacity ^
--resource-id spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-37294EXAMPLE ^
--scheduled-action-name my-recurring-action
```

Untuk membatalkan pendaftaran target yang dapat diskalakan

Jika Anda juga selesai dengan target yang dapat diskalakan, Anda dapat membatalkan pendaftarannya. Gunakan perintah berikut [deregister-scalabe-target](#). Jika ada kebijakan penskalaan atau tindakan terjadwal yang belum dihapus, mereka akan dihapus oleh perintah ini. Jika berhasil, perintah ini tidak mengembalikan output apa pun.

Linux, macOS, atau Unix

```
aws application-autoscaling deregister-scalabe-target \
--service-namespace ec2 \
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \
--resource-id spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-37294EXAMPLE
```

Windows

```
aws application-autoscaling deregister-scalabe-target ^
--service-namespace ec2 ^
--scalable-dimension ec2:spot-fleet-request:TargetCapacity ^
--resource-id spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-37294EXAMPLE
```

Kebijakan penskalaan pelacakan target untuk Application Auto Scaling

Kebijakan penskalaan pelacakan target secara otomatis menskalakan aplikasi Anda berdasarkan nilai metrik target. Hal ini memungkinkan aplikasi Anda untuk mempertahankan kinerja optimal dan efisiensi biaya tanpa intervensi manual.

Dengan pelacakan target, Anda memilih metrik dan nilai target untuk mewakili tingkat pemanfaatan atau throughput rata-rata yang ideal untuk aplikasi Anda. Application Auto Scaling membuat dan mengelola CloudWatch alarm yang memicu peristiwa penskalaan saat metrik menyimpang dari target. Ini mirip dengan bagaimana termostat mempertahankan suhu target.

Misalnya, katakanlah Anda saat ini memiliki aplikasi yang berjalan di Spot Fleet, dan Anda ingin pemanfaatan CPU armada tetap sekitar 50 persen saat beban pada aplikasi berubah. Ini memberi Anda kapasitas ekstra untuk menangani lonjakan lalu lintas tanpa mempertahankan jumlah berlebih dari sumber daya yang tidak aktif.

Anda dapat memenuhi kebutuhan ini dengan membuat kebijakan penskalaan pelacakan target yang menargetkan pemanfaatan CPU rata-rata 50 persen. Kemudian, Application Auto Scaling akan keluar (meningkatkan kapasitas) ketika CPU melebihi 50 persen untuk menangani peningkatan beban. Ini akan menskalakan (penurunan kapasitas) ketika CPU turun di bawah 50 persen untuk mengoptimalkan biaya selama periode pemanfaatan rendah.

Kebijakan pelacakan target menghilangkan kebutuhan untuk menentukan CloudWatch alarm dan penyesuaian penskalaan secara manual. Application Auto Scaling menangani ini secara otomatis berdasarkan target yang Anda tetapkan.

Anda dapat mendasarkan kebijakan pelacakan target pada metrik yang telah ditentukan atau kustom:

- Metrik yang telah ditentukan sebelumnya —Metrik yang disediakan oleh Application Auto Scaling seperti penggunaan CPU rata-rata atau jumlah permintaan rata-rata per target.
- Metrik kustom —Anda dapat menggunakan matematika metrik untuk menggabungkan metrik, memanfaatkan metrik yang ada, atau menggunakan metrik kustom Anda sendiri yang dipublikasikan. CloudWatch

Pilih metrik yang berubah berbanding terbalik dengan perubahan kapasitas target Anda yang dapat diskalakan. Jadi jika Anda menggandakan kapasitas, metriknya berkurang 50 persen. Hal ini memungkinkan data metrik untuk secara akurat memicu peristiwa penskalaan proporsional.

Daftar Isi

- [Cara kerja penskalaan pelacakan target untuk Application Auto Scaling](#)
- [Membuat kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan AWS CLI](#)
- [Menghapus kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan AWS CLI](#)
- [Membuat kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan matematika metrik](#)

Cara kerja penskalaan pelacakan target untuk Application Auto Scaling

Topik ini menjelaskan cara kerja penskalaan pelacakan target dan memperkenalkan elemen kunci dari kebijakan penskalaan pelacakan target.

Daftar Isi

- [Cara kerjanya](#)
- [Pilih metrik](#)
- [Tentukan nilai target](#)
- [Tentukan periode cooldown](#)
- [Pertimbangan](#)
- [Beberapa kebijakan penskalaan](#)
- [Perintah yang umum digunakan untuk penskalaan pembuatan kebijakan, manajemen, dan penghapusan](#)
- [Sumber daya terkait](#)
- [Batasan](#)

Cara kerjanya

Untuk menggunakan penskalaan pelacakan target, Anda membuat kebijakan penskalaan pelacakan target dan menentukan hal berikut:

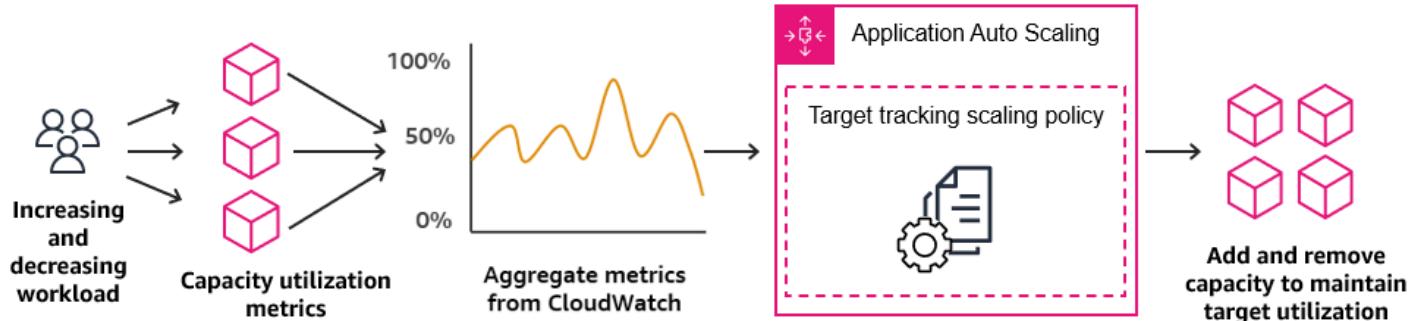
- Metrik CloudWatch —Metrik untuk dilacak, seperti pemanfaatan CPU rata-rata atau jumlah permintaan rata-rata per target.
- Nilai target — Nilai target untuk metrik, seperti 50 persen pemanfaatan CPU atau 1000 permintaan per target per menit.

Application Auto Scaling membuat dan mengelola CloudWatch alarm yang menjalankan kebijakan penskalaan dan menghitung penyesuaian penskalaan berdasarkan metrik dan nilai target. Ini menambah dan menghapus kapasitas seperti yang diperlukan untuk menjaga metrik pada, atau mendekati, nilai target yang ditentukan.

Ketika metrik berada di atas nilai target, Application Auto Scaling keluar dengan menambahkan kapasitas untuk mengurangi perbedaan antara nilai metrik dan nilai target. Ketika metrik berada di bawah nilai target, Application Auto Scaling masuk dengan menghapus kapasitas.

Aktivitas penskalaan dilakukan dengan periode cooldown di antara mereka untuk mencegah fluktuasi kapasitas yang cepat. Anda dapat secara opsional mengonfigurasi periode cooldown untuk kebijakan penskalaan Anda.

Diagram berikut menunjukkan gambaran umum tentang cara kerja kebijakan penskalaan pelacakan target saat penyiapan selesai.



Perhatikan bahwa kebijakan penskalaan pelacakan target lebih agresif dalam menambah kapasitas saat pemanfaatan meningkat daripada menghilangkan kapasitas saat pemanfaatan menurun. Misalnya, jika metrik yang ditentukan kebijakan mencapai nilai targetnya, kebijakan tersebut mengasumsikan bahwa aplikasi Anda sudah banyak dimuat. Jadi metrik akan merespons dengan

menambahkan kapasitas proporsional terhadap nilai metrik secepat mungkin. Semakin tinggi metrik, semakin banyak kapasitas yang ditambahkan.

Ketika metrik berada di bawah nilai target, kebijakan “mengharapkan” bahwa pemanfaatan pada akhirnya akan meningkat lagi. Dalam hal ini, memperlambat penskalaan dengan menghapus kapasitas hanya ketika pemanfaatan melewati ambang batas yang cukup jauh di bawah nilai target (biasanya lebih dari 10% lebih rendah) agar pemanfaatan dianggap melambat. Tujuan dari perilaku yang lebih konservatif ini adalah untuk memastikan bahwa menghapus kapasitas hanya terjadi ketika aplikasi tidak lagi mengalami permintaan pada tingkat yang sama tinggi seperti sebelumnya.

Pilih metrik

Anda dapat membuat kebijakan penskalaan pelacakan target dengan metrik yang telah ditentukan sebelumnya atau metrik khusus.

Saat membuat kebijakan penskalaan pelacakan target dengan tipe metrik yang telah ditentukan sebelumnya, Anda memilih satu metrik dari daftar metrik yang telah ditentukan sebelumnya. [Metrik yang telah ditentukan sebelumnya untuk kebijakan penskalaan pelacakan target](#)

Inginlah hal-hal berikut ini saat memilih metrik:

- Tidak semua metrik khusus berfungsi untuk pelacakan target. Metrik harus berupa metrik pemanfaatan yang valid dan menjelaskan seberapa sibuk target yang dapat diskalakan. Nilai metrik harus meningkat atau menurun secara proporsional sesuai kapasitas target yang dapat diskalakan, sehingga data metrik dapat digunakan untuk skala proporsional pada target yang dapat diskalakan.
- Untuk menggunakan metrik ALBRequestCountPerTarget, Anda harus menentukan parameter ResourceLabel guna mengidentifikasi grup target yang terkait dengan metrik.
- Ketika metrik memancarkan nilai 0 nyata ke CloudWatch (misalnya, ALBRequestCountPerTarget), Application Auto Scaling dapat menskalakan ke 0 ketika tidak ada lalu lintas ke aplikasi Anda untuk jangka waktu yang berkelanjutan. Untuk memiliki skala target yang dapat diskalakan Anda ke 0 ketika tidak ada permintaan yang dirutekan, kapasitas minimum target yang dapat diskalakan harus diatur ke 0.
- Alih-alih menerbitkan metrik baru untuk digunakan dalam kebijakan penskalaan, Anda dapat menggunakan matematika metrik untuk menggabungkan metrik yang ada. Untuk informasi selengkapnya, lihat [Membuat kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan matematika metrik](#).

- Untuk melihat apakah layanan yang Anda gunakan mendukung penetapan metrik kustom di konsol layanan, lihat dokumentasi untuk layanan tersebut.
- Kami menyarankan Anda menggunakan metrik yang tersedia pada interval satu menit untuk membantu Anda menskalakan lebih cepat dalam menanggapi perubahan pemanfaatan. Pelacakan target akan mengevaluasi metrik yang dikumpulkan pada perincian satu menit untuk semua metrik dan metrik khusus yang telah ditentukan sebelumnya, tetapi metrik yang mendasarinya mungkin lebih jarang mempublikasikan data. Misalnya, semua metrik Amazon EC2 dikirim dalam interval lima menit secara default, tetapi dapat dikonfigurasi hingga satu menit (dikenal sebagai pemantauan terperinci). Pilihan ini terserah layanan individu. Sebagian besar mencoba menggunakan interval sekecil mungkin.

Tentukan nilai target

Saat membuat kebijakan penskalaan pelacakan target, Anda harus menentukan nilai target. Nilai target mewakili pemanfaatan atau throughput rata-rata optimal untuk aplikasi Anda. Untuk menggunakan biaya sumber daya secara efisien, tetapkan nilai target setinggi mungkin dengan buffer yang masuk akal untuk peningkatan lalu lintas yang tidak terduga. Ketika aplikasi Anda diskalakan secara optimal untuk arus lalu lintas normal, nilai metrik sebenarnya harus berada pada atau tepat di bawah nilai target.

Jika kebijakan penskalaan didasarkan pada throughput, seperti jumlah permintaan per target untuk Application Load Balancer, I/O jaringan, atau metrik hitungan lainnya, nilai target mewakili throughput rata-rata optimal dari satu entitas (seperti target tunggal grup target Application Load Balancer Anda), selama satu menit.

Tentukan periode cooldown

Anda dapat secara opsional menentukan periode cooldown dalam kebijakan penskalaan pelacakan target Anda.

Periode cooldown menentukan jumlah waktu kebijakan penskalaan menunggu aktivitas penskalaan sebelumnya berlaku.

Ada dua jenis periode cooldown:

- Dengan periode jeda pakai untuk pengecilan skala, tujuannya adalah untuk menskalakan secara terus-menerus (tetapi tidak berlebihan). Setelah Application Auto Scaling berhasil menskalakan menggunakan kebijakan penskalaan, Application Auto Scaling mulai menghitung

waktu cooldown. Kebijakan penskalaan tidak akan meningkatkan kapasitas yang diinginkan lagi kecuali jika skala keluar yang lebih besar dipicu atau periode cooldown berakhir. Selama periode pendinginan penskalaan keluar berlaku, kapasitas yang ditambahkan dengan cara memulai aktivitas penskalaan keluar dihitung sebagai bagian dari kapasitas yang diinginkan untuk aktivitas penskalaan keluar berikutnya.

- Dengan periode cooldown scale-in, tujuannya adalah untuk menskalakan secara konservatif untuk melindungi ketersediaan aplikasi Anda, sehingga aktivitas scale-in diblokir hingga periode cooldown scale-in berakhir. Namun, jika alarm lain memicu aktivitas pengecilan skala selama periode jeda pakai untuk pembesaran skala, Application Auto Scaling akan langsung memperkecil skala target. Dalam hal ini, periode cooldown scale-in berhenti dan tidak selesai.

Setiap periode jeda pakai diukur dalam hitungan detik dan hanya berlaku untuk aktivitas penskalaan terkait kebijakan. Selama periode jeda pakai, ketika tindakan terjadwal dimulai pada waktu yang dijadwalkan, tindakan ini dapat segera memicu aktivitas penskalaan tanpa menunggu periode jeda pakai berakhir.

Anda dapat mulai dengan nilai default, yang dapat diatur kemudian. Misalnya, Anda mungkin perlu meningkatkan periode jeda pakai untuk mencegah kebijakan penskalaan pelacakan target Anda menjadi terlalu agresif terhadap perubahan yang terjadi dalam periode waktu singkat.

Nilai default

Application Auto Scaling memberikan nilai default 600 untuk grup ElastiCache replikasi dan nilai default 300 untuk target skalabel berikut:

- AppStream 2.0 armada
- Klaster DB Aurora
- Layanan ECS
- Cluster Neptunus
- SageMaker varian titik akhir
- SageMaker komponen inferensi
- SageMaker Konkurensi yang disediakan tanpa server
- Armada Spot
- Kolam renang WorkSpaces
- Sumber daya khusus

Untuk semua target skala lainnya, nilai defaultnya adalah 0 atau null:

- Klasifikasi dokumen dan titik akhir pengenal entitas Amazon Comprehend
- Tabel DynamoDB dan indeks sekunder global
- Tabel Amazon Keyspaces
- Konkurensi terprovisi Lambda
- Penyimpanan broker Amazon MSK

Nilai nol diperlakukan sama dengan nilai nol saat Application Auto Scaling mengevaluasi periode cooldown.

Anda dapat memperbarui salah satu nilai default, termasuk nilai nol, untuk mengatur periode cooldown Anda sendiri.

Pertimbangan

Pertimbangan berikut berlaku saat bekerja dengan kebijakan penskalaan pelacakan target:

- Jangan membuat, mengedit, atau menghapus CloudWatch alarm yang digunakan dengan kebijakan penskalaan pelacakan target. Application Auto Scaling membuat dan mengelola CloudWatch alarm yang terkait dengan kebijakan penskalaan pelacakan target Anda dan menghapusnya saat tidak diperlukan lagi.
- Jika metrik kehilangan titik data, ini menyebabkan status CloudWatch alarm berubah menjadi `INSUFFICIENT_DATA`. Ketika ini terjadi, Application Auto Scaling tidak dapat menskalakan target Anda yang dapat diskalakan hingga titik data baru ditemukan. Untuk informasi selengkapnya, lihat [Mengonfigurasi cara CloudWatch alarm menangani data yang hilang](#) di CloudWatch Panduan Pengguna Amazon.
- Jika metrik jarang dilaporkan oleh desain, matematika metrik dapat membantu. Misalnya, untuk menggunakan nilai terbaru, maka gunakan `FILL(m1, REPEAT)` fungsi di `m1` mana metrik.
- Anda mungkin melihat kesenjangan antara nilai target dan titik data metrik aktual. Ini karena Application Auto Scaling selalu bertindak konservatif dengan membulatkan ke atas atau ke bawah saat menentukan berapa banyak kapasitas yang dapat ditambahkan atau dihapus. Hal ini mencegah penambahan kapasitas yang tidak memadai atau menghilangkan kapasitas yang terlalu banyak. Namun, untuk target yang dapat diskalakan dengan kapasitas kecil, titik data metrik aktual mungkin tampak jauh dari nilai target.

Untuk target yang dapat diskalakan dengan kapasitas yang lebih besar, menambah atau menghilangkan kapasitas menyebabkan berkurangnya kesenjangan antara nilai target dan titik data metrik aktual.

- Kebijakan penskalaan pelacakan target mengasumsikan bahwa penskalaan ke luar harus dilakukan saat metrik yang ditentukan berada di atas nilai target. Anda tidak dapat menggunakan kebijakan penskalaan pelacakan target untuk menskalakan ke luar jika metrik yang ditentukan berada di bawah nilai target.

Beberapa kebijakan penskalaan

Anda dapat memiliki beberapa kebijakan penskalaan pelacakan target untuk target yang dapat diskalakan, asalkan setiapnya menggunakan metrik yang berbeda. Tujuan Application Auto Scaling adalah untuk selalu memprioritaskan ketersediaan, sehingga perilakunya berbeda tergantung pada apakah kebijakan pelacakan target siap untuk diperkecil atau diperbesar. Hal ini akan memperkecil skala target yang dapat diskala jika salah satu kebijakan pelacakan target siap untuk diperkecil skalanya, tetapi hanya akan memperbesar skala jika semua kebijakan pelacakan target (dengan penskalaan dalam porsi aktif) siap untuk diperbesar skalanya.

Jika beberapa kebijakan penskalaan menginstruksikan target yang dapat diskalakan untuk skala keluar atau masuk pada saat yang sama, Application Auto Scaling menskalakan berdasarkan kebijakan yang menyediakan kapasitas terbesar untuk skala masuk dan skala keluar. Ini memberikan fleksibilitas yang lebih besar untuk mencakup beberapa skenario dan memastikan bahwa selalu ada kapasitas yang cukup untuk memproses beban kerja Anda.

Anda dapat menonaktifkan bagian penskalaan dari kebijakan penskalaan pelacakan target untuk menggunakan metode penskalaan yang berbeda dari yang Anda gunakan untuk skala keluar. Misalnya, Anda dapat menggunakan kebijakan penskalaan langkah untuk memperbesar skala saat menggunakan kebijakan penskalaan pelacakan target untuk memperkecil skala.

Namun, kami menyarankan untuk berhati-hati ketika menggunakan kebijakan penskalaan pelacakan target dengan kebijakan penskalaan langkah karena konflik antarkebijakan ini dapat menyebabkan hal yang tidak diinginkan. Misalnya, jika kebijakan penskalaan langkah memulai aktivitas pembesaran skala sebelum kebijakan pelacakan target siap untuk memulai pembesaran skala, aktivitas pembesaran skala tidak akan diblokir. Setelah aktivitas pembesaran skala selesai, kebijakan pelacakan target dapat menginstruksikan target yang dapat diskalakan untuk kembali diperkecil scalanya.

Untuk muatan kerja yang bersifat siklus, Anda juga memiliki opsi untuk mengotomatisasi perubahan kapasitas pada jadwal menggunakan penskalaan terjadwal. Untuk setiap tindakan terjadwal, nilai kapasitas minimum dan maksimum yang baru dapat ditentukan. Nilai ini membentuk batasan kebijakan penskalaan. Kombinasi penskalaan terjadwal dan penskalaan pelacakan target dapat membantu mengurangi dampak peningkatan tajam pada tingkat pemanfaatan, ketika kapasitas diperlukan dengan segera.

Perintah yang umum digunakan untuk penskalaan pembuatan kebijakan, manajemen, dan penghapusan

Perintah yang umum digunakan untuk bekerja dengan kebijakan penskalaan meliputi:

- [register-scalable-target](#)untuk mendaftarkan AWS atau menyesuaikan sumber daya sebagai target yang dapat diskalakan (sumber daya yang dapat diskalakan oleh Application Auto Scaling), dan untuk menangguhkan dan melanjutkan penskalaan.
- [put-scaling-policy](#)untuk menambah atau memodifikasi kebijakan penskalaan untuk target skalabel yang ada.
- [describe-scaling-activities](#)untuk mengembalikan informasi tentang aktivitas penskalaan di suatu AWS Wilayah.
- [describe-scaling-policies](#)untuk mengembalikan informasi tentang kebijakan penskalaan di AWS Wilayah.
- [delete-scaling-policy](#) untuk menghapus kebijakan penskalaan.

Sumber daya terkait

Untuk informasi tentang membuat kebijakan penskalaan pelacakan target untuk grup Auto Scaling, lihat [Kebijakan penskalaan pelacakan target untuk Penskalaan Otomatis Amazon EC2 di Panduan Pengguna Penskalaan Otomatis Amazon EC2](#).

Batasan

Berikut ini adalah keterbatasan saat menggunakan kebijakan penskalaan pelacakan target:

- Target yang dapat diskalakan tidak bisa menjadi klaster Amazon EMR. Kebijakan penskalaan pelacakan target untuk Amazon EMR tidak didukung.
- Ketika sebuah klaster Amazon MSK adalah target yang dapat diskalakan, skala di dinonaktifkan dan tidak dapat diaktifkan.

- Anda tidak dapat menggunakan operasi RegisterScalableTarget atau PutScalingPolicy API untuk memperbarui rencana AWS Auto Scaling penskalaan.
- Akses konsol untuk melihat, menambah, memperbarui, atau menghapus kebijakan penskalaan pelacakan target pada sumber daya yang dapat diskalakan bergantung pada sumber daya yang Anda gunakan. Untuk informasi selengkapnya, lihat [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

Membuat kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan AWS CLI

Contoh ini menggunakan AWS CLI perintah untuk membuat kebijakan racking target untuk Armada Spot Amazon EC2. Untuk target skala yang berbeda, tentukan namespace di `--service-namespace`, dimensi yang dapat diskalakan di `--scalable-dimension`, dan ID sumber dayanya di `--resource-id`

Saat menggunakan AWS CLI, ingatlah bahwa perintah Anda berjalan di Wilayah AWS konfigurasi untuk profil Anda. Jika Anda ingin menjalankan perintah di Wilayah yang berbeda, ubah Wilayah default untuk profil Anda, atau gunakan parameter `--region` bersama perintah tersebut.

Tugas

- [Langkah 1: Daftarkan target yang dapat diskalakan](#)
- [Langkah 2: Buat kebijakan penskalaan pelacakan target](#)
- [Langkah 3: Jelaskan kebijakan penskalaan pelacakan target](#)

Langkah 1: Daftarkan target yang dapat diskalakan

Jika Anda belum melakukannya, daftarkan target yang dapat diskalakan. Gunakan [`register-scalable-target`](#) perintah untuk mendaftarkan sumber daya tertentu dalam layanan target sebagai target yang dapat diskalakan. Contoh berikut meregistrasikan permintaan Armada Spot dengan Application Auto Scaling. Application Auto Scaling dapat menskalakan jumlah kasus di Armada Spot pada minimum 2 instans dan maksimum 10 instans. Ganti setiap *placeholder masukan pengguna* dengan informasi Anda sendiri.

Linux, macOS, atau Unix

```
aws application-autoscaling register-scalabe-target --service-namespace ec2 \
```

```
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \
--resource-id spot-fleet-request/sfr-73fbcd2ce-aa30-494c-8788-1cee4EXAMPLE \
--min-capacity 2 --max-capacity 10
```

Windows

```
aws application-autoscaling register-scalable-target --service-namespace ec2 ^
--scalable-dimension ec2:spot-fleet-request:TargetCapacity ^
--resource-id spot-fleet-request/sfr-73fbcd2ce-aa30-494c-8788-1cee4EXAMPLE ^
--min-capacity 2 --max-capacity 10
```

Output

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan. Berikut ini adalah output contoh.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

Langkah 2: Buat kebijakan penskalaan pelacakan target

Untuk membuat kebijakan penskalaan pelacakan target, Anda dapat menggunakan contoh berikut untuk membantu Anda memulai.

Untuk membuat kebijakan penskalaan pelacakan target

1. Gunakan cat perintah berikut untuk menyimpan nilai target untuk kebijakan penskalaan Anda dan spesifikasi metrik yang telah ditentukan sebelumnya dalam file JSON yang diberi nama config.json di direktori home Anda. Berikut ini adalah contoh konfigurasi pelacakan target yang menjaga pemanfaatan CPU rata-rata sebesar 50 persen.

```
$ cat ~/config.json
{
  "TargetValue": 50.0,
  "PredefinedMetricSpecification":
  {
    "PredefinedMetricType": "EC2SpotFleetRequestAverageCPUUtilization"
  }
}
```

Untuk informasi selengkapnya, lihat [PredefinedMetricSpecification](#) di Referensi API Application Auto Scaling.

Atau, Anda dapat menggunakan metrik khusus untuk penskalaan dengan membuat spesifikasi metrik yang disesuaikan dan menambahkan nilai untuk setiap parameter dari CloudWatch. Berikut ini adalah contoh konfigurasi pelacakan target yang menjaga pemanfaatan rata-rata metrik yang ditentukan pada 100.

```
$ cat ~/config.json
{
    "TargetValue": 100.0,
    "CustomizedMetricSpecification": {
        "MetricName": "MyUtilizationMetric",
        "Namespace": "MyNamespace",
        "Dimensions": [
            {
                "Name": "MyOptionalMetricDimensionName",
                "Value": "MyOptionalMetricDimensionValue"
            }
        ],
        "Statistic": "Average",
        "Unit": "Percent"
    }
}
```

Untuk informasi selengkapnya, lihat [CustomizedMetricSpecification](#) di Referensi API Application Auto Scaling.

2. Gunakan [put-scaling-policy](#) perintah berikut, bersama dengan config.json file yang Anda buat, untuk membuat kebijakan penskalaan bernama `cpu50-target-tracking-scaling-policy`.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scaling-policy --service-name ec2 \
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \
--resource-id spot-fleet-request/sfr-73fdb2ce-aa30-494c-8788-1cee4EXAMPLE \
--policy-name cpu50-target-tracking-scaling-policy --policy-type
TargetTrackingScaling \
--target-tracking-scaling-policy-configuration file://config.json
```

Windows

```
aws application-autoscaling put-scaling-policy --service-namespace ec2 ^
--scalable-dimension ec2:spot-fleet-request:TargetCapacity ^
--resource-id spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-1cee4EXAMPLE ^
--policy-name cpu50-target-tracking-scaling-policy --policy-type
TargetTrackingScaling ^
--target-tracking-scaling-policy-configuration file://config.json
```

Output

Jika berhasil, perintah ini mengembalikan ARN dan nama dari dua CloudWatch alarm yang dibuat atas nama Anda. Berikut ini adalah output contoh.

```
{
  "PolicyARN": "arn:aws:autoscaling:region:account-
id:scalingPolicy:policy-id:resource/ec2/spot-fleet-request/sfr-73fb2ce-
aa30-494c-8788-1cee4EXAMPLE:policyName/cpu50-target-tracking-scaling-policy",
  "Alarms": [
    {
      "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-
spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-
b46e-434a-a60f-3b36d653fec",
      "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fb2ce-
aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-b46e-434a-a60f-3b36d653fec"
    },
    {
      "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-
spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-
d19b-4a63-a812-6c67aaf2910d",
      "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fb2ce-
aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-d19b-4a63-a812-6c67aaf2910d"
    }
  ]
}
```

Langkah 3: Jelaskan kebijakan penskalaan pelacakan target

Anda dapat menjelaskan semua kebijakan penskalaan untuk namespace layanan yang ditentukan menggunakan perintah berikut. [describe-scaling-policies](#)

```
aws application-autoscaling describe-scaling-policies --service-namespace ec2
```

Anda dapat memfilter hasil hanya untuk kebijakan penskalaan pelacakan target menggunakan parameter `--query`. Untuk informasi lebih lanjut tentang sintaks untuk query, lihat [Mengontrol output perintah dari AWS CLI](#) di AWS Command Line Interface Panduan Pengguna.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scaling-policies --service-namespace ec2 \
--query 'ScalingPolicies[?PolicyType==`TargetTrackingScaling`]'
```

Windows

```
aws application-autoscaling describe-scaling-policies --service-namespace ec2 ^
--query "ScalingPolicies[?PolicyType==`TargetTrackingScaling`]"
```

Output

Berikut ini adalah output contoh.

```
[  
  {  
    "PolicyARN": "PolicyARN",  
    "TargetTrackingScalingPolicyConfiguration": {  
      "PredefinedMetricSpecification": {  
        "PredefinedMetricType": "EC2SpotFleetRequestAverageCPUUtilization"  
      },  
      "TargetValue": 50.0  
    },  
    "PolicyName": "cpu50-target-tracking-scaling-policy",  
    "ScalableDimension": "ec2:spot-fleet-request:TargetCapacity",  
    "ServiceNamespace": "ec2",  
    "PolicyType": "TargetTrackingScaling",  
    "ResourceId": "spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-1cee4EXAMPLE",  
    "Alarms": [  
      {  
        "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-  
spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-  
b46e-434a-a60f-3b36d653feca",  
        "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fb2ce-  
aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-b46e-434a-a60f-3b36d653feca"
```

```
        },
        {
            "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-
spot-fleet-request/sfr-73fbcd2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-
d19b-4a63-a812-6c67aaf2910d",
            "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fbcd2ce-
aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-d19b-4a63-a812-6c67aaf2910d"
        }
    ],
    "CreationTime": 1515021724.807
}
]
```

Menghapus kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan AWS CLI

Setelah selesai dengan kebijakan penskalaan pelacakan target, Anda dapat menghapusnya menggunakan [delete-scaling-policy](#) perintah.

Perintah berikut akan menghapus kebijakan penskalaan target tertentu untuk permintaan Armada Spot tertentu. Ini juga menghapus CloudWatch alarm yang Application Auto Scaling dibuat atas nama Anda.

Linux, macOS, atau Unix

```
aws application-autoscaling delete-scaling-policy --service-namespace ec2 \
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \
--resource-id spot-fleet-request/sfr-73fbcd2ce-aa30-494c-8788-1cee4EXAMPLE \
--policy-name cpu50-target-tracking-scaling-policy
```

Windows

```
aws application-autoscaling delete-scaling-policy --service-namespace ec2 ^
--scalable-dimension ec2:spot-fleet-request:TargetCapacity ^
--resource-id spot-fleet-request/sfr-73fbcd2ce-aa30-494c-8788-1cee4EXAMPLE ^
--policy-name cpu50-target-tracking-scaling-policy
```

Membuat kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan matematika metrik

Menggunakan matematika metrik, Anda dapat menanyakan beberapa CloudWatch metrik dan menggunakan ekspresi matematika untuk membuat deret waktu baru berdasarkan metrik ini. Anda dapat memvisualisasikan deret waktu yang dihasilkan di CloudWatch konsol dan menambahkannya ke dasbor. Untuk informasi selengkapnya tentang matematika [metrik, lihat Menggunakan matematika metrik](#) di Panduan CloudWatch Pengguna Amazon.

Pertimbangan berikut berlaku untuk ekspresi matematika metrik:

- Anda dapat menanyakan CloudWatch metrik apa pun yang tersedia. Setiap metrik adalah kombinasi unik dari nama metrik, namespace, dan nol atau lebih dimensi.
- Anda dapat menggunakan operator aritmatika (+ - * / ^), fungsi statistik (seperti AVG atau SUM), atau fungsi lain yang mendukung CloudWatch
- Anda dapat menggunakan metrik dan hasil ekspresi matematika lainnya dalam rumus ekspresi matematika.
- Setiap ekspresi yang digunakan dalam spesifikasi metrik pada akhirnya harus mengembalikan satu deret waktu.
- Anda dapat memverifikasi bahwa ekspresi matematika metrik valid dengan menggunakan CloudWatch konsol atau CloudWatch [GetMetricData](#) API.

Topik

- [Contoh: backlog antrian Amazon SQS per tugas](#)
- [Batasan](#)

Contoh: backlog antrian Amazon SQS per tugas

Untuk menghitung backlog antrean Amazon SQS per tugas, ambil perkiraan jumlah pesan yang tersedia untuk diambil dari antrian dan bagi nomor tersebut dengan jumlah tugas Amazon ECS yang berjalan di layanan. Untuk informasi selengkapnya, lihat [Auto Scaling Amazon Elastic Container Service \(ECS\) menggunakan metrik kustom](#) di AWS Blog Komputasi.

Logika untuk ekspresi adalah ini:

sum of (number of messages in the queue)/(number of tasks that are currently in the RUNNING state)

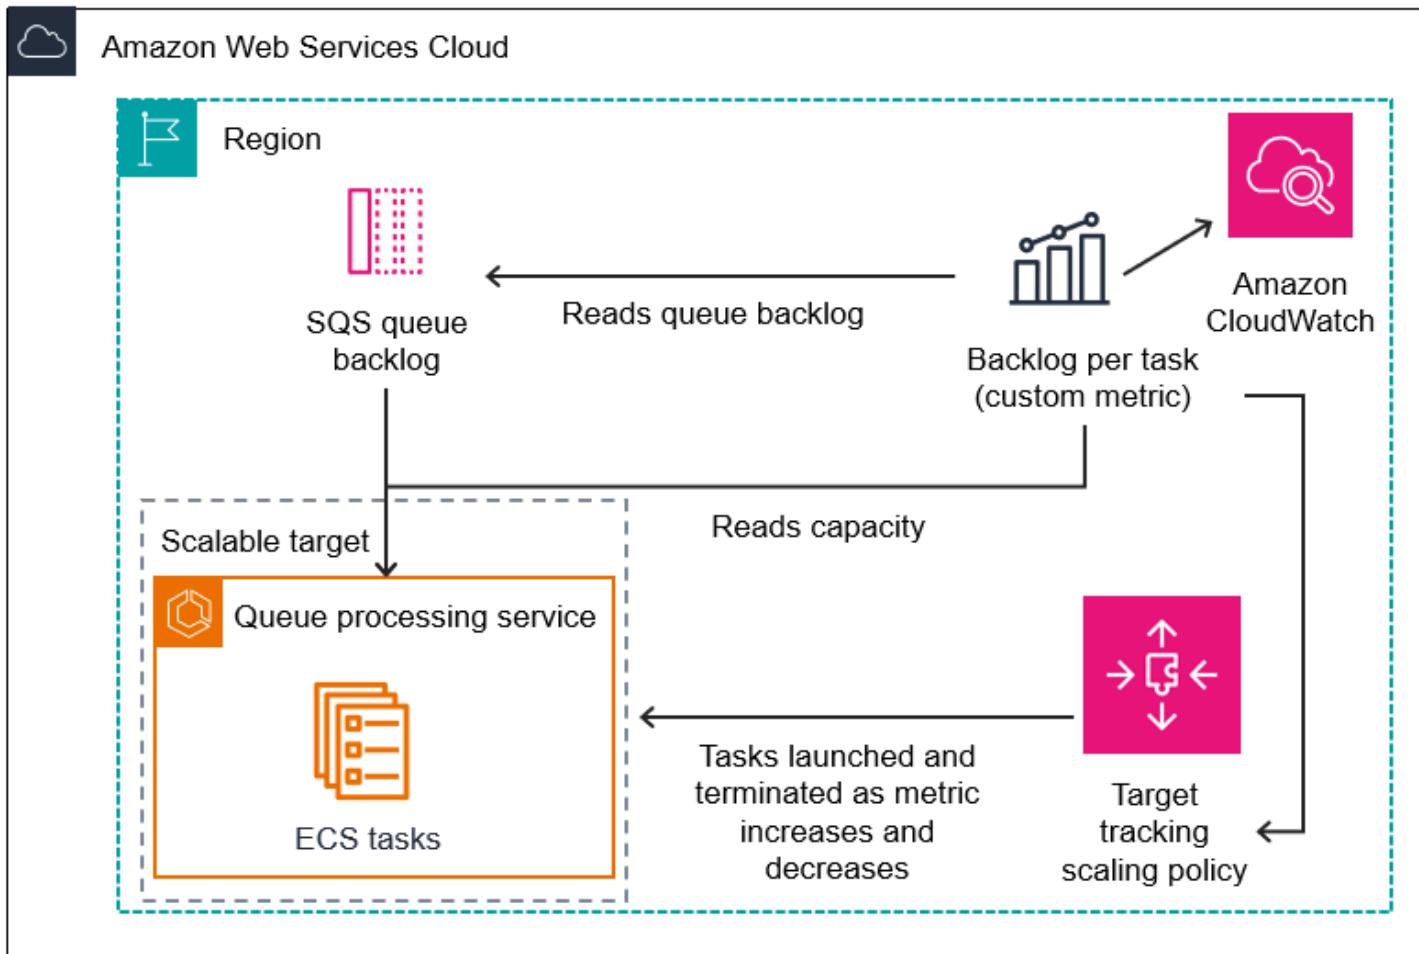
Maka informasi CloudWatch metrik Anda adalah sebagai berikut.

ID	CloudWatch metrik	Statistik	Periode
m1	ApproximateNumberOfVisibleMessages	Jumlah	1 menit
m2	RunningTaskCount	Rata-rata	1 menit

ID dan ekspresi matematika metrik Anda adalah sebagai berikut.

ID	Ekspresi
e1	(m1)/(m2)

Diagram berikut menggambarkan arsitektur untuk metrik ini:



Untuk menggunakan matematika metrik ini untuk membuat kebijakan penskalaan pelacakan target ()AWS CLI

1. Simpan ekspresi matematika metrik sebagai bagian dari spesifikasi metrik yang disesuaikan dalam file JSON bernama `config.json`.

Gunakan contoh berikut untuk membantu Anda memulai. Ganti setiap *placeholder masukan pengguna* dengan informasi Anda sendiri.

```
{
  "CustomizedMetricSpecification": {
    "Metrics": [
      {
        "Label": "Get the queue size (the number of messages waiting to be processed)",
        "Id": "m1",
        "MetricStat": {
          "stat": "Sum"
        }
      }
    ],
    "Unit": "Count"
  }
}
```

```
"Metric": {
    "MetricName": "ApproximateNumberOfMessagesVisible",
    "Namespace": "AWS/SQS",
    "Dimensions": [
        {
            "Name": "QueueName",
            "Value": "my-queue"
        }
    ],
    "Stat": "Sum"
},
"ReturnData": false
},
{
    "Label": "Get the ECS running task count (the number of currently
running tasks)",
    "Id": "m2",
    "MetricStat": {
        "Metric": {
            "MetricName": "RunningTaskCount",
            "Namespace": "ECS/ContainerInsights",
            "Dimensions": [
                {
                    "Name": "ClusterName",
                    "Value": "my-cluster"
                },
                {
                    "Name": "ServiceName",
                    "Value": "my-service"
                }
            ]
        },
        "Stat": "Average"
},
    "ReturnData": false
},
{
    "Label": "Calculate the backlog per instance",
    "Id": "e1",
    "Expression": "m1 / m2",
    "ReturnData": true
}
]
```

```
},  
    "TargetValue": 100  
}
```

Untuk informasi selengkapnya, lihat [TargetTrackingScalingPolicyConfiguration](#) di Referensi API Application Auto Scaling.

Note

Berikut adalah beberapa sumber daya tambahan yang dapat membantu Anda menemukan nama metrik, ruang nama, dimensi, dan statistik untuk CloudWatch metrik:

- Untuk informasi tentang metrik yang tersedia untuk AWS layanan, lihat [AWS layanan yang memublikasikan CloudWatch metrik](#) di CloudWatch Panduan Pengguna Amazon.
- [Untuk mendapatkan nama metrik, namespace, dan dimensi yang tepat \(jika ada\) untuk CloudWatch metrik dengan metrik AWS CLI, lihat daftar-metrik.](#)

2. Untuk membuat kebijakan ini, jalankan `put-scaling-policy` perintah menggunakan file JSON sebagai input, seperti yang ditunjukkan dalam contoh berikut.

```
aws application-autoscaling put-scaling-policy --policy-name sqs-backlog-target-tracking-scaling-policy \  
  --service-namespace ecs --scalable-dimension ecs:service:DesiredCount --resource-id service/my-cluster/my-service \  
  --policy-type TargetTrackingScaling --target-tracking-scaling-policy-configuration file://config.json
```

Jika berhasil, perintah ini mengembalikan Amazon Resource Name (ARN) kebijakan dan ARN dari dua CloudWatch alarm yang dibuat atas nama Anda.

```
{  
    "PolicyARN": "arn:aws:autoscaling:us-west-2:012345678910:scalingPolicy:  
8784a896-b2ba-47a1-b08c-27301cc499a1:resource/ecs/service/my-cluster/my-  
service:policyName/sqs-backlog-target-tracking-scaling-policy",  
    "Alarms": [  
        {  
            "AlarmARN": "arn:aws:cloudwatch:us-  
west-2:012345678910:alarm:TargetTracking-service/my-cluster/my-service-  
AlarmHigh-9bc77b56-0571-4276-ba0f-d4178882e0a0",  
        }  
    ]  
}
```

```
        "AlarmName": "TargetTracking-service/my-cluster/my-service-
AlarmHigh-9bc77b56-0571-4276-ba0f-d4178882e0a0"
    },
{
    "AlarmARN": "arn:aws:cloudwatch:us-
west-2:012345678910:alarm:TargetTracking-service/my-cluster/my-service-
AlarmLow-9b6ad934-6d37-438e-9e05-02836ddcbdc4",
    "AlarmName": "TargetTracking-service/my-cluster/my-service-
AlarmLow-9b6ad934-6d37-438e-9e05-02836ddcbdc4"
}
]
```

 Note

Jika perintah ini menimbulkan kesalahan, pastikan Anda telah memperbarui AWS CLI secara lokal ke versi terbaru.

Batasan

- Ukuran permintaan maksimum adalah 50 KB. Ini adalah ukuran payload total untuk permintaan [PutScalingPolicy](#) API saat Anda menggunakan matematika metrik dalam definisi kebijakan. Jika Anda melebihi batas ini, Application Auto Scaling menolak permintaan tersebut.
- Layanan berikut tidak didukung saat menggunakan matematika metrik dengan kebijakan penskalaan pelacakan target:
 - Amazon Keyspaces (untuk Apache Cassandra)
 - DynamoDB
 - Amazon EMR
 - Amazon MSK
 - Amazon Neptune

Kebijakan penskalaan langkah untuk Application Auto Scaling

Kebijakan penskalaan langkah menskalakan kapasitas aplikasi Anda dalam peningkatan yang telah ditentukan berdasarkan alarm. CloudWatch Anda dapat menentukan kebijakan penskalaan terpisah untuk menangani penskalaan (peningkatan kapasitas) dan penskalaan (penurunan kapasitas) saat ambang alarm dilanggar.

Dengan kebijakan penskalaan langkah, Anda membuat dan mengelola CloudWatch alarm yang menjalankan proses penskalaan. Ketika alarm dilanggar, Application Auto Scaling memulai kebijakan penskalaan yang terkait dengan alarm tersebut.

Kebijakan penskalaan langkah menskalakan kapasitas menggunakan serangkaian penyesuaian, yang dikenal sebagai penyesuaian langkah. Ukuran penyesuaian bervariasi berdasarkan besarnya pelanggaran alarm.

- Jika pelanggaran melebihi ambang batas pertama, Application Auto Scaling akan menerapkan penyesuaian langkah pertama.
- Jika pelanggaran melebihi ambang kedua, Application Auto Scaling akan menerapkan penyesuaian langkah kedua, dan seterusnya.

Hal ini memungkinkan kebijakan penskalaan untuk merespons dengan tepat perubahan kecil dan besar dalam metrik alarm.

Kebijakan ini akan terus menanggapi pelanggaran alarm tambahan, bahkan saat aktivitas penskalaan sedang berlangsung. Ini berarti Application Auto Scaling akan mengevaluasi semua pelanggaran alarm saat terjadi. Periode cooldown digunakan untuk melindungi terhadap penskalaan berlebih karena beberapa pelanggaran alarm yang terjadi secara berurutan.

Seperti pelacakan target, penskalaan langkah dapat membantu secara otomatis menskalakan kapasitas aplikasi Anda saat terjadi perubahan lalu lintas. Namun, kebijakan pelacakan target cenderung lebih mudah diterapkan dan dikelola untuk kebutuhan penskalaan yang stabil.

Target yang dapat diskalakan yang didukung

Anda dapat menggunakan kebijakan penskalaan langkah dengan target skala label berikut:

- AppStream 2.0 armada

- Klaster DB Aurora
- Layanan ECS
- Klaster EMR
- SageMaker varian titik akhir
- SageMaker komponen inferensi
- SageMaker Konkurensi yang disediakan tanpa server
- Armada Spot
- Sumber daya khusus

Daftar Isi

- [Cara kerja penskalaan langkah untuk Application Auto Scaling](#)
- [Buat kebijakan penskalaan langkah untuk Application Auto Scaling menggunakan AWS CLI](#)
- [Jelaskan kebijakan penskalaan langkah untuk Application Auto Scaling menggunakan AWS CLI](#)
- [Menghapus kebijakan penskalaan langkah untuk Application Auto Scaling menggunakan AWS CLI](#)

Cara kerja penskalaan langkah untuk Application Auto Scaling

Topik ini menjelaskan cara kerja penskalaan langkah dan memperkenalkan elemen kunci dari kebijakan penskalaan langkah.

Daftar Isi

- [Cara kerjanya](#)
- [Penyesuaian langkah](#)
- [Jenis penyesuaian penskalaan](#)
- [Periode pendinginan](#)
- [Perintah yang umum digunakan untuk penskalaan pembuatan kebijakan, manajemen, dan penghapusan](#)
- [Pertimbangan](#)
- [Sumber daya terkait](#)
- [Akses konsol](#)

Cara kerjanya

Untuk menggunakan penskalaan langkah, Anda membuat CloudWatch alarm yang memantau metrik untuk target yang dapat diskalakan. Tentukan metrik, nilai ambang batas, dan jumlah periode evaluasi yang menentukan pelanggaran alarm. Anda juga membuat kebijakan penskalaan langkah yang menentukan cara menskalakan kapasitas saat ambang alarm dilanggar dan mengaitkannya dengan target yang dapat diskalakan.

Tambahkan penyesuaian langkah dalam kebijakan. Anda dapat menentukan penyesuaian langkah yang berbeda berdasarkan ukuran pelanggaran alarm. Sebagai contoh:

- Skalakan 10 unit kapasitas jika metrik alarm mencapai 60 persen
- Skalakan 30 unit kapasitas jika metrik alarm mencapai 75 persen
- Skalakan dengan 40 unit kapasitas jika metrik alarm mencapai 85 persen

Ketika ambang batas alarm dilanggar untuk jumlah periode evaluasi yang ditentukan, Application Auto Scaling akan menerapkan penyesuaian langkah yang ditentukan dalam kebijakan. Penyesuaian dapat berlanjut untuk pelanggaran alarm tambahan hingga status alarm kembali ke. OK

Aktivitas penskalaan dilakukan dengan periode cooldown di antara mereka untuk mencegah fluktuasi kapasitas yang cepat. Anda dapat secara opsional mengkonfigurasi periode cooldown untuk kebijakan penskalaan Anda.

Penyesuaian langkah

Saat membuat kebijakan penskalaan langkah, Anda menentukan satu atau beberapa penyesuaian langkah yang secara otomatis menskalakan kapasitas target secara dinamis berdasarkan ukuran pelanggaran alarm. Setiap penyesuaian langkah menentukan hal berikut:

- Batas bawah untuk nilai metrik
- Batas atas untuk nilai metrik
- Jumlah yang ditentukan untuk diskalakan, berdasarkan jenis penyesuaian penskalaan

CloudWatch mengumpulkan titik data metrik berdasarkan statistik untuk metrik yang terkait dengan CloudWatch alarm Anda. Ketika alarm dilanggar, kebijakan penskalaan yang sesuai akan dipanggil. Application Auto Scaling menerapkan tipe agregasi yang Anda tentukan ke titik data metrik terbaru dari CloudWatch (sebagai lawan dari data metrik mentah). Penskalaan ini membandingkan nilai

metrik agregat ini terhadap batas atas dan bawah yang ditentukan oleh penyesuaian langkah untuk menentukan penyesuaian langkah mana yang harus dilakukan.

Anda menentukan batas atas dan bawah terkait dengan ambang batas pelanggaran. Sebagai contoh, katakanlah Anda membuat CloudWatch alarm dan kebijakan scale-out ketika metrik di atas 50 persen. Anda kemudian membuat alarm kedua dan kebijakan skala dalam ketika metrik di bawah 50 persen. Anda membuat serangkaian penyesuaian langkah dengan jenis penyesuaian PercentChangeInCapacity untuk setiap kebijakan:

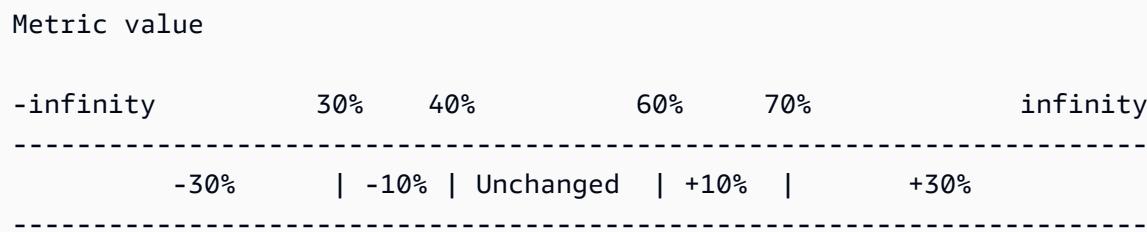
Contoh: Penyesuaian langkah untuk kebijakan menskalakan keluar

Batas bawah	Batas atas	Penyesuaian
0	10	0
10	20	10
20	nol	30

Contoh: Penyesuaian langkah untuk kebijakan penskalaan kedalam

Batas bawah	Batas atas	Penyesuaian
-10	0	0
-20	-10	-10
nol	-20	-30

Ini membuat konfigurasi penskalaan berikut.



Sekarang, katakanlah Anda menggunakan konfigurasi penskalaan ini pada target yang dapat diskalakan yang memiliki kapasitas 10. Poin-poin berikut merangkum perilaku konfigurasi penskalaan dalam kaitannya dengan kapasitas target yang dapat diskalakan:

- Kapasitas asli dipertahankan sementara nilai metrik agregat lebih besar dari 40 dan kurang dari 60.
- Jika nilai metrik mencapai 60, Application Auto Scaling meningkatkan kapasitas target yang dapat diskalakan sebesar 1, menjadi 11. Itu berdasarkan penyesuaian langkah kedua dari kebijakan penskalaan naik (tambahkan 10 persen dari 10). Setelah kapasitas baru ditambahkan, Application Auto Scaling meningkatkan kapasitas saat ini menjadi 11. Jika nilai metrik meningkat menjadi 70 bahkan setelah peningkatan kapasitas, Application Auto Scaling meningkatkan kapasitas target sebesar 3, menjadi 14. Itu berdasarkan penyesuaian langkah ketiga dari kebijakan penskalaan (tambahkan 30 persen dari 11, 3,3 dibulatkan ke bawah menjadi 3).
- Jika nilai metrik mencapai 40, Application Auto Scaling mengurangi kapasitas target yang dapat diskalakan sebesar 1, menjadi 13, berdasarkan penyesuaian langkah kedua dari kebijakan scale-in (hapus 10 persen dari 14, 1,4, dibulatkan ke 1). Jika nilai metrik turun menjadi 30 bahkan setelah penurunan kapasitas ini, Application Auto Scaling mengurangi kapasitas target sebesar 3, menjadi 10, berdasarkan penyesuaian langkah ketiga pada kebijakan skala (hapus 30 persen 13, 3,9 dibulatkan ke bawah menjadi 3).

Saat Anda menentukan penyesuaian langkah untuk kebijakan penskalaan Anda, perhatikan hal berikut:

- Rentang penyesuaian langkah Anda tidak dapat tumpang tindih atau memiliki kesenjangan.
- Hanya satu penyesuaian langkah yang dapat memiliki batas bawah nol (negatif tak terhingga). Jika satu penyesuaian langkah memiliki batas bawah negatif, maka harus ada penyesuaian langkah dengan batas bawah nol.
- Hanya satu penyesuaian langkah yang dapat memiliki batas atas nol (positif tak terhingga). Jika satu penyesuaian langkah memiliki batas atas positif, maka harus ada penyesuaian langkah dengan batas atas nol.
- Batas atas dan bawah tidak boleh nol dalam penyesuaian langkah yang sama.
- Apabila nilai metrik berada di atas ambang batas penembusan, batas bawah bersifat inklusif dan batas atas bersifat eksklusif. Apabila nilai metrik berada di bawah ambang batas penembusan, batas bawah bersifat eksklusif dan batas atas bersifat inklusif.

Jenis penyesuaian penskalaan

Anda dapat menentukan kebijakan penskalaan yang melakukan tindakan penskalaan optimal, berdasarkan jenis penyesuaian penskalaan yang Anda pilih. Anda dapat menentukan jenis penyesuaian sebagai persentase dari kapasitas saat ini pada target yang dapat diskalakan atau dalam jumlah mutlak.

Application Auto Scaling mendukung jenis penyesuaian berikut untuk kebijakan penskalaan langkah:

- **ChangeInCapacity**—Meningkatkan atau mengurangi kapasitas saat ini dari target yang dapat diskalakan dengan nilai yang ditentukan. Nilai positif meningkatkan kapasitas dan nilai negatif menurunkan kapasitas. Misalnya: Jika kapasitas saat ini adalah 3 dan penyesuaianya adalah 5, Application Auto Scaling akan menambahkan 5 ke kapasitas sehingga totalnya adalah 8.
- **ExactCapacity**—Ubah kapasitas saat ini dari target yang dapat diskalakan ke nilai yang ditentukan. Tentukan nilai non-negatif dengan jenis penyesuaian ini. Misalnya: Jika kapasitas saat ini adalah 3 dan penyesuaianya adalah 5, maka Application Auto Scaling akan mengubah kapasitas menjadi 5.
- **PercentChangeInCapacity**—Meningkatkan atau mengurangi kapasitas saat ini dari target yang dapat diskalakan dengan persentase yang ditentukan. Nilai positif meningkatkan kapasitas dan nilai negatif menurunkan kapasitas. Misalnya: Jika kapasitas saat ini adalah 10 dan penyesuaianya adalah 10 persen, Application Auto Scaling menambahkan 1 ke kapasitas sehingga totalnya adalah 11.

Jika nilai yang dihasilkan bukan bilangan bulat, Application Auto Scaling membulatkannya sebagai berikut:

- Nilai yang lebih besar dari 1 dibulatkan ke bawah. Misalnya, 12.7 dibulatkan ke 12.
- Nilai antara 0 dan 1 dibulatkan ke 1. Misalnya, .67 dibulatkan ke 1.
- Nilai antara 0 dan -1 dibulatkan ke -1. Misalnya, -.58 dibulatkan ke -1.
- Nilai kurang dari -1 dibulatkan ke atas. Misalnya, -6.67 dibulatkan ke -6.

Dengan PercentChangeInCapacity, Anda juga dapat menentukan jumlah minimum untuk skala menggunakan **MinAdjustmentMagnitude** parameter. Misalnya, anggaplah Anda membuat kebijakan yang menambahkan 25 persen dan Anda menentukan jumlah minimum sebesar 2. Jika target yang dapat diskalakan memiliki kapasitas 4 dan kebijakan penskalaan dilakukan, 25 persen dari 4 adalah 1. Namun, karena Anda menentukan peningkatan minimum sebesar 2, Application Auto Scaling akan menambahkan 2.

Periode pendinginan

Anda dapat secara opsional menentukan periode cooldown dalam kebijakan penskalaan langkah Anda.

Periode cooldown menentukan jumlah waktu kebijakan penskalaan menunggu aktivitas penskalaan sebelumnya berlaku.

Ada dua cara untuk merencanakan penggunaan periode cooldown untuk konfigurasi penskalaan langkah:

- Dengan periode cooldown untuk kebijakan scale-out, tujuannya adalah untuk terus (tetapi tidak berlebihan) skala keluar. Setelah Application Auto Scaling berhasil menskalakan menggunakan kebijakan penskalaan, Application Auto Scaling mulai menghitung waktu cooldown. Kebijakan penskalaan tidak akan meningkatkan kapasitas yang diinginkan lagi kecuali jika skala keluar yang lebih besar dipicu atau periode cooldown berakhir. Selama periode pendinginan penskalaan keluar berlaku, kapasitas yang ditambahkan dengan cara memulai aktivitas penskalaan keluar dihitung sebagai bagian dari kapasitas yang diinginkan untuk aktivitas penskalaan keluar berikutnya.
- Dengan periode cooldown untuk kebijakan scale-in, tujuannya adalah untuk meningkatkan skala secara konservatif untuk melindungi ketersediaan aplikasi Anda, sehingga aktivitas scale-in diblokir hingga periode cooldown scale-in berakhir. Namun, jika alarm lain memicu aktivitas pengecilan skala selama periode jeda pakai untuk pembesaran skala, Application Auto Scaling akan langsung memperkecil skala target. Dalam hal ini, periode cooldown scale-in berhenti dan tidak selesai.

Misalnya, ketika puncak lalu lintas terjadi, alarm dipicu dan Application Auto Scaling secara otomatis menambah kapasitas untuk membantu menangani peningkatan beban. Jika Anda menetapkan periode cooldown untuk kebijakan scale-out Anda, ketika alarm memicu kebijakan untuk meningkatkan kapasitas sebesar 2, aktivitas penskalaan berhasil diselesaikan, dan periode cooldown scale-out dimulai. Jika alarm memicu lagi selama periode cooldown tetapi pada penyesuaian langkah yang lebih agresif 3, peningkatan sebelumnya 2 dianggap sebagai bagian dari kapasitas saat ini. Oleh karena itu, hanya 1 yang ditambahkan ke kapasitas. Ini memungkinkan penskalaan lebih cepat daripada menunggu cooldown berakhir tetapi tanpa menambahkan kapasitas lebih dari yang Anda butuhkan.

Periode jeda pakai diukur dalam hitungan detik dan hanya berlaku untuk aktivitas penskalaan yang terkait kebijakan. Selama periode jeda pakai, ketika tindakan terjadwal dimulai pada waktu yang dijadwalkan, tindakan ini dapat segera memicu aktivitas penskalaan tanpa menunggu periode jeda pakai berakhir.

Nilai default adalah 300 jika tidak ada nilai yang ditentukan.

Perintah yang umum digunakan untuk penskalaan pembuatan kebijakan, manajemen, dan penghapusan

Perintah yang umum digunakan untuk bekerja dengan kebijakan penskalaan meliputi:

- [register-scalable-target](#)untuk mendaftarkan AWS atau menyesuaikan sumber daya sebagai target yang dapat diskalakan (sumber daya yang dapat diskalakan oleh Application Auto Scaling), dan untuk menangguhkan dan melanjutkan penskalaan.
- [put-scaling-policy](#)untuk menambah atau memodifikasi kebijakan penskalaan untuk target skalabel yang ada.
- [describe-scaling-activities](#)untuk mengembalikan informasi tentang aktivitas penskalaan di suatu AWS Wilayah.
- [describe-scaling-policies](#)untuk mengembalikan informasi tentang kebijakan penskalaan di AWS Wilayah.
- [delete-scaling-policy](#) untuk menghapus kebijakan penskalaan.

Pertimbangan

Pertimbangan berikut berlaku saat bekerja dengan kebijakan penskalaan langkah:

- Pertimbangkan apakah Anda dapat memprediksi penyesuaian langkah pada aplikasi dengan cukup akurat untuk menggunakan penskalaan langkah. Jika metrik penskalaan Anda meningkat atau menurun secara proporsional dengan kapasitas target yang dapat diskalakan, sebaiknya gunakan kebijakan penskalaan pelacakan target sebagai gantinya. Anda masih memiliki opsi untuk menggunakan penskalaan langkah sebagai kebijakan tambahan untuk konfigurasi yang lebih canggih. Misalnya, Anda dapat mengonfigurasi respons yang lebih agresif saat pemanfaatan mencapai tingkat tertentu.
- Pastikan untuk memilih margin yang memadai antara ambang scale-out dan scale-in untuk mencegah flapping. Flapping adalah lingkaran penskalaan dan penskalaan yang tak terbatas. Artinya, jika tindakan penskalaan diambil, nilai metrik akan berubah dan memulai tindakan penskalaan lain dalam arah sebaliknya.

Sumber daya terkait

Untuk informasi tentang cara membuat kebijakan penskalaan langkah untuk grup Auto Scaling, lihat [Langkah dan kebijakan penskalaan sederhana untuk Penskalaan Otomatis Amazon EC2 di Panduan Pengguna Auto Scaling Amazon EC2](#).

Akses konsol

Akses konsol untuk melihat, menambah, memperbarui, atau menghapus kebijakan penskalaan langkah pada sumber daya yang dapat diskalakan bergantung pada sumber daya yang Anda gunakan. Untuk informasi selengkapnya, lihat [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

Buat kebijakan penskalaan langkah untuk Application Auto Scaling menggunakan AWS CLI

Contoh ini menggunakan AWS CLI perintah untuk membuat kebijakan penskalaan langkah untuk layanan Amazon ECS. Untuk target skalabel yang berbeda, tentukan namespace di `--service-namespace`, dimensi yang dapat diskalakan di `--scalable-dimension`, dan ID sumber dayanya di `--resource-id`

Saat menggunakan AWS CLI, ingatlah bahwa perintah Anda berjalan di Wilayah AWS konfigurasi untuk profil Anda. Jika Anda ingin menjalankan perintah di Wilayah yang berbeda, ubah Wilayah default untuk profil Anda, atau gunakan parameter `--region` bersama perintah tersebut.

Tugas

- [Langkah 1: Daftarkan target yang dapat diskalakan](#)
- [Langkah 2: Buat kebijakan penskalaan langkah](#)
- [Langkah 3: Buat alarm yang memanggil kebijakan penskalaan](#)

Langkah 1: Daftarkan target yang dapat diskalakan

Jika Anda belum melakukannya, daftarkan target yang dapat diskalakan. Gunakan [register-scalable-target](#) perintah untuk mendaftarkan sumber daya tertentu dalam layanan target sebagai target yang dapat diskalakan. Contoh berikut mendaftarkan layanan ECS Amazon dengan Application Auto Scaling. Application Auto Scaling dapat menskalakan jumlah tugas pada minimum 2 tugas dan

maksimum 10 tugas. Ganti setiap *placeholder masukan pengguna* dengan informasi Anda sendiri.

Linux, macOS, atau Unix

```
aws application-autoscaling register-scalable-target --service-namespace ecs \  
--scalable-dimension ecs:service:DesiredCount \  
--resource-id service/my-cluster/my-service \  
--min-capacity 2 --max-capacity 10
```

Windows

```
aws application-autoscaling register-scalable-target --service-namespace ecs ^  
--scalable-dimension ecs:service:DesiredCount ^  
--resource-id service/my-cluster/my-service ^  
--min-capacity 2 --max-capacity 10
```

Output

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan. Berikut ini adalah output contoh.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Langkah 2: Buat kebijakan penskalaan langkah

Untuk membuat kebijakan penskalaan langkah untuk target yang dapat diskalakan, Anda dapat menggunakan contoh berikut untuk membantu Anda memulai.

Scale out

Untuk membuat kebijakan penskalaan langkah untuk skala keluar (meningkatkan kapasitas)

1. Gunakan cat perintah berikut untuk menyimpan konfigurasi kebijakan penskalaan langkah dalam file JSON bernama config.json di direktori home Anda. Berikut ini adalah contoh konfigurasi dengan jenis penyesuaian PercentChangeInCapacity yang meningkatkan kapasitas target yang dapat diskalakan berdasarkan penyesuaian langkah berikut (dengan asumsi ambang CloudWatch alarm 70):

- Tingkatkan kapasitas sebesar 10 persen ketika nilai metrik lebih besar dari atau sama dengan 70 tetapi kurang dari 85
- Tingkatkan kapasitas sebesar 20 persen ketika nilai metrik lebih besar dari atau sama dengan 85 tetapi kurang dari 95
- Tingkatkan kapasitas sebesar 30 persen ketika nilai metrik lebih besar dari atau sama dengan 95

```
$ cat ~/config.json
{
    "AdjustmentType": "PercentChangeInCapacity",
    "MetricAggregationType": "Average",
    "Cooldown": 60,
    "MinAdjustmentMagnitude": 1,
    "StepAdjustments": [
        {
            "MetricIntervalLowerBound": 0.0,
            "MetricIntervalUpperBound": 15.0,
            "ScalingAdjustment": 10
        },
        {
            "MetricIntervalLowerBound": 15.0,
            "MetricIntervalUpperBound": 25.0,
            "ScalingAdjustment": 20
        },
        {
            "MetricIntervalLowerBound": 25.0,
            "ScalingAdjustment": 30
        }
    ]
}
```

Untuk informasi selengkapnya, lihat [StepScalingPolicyConfiguration](#) di Referensi API Application Auto Scaling.

2. Gunakan [put-scaling-policy](#) perintah berikut, bersama dengan config.json file yang Anda buat, untuk membuat kebijakan penskalaan bernamamy-step-scaling-policy.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scaling-policy --service-namespace ecs \
```

```
--scalable-dimension ecs:service:DesiredCount \
--resource-id service/my-cluster/my-service \
--policy-name my-step-scaling-policy --policy-type StepScaling \
--step-scaling-policy-configuration file://config.json
```

Windows

```
aws application-autoscaling put-scaling-policy --service-namespace ecs ^
--scalable-dimension ecs:service:DesiredCount ^
--resource-id service/my-cluster/my-service ^
--policy-name my-step-scaling-policy --policy-type StepScaling ^
--step-scaling-policy-configuration file://config.json
```

Output

Output mencakup ARN yang berfungsi sebagai nama unik untuk kebijakan tersebut. Anda membutuhkannya untuk membuat CloudWatch alarm untuk kebijakan Anda. Berikut ini adalah output contoh.

```
{
    "PolicyARN":  
    "arn:aws:autoscaling:region:123456789012:scalingPolicy:ac542982-cbeb-4294-891c-  
    a5a941dfa787:resource/ecs/service/my-cluster/my-service:policyName/my-step-  
    scaling-policy"
}
```

Scale in

Untuk membuat kebijakan penskalaan langkah untuk skala (kurangi kapasitas)

1. Gunakan cat perintah berikut untuk menyimpan konfigurasi kebijakan penskalaan langkah dalam file JSON bernama config.json di direktori home Anda. Berikut ini adalah contoh konfigurasi dengan jenis penyesuaian ChangeInCapacity yang mengurangi kapasitas target yang dapat diskalakan berdasarkan penyesuaian langkah berikut (dengan asumsi ambang CloudWatch alarm 50):
 - Kurangi kapasitas sebesar 1 ketika nilai metrik kurang dari atau sama dengan 50 tetapi lebih besar dari 40

- Kurangi kapasitas sebesar 2 ketika nilai metrik kurang dari atau sama dengan 40 tetapi lebih besar dari 30
- Kurangi kapasitas sebesar 3 ketika nilai metrik kurang dari atau sama dengan 30

```
$ cat ~/config.json
{
  "AdjustmentType": "ChangeInCapacity",
  "MetricAggregationType": "Average",
  "Cooldown": 60,
  "StepAdjustments": [
    {
      "MetricIntervalUpperBound": 0.0,
      "MetricIntervalLowerBound": -10.0,
      "ScalingAdjustment": -1
    },
    {
      "MetricIntervalUpperBound": -10.0,
      "MetricIntervalLowerBound": -20.0,
      "ScalingAdjustment": -2
    },
    {
      "MetricIntervalUpperBound": -20.0,
      "ScalingAdjustment": -3
    }
  ]
}
```

Untuk informasi selengkapnya, lihat [StepScalingPolicyConfiguration](#) di Referensi API Application Auto Scaling.

2. Gunakan [put-scaling-policy](#) perintah berikut, bersama dengan config.json file yang Anda buat, untuk membuat kebijakan penskalaan bernamamy-step-scaling-policy.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scaling-policy --service-namespace ecs \
--scalable-dimension ecs:service:DesiredCount \
--resource-id service/my-cluster/my-service \
--policy-name my-step-scaling-policy --policy-type StepScaling \
--step-scaling-policy-configuration file://config.json
```

Windows

```
aws application-autoscaling put-scaling-policy --service-namespace ecs ^
--scalable-dimension ecs:service:DesiredCount ^
--resource-id service/my-cluster/my-service ^
--policy-name my-step-scaling-policy --policy-type StepScaling ^
--step-scaling-policy-configuration file://config.json
```

Output

Output mencakup ARN yang berfungsi sebagai nama unik untuk kebijakan tersebut. Anda memerlukan ARN ini untuk membuat CloudWatch alarm untuk kebijakan Anda. Berikut ini adalah output contoh.

```
{
  "PolicyARN":  
  "arn:aws:autoscaling:region:123456789012:scalingPolicy:ac542982-cbeb-4294-891c-a5a941dfa787:resource/ecs/service/my-cluster/my-service:policyName/my-step-scaling-policy"  
}
```

Langkah 3: Buat alarm yang memanggil kebijakan penskalaan

Terakhir, gunakan CloudWatch [put-metric-alarm](#) perintah berikut untuk membuat alarm untuk digunakan dengan kebijakan penskalaan langkah Anda. Dalam contoh ini, Anda memiliki alarm yang didasarkan pada pemanfaatan CPU rata-rata. Alarm dikonfigurasi untuk berada dalam status ALARM jika mencapai ambang batas 70 persen selama setidaknya dua periode evaluasi sepanjang 60 detik secara berturut-turut. Untuk menentukan CloudWatch metrik yang berbeda atau menggunakan metrik kustom Anda sendiri, tentukan namanya di `--metric-name` dan namespace di `--namespace`

Linux, macOS, atau Unix

```
aws cloudwatch put-metric-alarm --alarm-name Step-Scaling-AlarmHigh-ECS:service/my-cluster/my-service \
--metric-name CPUUtilization --namespace AWS/ECS --statistic Average \
--period 60 --evaluation-periods 2 --threshold 70 \
--comparison-operator GreaterThanOrEqualToThreshold \
--dimensions Name=ClusterName,Value=default Name=ServiceName,Value=sample-app-service
\
```

```
--alarm-actions PolicyARN
```

Windows

```
aws cloudwatch put-metric-alarm --alarm-name Step-Scaling-AlarmHigh-ECS:service/my-cluster/my-service ^
--metric-name CPUUtilization --namespace AWS/ECS --statistic Average ^
--period 60 --evaluation-periods 2 --threshold 70 ^
--comparison-operator GreaterThanOrEqualToThreshold ^
--dimensions Name=ClusterName,Value=default Name=ServiceName,Value=sample-app-service ^
--alarm-actions PolicyARN
```

Jelaskan kebijakan penskalaan langkah untuk Application Auto Scaling menggunakan AWS CLI

Anda dapat menjelaskan semua kebijakan penskalaan untuk namespace layanan menggunakan perintah. [describe-scaling-policies](#) Contoh berikut menjelaskan semua kebijakan penskalaan untuk semua layanan Amazon ECS. Untuk mencantumkannya untuk layanan Amazon ECS tertentu hanya tambahkan --resource-id opsi.

```
aws application-autoscaling describe-scaling-policies --service-namespace ecs
```

Anda dapat memfilter hasilnya menjadi hanya kebijakan penskalaan langkah menggunakan parameter --query. Untuk informasi lebih lanjut tentang sintaks untuk query, lihat [Mengontrol output perintah dari AWS CLI](#) di AWS Command Line Interface Panduan Pengguna.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scaling-policies --service-namespace ecs \
--query 'ScalingPolicies[?PolicyType==`StepScaling`]'
```

Windows

```
aws application-autoscaling describe-scaling-policies --service-namespace ecs ^
--query "ScalingPolicies[?PolicyType==`StepScaling`]"
```

Output

Berikut ini adalah output contoh.

```
[  
 {  
     "PolicyARN": "PolicyARN",  
     "StepScalingPolicyConfiguration": {  
         "MetricAggregationType": "Average",  
         "Cooldown": 60,  
         "StepAdjustments": [  
             {  
                 "MetricIntervalLowerBound": 0.0,  
                 "MetricIntervalUpperBound": 15.0,  
                 "ScalingAdjustment": 1  
             },  
             {  
                 "MetricIntervalLowerBound": 15.0,  
                 "MetricIntervalUpperBound": 25.0,  
                 "ScalingAdjustment": 2  
             },  
             {  
                 "MetricIntervalLowerBound": 25.0,  
                 "ScalingAdjustment": 3  
             }  
         ],  
         "AdjustmentType": "ChangeInCapacity"  
     },  
     "PolicyType": "StepScaling",  
     "ResourceId": "service/my-cluster/my-service",  
     "ServiceNamespace": "ecs",  
     "Alarms": [  
         {  
             "AlarmName": "Step-Scaling-AlarmHigh-ECS:service/my-cluster/my-service",  
             "AlarmARN": "arn:aws:cloudwatch:region:012345678910:alarm:Step-Scaling-AlarmHigh-ECS:service/my-cluster/my-service"  
         }  
     ],  
     "PolicyName": "my-step-scaling-policy",  
     "ScalableDimension": "ecs:service:DesiredCount",  
     "CreationTime": 1515024099.901  
 }]  
 ]
```

Menghapus kebijakan penskalaan langkah untuk Application Auto Scaling menggunakan AWS CLI

Saat Anda tidak lagi memerlukan suatu kebijakan penskalaan langkah, Anda dapat menghapusnya. Untuk menghapus kebijakan penskalaan dan CloudWatch alarm terkait, selesaikan tugas berikut.

Untuk menghapus kebijakan penskalaan Anda

Gunakan perintah [delete-scaling-policy](#).

Linux, macOS, atau Unix

```
aws application-autoscaling delete-scaling-policy --service-namespace ecs \  
--scalable-dimension ecs:service:DesiredCount \  
--resource-id service/my-cluster/my-service \  
--policy-name my-step-scaling-policy
```

Windows

```
aws application-autoscaling delete-scaling-policy --service-namespace ecs ^  
--scalable-dimension ecs:service:DesiredCount ^  
--resource-id service/my-cluster/my-service ^  
--policy-name my-step-scaling-policy
```

Untuk menghapus CloudWatch alarm

Gunakan perintah [hapus-alarm](#). Anda dapat menghapus satu atau beberapa alarm sekaligus. Misalnya, gunakan perintah berikut untuk menghapus alarm Step-Scaling-AlarmHigh-ECS:service/my-cluster/my-service dan Step-Scaling-AlarmLow-ECS:service/my-cluster/my-service.

```
aws cloudwatch delete-alarms --alarm-name Step-Scaling-AlarmHigh-ECS:service/my-  
cluster/my-service Step-Scaling-AlarmLow-ECS:service/my-cluster/my-service
```

Tutorial: Konfigurasikan penskalaan otomatis untuk menangani beban kerja yang berat

Dalam tutorial ini, Anda mempelajari cara skala dan berdasarkan jendela waktu ketika aplikasi Anda akan memiliki beban kerja yang lebih berat dari biasanya. Ini sangat membantu ketika Anda memiliki aplikasi yang tiba-tiba dapat memiliki sejumlah besar pengunjung pada jadwal reguler atau secara musiman.

Anda dapat menggunakan kebijakan penskalaan pelacakan target bersama dengan penskalaan terjadwal untuk menangani beban tambahan. Skala terjadwal secara otomatis memulai perubahan pada MinCapacity dan MaxCapacity atas nama Anda, berdasarkan jadwal yang Anda tentukan. Ketika kebijakan penskalaan pelacakan target aktif pada sumber daya, kebijakan tersebut dapat menskalakan secara dinamis berdasarkan pemanfaatan sumber daya saat ini, dalam rentang kapasitas minimum dan maksimum yang baru.

Setelah menyelesaikan tutorial ini, Anda akan tahu cara:

- Gunakan penskalaan terjadwal untuk menambah kapasitas ekstra untuk memenuhi beban berat sebelum tiba, lalu lepaskan kapasitas ekstra saat tidak lagi diperlukan.
- Gunakan kebijakan penskalaan pelacakan target untuk menskalakan aplikasi Anda berdasarkan pemanfaatan sumber daya saat ini.

Daftar Isi

- [Prasyarat](#)
- [Langkah 1: Daftarkan target yang dapat diskalakan](#)
- [Langkah 2: Siapkan tindakan terjadwal sesuai dengan kebutuhan Anda](#)
- [Langkah 3: Tambahkan kebijakan penskalaan pelacakan target](#)
- [Langkah 4: Langkah selanjutnya](#)
- [Langkah 5: Bersihkan](#)

Prasyarat

Tutorial ini mengasumsikan bahwa Anda telah melakukan hal berikut:

- Dibuat sebuah Akun AWS.

- Menginstal dan mengkonfigurasi file AWS CLI.
- Memberikan izin yang diperlukan untuk mendaftarkan dan membatalkan pendaftaran sumber daya sebagai target yang dapat diskalakan dengan Application Auto Scaling. Selain itu, diberikan izin yang diperlukan untuk membuat kebijakan penskalaan dan tindakan terjadwal. Untuk informasi selengkapnya, lihat [Identity and Access Management untuk Application Auto Scaling](#).
- Membuat sumber daya yang didukung di lingkungan non-produksi yang tersedia untuk digunakan untuk tutorial ini. Jika Anda belum memiliki, buat sekarang. Untuk informasi tentang AWS layanan dan sumber daya yang bekerja dengan Application Auto Scaling, lihat bagian. [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#)

 Note

Saat menyelesaikan tutorial ini, ada dua langkah di mana Anda mengatur nilai kapasitas minimum dan maksimum sumber daya Anda ke 0 untuk mengatur ulang kapasitas saat ini ke 0. Bergantung pada sumber daya yang Anda gunakan dengan Application Auto Scaling, Anda mungkin tidak dapat mengatur ulang kapasitas saat ini ke 0 selama langkah-langkah ini. Untuk membantu Anda mengatasi masalah ini, pesan dalam output akan menunjukkan bahwa kapasitas minimum tidak boleh kurang dari nilai yang ditentukan dan akan memberikan nilai kapasitas minimum yang dapat diterima AWS sumber daya.

Langkah 1: Daftarkan target yang dapat diskalakan

Mulailah dengan meregistrasikan sumber daya Anda sebagai target yang dapat diskalakan dengan Application Auto Scaling. Target yang dapat diskalakan adalah sumber daya yang dapat diskalakan dan diskalakan oleh Application Auto Scaling.

Untuk mendaftarkan target yang dapat diskalakan dengan Application Auto Scaling

- Gunakan [register-scalable-target](#) perintah berikut untuk mendaftarkan target baru yang dapat diskalakan. Tetapkan `--min-capacity` dan `--max-capacity` ke 0 untuk mengatur ulang kapasitas saat ini ke 0.

Ganti teks sampel `--service-namespace` dengan namespace AWS layanan yang Anda gunakan dengan Application Auto Scaling `--scalable-dimension`, dengan dimensi skalabel yang terkait dengan sumber daya yang Anda daftarkan, `--resource-id` dan dengan pengenal untuk sumber daya. Nilai-nilai ini bervariasi berdasarkan sumber daya yang digunakan dan

bagaimana ID sumber daya dibangun. Lihat topik di [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#) bagian untuk informasi lebih lanjut. Topik ini mencakup contoh perintah yang menunjukkan cara mendaftarkan target yang dapat diskalakan dengan Application Auto Scaling.

Linux, macOS, atau Unix

```
aws application-autoscaling register-scalable-target \
--service-namespace namespace \
--scalable-dimension dimension \
--resource-id identifier \
--min-capacity 0 --max-capacity 0
```

Windows

```
aws application-autoscaling register-scalable-target --service-namespace namespace
--scalable-dimension dimension --resource-id identifier --min-capacity 0 --max-
capacity 0
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-target/1234abcd56ab78cd901ef1234567890ab123"
}
```

Langkah 2: Siapkan tindakan terjadwal sesuai dengan kebutuhan Anda

Anda dapat menggunakan [put-scheduled-action](#) perintah untuk membuat tindakan terjadwal yang dikonfigurasi untuk memenuhi kebutuhan bisnis Anda. Dalam tutorial ini, kami fokus pada konfigurasi yang berhenti mengkonsumsi sumber daya di luar jam kerja dengan mengurangi kapasitas menjadi 0.

Untuk membuat tindakan terjadwal yang akan disesuaikan di pagi hari

1. Untuk menskalakan target yang dapat diskalakan, gunakan [put-scheduled-action](#) perintah berikut. Sertakan parameter `--schedule` dengan jadwal berulang, dalam UTC, menggunakan ekspresi cron.

Pada jadwal yang ditentukan (setiap hari pukul 9:00 pagi UTC), Application Auto Scaling memperbarui MinCapacity dan MaxCapacity ke rentang unit kapasitas 1-5 yang diinginkan.

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action \
--service-namespace namespace \
--scalable-dimension dimension \
--resource-id identifier \
--scheduled-action-name my-first-scheduled-action \
--schedule "cron(0 9 * * ? *)" \
--scalable-target-action MinCapacity=1,MaxCapacity=5
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace namespace --scalable-dimension dimension --resource-id identifier --scheduled-action-name my-first-scheduled-action --schedule "cron(0 9 * * ? *)" --scalable-target-action MinCapacity=1,MaxCapacity=5
```

Perintah ini tidak akan memberikan output jika berhasil.

2. Untuk mengonfirmasi bahwa tindakan terjadwal Anda ada, gunakan [describe-scheduled-actions](#) perintah berikut.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scheduled-actions \
--service-namespace namespace \
--query 'ScheduledActions[?ResourceId==`identifier`]'
```

Windows

```
aws application-autoscaling describe-scheduled-actions --service-namespace namespace --query "ScheduledActions[?ResourceId=='identifier']"
```

Berikut ini adalah contoh output.

```
[  
 {  
     "ScheduledActionName": "my-first-scheduled-action",  
     "ScheduledActionARN": "arn",  
     "Schedule": "cron(0 9 * * ? *)",  
     "ScalableTargetAction": {  
         "MinCapacity": 1,  
         "MaxCapacity": 5  
     },  
     ...  
 }  
 ]
```

Untuk membuat jadwal tindakan pembesaran skala di malam hari

1. Ulangi prosedur sebelumnya untuk membuat tindakan terjadwal lainnya yang digunakan Application Auto Scaling untuk memperbesar skala di akhir hari.

Pada jadwal yang ditentukan (setiap hari pukul 8:00 PM UTC), Application Auto Scaling memperbarui target MinCapacity MaxCapacity dan ke 0, seperti yang diinstruksikan oleh perintah berikut. [put-scheduled-action](#)

Linux, macOS, atau Unix

```
aws application-autoscaling put-scheduled-action \  
  --service-namespace namespace \  
  --scalable-dimension dimension \  
  --resource-id identifier \  
  --scheduled-action-name my-second-scheduled-action \  
  --schedule "cron(0 20 * * ? *)" \  
  --scalable-target-action MinCapacity=0,MaxCapacity=0
```

Windows

```
aws application-autoscaling put-scheduled-action --service-namespace namespace --scalable-dimension dimension --resource-id identifier --scheduled-action-name my-second-scheduled-action --schedule "cron(0 20 * * ? *)" --scalable-target-action MinCapacity=0,MaxCapacity=0
```

- Untuk mengonfirmasi bahwa tindakan terjadwal Anda ada, gunakan [describe-scheduled-actions](#) perintah berikut.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scheduled-actions \  
--service-namespace namespace \  
--query 'ScheduledActions[?ResourceId==`identifier`]'
```

Windows

```
aws application-autoscaling describe-scheduled-actions --service-namespace namespace --query "ScheduledActions[?ResourceId==`identifier`]"
```

Berikut ini adalah output contoh.

```
[  
 {  
     "ScheduledActionName": "my-first-scheduled-action",  
     "ScheduledActionARN": "arn",  
     "Schedule": "cron(0 9 * * ? *)",  
     "ScalableTargetAction": {  
         "MinCapacity": 1,  
         "MaxCapacity": 5  
     },  
     ...  
 },  
 {  
     "ScheduledActionName": "my-second-scheduled-action",  
     "ScheduledActionARN": "arn",  
     "Schedule": "cron(0 20 * * ? *)",  
     "ScalableTargetAction": {  
         "MinCapacity": 0,  
         "MaxCapacity": 0  
     },  
     ...  
 }
```

```
}
```

Langkah 3: Tambahkan kebijakan penskalaan pelacakan target

Sekarang setelah Anda memiliki jadwal dasar, tambahkan kebijakan penskalaan pelacakan target ke skala berdasarkan pemanfaatan sumber daya saat ini.

Dengan pelacakan target, Application Auto Scaling membandingkan nilai target dalam kebijakan dengan nilai saat ini dari metrik yang ditentukan. Jika tidak sama untuk periode waktu tertentu, Application Auto Scaling akan menambah atau menghapus kapasitas untuk mempertahankan kinerja yang stabil. Saat beban pada aplikasi Anda dan nilai metrik meningkat, Application Auto Scaling menambah kapasitas secepat mungkin tanpa melebihi MaxCapacity. Ketika Application Auto Scaling menghapus kapasitas karena beban minimal, itu melakukannya tanpa di bawah MinCapacity. Dengan menyesuaikan kapasitas berdasarkan penggunaan, Anda hanya membayar untuk kebutuhan aplikasi Anda.

Jika metrik memiliki data yang tidak cukup karena aplikasi Anda tidak memiliki beban apa pun, Application Auto Scaling tidak menambah atau menghapus kapasitas. Dengan kata lain, Application Auto Scaling memprioritaskan ketersediaan dalam situasi di mana tidak cukup informasi yang tersedia.

Anda dapat menambahkan beberapa kebijakan penskalaan, tetapi pastikan Anda tidak menambahkan kebijakan penskalaan langkah yang bertentangan, yang dapat menyebabkan perilaku yang tidak diinginkan. Misalnya, jika kebijakan penskalaan langkah memulai aktivitas pembesaran skala sebelum kebijakan pelacakan target siap untuk memulai pembesaran skala, aktivitas pembesaran skala tidak akan diblokir. Setelah aktivitas scale-in selesai, kebijakan pelacakan target dapat menginstruksikan Application Auto Scaling untuk skala keluar lagi.

Untuk membuat kebijakan penskalaan pelacakan target

1. Gunakan [put-scaling-policy](#) perintah berikut untuk membuat kebijakan.

Metrik yang paling sering digunakan untuk pelacakan target sudah ditentukan sebelumnya, dan Anda dapat menggunakannya tanpa menyediakan spesifikasi metrik lengkap dari CloudWatch Metrics. Untuk informasi selengkapnya tentang metrik standar yang tersedia, lihat [Kebijakan penskalaan pelacakan target untuk Application Auto Scaling](#).

Sebelum menjalankan perintah ini, pastikan metrik yang sudah ditentukan sebelumnya menetapkan nilai target. Misalnya, untuk memperkecil skala ketika CPU mencapai 50% utilisasi, tentukan nilai target sebesar 50.0. Atau, untuk memperkecil skala konkurensi yang disediakan Lambda ketika penggunaan mencapai 70% pemanfaatan, tentukan nilai target sebesar 0,7. Untuk informasi tentang nilai target untuk sumber daya tertentu, lihat dokumentasi yang disediakan oleh layanan tentang cara mengonfigurasi pelacakan target. Untuk informasi selengkapnya, lihat [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

Linux, macOS, atau Unix

```
aws application-autoscaling put-scaling-policy \
--service-namespace namespace \
--scalable-dimension dimension \
--resource-id identifier \
--policy-name my-scaling-policy --policy-type TargetTrackingScaling \
--target-tracking-scaling-policy-configuration '{ "TargetValue": 50.0,
"PredefinedMetricSpecification": { "PredefinedMetricType": "predefinedmetric" }}'
```

Windows

```
aws application-autoscaling put-scaling-policy --service-namespace namespace --
scalable-dimension dimension --resource-id identifier --policy-name my-scaling-
policy --policy-type TargetTrackingScaling --target-tracking-scaling-policy-
configuration "{ \"TargetValue\": 50.0, \"PredefinedMetricSpecification\":
{ \"PredefinedMetricType\": \"predefinedmetric\" }}"
```

Jika berhasil, perintah ini mengembalikan ARN dan nama dari dua CloudWatch alarm yang dibuat atas nama Anda.

- Untuk mengonfirmasi bahwa tindakan terjadwal Anda ada, gunakan [describe-scaling-policies](#) perintah berikut.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scaling-policies --service-namespace namespace
\
--query 'ScalingPolicies[?ResourceId==`identifier`]'
```

Windows

```
aws application-autoscaling describe-scaling-policies --service-namespace namespace
--query "ScalingPolicies[?ResourceId=='identifier']"
```

Berikut ini adalah contoh output.

```
[  
 {  
     "PolicyARN": "arn",  
     "TargetTrackingScalingPolicyConfiguration": {  
         "PredefinedMetricSpecification": {  
             "PredefinedMetricType": "predefinedmetric"  
         },  
         "TargetValue": 50.0  
     },  
     "PolicyName": "my-scaling-policy",  
     "PolicyType": "TargetTrackingScaling",  
     "Alarms": [],  
     ...  
 }  
 ]
```

Langkah 4: Langkah selanjutnya

Saat aktivitas penskalaan terjadi, Anda akan melihat catatannya di output aktivitas penskalaan untuk target yang dapat diskalakan, misalnya:

```
Successfully set desired count to 1. Change successfully fulfilled by ecs.
```

Untuk memantau aktivitas penskalaan Anda dengan Application Auto Scaling, Anda dapat menggunakan perintah berikut. [describe-scaling-activities](#)

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scaling-activities  
--service-namespace namespace \  
--scalable-dimension dimension \  
--resource-id identifier
```

Windows

```
aws application-autoscaling describe-scaling-activities --service-namespace namespace
--scalable-dimension dimension --resource-id identifier
```

Langkah 5: Bersihkan

Untuk mencegah akun Anda menyesuaikan biaya untuk sumber daya yang diciptakan saat penskalaan aktif, Anda dapat membersihkan konfigurasi penskalaan terkait sebagai berikut.

Menghapus konfigurasi penskalaan tidak menghapus sumber daya yang mendasarinya AWS . Ini juga tidak akan mengembalikannya ke kapasitas asli. Anda dapat menggunakan konsol layanan tempat Anda membuat sumber daya untuk menghapusnya atau menyesuaikan kapasitasnya.

Untuk menghapus tindakan terjadwal

[delete-scheduled-action](#) Perintah berikut menghapus tindakan terjadwal yang ditentukan. Anda dapat melewati langkah ini jika Anda ingin mempertahankan tindakan terjadwal yang Anda buat.

Linux, macOS, atau Unix

```
aws application-autoscaling delete-scheduled-action \
--service-namespace namespace \
--scalable-dimension dimension \
--resource-id identifier \
--scheduled-action-name my-second-scheduled-action
```

Windows

```
aws application-autoscaling delete-scheduled-action --service-namespace namespace
--scalable-dimension dimension --resource-id identifier --scheduled-action-name my-
second-scheduled-action
```

Untuk menghapus kebijakan penskalaan

[delete-scaling-policy](#) Perintah berikut menghapus kebijakan penskalaan pelacakan target yang ditentukan. Anda dapat melewati langkah ini jika Anda ingin mempertahankan kebijakan penskalaan yang Anda buat.

Linux, macOS, atau Unix

```
aws application-autoscaling delete-scaling-policy \
```

```
--service-namespace namespace \
--scalable-dimension dimension \
--resource-id identifier \
--policy-name my-scaling-policy
```

Windows

```
aws application-autoscaling delete-scaling-policy --service-namespace namespace --
scalable-dimension dimension --resource-id identifier --policy-name my-scaling-policy
```

Untuk membatalkan pendaftaran target yang dapat diskalakan

Gunakan [deregister-scalable-target](#) perintah berikut untuk membatalkan pendaftaran target yang dapat diskalakan. Jika Anda memiliki kebijakan penskalaan yang Anda buat atau tindakan terjadwal yang belum dihapus, itu semua akan dihapus oleh perintah ini. Anda dapat melewati langkah ini jika Anda ingin menjaga target yang dapat diskalakan tetap terdaftar untuk penggunaan pada masa mendatang.

Linux, macOS, atau Unix

```
aws application-autoscaling deregister-scalable-target \
--service-namespace namespace \
--scalable-dimension dimension \
--resource-id identifier
```

Windows

```
aws application-autoscaling deregister-scalable-target --service-namespace namespace --
scalable-dimension dimension --resource-id identifier
```

Menangguhkan dan melanjutkan penskalaan untuk Application Auto Scaling

Topik ini menjelaskan cara menangguhkan dan kemudian melanjutkan satu atau beberapa aktivitas penskalaan untuk target yang dapat diskalakan dalam aplikasi Anda. Fitur tangguhkan-lanjutkan digunakan untuk secara sementara menjeda aktivitas penskalaan yang dipicu oleh kebijakan penskalaan dan tindakan terjadwal Anda. Ini dapat berguna, misalnya, ketika Anda tidak ingin penskalaan otomatis berpotensi mengganggu saat Anda melakukan perubahan atau menyelidiki masalah konfigurasi. Kebijakan penskalaan dan tindakan terjadwal Anda dapat dipertahankan, dan saat Anda siap, aktivitas penskalaan dapat dilanjutkan.

Dalam contoh perintah CLI yang mengikuti, Anda meneruskan parameter berformat JSON dalam file config.json. Anda juga dapat memberikan parameter ini di baris perintah dengan menggunakan tanda petik untuk menyertakan struktur data JSON. Untuk informasi lebih lanjut, lihat [Menggunakan tanda petik dengan string di AWS CLI](#) dalam AWS Command Line Interface Panduan Pengguna.

Daftar Isi

- [Aktivitas penskalaan](#)
- [Menangguhkan dan melanjutkan aktivitas penskalaan](#)

Note

Untuk petunjuk penangguhan proses penskalaan saat penerapan Amazon ECS sedang berlangsung, lihat dokumentasi berikut:

[Servis penskalaan dan penerapan otomatis](#) di Panduan Pengembang Layanan Amazon Elastic Container

Aktivitas penskalaan

Application Auto Scaling mendukung penetapan aktivitas penskalaan berikut dalam status ditangguhkan:

- Semua aktivitas penskalaan turun yang dipicu oleh kebijakan penskalaan.
- Semua aktivitas penskalaan naik yang dipicu oleh kebijakan penskalaan.

- Semua aktivitas penskalaan yang melibatkan tindakan terjadwal.

Deskripsi berikut menjelaskan apa yang terjadi saat tiap-tiap aktivitas penskalaan ditangguhkan. Tiap aktivitas dapat ditangguhkan dan dilanjutkan secara mandiri. Tergantung pada alasan untuk menangguhkan aktivitas penskalaan, Anda mungkin perlu menangguhkan beberapa aktivitas penskalaan sekaligus.

DynamicScalingInSuspended

- Application Auto Scaling tidak menghapus kapasitas ketika kebijakan penskalaan pelacakan target atau kebijakan penskalaan langkah dipicu. Ini memungkinkan Anda menonaktifkan sementara aktivitas penskalaan yang terkait dengan kebijakan penskalaan tanpa menghapus kebijakan penskalaan atau alarm terkait. CloudWatch Ketika Anda melanjutkan penskalaan turun, Application Auto Scaling mengevaluasi kebijakan dengan ambang batas alarm yang saat ini dilanggar.

DynamicScalingOutSuspended

- Application Auto Scaling tidak menambah kapasitas ketika kebijakan penskalaan pelacakan target atau kebijakan penskalaan langkah dipicu. Ini memungkinkan Anda menonaktifkan sementara aktivitas penskalaan yang terkait dengan kebijakan penskalaan tanpa menghapus kebijakan penskalaan atau alarm terkait. CloudWatch Ketika Anda melanjutkan penskalaan naik, Application Auto Scaling mengevaluasi kebijakan dengan ambang batas alarm yang saat ini dilanggar.

ScheduledScalingSuspended

- Application Auto Scaling tidak mengawali tindakan penskalaan yang dijadwalkan untuk dijalankan selama periode penangguhan. Ketika Anda melanjutkan penskalaan terjadwal, Application Auto Scaling hanya mengevaluasi tindakan terjadwal yang waktu pelaksanaannya belum berlalu.

Menangguhkan dan melanjutkan aktivitas penskalaan

Anda dapat menangguhkan dan melanjutkan aktivitas penskalaan individual atau semua aktivitas penskalaan untuk target Application Auto Scaling Anda yang dapat diskalakan.

Note

Demi keringkasan, contoh ini menggambarkan cara menangguhkan dan melanjutkan penskalaan untuk tabel DynamoDB. Untuk menentukan target yang dapat diskalakan yang berbeda, tentukan namespace-nya di `--service-namespace`, dimensinya yang dapat diskalakan di `--scalable-dimension`, dan ID sumber dayanya di `--resource-id`. Untuk informasi selengkapnya dan contoh untuk setiap layanan, lihat topik di [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

Untuk menangguhkan aktivitas penskalaan

Buka jendela baris perintah dan gunakan perintah `register-scalable-target` dengan opsi sebagai berikut. `--suspended-state`

Linux, macOS, atau Unix

```
aws application-autoscaling register-scalable-target --service-namespace dynamodb \
--scalable-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table \
--suspended-state file://config.json
```

Windows

```
aws application-autoscaling register-scalable-target --service-namespace dynamodb \
--scalable-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table \
--suspended-state file://config.json
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

Untuk hanya menangguhkan aktivitas penskalaan turun yang dipicu oleh kebijakan penskalaan, tentukan hal berikut dalam config.json.

```
{
  "DynamicScalingInSuspended":true
```

{

Untuk hanya menangguhkan aktivitas penskalaan naik yang dipicu oleh kebijakan penskalaan, tentukan hal berikut dalam config.json.

```
{  
    "DynamicScalingOutSuspended":true  
}
```

Untuk hanya menangguhkan aktivitas penskalaan yang melibatkan tindakan terjadwal, tentukan hal berikut dalam config.json.

```
{  
    "ScheduledScalingSuspended":true  
}
```

Untuk menangguhkan semua aktivitas penskalaan

Gunakan perintah [register-scalable-target](#) dengan opsi sebagai berikut. --suspended-state

Linux, macOS, atau Unix

```
aws application-autoscaling register-scalable-target --service-name dynamodb \  
--scalable-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table \  
--suspended-state file://config.json
```

Windows

```
aws application-autoscaling register-scalable-target --service-name dynamodb --  
scalable-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table --  
suspended-state file://config.json
```

Contoh ini mengasumsikan bahwa file config.json berisi parameter yang diformat JSON berikut.

```
{  
    "DynamicScalingInSuspended":true,  
    "DynamicScalingOutSuspended":true,  
    "ScheduledScalingSuspended":true  
}
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{  
    "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-  
target/1234abcd56ab78cd901ef1234567890ab123"  
}
```

Melihat aktivitas penskalaan yang ditangguhkan

Gunakan [perintah deskripsi-scalabe-target](#) untuk menentukan aktivitas penskalaan mana yang berada dalam status ditangguhkan untuk target yang dapat diskalakan.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scalabe-targets --service-namespace dynamodb \  
--scalabe-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table
```

Windows

```
aws application-autoscaling describe-scalabe-targets --service-namespace dynamodb --  
scalabe-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table
```

Berikut ini adalah contoh output.

```
{  
    "ScalableTargets": [  
        {  
            "ServiceNamespace": "dynamodb",  
            "ScalableDimension": "dynamodb:table:ReadCapacityUnits",  
            "ResourceId": "table/my-table",  
            "MinCapacity": 1,  
            "MaxCapacity": 20,  
            "SuspendedState": {  
                "DynamicScalingOutSuspended": true,  
                "DynamicScalingInSuspended": true,  
                "ScheduledScalingSuspended": true  
            },  
            "CreationTime": 1558125758.957,  
            "RoleARN": "arn:aws:iam::123456789012:role/aws-  
service-role/dynamodb.application-autoscaling.amazonaws.com/  
AWSServiceRoleForApplicationAutoScaling_DynamoDBTable"
```

```
    }
]
}
```

Melanjutkan aktivitas penskalaan

Saat Anda siap untuk melanjutkan aktivitas penskalaan, Anda dapat melanjutkannya menggunakan perintah [register-scalable-target](#).

Contoh perintah berikut melanjutkan semua aktivitas penskalaan untuk target yang dapat diskalakan tertentu.

Linux, macOS, atau Unix

```
aws application-autoscaling register-scalable-target --service-namespace dynamodb \
--scalable-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table \
--suspended-state file://config.json
```

Windows

```
aws application-autoscaling register-scalable-target --service-namespace dynamodb \
--scalable-dimension dynamodb:table:ReadCapacityUnits --resource-id table/my-table \
--suspended-state file://config.json
```

Contoh ini mengasumsikan bahwa file config.json berisi parameter yang diformat JSON berikut.

```
{
  "DynamicScalingInSuspended":false,
  "DynamicScalingOutSuspended":false,
  "ScheduledScalingSuspended":false
}
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

Aktivitas penskalaan untuk Application Auto Scaling

Application Auto Scaling memantau CloudWatch metrik kebijakan penskalaan Anda dan memulai aktivitas penskalaan saat ambang batas terlampaui. Ini juga memulai aktivitas penskalaan saat Anda memodifikasi ukuran maksimum atau minimum target yang dapat diskalakan, baik secara manual atau mengikuti jadwal.

Ketika aktivitas penskalaan terjadi, Application Auto Scaling melakukan salah satu hal berikut:

- Meningkatkan kapasitas target yang dapat diskalakan (disebut sebagai scaling out)
- Mengurangi kapasitas target yang dapat diskalakan (disebut sebagai penskalaan)

Anda dapat mencari aktivitas penskalaan dari enam minggu terakhir.

Cari aktivitas penskalaan berdasarkan target yang dapat diskalakan

Untuk melihat aktivitas penskalaan untuk target tertentu yang dapat diskalakan, gunakan perintah [deskripsi-penskalaan-aktivitas](#) berikut.

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scaling-activities --service-namespace ecs \  
--scalable-dimension ecs:service:DesiredCount --resource-id service/my-cluster/my-service
```

Windows

```
aws application-autoscaling describe-scaling-activities --service-namespace ecs --  
scalable-dimension ecs:service:DesiredCount --resource-id service/my-cluster/my-service
```

Berikut ini adalah contoh respons, yang StatusCode berisi status aktivitas saat ini dan StatusMessage berisi informasi tentang status aktivitas penskalaan.

```
{  
  "ScalingActivities": [  
    {
```

```
{  
    "ScalableDimension": "ecs:service:DesiredCount",  
    "Description": "Setting desired count to 1.",  
    "ResourceId": "service/my-cluster/my-service",  
    "ActivityId": "e6c5f7d1-dbbb-4a3f-89b2-51f33e766399",  
    "StartTime": 1462575838.171,  
    "ServiceNamespace": "ecs",  
    "EndTime": 1462575872.111,  
    "Cause": "monitor alarm web-app-cpu-lt-25 in state ALARM triggered policy  
web-app-cpu-lt-25",  
    "StatusMessage": "Successfully set desired count to 1. Change successfully  
fulfilled by ecs.",  
    "StatusCode": "Successful"  
}  
]  
}
```

Untuk deskripsi bidang dalam respons, lihat [ScalingActivity](#)di Referensi API Application Auto Scaling.

Kode status berikut menunjukkan kapan peristiwa penskalaan yang mengarah ke aktivitas penskalaan mencapai status selesai:

- **Successful**— Penskalaan berhasil diselesaikan
- **Overridden**— Kapasitas yang diinginkan diperbarui oleh acara penskalaan yang lebih baru
- **Unfulfilled**— Penskalaan waktunya habis atau layanan target tidak dapat memenuhi permintaan
- **Failed**— Penskalaan gagal dengan pengecualian

 Note

Aktivitas penskalaan mungkin juga memiliki status Pending atau InProgress. Semua aktivitas penskalaan memiliki Pending status sebelum layanan target merespons. Setelah target merespons, status aktivitas penskalaan berubah menjadi InProgress

Sertakan aktivitas yang tidak diskalakan

Secara default, aktivitas penskalaan tidak mencerminkan waktu ketika Application Auto Scaling membuat keputusan tentang apakah tidak akan menskalakan.

Misalnya, misalkan layanan Amazon ECS melebihi ambang batas maksimum metrik yang diberikan, tetapi jumlah tugas sudah mencapai jumlah maksimum tugas yang diizinkan. Dalam hal ini, Application Auto Scaling tidak mengurangi jumlah tugas yang diinginkan.

Untuk menyertakan aktivitas yang tidak diskalakan (bukan aktivitas yang diskalakan) dalam respons, tambahkan `--include-not-scaled-activities` opsi ke perintah [describe-scaling-activities](#).

Linux, macOS, atau Unix

```
aws application-autoscaling describe-scaling-activities --include-not-scaled-activities \
--service-namespace ecs --scalable-dimension ecs:service:DesiredCount \
--resource-id service/my-cluster/my-service
```

Windows

```
aws application-autoscaling describe-scaling-activities --include-not-scaled-activities \
--service-namespace ecs --scalable-dimension ecs:service:DesiredCount --resource-
id service/my-cluster/my-service
```

Note

Jika perintah ini menimbulkan kesalahan, pastikan Anda telah memperbarui AWS CLI secara lokal ke versi terbaru.

Untuk mengonfirmasi bahwa respons mencakup aktivitas yang tidak diskalakan, `NotScaledReasons` elemen ditampilkan dalam output untuk beberapa, jika tidak semua, aktivitas penskalaan yang gagal.

```
{
  "ScalingActivities": [
    {
      "ScalableDimension": "ecs:service:DesiredCount",
      "Description": "Attempting to scale due to alarm triggered",
      "ResourceId": "service/my-cluster/my-service",
      "ActivityId": "4d759079-a31f-4d0c-8468-504c56e2eecf",
      "StartTime": 1664928867.915,
      "ServiceNamespace": "ecs",
      "Cause": "monitor alarm web-app-cpu-gt-75 in state ALARM triggered policy web-app-cpu-gt-75",
```

```
        "StatusCode": "Failed",
        "NotScaledReasons": [
            {
                "Code": "AlreadyAtMaxCapacity",
                "MaxCapacity": 4
            }
        ]
    }
}
```

Untuk deskripsi bidang dalam respons, lihat [ScalingActivity](#) di Referensi API Application Auto Scaling.

Jika aktivitas yang tidak diskalakan dikembalikan, tergantung pada kode alasan yang tercantum dalamCode, atribut seperti CurrentCapacityMaxCapacity,, dan MinCapacity mungkin ada dalam respons.

Untuk mencegah entri duplikat dalam jumlah besar, hanya aktivitas pertama yang tidak diskalakan yang akan dicatat dalam riwayat aktivitas penskalaan. Setiap aktivitas yang tidak diskalakan berikutnya tidak akan menghasilkan entri baru kecuali alasan untuk tidak mengubah penskalaan.

Kode alasan

Berikut ini adalah kode alasan untuk aktivitas yang tidak diskalakan.

Kode alasan	Definisi
AutoScalingAnticipatingFlapping	Algoritma penskalaan otomatis yang memutuskan untuk tidak mengambil tindakan penskalaan karena akan menyebabkan flapping. Flapping adalah lingkaran penskalaan dan

Kode alasan	Definisi			
	<p>penskalaan yang tak terbatas.</p> <p>Artinya, jika tindakan penskalaa n diambil, nilai metrik akan berubah untuk memulai tindakan penskalaan lain dalam arah sebaliknya.</p>			
TargetServicePutRequest	<p>Layanan target untuk sementara menempatkan sumber daya dalam keadaan tidak dapat diskalakan.</p> <p>Application Auto Scaling akan mencoba lagi jika kondisi penskalaa n otomatis yang dikonfigurasi dalam kebijakan penskalaan terpenuhi.</p>			

Kode alasan	Definisi
AlreadyAtMaxCapacity	Penskalaan diblokir oleh kapasitas maksimum yang Anda tentukan. Jika Anda ingin Application Auto Scaling ditingkatkan, Anda perlu meningkatkan kapasitas maksimum.
AlreadyAtMinCapacity	Penskalaan diblokir oleh kapasitas minimum yang Anda tentukan. Jika Anda ingin Application Auto Scaling masuk, Anda perlu mengurangi kapasitas minimum.
AlreadyAtDesiredCapacity	Algoritma penskalaa n otomatis menghitung kapasitas yang direvisi menjadi sama dengan kapasitas saat ini.

Pemantauan Aplikasi Auto Scaling

Pemantauan adalah bagian penting dalam menjaga keandalan, ketersediaan, dan kinerja Application Auto Scaling dan solusi Anda yang lain AWS . Anda harus mengumpulkan data pemantauan dari semua bagian AWS solusi Anda sehingga Anda dapat lebih mudah men-debug kegagalan multi-titik jika terjadi. AWS menyediakan alat pemantauan untuk menonton Application Auto Scaling, melaporkan ketika ada sesuatu yang salah, dan mengambil tindakan otomatis bila perlu.

Anda dapat menggunakan fitur-fitur berikut untuk membantu Anda mengelola AWS sumber daya Anda:

AWS CloudTrail

Dengan AWS CloudTrail, Anda dapat melacak panggilan yang dilakukan ke Application Auto Scaling API oleh atau atas nama Anda. Akun AWS CloudTrail menyimpan informasi dalam file log di bucket Amazon S3 yang Anda tentukan. Anda dapat mengidentifikasi pengguna dan akun mana yang disebut Application Auto Scaling, alamat IP sumber dari mana panggilan dilakukan, dan kapan panggilan terjadi. Untuk informasi selengkapnya, lihat [Log Application Auto Scaling panggilan menggunakan API AWS CloudTrail](#).

Note

Untuk informasi tentang AWS layanan lain yang dapat membantu Anda mencatat dan mengumpulkan data tentang beban kerja Anda, lihat [panduan Pencatatan dan pemantauan untuk pemilik aplikasi](#) di Panduan AWS Preskriptif.

Amazon CloudWatch

Amazon CloudWatch membantu Anda menganalisis log dan, secara real time, memantau metrik AWS sumber daya dan aplikasi yang dihosting. Anda dapat mengumpulkan dan melacak metrik, membuat dasbor yang disesuaikan, dan mengatur alarm yang memberi tahu Anda atau mengambil tindakan saat metrik tertentu mencapai ambang batas yang ditentukan. Misalnya, Anda dapat CloudWatch melacak pemanfaatan sumber daya dan memberi tahu Anda saat pemanfaatan sangat tinggi atau ketika alarm metrik telah masuk ke status INSUFFICIENT_DATA Untuk informasi selengkapnya, lihat [Memantau penggunaan sumber daya yang dapat diskalakan menggunakan CloudWatch](#).

CloudWatch juga melacak metrik AWS API penggunaan untuk Application Auto Scaling. Anda dapat menggunakan metrik ini untuk mengonfigurasi alarm yang memberi tahu Anda saat volume API panggilan melanggar ambang batas yang Anda tentukan. Untuk informasi selengkapnya, lihat [metrik AWS penggunaan](#) di Panduan CloudWatch Pengguna Amazon.

Amazon EventBridge

Amazon EventBridge adalah layanan bus acara tanpa server yang memudahkan untuk menghubungkan aplikasi Anda dengan data dari berbagai sumber. EventBridge memberikan aliran data real-time dari aplikasi Anda sendiri, aplikasi software-as-a Service (SaaS), dan AWS layanan serta rute data tersebut ke target seperti Lambda. Ini memungkinkan Anda memantau peristiwa yang terjadi di layanan, dan membangun arsitektur berbasis peristiwa. Untuk informasi selengkapnya, lihat [Memantau peristiwa Application Auto Scaling menggunakan Amazon EventBridge](#).

AWS Health Dashboard

The AWS Health Dashboard (PHD) menampilkan informasi, dan juga menyediakan pemberitahuan yang dipanggil oleh perubahan kesehatan AWS sumber daya. Informasi ini disajikan dalam dua cara: di dasbor yang menampilkan peristiwa terbaru dan mendatang yang diatur berdasarkan kategori, dan dalam catatan peristiwa lengkap yang menampilkan semua peristiwa dari 90 hari terakhir. Untuk informasi selengkapnya, lihat [Memulai dengan Anda AWS Health Dashboard](#).

Memantau penggunaan sumber daya yang dapat diskalakan menggunakan CloudWatch

Dengan Amazon CloudWatch, Anda mendapatkan visibilitas yang hampir terus menerus ke dalam aplikasi Anda di seluruh sumber daya yang dapat diskalakan. CloudWatch adalah layanan pemantauan untuk AWS sumber daya. Anda dapat menggunakan CloudWatch untuk mengumpulkan dan melacak metrik, menyetel alarm, dan bereaksi secara otomatis terhadap perubahan sumber daya Anda AWS . Anda juga dapat membuat dasbor untuk memantau metrik atau set metrik tertentu yang Anda butuhkan.

Saat Anda berinteraksi dengan layanan yang terintegrasi dengan Application Auto Scaling, mereka akan mengirimkan metrik yang ditunjukkan pada tabel berikut. CloudWatch Dalam CloudWatch, metrik dikelompokkan terlebih dahulu oleh namespace layanan, dan kemudian oleh berbagai kombinasi dimensi dalam setiap namespace. Metrik ini dapat membantu Anda memantau

penggunaan sumber daya dan kapasitas rencana untuk aplikasi Anda. Jika beban kerja aplikasi Anda tidak konstan, ini menunjukkan bahwa Anda harus mempertimbangkan untuk menggunakan penskalaan otomatis. Untuk deskripsi mendetail tentang metrik ini, lihat dokumentasi untuk metrik yang diminati.

Daftar Isi

- [CloudWatch metrik untuk memantau penggunaan sumber daya](#)
- [Metrik yang telah ditentukan sebelumnya untuk kebijakan penskalaan pelacakan target](#)

CloudWatch metrik untuk memantau penggunaan sumber daya

Tabel berikut mencantumkan CloudWatch metrik yang tersedia untuk mendukung pemantauan penggunaan sumber daya. Daftar ini tidak lengkap tetapi akan memberi Anda titik awal yang baik. Jika Anda tidak melihat metrik ini di CloudWatch konsol, pastikan Anda telah menyelesaikan pengaturan sumber daya. Untuk informasi selengkapnya, lihat [Panduan CloudWatch Pengguna Amazon](#).

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
AppStream 2.0			
Armada	AWS/AppStream	Nama: Available Capacity Dimensi: Armada	AppStream 2.0 metrik
Armada	AWS/AppStream	Nama: CapacityUtilization Dimensi: Armada	AppStream 2.0 metrik
Aurora			

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Replika	AWS/RDS	Nama: CPUUtilization Dimensi: DBClusterIdentifier, Peran (READER)	Metrik tingkat klaster Aurora
Replika	AWS/RDS	Nama: DatabaseConnections Dimensi: DBClusterIdentifier, Peran (READER)	Metrik tingkat klaster Aurora
Amazon Comprehend			
Titik akhir klasifikasi dokumen	AWS/Memahami	Nama: InferenceUtilization Dimensi: EndpointArn	Amazon Comprehend metrik titik akhir

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Titik akhir pengenal entitas	AWS/Memahami	Nama: InferenceUtilization Dimensi: EndpointArn	Amazon Comprehend metrik titik akhir
DynamoDB			
Tabel dan indeks sekunder global	AWS/DynamoDB	Nama: ProvisionedReadCapacityUnits Dimensi: TableName, GlobalSecondaryIndexName	Metrik DynamoDB
Tabel dan indeks sekunder global	AWS/DynamoDB	Nama: ProvisionedWriteCapacityUnits Dimensi: TableName, GlobalSecondaryIndexName	Metrik DynamoDB

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Tabel dan indeks sekunder global	AWS/DynamoDB	Nama: ConsumedReadCapacityUnits Dimensi: TableName, GlobalSecondaryIndexName	Metrik DynamoDB
Tabel dan indeks sekunder global	AWS/DynamoDB	Nama: ConsumedWriteCapacityUnits Dimensi: TableName, GlobalSecondaryIndexName	Metrik DynamoDB
Amazon ECS			
Layanan	AWS/ECS	Nama: CPUUtilization Dimensi: ClusterName, ServiceName	ECS Metrik Amazon

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Layanan	AWS/ECS	Nama: MemoryUtilization Dimensi: ClusterName, ServiceName	ECS Metrik Amazon
Layanan	AWS/Aplikasi ELB	Nama: RequestCountPerTarget Dimensi: TargetGroup	Metrik Application Load Balancer
ElastiCache			
Cluster (kelompok replikasi)	AWS/ElastiCache	Nama: DatabaseMemoryUsage Dimensi: ReplicationGroup	ElastiCache (Redis OSS) metrik

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Cluster (kelompok replikasi)	AWS/ElastiCache	Nama: DatabaseCapacityUsage ageCountedForEviction Percentaged Dimensi: ReplicationGroupId	ElastiCache (RedisOSS) metrik
Cluster (kelompok replikasi)	AWS/ElastiCache	Nama: EngineCPUUtilization Dimensi: ReplicationGroupId, Peran (Utama)	ElastiCache (RedisOSS) metrik
Cluster (kelompok replikasi)	AWS/ElastiCache	Nama: EngineCPUUtilization Dimensi: ReplicationGroupId, Peran (Replika)	ElastiCache (RedisOSS) metrik
Amazon EMR			

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Klaster	AWS/ElasticMapReduce	Nama: YARNMemoryAvailablePercentage Dimensi: ClusterId	EMR Metrik Amazon
Keyspaces Amazon			
Tabel	AWS/Cassandra	Nama: ProvisionedReadCapacityUnits Dimensi: Keyspace, TableName	Metrik Amazon Keyspaces
Tabel	AWS/Cassandra	Nama: ProvisionedWriteCapacityUnits Dimensi: Keyspace, TableName	Metrik Amazon Keyspaces

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Tabel	AWS/Cassandra	Nama: ConsumedReadCapacityUnits Dimensi: Keyspace, TableName	Metrik Amazon Keyspaces
Tabel	AWS/Cassandra	Nama: ConsumedWriteCapacityUnits Dimensi: Keyspace, TableName	Metrik Amazon Keyspaces
Lambda			
Konkurensi terprovisi	AWS/Lambda	Nama: ProvisionedConcurrencyUtilization Dimensi: FunctionName, Sumber	Metrik fungsi Lambda
Amazon MSK			

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Penyimpanan broker	AWS/Kafka	Nama: KafkaDataLogsDiskU sed Dimensi: Nama Cluster	MSK Metrik Amazon
Penyimpanan broker	AWS/Kafka	Nama: KafkaDataLogsDiskU sed Dimensi: Nama Cluster, ID Broker	MSK Metrik Amazon
Neptunus			
Klaster	AWS/Neptunus	Nama: CPUUtilization Dimensi:D BClusterIdentifier , Peran (READER)	Metrik Neptunus
SageMaker			

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Varian titik akhir	AWS/SageMaker	Nama: InvocationsPerInstance Dimensi: EndpointName, VariantName	Metrik pemanggilan
Komponen inferensi	AWS/SageMaker	Nama: InvocationsPerCopy Dimensi: InferenceComponentName	Metrik pemanggilan
Konkurensi yang disediakan untuk titik akhir tanpa server	AWS/SageMaker	Nama: ServerlessProvisionedConcurrencyUtilization Dimensi: EndpointName, VariantName	Metrik titik akhir tanpa server
Armada Spot (AmazonEC2)			

Sumber daya yang dapat diskalakan	Namespace	CloudWatch metrik	Tautan ke dokumentasi
Armada Spot	AWS/EC2Spot	Nama: CPUUtilization Dimensi: FleetRequestId	Metrik Armada Spot
Armada Spot	AWS/EC2Spot	Nama: NetworkIn Dimensi: FleetRequestId	Metrik Armada Spot
Armada Spot	AWS/EC2Spot	Nama: NetworkOut Dimensi: FleetRequestId	Metrik Armada Spot
Armada Spot	AWS/Aplikasi ELB	Nama: RequestCountPerTarget Dimensi: TargetGroup	Metrik Application Load Balancer

Metrik yang telah ditentukan sebelumnya untuk kebijakan penskalaan pelacakan target

Tabel berikut mencantumkan tipe metrik yang telah ditentukan dari Referensi [Application Auto API Scaling](#) dengan nama metrik yang CloudWatch sesuai. Setiap metrik yang telah ditentukan mewakili agregasi nilai metrik yang mendasarinya CloudWatch . Hasilnya adalah penggunaan sumber daya rata-rata selama periode satu menit, berdasarkan persentase kecuali dinyatakan lain. Metrik yang telah ditentukan hanya digunakan dalam konteks pengaturan kebijakan penskalaan pelacakan target.

Anda dapat menemukan informasi selengkapnya tentang metrik ini di dokumentasi layanan yang tersedia dari tabel di[CloudWatch metrik untuk memantau penggunaan sumber daya](#).

Jenis metrik yang telah ditentukan	CloudWatch nama metrik
AppStream 2.0	
AppStreamAverageCapacityUtilization	CapacityUtilization
Aurora	
RDSReaderAverageCPUUtilization	CPUUtilization
RDSReaderAverageDatabaseConnections	DatabaseConnections ¹
Amazon Comprehend	
ComprehendInferenceUtilization	InferenceUtilization
DynamoDB	
DynamoDBReadCapacityUtilization	ProvisionedReadCapacityUnits, ConsumedReadCapacityUnits ²
DynamoDBWriteCapacityUtilization	ProvisionedWriteCapacityUnits, ConsumedWriteCapacityUnits ²
Amazon ECS	

Jenis metrik yang telah ditentukan	CloudWatch nama metrik
ECSServiceAverageCPUUtilization	CPUUtilization
ECSServiceAverageMemoryUtilization	MemoryUtilization
ALBRequestCountPerTarget	RequestCountPerTarget ¹
ElastiCache	
ElastiCacheDatabaseMemoryUsageCountedForEvictPercentage	DatabaseMemoryUsageCountedForEvictPercentage
ElastiCacheDatabaseCapacityUsageCountedForEvictPercentage	DatabaseCapacityUsageCountedForEvictPercentage
ElastiCachePrimaryEngineCPUUtilization	EngineCPUUtilization
ElastiCacheReplicaEngineCPUUtilization	EngineCPUUtilization
Keyspaces Amazon	
CassandraReadCapacityUtilization	ProvisionedReadCapacityUnits, ConsumedReadCapacityUnits ²
CassandraWriteCapacityUtilization	ProvisionedWriteCapacityUnits, ConsumedWriteCapacityUnits ²
Lambda	
LambdaProvisionedConcurrencyUtilization	ProvisionedConcurrencyUtilization
Amazon MSK	
KafkaBrokerStorageUtilization	KafkaDataLogsDiskUsed
Neptunus	

Jenis metrik yang telah ditentukan	CloudWatch nama metrik
NeptuneReaderAverageCPUUtilization	CPUUtilization
SageMaker	
SageMakerVariantInvocationsPerInstance	InvocationsPerInstance ¹
SageMakerInferenceComponent InvocationsPerCopy	InvocationsPerCopy ¹
SageMakerVariantProvisionedConcurrencyUtilization	ServerlessProvisionedConcurrencyUtilization
SageMakerInferenceComponent ConcurrentRequestsPerCopyHighResolution	ConcurrentRequestsPerCopy
SageMakerVariantConcurrentRequestsPerModelHighResolution	ConcurrentRequestsPerModel
Armada Spot	
EC2SpotFleetRequestAverageCPUUtilization	CPUUtilization ³
EC2SpotFleetRequestAverageNetworkIn ³	NetworkIn ^{1 3}
EC2SpotFleetRequestAverageNetworkOut ³	NetworkOut ^{1 3}
ALBRequestCountPerTarget	RequestCountPerTarget ¹

¹ Metrik didasarkan pada hitungan, bukan persentase.

² Untuk DynamoDB dan Amazon Keyspaces, metrik yang telah ditentukan adalah agregasi dari dua metrik untuk mendukung penskalaan berdasarkan konsumsi CloudWatch throughput yang disediakan.

³ Untuk kinerja penskalaan terbaik, pemantauan EC2 terperinci Amazon harus digunakan.

Log Application Auto Scaling panggilan menggunakan API AWS CloudTrail

Application Auto Scaling terintegrasi dengan AWS CloudTrail, layanan yang menyediakan catatan tindakan yang diambil oleh pengguna, peran, atau Layanan AWS menggunakan Application Auto Scaling. API CloudTrail menangkap semua API panggilan untuk Application Auto Scaling sebagai acara. Panggilan yang diambil termasuk panggilan dari panggilan AWS Management Console dan kode ke Application Auto API Scaling. Jika Anda membuat jejak, Anda dapat mengaktifkan pengiriman CloudTrail acara secara terus menerus ke bucket Amazon S3, termasuk peristiwa untuk Application Auto Scaling. Jika Anda tidak mengkonfigurasi jejak, Anda masih dapat melihat peristiwa terbaru di CloudTrail konsol dalam Riwayat acara. Dengan menggunakan informasi yang dikumpulkan oleh CloudTrail, Anda dapat menentukan permintaan yang dibuat untuk Application Auto Scaling, alamat IP dari mana permintaan dibuat, siapa yang membuat permintaan, kapan dibuat, dan detail tambahan.

Untuk mempelajari selengkapnya CloudTrail, lihat [Panduan AWS CloudTrail Pengguna](#).

Informasi Application Auto Scaling di CloudTrail

CloudTrail diaktifkan pada Akun AWS saat Anda membuat akun. Ketika aktivitas Application Auto Scaling terjadi, aktivitas tersebut direkam dalam suatu CloudTrail peristiwa bersama dengan peristiwa AWS layanan lainnya dalam riwayat Acara. Anda dapat melihat, mencari, dan mengunduh acara terbaru di situs Anda Akun AWS. Untuk informasi selengkapnya, lihat [Melihat peristiwa dengan riwayat CloudTrail acara](#).

Untuk catatan peristiwa yang sedang berlangsung di Anda Akun AWS, termasuk acara untuk Application Auto Scaling, buat jejak. Jejak memungkinkan CloudTrail untuk mengirimkan file log ke bucket Amazon S3. Secara default, saat Anda membuat jejak di konsol, jejak tersebut berlaku untuk semua Wilayah AWS. Jejak mencatat peristiwa dari semua Wilayah di AWS partisi dan mengirimkan file log ke bucket Amazon S3 yang Anda tentukan. Selain itu, Anda dapat mengkonfigurasi Amazon Web Services lainnya untuk menganalisis lebih lanjut dan menindaklanjuti data peristiwa yang dikumpulkan dalam CloudTrail log. Untuk informasi selengkapnya, lihat berikut:

- [Gambaran umum untuk membuat jejak](#)
- [CloudTrail layanan dan integrasi yang didukung](#)
- [Mengonfigurasi SNS notifikasi Amazon untuk CloudTrail](#)
- [Menerima file CloudTrail log dari beberapa wilayah](#) dan [Menerima file CloudTrail log dari beberapa akun](#)

Semua tindakan Application Auto Scaling dicatat oleh CloudTrail dan didokumentasikan dalam Referensi [Application Auto API](#) Scaling. Misalnya, panggilan ke `PutScalingPolicy`, `DeleteScalingPolicy`, dan `DescribeScalingPolicies` tindakan menghasilkan entri dalam file CloudTrail log.

Setiap entri peristiwa atau log berisi informasi tentang siapa yang membuat permintaan tersebut. Informasi identitas membantu Anda menentukan berikut ini:

- Apakah permintaan dibuat dengan root atau AWS Identity and Access Management (IAM) kredensional pengguna.
- Apakah permintaan tersebut dibuat dengan kredensial keamanan sementara untuk satu peran atau pengguna terfederasi.
- Apakah permintaan itu dibuat oleh AWS layanan lain.

Untuk informasi lebih lanjut, lihat [CloudTrail userIdentity elemen](#).

Memahami entri file log Application Auto Scaling

Trail adalah konfigurasi yang memungkinkan pengiriman peristiwa sebagai file log ke bucket Amazon S3 yang Anda tentukan. CloudTrail file log berisi satu atau lebih entri log. Peristiwa mewakili permintaan tunggal dari sumber manapun dan mencakup informasi tentang tindakan yang diminta, tanggal dan waktu tindakan, parameter permintaan, dan sebagainya. CloudTrail file log bukanlah jejak tumpukan yang diurutkan dari API panggilan publik, sehingga tidak muncul dalam urutan tertentu.

Contoh berikut menunjukkan entri CloudTrail log yang menunjukkan `DescribeScalableTargets` tindakan.

```
{  
  "eventVersion": "1.05",  
  "userIdentity": {
```

```
"type": "Root",
"principalId": "123456789012",
"arn": "arn:aws:iam::123456789012:root",
"accountId": "123456789012",
"accessKeyId": "AKIAIOSFODNN7EXAMPLE",
"sessionContext": {
    "attributes": {
        "mfaAuthenticated": "false",
        "creationDate": "2018-08-21T17:05:42Z"
    }
},
{
    "eventTime": "2018-08-16T23:20:32Z",
    "eventSource": "autoscaling.amazonaws.com",
    "eventName": "DescribeScalableTargets",
    "awsRegion": "us-west-2",
    "sourceIPAddress": "72.21.196.68",
    "userAgent": "EC2 Spot Console",
    "requestParameters": {
        "serviceNamespace": "ec2",
        "scalableDimension": "ec2:spot-fleet-request:TargetCapacity",
        "resourceIds": [
            "spot-fleet-request/sfr-05ceaf79-3ba2-405d-e87b-612857f1357a"
        ]
    },
    "responseElements": null,
    "additionalEventData": {
        "service": "application-autoscaling"
    },
    "requestID": "0737e2ea-fb2d-11e3-bfd8-99133058e7bb",
    "eventID": "3fcfb182-98f8-4744-bd45-b38835ab61cb",
    "eventType": "AwsApiCall",
    "recipientAccountId": "123456789012"
}
```

Sumber daya terkait

Dengan CloudWatch Log, Anda dapat memantau dan menerima peringatan untuk peristiwa tertentu yang ditangkap oleh CloudTrail. Peristiwa yang dikirim ke CloudWatch Log adalah peristiwa yang dikonfigurasi untuk dicatat oleh jejak Anda, jadi pastikan Anda telah mengonfigurasi jejak atau jejak Anda untuk mencatat jenis acara yang ingin Anda pantau. CloudWatch Log dapat memantau informasi dalam file log dan memberi tahu Anda ketika ambang batas tertentu terpenuhi. Anda

juga dapat mengarsipkan data log dalam penyimpanan yang sangat durabel. Untuk informasi selengkapnya, lihat [Panduan Pengguna Amazon CloudWatch Logs](#) dan [Memantau file CloudTrail log dengan topik Amazon CloudWatch Logs](#) di Panduan AWS CloudTrail Pengguna.

Memantau peristiwa Application Auto Scaling menggunakan Amazon EventBridge

Amazon EventBridge, sebelumnya disebut CloudWatch Events, membantu Anda memantau peristiwa yang khusus untuk Application Auto Scaling dan memulai tindakan target yang menggunakan lainnya. Layanan AWS Acara dari Layanan AWS dikirim ke EventBridge dalam waktu dekat.

Dengan menggunakan EventBridge, Anda dapat membuat aturan yang cocok dengan peristiwa yang masuk dan merutekkannya ke target untuk diproses.

Untuk informasi selengkapnya, lihat [Memulai Amazon EventBridge](#) di Panduan EventBridge Pengguna Amazon.

Peristiwa Application Auto Scaling

Contoh berikut menunjukkan peristiwa untuk Application Auto Scaling. Acara diproduksi atas dasar upaya terbaik.

Hanya peristiwa yang khusus untuk diskalakan ke max dan API panggilan via yang saat ini CloudTrail tersedia untuk Application Auto Scaling.

Jenis peristiwa

- [Peristiwa untuk perubahan status: diskalakan ke maks](#)
- [Acara untuk API panggilan melalui CloudTrail](#)

Peristiwa untuk perubahan status: diskalakan ke maks

Contoh peristiwa berikut menunjukkan bahwa Application Auto Scaling meningkatkan (memperkecil) kapasitas target yang dapat diskalakan hingga batas ukuran maksimumnya. Jika permintaan meningkat lagi, Application Auto Scaling akan dicegah dari penskalaan target ke ukuran yang lebih besar karena sudah diskalakan ke ukuran maksimumnya.

Dalam detail objek, nilai untuk, `resourceId`, `serviceNamespace`, dan `scalableDimension` atribut mengidentifikasi target yang dapat diskalakan. Nilai untuk `oldDesiredCapacity` atribut

`newDesiredCapacity` dan mengacu pada kapasitas baru setelah peristiwa scale-out dan kapasitas asli sebelum acara scale-out. `maxCapacity` ini adalah batas ukuran maksimum dari target yang dapat diskalakan.

```
{  
  "version": "0",  
  "id": "11112222-3333-4444-5555-666677778888",  
  "detail-type": "Application Auto Scaling Scaling Activity State Change",  
  "source": "aws.application-autoscaling",  
  "account": "123456789012",  
  "time": "2019-06-12T10:23:40Z",  
  "region": "us-west-2",  
  "resources": [],  
  "detail": {  
    "startTIme": "2022-06-12T10:20:43Z",  
    "endTIme": "2022-06-12T10:23:40Z",  
    "newDesiredCapacity": 8,  
    "oldDesiredCapacity": 5,  
    "minCapacity": 2,  
    "maxCapacity": 8,  
    "resourceId": "table/my-table",  
    "scalableDimension": "dynamodb:table:WriteCapacityUnits",  
    "serviceNamespace": "dynamodb",  
    "statusCode": "Successful",  
    "scaledToMax": true,  
    "direction": "scale-out"  
  }  
}
```

Untuk membuat aturan yang menangkap semua peristiwa perubahan `scaledToMax` status untuk semua target yang dapat diskalakan, gunakan contoh pola peristiwa berikut.

```
{  
  "source": [  
    "aws.application-autoscaling"  
  ],  
  "detail-type": [  
    "Application Auto Scaling Scaling Activity State Change"  
  ],  
  "detail": {  
    "scaledToMax": [  
      true  
    ]  
  }  
}
```

```
 }  
 }
```

Acara untuk API panggilan melalui CloudTrail

Trail adalah konfigurasi yang AWS CloudTrail digunakan untuk mengirimkan peristiwa sebagai file log ke bucket Amazon S3. CloudTrail file log berisi entri log. Suatu peristiwa mewakili entri log, dan mencakup informasi tentang tindakan yang diminta, tanggal dan waktu tindakan, dan parameter permintaan. Untuk mempelajari cara memulai CloudTrail, lihat [Membuat jejak](#) di Panduan AWS CloudTrail Pengguna.

Acara yang disampaikan melalui CloudTrail memiliki AWS API Call via CloudTrail nilai untuk detail-type.

Contoh peristiwa berikut mewakili entri file CloudTrail log yang menunjukkan bahwa pengguna konsol disebut tindakan Application Auto Scaling. [RegisterScalableTarget](#)

```
{  
  "version": "0",  
  "id": "99998888-7777-6666-5555-444433332222",  
  "detail-type": "AWS API Call via CloudTrail",  
  "source": "aws.autoscaling",  
  "account": "123456789012",  
  "time": "2022-07-13T16:50:15Z",  
  "region": "us-west-2",  
  "resources": [],  
  "detail": {  
    "eventVersion": "1.08",  
    "userIdentity": {  
      "type": "IAMUser",  
      "principalId": "123456789012",  
      "arn": "arn:aws:iam::123456789012:user/Bob",  
      "accountId": "123456789012",  
      "accessKeyId": "AKIAIOSFODNN7EXAMPLE",  
      "sessionContext": {  
        "sessionIssuer": {  
          "type": "Role",  
          "principalId": "123456789012",  
          "arn": "arn:aws:iam::123456789012:role/Admin",  
          "accountId": "123456789012",  
          "userName": "Admin"  
        },  
      },  
    },  
  },  
}
```

```
        "webIdFederationData": {},
        "attributes": {
            "creationDate": "2022-07-13T15:17:08Z",
            "mfaAuthenticated": "false"
        }
    },
    "eventTime": "2022-07-13T16:50:15Z",
    "eventSource": "autoscaling.amazonaws.com",
    "eventName": "RegisterScalableTarget",
    "awsRegion": "us-west-2",
    "sourceIPAddress": "AWS Internal",
    "userAgent": "EC2 Spot Console",
    "requestParameters": {
        "resourceId": "spot-fleet-request/sfr-73fb2ce-aa30-494c-8788-1cee4EXAMPLE",
        "serviceNamespace": "ec2",
        "scalableDimension": "ec2:spot-fleet-request:TargetCapacity",
        "minCapacity": 2,
        "maxCapacity": 10
    },
    "responseElements": null,
    "additionalEventData": {
        "service": "application-autoscaling"
    },
    "requestID": "e9caf887-8d88-11e5-a331-3332aa445952",
    "eventID": "49d14f36-6450-44a5-a501-b0fdcdfaeb98",
    "readOnly": false,
    "eventType": "AwsApiCall",
    "managementEvent": true,
    "recipientAccountId": "123456789012",
    "eventCategory": "Management",
    "sessionCredentialFromConsole": "true"
}
}
```

Untuk membuat aturan berdasarkan semua [DeleteScalingPolicy](#) dan [DeregisterScalableTarget](#) API panggilan untuk semua target yang dapat diskalakan, gunakan contoh pola peristiwa berikut:

```
{
    "source": [
        "aws.autoscaling"
    ],
}
```

```
"detail-type": [
    "AWS API Call via CloudTrail"
],
"detail": {
    "eventSource": [
        "autoscaling.amazonaws.com"
    ],
    "eventName": [
        "DeleteScalingPolicy",
        "DeregisterScalableTarget"
    ],
    "additionalEventData": {
        "service": [
            "application-autoscaling"
        ]
    }
}
}
```

Untuk informasi selengkapnya tentang penggunaan CloudTrail, lihat [Log Application Auto Scaling panggilan menggunakan API AWS CloudTrail](#).

Dukungan penandaan untuk Application Auto Scaling

Anda dapat menggunakan AWS CLI atau SDK untuk menandai target Application Auto Scaling yang dapat diskalakan. Target yang dapat diskalakan adalah entitas yang mewakili AWS atau sumber daya kustom yang dapat diskalakan oleh Application Auto Scaling.

Setiap tag adalah label yang terdiri dari kunci dan nilai yang ditentukan pengguna menggunakan Application Auto Scaling API. Tag dapat membantu Anda mengonfigurasi akses terperinci ke target tertentu yang dapat diskalakan sesuai dengan kebutuhan organisasi Anda. Untuk informasi selengkapnya, lihat [ABAC dengan Application Auto Scaling](#).

Anda dapat menambahkan tag ke target baru yang dapat diskalakan saat Anda mendaftarkannya, atau Anda dapat menambahkannya ke target skalabel yang ada.

Perintah yang umum digunakan untuk mengelola tag meliputi:

- [register-scalable-target](#) untuk menandai target baru yang dapat diskalakan saat Anda mendaftarkannya.
- [tag-resource](#) untuk menambahkan tag ke target skalabel yang ada.
- [list-tags-for-resource](#) untuk mengembalikan tag pada target yang dapat diskalakan.
- [untag-resource](#) untuk menghapus tag.

Contoh penandaan

Gunakan perintah [register-scalable-target](#) berikut dengan opsi. --tags Contoh ini menandai target yang dapat diskalakan dengan dua tag: kunci tag bernama **environment** dengan nilai tag **dari production**, dan kunci tag bernama **iscontainerbased** dengan nilai **true** tag.

Ganti nilai sampel untuk **--min-capacity** dan **--max-capacity** dan contoh teks **--service-namespace** dengan namespace AWS layanan yang Anda gunakan dengan Application Auto Scaling **--scalable-dimension**, dengan dimensi skalabel yang terkait dengan sumber daya yang Anda daftarkan, **--resource-id** dan dengan pengenal untuk sumber daya. Untuk informasi selengkapnya dan contoh untuk setiap layanan, lihat topik di [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

```
aws application-autoscaling register-scalable-target \
--service-namespace namespace \
```

```
--scalable-dimension dimension \
--resource-id identifier \
--min-capacity 1 --max-capacity 10 \
--tags environment=production,iscontainerbased=true
```

Jika berhasil, perintah ini mengembalikan ARN dari target yang dapat diskalakan.

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
}
```

Note

Jika perintah ini menimbulkan kesalahan, pastikan Anda telah memperbarui AWS CLI secara lokal ke versi terbaru.

Tag untuk keamanan

Gunakan tag untuk memverifikasi bahwa pemohon (seperti pengguna atau peran IAM) memiliki izin untuk melakukan tindakan tertentu. Berikan informasi tag dalam elemen kondisi kebijakan IAM dengan menggunakan satu atau beberapa kunci kondisi berikut:

- Gunakan `aws:ResourceTag/tag-key: tag-value` untuk mengizinkan (atau menolak) tindakan pengguna pada target yang dapat diskalakan dengan tag tertentu.
- Gunakan `aws:RequestTag/tag-key: tag-value` untuk meminta tag khusus dapat ada (atau tidak ada) dalam permintaan.
- Gunakan `aws:TagKeys [tag-key, ...]` untuk meminta kunci khusus dapat ada (atau tidak ada) dalam permintaan.

Misalnya, kebijakan IAM berikut memberikan izin untuk menggunakan `DeregisterScalableTarget`, `DeleteScalingPolicy`, dan tindakan `DeleteScheduledAction`. Namun, itu juga menyangkal tindakan jika target yang dapat diskalakan yang ditindaklanjuti memiliki tag **environment = .production**

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

```

"Statement": [
    {
        "Effect": "Allow",
        "Action": [
            "application-autoscaling:DeregisterScalableTarget",
            "application-autoscaling:DeleteScalingPolicy",
            "application-autoscaling:DeleteScheduledAction"
        ],
        "Resource": "*"
    }
],
{
    "Effect": "Deny",
    "Action": [
        "application-autoscaling:DeregisterScalableTarget",
        "application-autoscaling:DeleteScalingPolicy",
        "application-autoscaling:DeleteScheduledAction"
    ],
    "Resource": "*",
    "Condition": {
        "StringEquals": {"aws:ResourceTag/environment": "production"}
    }
}
]
}

```

Kontrol akses ke tag

Gunakan tag untuk memverifikasi bahwa pemohon (seperti pengguna atau peran IAM) memiliki izin untuk menambahkan, memodifikasi, atau menghapus tag untuk target yang dapat diskalakan.

Misalnya, Anda dapat membuat kebijakan IAM yang memungkinkan penghapusan hanya tag dengan **temporary** kunci dari target yang dapat diskalakan.

```

{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": "application-autoscaling:UntagResource",
            "Resource": "*",
            "Condition": {

```

```
        "ForAllValues:StringEquals": { "aws:TagKeys": ["temporary"] }
```

```
}
```

```
]
```

```
}
```

Keamanan dalam Application Auto Scaling

Keamanan cloud di AWS adalah prioritas tertinggi. Sebagai AWS pelanggan, Anda mendapat manfaat dari pusat data dan arsitektur jaringan yang dibangun untuk memenuhi persyaratan organisasi yang paling sensitif terhadap keamanan.

Keamanan adalah tanggung jawab bersama antara Anda AWS dan Anda. [Model tanggung jawab bersama](#) menjelaskan hal ini sebagai keamanan cloud dan keamanan dalam cloud:

- Keamanan cloud — AWS bertanggung jawab untuk melindungi infrastruktur yang menjalankan AWS layanan di AWS Cloud. AWS juga memberi Anda layanan yang dapat Anda gunakan dengan aman. Auditor pihak ketiga secara teratur menguji dan memverifikasi efektivitas keamanan kami sebagai bagian dari [program AWS kepatuhan program AWS](#). Untuk mempelajari tentang program kepatuhan yang berlaku untuk Application Auto Scaling, lihat [AWS layanan dalam cakupan berdasarkan AWS layanan program kepatuhan](#).
- Keamanan di cloud — Tanggung jawab Anda ditentukan oleh AWS layanan yang Anda gunakan. Anda juga bertanggung jawab atas faktor lain termasuk sensitivitas data Anda, persyaratan perusahaan Anda, serta undang-undang dan peraturan yang berlaku.

Dokumentasi ini membantu Anda memahami cara menerapkan model tanggung jawab bersama saat menggunakan Application Auto Scaling. Topik berikut menunjukkan kepada Anda cara mengkonfigurasi Application Auto Scaling untuk memenuhi tujuan keamanan dan kepatuhan Anda. Anda juga mempelajari cara menggunakan AWS layanan lain yang membantu Anda memantau dan mengamankan sumber daya Application Auto Scaling Anda.

Daftar Isi

- [Perlindungan data dalam Application Auto Scaling](#)
- [Identity and Access Management untuk Application Auto Scaling](#)
- [Akses Application Auto Scaling menggunakan endpoint antarmuka VPC](#)
- [Ketahanan dalam Application Auto Scaling](#)
- [Keamanan infrastruktur dalam Application Auto Scaling](#)
- [Validasi kepatuhan untuk Application Auto Scaling](#)

Perlindungan data dalam Application Auto Scaling

[Model tanggung jawab AWS bersama model](#) berlaku untuk perlindungan data dalam Application Auto Scaling. Seperti yang dijelaskan dalam model AWS ini, bertanggung jawab untuk melindungi infrastruktur global yang menjalankan semua AWS Cloud. Anda bertanggung jawab untuk mempertahankan kendali atas konten yang di-host pada infrastruktur ini. Anda juga bertanggung jawab atas tugas-tugas konfigurasi dan manajemen keamanan untuk Layanan AWS yang Anda gunakan. Untuk informasi selengkapnya tentang privasi data, lihat [Privasi Data FAQ](#). Untuk informasi tentang perlindungan data di Eropa, lihat [Model Tanggung Jawab AWS Bersama dan](#) posting GDPR blog di Blog AWS Keamanan.

Untuk tujuan perlindungan data, kami menyarankan Anda melindungi Akun AWS kredensil dan mengatur pengguna individu dengan AWS IAM Identity Center atau AWS Identity and Access Management (IAM). Dengan cara itu, setiap pengguna hanya diberi izin yang diperlukan untuk memenuhi tanggung jawab tugasnya. Kami juga menyarankan supaya Anda mengamankan data dengan cara-cara berikut:

- Gunakan otentikasi multi-faktor (MFA) dengan setiap akun.
- Gunakan SSL/TLS untuk berkomunikasi dengan AWS sumber daya. Kami membutuhkan TLS 1.2 dan merekomendasikan TLS 1.3.
- Siapkan API dan pencatatan aktivitas pengguna dengan AWS CloudTrail.
- Gunakan solusi AWS enkripsi, bersama dengan semua kontrol keamanan default di dalamnya Layanan AWS.
- Gunakan layanan keamanan terkelola lanjut seperti Amazon Macie, yang membantu menemukan dan mengamankan data sensitif yang disimpan di Amazon S3.
- Jika Anda memerlukan FIPS 140-3 modul kriptografi yang divalidasi saat mengakses AWS melalui antarmuka baris perintah atau, gunakan titik akhir API FIPS. Untuk informasi selengkapnya tentang FIPS titik akhir yang tersedia, lihat [Standar Pemrosesan Informasi Federal \(FIPS\) 140-3](#).

Kami sangat merekomendasikan agar Anda tidak pernah memasukkan informasi identifikasi yang sensitif, seperti nomor rekening pelanggan Anda, ke dalam tanda atau bidang isian bebas seperti bidang Nama. Ini termasuk saat Anda bekerja dengan Application Auto Scaling atau lainnya Layanan AWS menggunakan konsol, API AWS CLI, atau AWS SDKs. Data apa pun yang Anda masukkan ke dalam tanda atau bidang isian bebas yang digunakan untuk nama dapat digunakan untuk log penagihan atau log diagnostik. Jika Anda memberikan URL ke server eksternal, kami sangat

menyarankan agar Anda tidak menyertakan informasi kredensil dalam URL untuk memvalidasi permintaan Anda ke server tersebut.

Identity and Access Management untuk Application Auto Scaling

AWS Identity and Access Management (IAM) adalah Layanan AWS yang membantu administrator mengontrol akses ke AWS sumber daya dengan aman. IAM administrator mengontrol siapa yang dapat diautentikasi (masuk) dan diberi wewenang (memiliki izin) untuk menggunakan sumber daya Application Auto Scaling. IAM adalah Layanan AWS yang dapat Anda gunakan tanpa biaya tambahan.

Untuk IAM dokumentasi lengkap, lihat [Panduan IAM Pengguna](#).

Kontrol akses

Anda dapat memiliki kredensial yang valid untuk mengautentikasi permintaan Anda, kecuali jika Anda memiliki izin, Anda tidak dapat membuat atau mengakses sumber daya Application Auto Scaling. Misalnya, Anda harus memiliki izin untuk membuat kebijakan penskalaan, mengonfigurasi penskalaan terjadwal, dan sebagainya.

Bagian berikut memberikan rincian tentang bagaimana IAM administrator dapat menggunakan IAM untuk membantu mengamankan AWS sumber daya Anda, dengan mengontrol siapa yang dapat melakukan tindakan Application Auto Scaling API.

Daftar Isi

- [Bagaimana Application Auto Scaling bekerja dengan IAM](#)
- [AWS kebijakan terkelola untuk Application Auto Scaling](#)
- [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#)
- [Contoh kebijakan berbasis identitas Application Auto Scaling](#)
- [Pemecahan masalah akses Application Auto Scaling](#)
- [Validasi izin untuk panggilan Application Auto API Scaling pada sumber daya target](#)

Bagaimana Application Auto Scaling bekerja dengan IAM

Note

Pada bulan Desember 2017, terdapat pembaruan untuk Application Auto Scaling, yang memungkinkan beberapa peran yang ditautkan dengan layanan untuk layanan terpadu Application Auto Scaling. IAMIzin khusus dan peran terkait layanan Application Auto Scaling (atau peran layanan untuk penskalaan EMR otomatis Amazon) diperlukan agar pengguna dapat mengonfigurasi penskalaan.

Sebelum Anda menggunakan IAM untuk mengelola akses ke Application Auto Scaling, pelajari IAM fitur apa saja yang tersedia untuk digunakan dengan Application Auto Scaling.

IAMfitur yang dapat Anda gunakan dengan Application Auto Scaling

IAMfitur	Dukungan Application Auto Scaling
<u>Kebijakan berbasis identitas</u>	Ya
<u>Tindakan kebijakan</u>	Ya
<u>Sumber daya kebijakan</u>	Ya
<u>kunci-kunci persyaratan kebijakan (spesifik layanan)</u>	Ya
<u>Kebijakan berbasis sumber daya</u>	Tidak
<u>ACLs</u>	Tidak
<u>ABAC(tag dalam kebijakan)</u>	Parsial
<u>Kredensial sementara</u>	Ya
<u>Peran layanan</u>	Ya
<u>Peran terkait layanan</u>	Ya

Untuk mendapatkan tampilan tingkat tinggi tentang cara Application Auto Scaling dan fitur Layanan AWS lainnya bekerja dengan IAM sebagian besar fitur, [Layanan AWS lihat fitur tersebut berfungsi di IAM Panduan Pengguna](#).

Kebijakan berbasis identitas Application Auto Scaling

Mendukung kebijakan berbasis identitas: Ya

Kebijakan berbasis identitas adalah dokumen kebijakan JSON izin yang dapat dilampirkan ke identitas, seperti pengguna, grup IAM pengguna, atau peran. Kebijakan ini mengontrol jenis tindakan yang dapat dilakukan oleh pengguna dan peran, di sumber daya mana, dan berdasarkan kondisi seperti apa. Untuk mempelajari cara membuat kebijakan berbasis identitas, lihat [Membuat IAM kebijakan di Panduan Pengguna](#). IAM

Dengan kebijakan IAM berbasis identitas, Anda dapat menentukan tindakan dan sumber daya yang diizinkan atau ditolak serta kondisi di mana tindakan diizinkan atau ditolak. Anda tidak dapat menentukan secara spesifik prinsipal dalam sebuah kebijakan berbasis identitas karena prinsipal berlaku bagi pengguna atau peran yang melekat kepadanya. Untuk mempelajari semua elemen yang dapat Anda gunakan dalam JSON kebijakan, lihat [referensi elemen IAM JSON kebijakan](#) di Panduan IAM Pengguna.

Contoh kebijakan berbasis identitas untuk Application Auto Scaling

Untuk melihat contoh kebijakan berbasis identitas Application Auto Scaling, lihat [Contoh kebijakan berbasis identitas Application Auto Scaling](#).

Tindakan

Mendukung tindakan kebijakan: Ya

Dalam pernyataan IAM kebijakan, Anda dapat menentukan API tindakan apa pun dari layanan apa pun yang mendukung IAM. Untuk Application Auto Scaling, gunakan awalan berikut dengan nama tindakan: API application-autoscaling: Misalnya: application-autoscaling:RegisterScalableTarget, application-autoscaling:PutScalingPolicy, dan application-autoscaling:DeregisterScalableTarget.

Untuk menetapkan beberapa tindakan dalam satu pernyataan, pisahkan dengan koma seperti yang ditunjukkan dalam contoh berikut.

"Action": [

```
"application-autoscaling:DescribeScalingPolicies",
"application-autoscaling:DescribeScalingActivities"
```

Anda dapat menentukan beberapa tindakan menggunakan wildcard (*). Misalnya, untuk menentukan semua tindakan yang dimulai dengan kata **Describe**, sertakan tindakan berikut.

```
"Action": "application-autoscaling:Describe*"
```

Untuk daftar tindakan Application Auto Scaling, lihat [Tindakan yang ditentukan oleh AWS Application Auto Scaling](#) di Referensi Otorisasi Layanan.

Sumber daya

Mendukung sumber daya kebijakan: Ya

Dalam pernyataan IAM kebijakan, **Resource** elemen menentukan objek atau objek yang dicakup oleh pernyataan tersebut. Untuk Application Auto Scaling, setiap pernyataan IAM kebijakan berlaku untuk target yang dapat diskalakan yang Anda tentukan menggunakan Nama Sumber Daya Amazon (). ARNs

Format ARN sumber daya untuk target yang dapat diskalakan:

```
arn:aws:application-autoscaling:region:account-id:scalable-target/unique-identifier
```

Misalnya, Anda dapat menunjukkan target tertentu yang dapat diskalakan dalam pernyataan Anda menggunakan target ARN sebagai berikut. ID unik (1234abcd56ab78cd901ef1234567890ab123) adalah nilai yang ditetapkan oleh Application Auto Scaling ke target yang dapat diskalakan.

```
"Resource": "arn:aws:application-autoscaling:us-east-1:123456789012:scalable-
target/1234abcd56ab78cd901ef1234567890ab123"
```

Anda dapat menentukan semua instance milik akun tertentu dengan mengganti pengenal unik dengan wildcard (*) sebagai berikut.

```
"Resource": "arn:aws:application-autoscaling:us-east-1:123456789012:scalable-target/*"
```

Untuk menentukan semua sumber daya, atau jika API tindakan tertentu tidak mendukung ARNs, gunakan wildcard (*) sebagai **Resource** elemen sebagai berikut.

"Resource": "*"

Untuk informasi selengkapnya, lihat [Jenis sumber daya yang ditentukan oleh AWS Application Auto Scaling di Referensi Otorisasi Layanan](#).

Kunci syarat

Mendukung kunci kondisi kebijakan khusus layanan: Ya

Anda dapat menentukan kondisi dalam IAM kebijakan yang mengontrol akses ke sumber daya Application Auto Scaling. Pernyataan kebijakan hanya efektif jika syaratnya benar.

Application Auto Scaling mendukung kunci kondisi yang ditentukan layanan berikut yang dapat Anda gunakan dalam kebijakan berbasis identitas untuk menentukan siapa yang dapat melakukan tindakan Application Auto Scaling. API

- application-autoscaling:scalable-dimension
- application-autoscaling:service-namespace

Untuk mempelajari API tindakan Application Auto Scaling yang dapat Anda gunakan dengan kunci kondisi, lihat [Tindakan yang ditentukan oleh AWS Application Auto Scaling di Referensi Otorisasi Layanan](#). Untuk informasi selengkapnya tentang penggunaan tombol kondisi Application Auto Scaling, lihat [tombol Kondisi untuk AWS Application Auto Scaling](#).

Untuk melihat kunci kondisi global yang tersedia untuk semua layanan, lihat [kunci konteks kondisi AWS global](#) di Panduan IAM Pengguna.

Kebijakan berbasis sumber daya

Mendukung kebijakan berbasis sumber daya: Tidak

AWS Layanan lain, seperti Amazon Simple Storage Service, mendukung kebijakan izin berbasis sumber daya. Misalnya, Anda dapat melampirkan kebijakan izin ke bucket S3 untuk mengelola izin akses ke bucket tersebut.

Application Auto Scaling tidak mendukung kebijakan berbasis sumber daya.

Daftar Kontrol Akses (ACLs)

Mendukung ACLs: Tidak

Application Auto Scaling tidak mendukung Access Control Lists (ACLs).

ABAC dengan Application Auto Scaling

Mendukung ABAC (tag dalam kebijakan): Sebagian

Attribute-based access control (ABAC) adalah strategi otorisasi yang mendefinisikan izin berdasarkan atribut. Dalam AWS, atribut ini disebut tag. Anda dapat melampirkan tag ke IAM entitas (pengguna atau peran) dan ke banyak AWS sumber daya. Menandai entitas dan sumber daya adalah langkah pertama dari ABAC. Kemudian Anda merancang ABAC kebijakan untuk mengizinkan operasi ketika tag prinsipal cocok dengan tag pada sumber daya yang mereka coba akses.

ABAC membantu dalam lingkungan yang berkembang pesat dan membantu dengan situasi di mana manajemen kebijakan menjadi rumit.

Untuk mengendalikan akses berdasarkan tag, berikan informasi tentang tag di [elemen kondisi](#) dari kebijakan menggunakan kunci kondisi `aws:ResourceTag/key-name`, `aws:RequestTag/key-name`, atau `aws:TagKeys`.

ABAC dimungkinkan untuk sumber daya yang mendukung tag, tetapi tidak semuanya mendukung tag. Tindakan terjadwal dan kebijakan penskalaan tidak mendukung tag, tetapi target yang dapat diskalakan mendukung tag. Untuk informasi selengkapnya, lihat [Dukungan penandaan untuk Application Auto Scaling](#).

Untuk informasi lebih lanjut tentang ABAC, lihat [Apa itu ABAC?](#) dalam IAM User Guide. Untuk melihat tutorial dengan langkah-langkah penyiapan ABAC, lihat [Menggunakan kontrol akses berbasis atribut \(ABAC\)](#) di IAM Panduan Pengguna.

Menggunakan kredensial sementara dengan Application Auto Scaling

Mendukung kredensi sementara: Ya

Beberapa Layanan AWS tidak berfungsi saat Anda masuk menggunakan kredensi sementara. Untuk informasi tambahan, termasuk yang Layanan AWS bekerja dengan kredensi sementara, lihat [Layanan AWS yang berfungsi IAM](#) di IAM Panduan Pengguna.

Anda menggunakan kredensi sementara jika Anda masuk AWS Management Console menggunakan metode apa pun kecuali nama pengguna dan kata sandi. Misalnya, ketika Anda mengakses AWS menggunakan link sign-on (SSO) tunggal perusahaan Anda, proses tersebut secara otomatis

membuat kredensi sementara. Anda juga akan secara otomatis membuat kredensial sementara ketika Anda masuk ke konsol sebagai seorang pengguna lalu beralih peran. Untuk informasi selengkapnya tentang beralih peran, lihat [Beralih ke peran \(konsol\)](#) di Panduan IAM Pengguna.

Anda dapat secara manual membuat kredensi sementara menggunakan atau AWS CLI AWS API Anda kemudian dapat menggunakan kredensi sementara tersebut untuk mengakses AWS. AWS merekomendasikan agar Anda secara dinamis menghasilkan kredensi sementara alih-alih menggunakan kunci akses jangka panjang. Untuk informasi selengkapnya, lihat [Kredensi keamanan sementara](#) di IAM.

Peran layanan

Mendukung peran layanan: Ya

Jika EMR klaster Amazon Anda menggunakan penskalaan otomatis, fitur ini memungkinkan Application Auto Scaling untuk mengambil peran [layanan](#) atas nama Anda. Serupa dengan peran yang ditautkan dengan layanan, peran layanan memungkinkan layanan mengakses sumber daya dalam layanan lain untuk menyelesaikan tindakan atas nama Anda. Peran layanan muncul di IAM akun Anda dan dimiliki oleh akun. Ini berarti bahwa IAM administrator dapat mengubah izin untuk peran ini. Namun, melakukan hal itu dapat merusak fungsionalitas layanan.

Application Auto Scaling mendukung peran layanan hanya untuk Amazon EMR. Untuk dokumentasi peran EMR layanan, lihat [Menggunakan penskalaan otomatis dengan kebijakan khusus untuk grup instance](#) di Panduan EMR Manajemen Amazon.

Note

Dengan diperkenalkannya peran terkait layanan, beberapa peran layanan lama tidak lagi diperlukan, misalnya, untuk Amazon ECS dan Spot Fleet.

Peran terkait layanan

Mendukung peran terkait layanan: Ya

Peran terkait layanan adalah jenis peran layanan yang ditautkan ke Layanan AWS Layanan tersebut dapat menjalankan peran untuk melakukan tindakan atas nama Anda. Peran terkait layanan muncul di Akun AWS dan dimiliki oleh layanan. IAMAdministrator dapat melihat, tetapi tidak mengedit izin untuk peran terkait layanan.

Untuk informasi tentang peran terkait layanan Application Auto Scaling, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#)

AWS kebijakan terkelola untuk Application Auto Scaling

Kebijakan AWS terkelola adalah kebijakan mandiri yang dibuat dan dikelola oleh AWS. AWS Kebijakan terkelola dirancang untuk memberikan izin bagi banyak kasus penggunaan umum sehingga Anda dapat mulai menetapkan izin kepada pengguna, grup, dan peran.

Perlu diingat bahwa kebijakan AWS terkelola mungkin tidak memberikan izin hak istimewa paling sedikit untuk kasus penggunaan spesifik Anda karena tersedia untuk digunakan semua pelanggan. AWS Kami menyarankan Anda untuk mengurangi izin lebih lanjut dengan menentukan [kebijakan yang dikelola pelanggan](#) yang khusus untuk kasus penggunaan Anda.

Anda tidak dapat mengubah izin yang ditentukan dalam kebijakan AWS terkelola. Jika AWS memperbarui izin yang ditentukan dalam kebijakan AWS terkelola, pembaruan akan memengaruhi semua identitas utama (pengguna, grup, dan peran) yang dilampirkan kebijakan tersebut. AWS kemungkinan besar akan memperbarui kebijakan AWS terkelola saat baru Layanan AWS diluncurkan atau API operasi baru tersedia untuk layanan yang ada.

Untuk informasi selengkapnya, lihat [kebijakan AWS terkelola](#) di Panduan IAM Pengguna.

AWS kebijakan terkelola: AppStream 2.0 dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingAppStreamFleetPolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama

[AWSServiceRoleForApplicationAutoScaling_AppStreamFleet](#) untuk memungkinkan Application Auto Scaling memanggil AppStream Amazon CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait (“Resource”: “*”):

- Tindakan: appstream:DescribeFleets
- Tindakan: appstream:UpdateFleet
- Tindakan: cloudwatch:DescribeAlarms
- Tindakan: cloudwatch:PutMetricAlarm

- Tindakan: `cloudwatch:DeleteAlarms`

AWS kebijakan terkelola: Aurora dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingRDSClusterPolicy](#)

Kebijakan ini dilampirkan pada peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_RDSCluster](#) untuk memungkinkan Application Auto Scaling memanggil Aurora CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait (“Resource”: “*”):

- Tindakan: `rds:AddTagsToResource`
- Tindakan: `rds>CreateDBInstance`
- Tindakan: `rds>DeleteDBInstance`
- Tindakan: `rds:DescribeDBClusters`
- Tindakan: `rds:DescribeDBInstance`
- Tindakan: `cloudwatch:DescribeAlarms`
- Tindakan: `cloudwatch:PutMetricAlarm`
- Tindakan: `cloudwatch:DeleteAlarms`

AWS kebijakan terkelola: Amazon Comprehend dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingComprehendEndpointPolicy](#)

Kebijakan ini dilampirkan pada peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_ComprehendEndpoint](#) untuk memungkinkan Application Auto Scaling memanggil Amazon Comprehend dan serta melakukan penskalaan atas nama Anda. CloudWatch

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait (“Resource”: “*”):

- Tindakan: comprehend:UpdateEndpoint
- Tindakan: comprehend:DescribeEndpoint
- Tindakan: cloudwatch:DescribeAlarms
- Tindakan: cloudwatch:PutMetricAlarm
- Tindakan: cloudwatch:DeleteAlarms

AWS kebijakan terkelola: DynamoDB dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingDynamoDBTablePolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama

[AWSServiceRoleForApplicationAutoScaling_DynamoDBTable](#) untuk memungkinkan Application Auto Scaling memanggil DynamoDB dan CloudWatch D dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait (“Resource”: “*”):

- Tindakan: dynamodb:DescribeTable
- Tindakan: dynamodb:UpdateTable
- Tindakan: cloudwatch:DescribeAlarms
- Tindakan: cloudwatch:PutMetricAlarm
- Tindakan: cloudwatch:DeleteAlarms

AWS kebijakan terkelola: Amazon ECS dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingECSServicePolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama

[AWSServiceRoleForApplicationAutoScaling_ECSService](#) untuk memungkinkan Application Auto Scaling memanggil ECS Amazon CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait (“Resource”: “*”):

- Tindakan: `ecs:DescribeServices`
- Tindakan: `ecs:UpdateService`
- Tindakan: `cloudwatch:DescribeAlarms`
- Tindakan: `cloudwatch:PutMetricAlarm`
- Tindakan: `cloudwatch:DeleteAlarms`

AWS kebijakan terkelola: ElastiCache dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingElastiCacheRGPolicy](#)

Kebijakan ini dilampirkan pada peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_ElastiCache RG](#) untuk memungkinkan Application Auto Scaling ElastiCache memanggil CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada sumber daya yang ditentukan:

- Tindakan: `elasticache:DescribeReplicationGroups` pada semua sumber daya
- Tindakan: `elasticache:ModifyReplicationGroupShardConfiguration` pada semua sumber daya
- Tindakan: `elasticache:IncreaseReplicaCount` pada semua sumber daya
- Tindakan: `elasticache:DecreaseReplicaCount` pada semua sumber daya
- Tindakan: `elasticache:DescribeCacheClusters` pada semua sumber daya
- Tindakan: `elasticache:DescribeCacheParameters` pada semua sumber daya
- Tindakan: `cloudwatch:DescribeAlarms` pada semua sumber daya
- Tindakan: `cloudwatch:PutMetricAlarm` pada sumber daya
`arn:aws:cloudwatch:*:*:alarm:TargetTracking*`
- Tindakan: `cloudwatch:DeleteAlarms` pada sumber daya
`arn:aws:cloudwatch:*:*:alarm:TargetTracking*`
- Tindakan: `cloudwatch:DeleteAlarms`

AWS kebijakan terkelola: Amazon Keyspaces dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingCassandraTablePolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_CassandraTable](#) untuk memungkinkan Application Auto Scaling memanggil Amazon Keyspaces CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada sumber daya yang ditentukan:

- Tindakan: `cassandra:Select` pada sumber daya berikut:
 - `arn:*:cassandra:*:*:*/keyspace/system/table/*`
 - `arn:*:cassandra:*:*:*/keyspace/system_schema/table/*`
 - `arn:*:cassandra:*:*:*/keyspace/system_schema_mcs/table/*`
- Tindakan: `cassandra:Alter` pada semua sumber daya
- Tindakan: `cloudwatch:DescribeAlarms` pada semua sumber daya
- Tindakan: `cloudwatch:PutMetricAlarm` pada semua sumber daya
- Tindakan: `cloudwatch:DeleteAlarms` pada semua sumber daya

AWS kebijakan terkelola: Lambda dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingLambdaConcurrencyPolicy](#)

Kebijakan ini dilampirkan pada peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_LambdaConcurrency](#) untuk memungkinkan Application Auto Scaling memanggil Lambda CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait (“Resource”: “*”):

- Tindakan: `lambda:PutProvisionedConcurrencyConfig`
- Tindakan: `lambda:GetProvisionedConcurrencyConfig`

- Tindakan: lambda:DeleteProvisionedConcurrencyConfig
- Tindakan: cloudwatch:DescribeAlarms
- Tindakan: cloudwatch:PutMetricAlarm
- Tindakan: cloudwatch:DeleteAlarms

AWS kebijakan terkelola: Amazon MSK dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingKafkaClusterPolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama

[AWSServiceRoleForApplicationAutoScaling_KafkaCluster](#) untuk memungkinkan Application Auto Scaling memanggil MSK Amazon CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait (“Resource”: “*”):

- Tindakan: kafka:DescribeCluster
- Tindakan: kafka:DescribeClusterOperation
- Tindakan: kafka:UpdateBrokerStorage
- Tindakan: cloudwatch:DescribeAlarms
- Tindakan: cloudwatch:PutMetricAlarm
- Tindakan: cloudwatch:DeleteAlarms

AWS kebijakan terkelola: Neptunus dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingNeptuneClusterPolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama

[AWSServiceRoleForApplicationAutoScaling_NeptuneCluster](#) untuk memungkinkan Application Auto Scaling memanggil CloudWatch Neptunus dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada sumber daya yang ditentukan:

- Tindakan: `rds>ListTagsForResource` pada semua sumber daya
- Tindakan: `rdsDescribeDBInstances` pada semua sumber daya
- Tindakan: `rdsDescribeDBClusters` pada semua sumber daya
- Tindakan: `rdsDescribeDBClusterParameters` pada semua sumber daya
- Tindakan: `cloudwatchDescribeAlarms` pada semua sumber daya
- Tindakan: `rdsAddTagsToResource` pada sumber daya dengan awalan pembaca berskala otomatis di mesin database Amazon Neptunus () "Condition": {"StringEquals": {"rds:DatabaseEngine": "neptune"}}
- Tindakan: `rdsCreateDBInstance` pada sumber daya dengan awalan pembaca berskala otomatis di semua cluster DB () di mesin database Amazon Neptunus () "Resource": "arn:aws:rds:cluster:db:autoscaled-reader*", "arn:aws:rds:cluster:alarm:TargetTracking" "Condition": {"StringEquals": {"rds:DatabaseEngine": "neptune"}}
- Tindakan: `rdsDeleteDBInstance` pada sumber daya `arn:aws:rds:db:autoscaled-reader*`
- Tindakan: `cloudwatchPutMetricAlarm` pada sumber daya `arn:aws:cloudwatch:alarm:TargetTracking*`
- Tindakan: `cloudwatchDeleteAlarms` pada sumber daya `arn:aws:cloudwatch:alarm:TargetTracking*`

AWS kebijakan terkelola: SageMaker dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingSageMakerEndpointPolicy](#)

Kebijakan ini dilampirkan pada peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_SageMakerEndpoint](#) untuk memungkinkan Application Auto Scaling SageMaker memanggil CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada sumber daya yang ditentukan:

- Tindakan: `sagemakerDescribeEndpoint` pada semua sumber daya
- Tindakan: `sagemakerDescribeEndpointConfig` pada semua sumber daya

- Tindakan: `sagemaker:DescribeInferenceComponent` pada semua sumber daya
- Tindakan: `sagemaker:UpdateEndpointWeightsAndCapacities` pada semua sumber daya
- Tindakan: `sagemaker:UpdateInferenceComponentRuntimeConfig` pada semua sumber daya
- Tindakan: `cloudwatch:DescribeAlarms` pada semua sumber daya
- Tindakan: `cloudwatch:GetMetricData` pada semua sumber daya
- Tindakan: `cloudwatch:PutMetricAlarm` pada sumber daya
`arn:aws:cloudwatch:*:*:alarm:TargetTracking*`
- Tindakan: `cloudwatch:DeleteAlarms` pada sumber daya
`arn:aws:cloudwatch:*:*:alarm:TargetTracking*`

AWS kebijakan terkelola: Armada EC2 Spot dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingEC2SpotFleetRequestPolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama

[AWSServiceRoleForApplicationAutoScaling_EC2SpotFleetRequest](#) untuk memungkinkan Application Auto Scaling memanggil EC2 Amazon CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait ("Resource": "*"):

- Tindakan: `ec2:DescribeSpotFleetRequests`
- Tindakan: `ec2:ModifySpotFleetRequest`
- Tindakan: `cloudwatch:DescribeAlarms`
- Tindakan: `cloudwatch:PutMetricAlarm`
- Tindakan: `cloudwatch:DeleteAlarms`

AWS kebijakan terkelola: WorkSpaces dan CloudWatch

Nama kebijakan: [AWSApplicationAutoscalingWorkSpacesPoolPolicy](#)

Kebijakan ini dilampirkan pada peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_WorkSpacesPool](#) untuk memungkinkan Application Auto Scaling WorkSpaces memanggil CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada sumber daya yang ditentukan:

- Tindakan: `workspaces:DescribeWorkspacesPools` pada semua sumber daya dari akun yang sama dengan SLR
- Tindakan: `workspaces:UpdateWorkspacesPool` pada semua sumber daya dari akun yang sama dengan SLR
- Tindakan: `cloudwatch:DescribeAlarms` pada semua alarm dari akun yang sama dengan SLR
- Tindakan: `cloudwatch:PutMetricAlarm` pada semua alarm dari akun yang sama dengan SLR, di mana nama alarm dimulai dengan TargetTracking
- Tindakan: `cloudwatch:DeleteAlarms` pada semua alarm dari akun yang sama dengan SLR, di mana nama alarm dimulai dengan TargetTracking

AWS kebijakan terkelola: sumber daya khusus dan CloudWatch

Nama kebijakan: [AWSApplicationAutoScalingCustomResourcePolicy](#)

Kebijakan ini dilampirkan ke peran terkait layanan bernama [AWSServiceRoleForApplicationAutoScaling_CustomResource](#) untuk memungkinkan Application Auto Scaling memanggil sumber daya kustom Anda yang tersedia API melalui Gateway CloudWatch dan melakukan penskalaan atas nama Anda.

Detail izin

Kebijakan izin memungkinkan Application Auto Scaling untuk menyelesaikan tindakan berikut pada semua sumber daya terkait ("Resource": "*"):

- Tindakan: `execute-api:Invoke`
- Tindakan: `cloudwatch:DescribeAlarms`
- Tindakan: `cloudwatch:PutMetricAlarm`
- Tindakan: `cloudwatch:DeleteAlarms`

Pembaruan Application Auto Scaling ke AWS kebijakan terkelola

Lihat detail tentang pembaruan kebijakan AWS terkelola untuk Application Auto Scaling sejak layanan ini mulai melacak perubahan ini. Untuk peringatan otomatis tentang perubahan pada halaman ini, berlangganan RSS feed di halaman riwayat Dokumen Penskalaan Otomatis Aplikasi.

Perubahan	Deskripsi	Tanggal
<u>AWSApplicationAutoScalingWorkSpacesPoolPolicy</u> – Kebijakan baru	Menambahkan kebijakan terkelola untuk Amazon WorkSpaces. Kebijakan ini dilampirkan pada <u>peran terkait layanan</u> yang memungkinkan Application Auto Scaling untuk WorkSpaces memanggil CloudWatch dan melakukan penskalaan atas nama Anda.	Juni 24, 2024
<u>AWSApplicationAutoscalingSageMakerEndpointPolicy</u> – Pembaruan ke kebijakan yang ada	Menambahkan izin untuk memanggil SageMaker DescribeInferenceComponent dan UpdateInferenceComponentRun timeConfig API tindakan untuk mendukung kompatibilitas penskalaan otomatis SageMaker sumber daya untuk integrasi yang akan datang. Kebijakan ini juga sekarang membatasi CloudWatch PutMetric Alarm dan DeleteAlarms API tindakan untuk CloudWatch alarm yang digunakan dengan kebijakan penskalaan pelacakan target.	13 November 2023

Perubahan	Deskripsi	Tanggal
<u>AWSApplicationAuto scalingNeptuneClusterPolicy</u> – Kebijakan baru	Menambahkan kebijakan terkelola untuk Neptune. Kebijakan ini dilampirkan pada <u>peran terkait layanan</u> yang memungkinkan Application Auto Scaling memanggil CloudWatch Neptune dan melakukan penskalaan atas nama Anda.	Oktober 6, 2021
<u>AWSApplicationAuto scalingRDSClusterPolicy</u> – Kebijakan baru	Menambahkan kebijakan terkelola untuk ElastiCache. Kebijakan ini dilampirkan pada <u>peran terkait layanan</u> yang memungkinkan Application Auto Scaling untuk ElastiCache memanggil CloudWatch dan melakukan penskalaan atas nama Anda.	19 Agustus 2021
Application Auto Scaling mulai melacak perubahan	Application Auto Scaling mulai melacak perubahan untuk kebijakan yang AWS dikelola.	19 Agustus 2021

Peran yang ditautkan dengan layanan untuk Application Auto Scaling

Application Auto Scaling menggunakan [peran terkait layanan](#) untuk izin yang diperlukan untuk memanggil layanan lain AWS atas nama Anda. Peran terkait layanan adalah jenis peran AWS Identity and Access Management (IAM) unik yang ditautkan langsung ke layanan. AWS Peran terkait layanan menyediakan cara aman untuk mendelegasikan izin ke AWS layanan karena hanya layanan tertaut yang dapat mengambil peran terkait layanan.

Untuk layanan yang terintegrasi dengan Application Auto Scaling, Application Auto Scaling membuat peran terkait layanan untuk Anda. Ada satu peran terkait layanan untuk setiap layanan. Setiap

peran yang ditautkan dengan layanan memercayai prinsip layanan yang ditentukan untuk mengasumsikannya. Untuk informasi selengkapnya, lihat [Referensi peran terkait layanan ARN](#).

Application Auto Scaling mencakup semua izin yang diperlukan untuk setiap peran terkait layanan. Izin terkelola ini dibuat dan dikelola oleh Application Auto Scaling, dan mereka menentukan tindakan yang diizinkan untuk setiap jenis sumber daya. Untuk detail tentang izin yang diberikan setiap peran, lihat [AWS kebijakan terkelola untuk Application Auto Scaling](#)

Daftar Isi

- [Izin yang diperlukan untuk membuat peran yang ditautkan dengan layanan](#)
- [Buat peran yang ditautkan dengan layanan \(otomatis\)](#)
- [Buat peran yang ditautkan dengan layanan \(manual\)](#)
- [Edit peran yang ditautkan dengan layanan](#)
- [Hapus peran yang ditautkan dengan layanan](#)
- [Wilayah yang Didukung untuk peran terkait layanan Application Auto Scaling](#)
- [Referensi peran terkait layanan ARN](#)

Izin yang diperlukan untuk membuat peran yang ditautkan dengan layanan

Application Auto Scaling memerlukan izin untuk membuat peran terkait layanan saat pertama kali setiap pengguna dalam Akun AWS panggilan RegisterScalableTarget Anda untuk layanan tertentu. Application Auto Scaling membuat peran teraut terikat layanan untuk layanan target di akun Anda, jika peran tersebut belum ada. Peran yang ditautkan dengan layanan memberikan izin untuk Application Auto Scaling sehingga dapat menghubungi layanan target atas nama Anda.

Agar pembuatan peran otomatis berhasil, pengguna harus memiliki izin untuk tindakan `iam:CreateServiceLinkedRole` nyata.

```
"Action": "iam:CreateServiceLinkedRole"
```

Berikut ini adalah kebijakan berbasis identitas yang memberikan izin untuk membuat peran terkait layanan untuk Armada Spot. Anda dapat menentukan peran terkait layanan di Resource bidang kebijakan sebagai ARN, dan prinsip layanan untuk peran terkait layanan Anda sebagai kondisi, seperti yang ditunjukkan. ARN Untuk setiap layanan, lihat [Referensi peran terkait layanan ARN](#).

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

```
"Statement": [
    {
        "Effect": "Allow",
        "Action": "iam:CreateServiceLinkedRole",
        "Resource": "arn:aws:iam::*:role/aws-service-role/ec2.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_EC2SpotFleetRequest",
        "Condition": {
            "StringLike": {
                "iam:AWSServiceName": "ec2.application-autoscaling.amazonaws.com"
            }
        }
    }
]
```

Note

Kunci `iam:AWSServiceName` IAM kondisi menentukan prinsip layanan tempat peran dilampirkan, yang ditunjukkan dalam contoh kebijakan ini sebagai `ec2.application-autoscaling.amazonaws.com`. Jangan mencoba menebak prinsip utama layanan. Untuk melihat prinsip layanan untuk suatu layanan, lihat [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#).

Buat peran yang ditautkan dengan layanan (otomatis)

Anda tidak perlu membuat peran yang ditautkan dengan layanan secara manual. Application Auto Scaling membuat peran yang ditautkan dengan layanan sesuai untuk Anda saat Anda menelepon `RegisterScalableTarget`. Misalnya, jika Anda mengatur penskalaan otomatis untuk ECS layanan Amazon, Application Auto Scaling akan membuat `AWSServiceRoleForApplicationAutoScaling_ECSService` peran tersebut.

Buat peran yang ditautkan dengan layanan (manual)

Untuk membuat peran terkait layanan, Anda dapat menggunakan IAM konsol, AWS CLI, atau IAM API. Untuk informasi selengkapnya, lihat [Membuat peran terkait layanan](#) di IAM Panduan Pengguna.

Untuk membuat peran terkait layanan (AWS CLI)

Gunakan [`create-service-linked-role`](#) CLI perintah berikut untuk membuat peran terkait layanan Application Auto Scaling. Dalam permintaan, tentukan nama layanan “awalan”.

Untuk menemukan awalan nama layanan, lihat informasi tentang prinsip layanan untuk peran terkait layanan untuk setiap layanan di bagian [Layanan AWS yang dapat Anda gunakan dengan Application Auto Scaling](#). Nama layanan dan kepala layanan berbagi awalan yang sama. Misalnya, untuk membuat peran AWS Lambda terkait layanan, gunakan `lambda.application-autoscaling.amazonaws.com`

```
aws iam create-service-linked-role --aws-service-name prefix.application-autoscaling.amazonaws.com
```

Edit peran yang ditautkan dengan layanan

Dengan peran yang ditautkan layanan yang dibuat oleh Application Auto Scaling, Anda dapat mengedit deskripsi mereka saja. Untuk informasi selengkapnya, lihat [Mengedit peran terkait layanan](#) di IAM Panduan Pengguna.

Hapus peran yang ditautkan dengan layanan

Jika Anda tidak lagi menggunakan Application Auto Scaling dengan layanan yang didukung, kami sarankan Anda menghapus peran yang ditautkan dengan layanan.

Anda dapat menghapus peran terhubung layanan hanya setelah pertama kali menghapus sumber daya AWS terkait. Hal ini melindungi Anda agar tidak merusak izin Application Auto Scaling ke sumber daya Anda secara tidak sengaja. Untuk informasi lebih lanjut, lihat [dokumentasi](#) sumber daya yang dapat diskalakan. Misalnya, untuk menghapus ECS layanan Amazon, lihat [Menghapus layanan di Panduan Pengembang Layanan](#) Amazon Elastic Container.

Anda dapat menggunakan IAM untuk menghapus peran terkait layanan. Untuk informasi selengkapnya, lihat [Menghapus peran terkait layanan di Panduan Pengguna](#).

Setelah Anda menghapus peran yang ditautkan dengan layanan, Application Auto Scaling akan membuat peran itu lagi saat Anda memanggil `RegisterScalableTarget`.

Wilayah yang Didukung untuk peran terkait layanan Application Auto Scaling

Application Auto Scaling mendukung penggunaan peran terkait layanan di semua AWS Wilayah tempat layanan tersedia.

Referensi peran terkait layanan ARN

Tabel berikut mencantumkan Nama Sumber Daya Amazon (ARN) dari peran terkait layanan untuk setiap peran Layanan AWS yang berfungsi dengan Application Auto Scaling.

Layanan	ARN
AppStream 2.0	arn:aws:iam:: 012345678910 :role/aws-service-role/appstream.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_AppStreamFleet
Aurora	arn:aws:iam:: 012345678910 :role/aws-service-role/rds.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_RDSCluster
Comprehend	arn:aws:iam:: 012345678910 :role/aws-service-role/comprehend.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_ComprehendEndpoint
DynamoDB	arn:aws:iam:: 012345678910 :role/aws-service-role/dynamodb.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_DynamoDBTable
ECS	arn:aws:iam:: 012345678910 :role/aws-service-role/ecs.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_ECSService
ElastiCache	arn:aws:iam:: 012345678910 :role/aws-service-role/elasticache.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_ElastiCacheRG
Keyspaces	arn:aws:iam:: 012345678910 :role/aws-service-role/cassandra.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_CassandraTable
Lambda	arn:aws:iam:: 012345678910 :role/aws-service-role/lambda.application-autoscaling.amazonaws.com/AWSS

Layanan	ARN
	serviceRoleForApplicationAutoScaling_LambdaConcurrency
MSK	arn:aws:iam:: 012345678910 :role/aws-service-role/kafka.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_KafkaCluster
Neptune	arn:aws:iam:: 012345678910 :role/aws-service-role/neptune.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_NeptuneCluster
SageMaker	arn:aws:iam:: 012345678910 :role/aws-service-role/sagemaker.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_SageMakerEndpoint
Armada Spot	arn:aws:iam:: 012345678910 :role/aws-service-role/ec2.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_EC2SpotFleetRequest
WorkSpaces	arn:aws:iam:: 012345678910 :role/aws-service-role/workspaces.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_WorkSpacesPool
Sumber daya khusus	arn:aws:iam:: 012345678910 :role/aws-service-role/custom-resource.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_CustomResource

 Note

Anda dapat menentukan peran ARN yang ditautkan layanan untuk RoleARN properti ScalableTarget sumber daya [AWS::ApplicationAutoScaling:](#) di templat AWS CloudFormation

tumpukan, meskipun peran terkait layanan yang ditentukan belum ada. Application Auto Scaling secara otomatis menciptakan peran untuk Anda.

Contoh kebijakan berbasis identitas Application Auto Scaling

Secara default, pengguna baru di Anda tidak Akun AWS memiliki izin untuk melakukan apa pun. IAMAdministrator harus membuat dan menetapkan IAM kebijakan yang memberikan izin IAM identitas (seperti pengguna atau peran) untuk melakukan tindakan Application Auto API Scaling.

Untuk mempelajari cara membuat IAM kebijakan menggunakan contoh dokumen JSON kebijakan berikut, lihat [Membuat kebijakan pada JSON tab](#) di Panduan IAM Pengguna.

Daftar Isi

- [Izin diperlukan untuk tindakan Application Auto API Scaling](#)
- [Izin diperlukan untuk API tindakan pada layanan target dan CloudWatch](#)
- [Izin untuk bekerja di AWS Management Console](#)

Izin diperlukan untuk tindakan Application Auto API Scaling

Kebijakan berikut memberikan izin untuk kasus penggunaan umum saat memanggil Application Auto API Scaling. Lihat bagian ini saat menulis kebijakan berbasis identitas. Setiap kebijakan memberikan izin untuk semua atau beberapa tindakan Application Auto API Scaling. Anda juga perlu memastikan bahwa pengguna akhir memiliki izin untuk layanan target dan CloudWatch (lihat bagian selanjutnya untuk detailnya).

Kebijakan berbasis identitas berikut memberikan izin untuk semua tindakan Application Auto Scaling. API

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "application-autoscaling:*"  
            ],  
            "Resource": "*"  
        }  
    ]}
```

```
]  
}
```

Kebijakan berbasis identitas berikut memberikan izin untuk semua tindakan Application Auto Scaling yang diperlukan untuk mengonfigurasi kebijakan penskalaan dan bukan API tindakan terjadwal.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "application-autoscaling:RegisterScalableTarget",  
                "application-autoscaling:DescribeScalableTargets",  
                "application-autoscaling:DeregisterScalableTarget",  
                "application-autoscaling:PutScalingPolicy",  
                "application-autoscaling:DescribeScalingPolicies",  
                "application-autoscaling:DescribeScalingActivities",  
                "application-autoscaling:DeleteScalingPolicy"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

Kebijakan berbasis identitas berikut memberikan izin untuk semua tindakan Application Auto Scaling yang diperlukan untuk mengonfigurasi API tindakan terjadwal dan bukan kebijakan penskalaan.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "application-autoscaling:RegisterScalableTarget",  
                "application-autoscaling:DescribeScalableTargets",  
                "application-autoscaling:DeregisterScalableTarget",  
                "application-autoscaling:PutScheduledAction",  
                "application-autoscaling:DescribeScheduledActions",  
                "application-autoscaling:DescribeScalingActivities",  
                "application-autoscaling:DeleteScheduledAction"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

```
        "Resource": "*"
    }
]
}
```

Izin diperlukan untuk API tindakan pada layanan target dan CloudWatch

Agar berhasil mengkonfigurasi dan menggunakan Application Auto Scaling dengan layanan target, pengguna akhir harus diberikan izin untuk Amazon CloudWatch dan untuk setiap layanan target yang akan mereka konfigurasi penskalaannya. Gunakan kebijakan berikut untuk memberikan izin minimum yang diperlukan untuk bekerja dengan layanan target dan CloudWatch.

Daftar Isi

- [AppStream 2.0 armada](#)
- [Replika Aurora](#)
- [Klasifikasi dokumen dan titik akhir pengenal entitas Amazon Comprehend](#)
- [Tabel DynamoDB dan indeks sekunder global](#)
- [ECSlayanan](#)
- [ElastiCache kelompok replikasi](#)
- [EMRCluster Amazon](#)
- [Tabel Amazon Keyspaces](#)
- [Fungsi Lambda](#)
- [Amazon Managed Streaming untuk Apache Kafka MSK \(\) penyimpanan broker](#)
- [Cluster Neptunus](#)
- [SageMaker titik akhir](#)
- [Armada Spot \(AmazonEC2\)](#)
- [Sumber daya khusus](#)

AppStream 2.0 armada

Kebijakan berbasis identitas berikut memberikan izin untuk semua AppStream 2.0 dan CloudWatch API tindakan yang diperlukan.

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

```

```
{  
    "Effect": "Allow",  
    "Action": [  
        "appstream:DescribeFleets",  
        "appstream:UpdateFleet",  
        "cloudwatch:DescribeAlarms",  
        "cloudwatch:PutMetricAlarm",  
        "cloudwatch:DeleteAlarms"  
    ],  
    "Resource": "*"  
}  
]  
}
```

Replika Aurora

Kebijakan berbasis identitas berikut memberikan izin untuk semua Aurora CloudWatch API dan tindakan yang diperlukan.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "rds:AddTagsToResource",  
                "rds>CreateDBInstance",  
                "rds>DeleteDBInstance",  
                "rds:DescribeDBClusters",  
                "rds:DescribeDBInstances",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DeleteAlarms"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

Klasifikasi dokumen dan titik akhir pengenal entitas Amazon Comprehend

Kebijakan berbasis identitas berikut memberikan izin ke semua Amazon Comprehend dan tindakan yang diperlukan. CloudWatch API

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "comprehend:UpdateEndpoint",  
                "comprehend:DescribeEndpoint",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DeleteAlarms"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

Tabel DynamoDB dan indeks sekunder global

Kebijakan berbasis identitas berikut memberikan izin ke semua DynamoDB dan tindakan yang diperlukan. CloudWatch API

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "dynamodb:DescribeTable",  
                "dynamodb:UpdateTable",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DeleteAlarms"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

ECSlayanan

Kebijakan berbasis identitas berikut memberikan izin untuk semua ECS dan CloudWatch API tindakan yang diperlukan.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "ecs:DescribeServices",  
                "ecs:UpdateService",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DeleteAlarms"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

ElastiCache kelompok replikasi

Kebijakan berbasis identitas berikut memberikan izin untuk semua ElastiCache dan CloudWatch API tindakan yang diperlukan.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "elasticache:ModifyReplicationGroupShardConfiguration",  
                "elasticache:IncreaseReplicaCount",  
                "elasticache:DecreaseReplicaCount",  
                "elasticache:DescribeReplicationGroups",  
                "elasticache:DescribeCacheClusters",  
                "elasticache:DescribeCacheParameters",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DeleteAlarms"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

```
        "Resource": "*"
    }
]
}
```

EMRCluster Amazon

Kebijakan berbasis identitas berikut memberikan izin ke semua EMR Amazon CloudWatch API dan tindakan yang diperlukan.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "elasticmapreduce:ModifyInstanceGroups",
                "elasticmapreduce>ListInstanceGroups",
                "cloudwatch:DescribeAlarms",
                "cloudwatch:PutMetricAlarm",
                "cloudwatch>DeleteAlarms"
            ],
            "Resource": "*"
        }
    ]
}
```

Tabel Amazon Keyspaces

Kebijakan berbasis identitas berikut memberikan izin ke semua CloudWatch API Keyspaces Amazon dan tindakan yang diperlukan.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "cassandra>Select",
                "cassandra>Alter",
                "cloudwatch:DescribeAlarms",
                "cloudwatch:PutMetricAlarm",
                "cloudwatch>DeleteAlarms"
            ]
        }
    ]
}
```

```
        ],
        "Resource": "*"
    }
]
}
```

Fungsi Lambda

Kebijakan berbasis identitas berikut memberikan izin untuk semua CloudWatch API Lambda dan tindakan yang diperlukan.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "lambda:PutProvisionedConcurrencyConfig",
                "lambda:GetProvisionedConcurrencyConfig",
                "lambda>DeleteProvisionedConcurrencyConfig",
                "cloudwatch:DescribeAlarms",
                "cloudwatch:PutMetricAlarm",
                "cloudwatch:DeleteAlarms"
            ],
            "Resource": "*"
        }
    ]
}
```

Amazon Managed Streaming untuk Apache Kafka MSK () penyimpanan broker

Kebijakan berbasis identitas berikut memberikan izin ke semua MSK Amazon CloudWatch API dan tindakan yang diperlukan.

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "kafka:DescribeCluster",
                "kafka:DescribeClusterOperation",
                "kafka:UpdateBrokerStorage",
                "kafka:ListClusters"
            ],
            "Resource": "*"
        }
    ]
}
```

```
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch:DeleteAlarms"
    ],
    "Resource": "*"
}
]
```

Cluster Neptunus

Kebijakan berbasis identitas berikut memberikan izin ke semua Neptunus dan tindakan yang diperlukan. CloudWatch API

```
{
    "Version": "2012-10-17",
    "Statement": [
        {
            "Effect": "Allow",
            "Action": [
                "rds:AddTagsToResource",
                "rds>CreateDBInstance",
                "rds:DescribeDBInstances",
                "rds:DescribeDBClusters",
                "rds:DescribeDBClusterParameters",
                "rds:DeleteDBInstance",
                "cloudwatch:DescribeAlarms",
                "cloudwatch:PutMetricAlarm",
                "cloudwatch:DeleteAlarms"
            ],
            "Resource": "*"
        }
    ]
}
```

SageMaker titik akhir

Kebijakan berbasis identitas berikut memberikan izin untuk semua SageMaker dan CloudWatch API tindakan yang diperlukan.

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

```
{  
    "Effect": "Allow",  
    "Action": [  
        "sagemaker:DescribeEndpoint",  
        "sagemaker:DescribeEndpointConfig",  
        "sagemaker:DescribeInferenceComponent",  
        "sagemaker:UpdateEndpointWeightsAndCapacities",  
        "sagemaker:UpdateInferenceComponentRuntimeConfig",  
        "cloudwatch:DescribeAlarms",  
        "cloudwatch:PutMetricAlarm",  
        "cloudwatch:DeleteAlarms"  
    ],  
    "Resource": "*"  
}  
]  
}
```

Armada Spot (AmazonEC2)

Kebijakan berbasis identitas berikut memberikan izin untuk semua Armada Spot dan CloudWatch API tindakan yang diperlukan.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "ec2:DescribeSpotFleetRequests",  
                "ec2:ModifySpotFleetRequest",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DeleteAlarms"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

Sumber daya khusus

Kebijakan berbasis identitas berikut memberikan izin untuk tindakan eksekusi Gateway. API API Kebijakan ini juga memberikan izin untuk semua CloudWatch tindakan yang diperlukan.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "execute-api:Invoke",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DeleteAlarms"  
            ],  
            "Resource": "*"  
        }  
    ]  
}
```

Izin untuk bekerja di AWS Management Console

Tidak ada konsol Application Auto Scaling mandiri. Sebagian besar layanan yang terintegrasi dengan Application Auto Scaling memiliki fitur yang dikhususkan untuk membantu Anda mengonfigurasi penskalaan dengan konsol mereka.

Dalam kebanyakan kasus, setiap layanan menyediakan IAM kebijakan AWS terkelola (yang telah ditentukan sebelumnya) yang menentukan akses ke konsol mereka, yang mencakup izin untuk tindakan Application Auto API Scaling. Untuk informasi lebih lanjut, lihat dokumentasi untuk layanan yang konsolnya ingin Anda gunakan.

Anda juga dapat membuat IAM kebijakan kustom Anda sendiri untuk memberi pengguna izin halus untuk melihat dan bekerja dengan tindakan Application Auto Scaling tertentu di API AWS Management Console Anda dapat menggunakan contoh kebijakan di bagian sebelumnya; namun, kebijakan tersebut dirancang untuk permintaan yang dibuat dengan AWS CLI atau SDK. Konsol menggunakan API tindakan tambahan untuk fitur-fiturnya, sehingga kebijakan ini mungkin tidak berfungsi seperti yang diharapkan. Misalnya, untuk mengonfigurasi penskalaan langkah, pengguna mungkin memerlukan izin tambahan untuk membuat dan mengelola CloudWatch alarm.

Tip

Untuk membantu Anda mengetahui API tindakan mana yang diperlukan untuk melakukan tugas di konsol, Anda dapat menggunakan layanan seperti AWS CloudTrail. Untuk informasi selengkapnya, lihat [Panduan Pengguna AWS CloudTrail](#).

Kebijakan berbasis identitas berikut memberikan izin untuk mengonfigurasi kebijakan penskalaan untuk Armada Spot. Selain IAM izin untuk Spot Fleet, pengguna konsol yang mengakses pengaturan penskalaan armada dari EC2 konsol Amazon harus memiliki izin yang sesuai untuk layanan yang mendukung penskalaan dinamis.

```
{  
    "Version": "2012-10-17",  
    "Statement": [  
        {  
            "Effect": "Allow",  
            "Action": [  
                "application-autoscaling:*",  
                "ec2:DescribeSpotFleetRequests",  
                "ec2:ModifySpotFleetRequest",  
                "cloudwatch:DeleteAlarms",  
                "cloudwatch:DescribeAlarmHistory",  
                "cloudwatch:DescribeAlarms",  
                "cloudwatch:DescribeAlarmsForMetric",  
                "cloudwatch:GetMetricStatistics",  
                "cloudwatch>ListMetrics",  
                "cloudwatch:PutMetricAlarm",  
                "cloudwatch:DisableAlarmActions",  
                "cloudwatch:EnableAlarmActions",  
                "sns>CreateTopic",  
                "sns:Subscribe",  
                "sns:Get*",  
                "sns>List*"  
            ],  
            "Resource": "*"  
        },  
        {  
            "Effect": "Allow",  
            "Action": "iam>CreateServiceLinkedRole",  
            "Resource": "arn:aws:iam::*:role/aws-service-role/ec2.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_EC2SpotFleetRequest",  
            "Condition": {  
                "StringLike": {  
                    "iam:AWSServiceName": "ec2.application-autoscaling.amazonaws.com"  
                }  
            }  
        }  
    ]  
}
```

}

Kebijakan ini memungkinkan pengguna konsol untuk melihat dan memodifikasi kebijakan penskalaan di EC2 konsol Amazon, serta membuat dan mengelola CloudWatch alarm di CloudWatch konsol.

Anda dapat menyesuaikan API tindakan untuk membatasi akses pengguna. Misalnya, mengganti `application-autoscaling:*` dengan `application-autoscaling:Describe*` berarti pengguna memiliki akses hanya-baca.

Anda juga dapat menyesuaikan CloudWatch izin yang diperlukan untuk membatasi akses pengguna ke CloudWatch fitur. Untuk informasi [selengkapnya, lihat Izin yang diperlukan untuk CloudWatch konsol](#) di Panduan CloudWatch Pengguna Amazon.

Pemecahan masalah akses Application Auto Scaling

Jika Anda menemukan `AccessDeniedException` atau kesulitan serupa saat bekerja dengan Application Auto Scaling, konsultasikan informasi di bagian ini.

Saya tidak diotorisasi untuk melakukan tindakan dalam Application Auto Scaling

Jika Anda menerima `AccessDeniedException` saat memanggil AWS API operasi, itu berarti kredensial AWS Identity and Access Management (IAM) yang Anda gunakan tidak memiliki izin yang diperlukan untuk melakukan panggilan tersebut.

Contoh kesalahan berikut terjadi ketika `mateojackson` pengguna mencoba melihat detail tentang target yang dapat diskalakan, tetapi tidak memiliki `application-autoscaling:DescribeScalableTargets` izin.

```
An error occurred (AccessDeniedException) when calling the DescribeScalableTargets operation: User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform: application-autoscaling:DescribeScalableTargets
```

Jika Anda menerima kesalahan ini atau yang serupa, Anda harus menghubungi administrator untuk mendapatkan bantuan.

Administrator untuk akun Anda perlu memastikan bahwa Anda memiliki izin untuk mengakses semua API tindakan yang digunakan Application Auto Scaling untuk mengakses sumber daya di layanan target dan CloudWatch Ada berbagai izin yang diperlukan tergantung pada sumber daya yang Anda gunakan. Application Auto Scaling juga memerlukan izin untuk membuat peran terkait layanan saat pertama kali pengguna mengkonfigurasi penskalaan untuk sumber daya tertentu.

Saya seorang administrator dan IAM kebijakan saya mengembalikan kesalahan atau tidak berfungsi seperti yang diharapkan

Selain tindakan Application Auto Scaling, IAM kebijakan Anda harus memberikan izin untuk memanggil layanan target dan CloudWatch. Jika pengguna atau aplikasi tidak memiliki izin tambahan ini, akses mereka mungkin akan ditolak secara tak terduga. Untuk menulis IAM kebijakan untuk pengguna dan aplikasi di akun Anda, lihat informasi di [Contoh kebijakan berbasis identitas Application Auto Scaling](#).

Untuk informasi tentang bagaimana validasi dilakukan, lihat [Validasi izin untuk panggilan Application Auto API Scaling pada sumber daya target](#).

Perhatikan bahwa beberapa masalah izin juga dapat disebabkan oleh masalah dengan membuat peran yang terkait layanan yang digunakan oleh Application Auto Scaling. Untuk informasi tentang peran terkait layanan, lihat [Peran yang ditautkan dengan layanan untuk Application Auto Scaling](#).

Validasi izin untuk panggilan Application Auto API Scaling pada sumber daya target

Membuat permintaan resmi untuk API tindakan Application Auto Scaling mengharuskan API pemanggil memiliki izin untuk mengakses AWS sumber daya di layanan target dan di CloudWatch. Application Auto Scaling memvalidasi izin untuk permintaan yang terkait dengan layanan target dan CloudWatch sebelum melanjutkan dengan permintaan. Untuk mencapai hal ini, kami mengeluarkan serangkaian panggilan untuk memvalidasi IAM izin pada sumber daya target. Ketika respons dikembalikan, itu dibaca oleh Application Auto Scaling. Jika IAM izin tidak mengizinkan tindakan yang diberikan, Application Auto Scaling gagal permintaan dan mengembalikan kesalahan kepada pengguna yang berisi informasi tentang izin yang hilang. Ini memastikan bahwa konfigurasi penskalaan yang ingin diterapkan pengguna berfungsi sebagaimana dimaksud, dan kesalahan yang berguna akan ditampilkan jika permintaan gagal.

Sebagai contoh cara kerjanya, informasi berikut memberikan rincian tentang bagaimana Application Auto Scaling melakukan validasi izin dengan Aurora dan CloudWatch.

Ketika pengguna memanggil `RegisterScalableTarget` API terhadap cluster Aurora DB, Application Auto Scaling melakukan semua pemeriksaan berikut untuk memverifikasi bahwa pengguna memiliki izin yang diperlukan (dalam huruf tebal).

- RDS: `CreateDBInstance`: Untuk menentukan apakah pengguna memiliki izin ini, kami mengirim permintaan ke `CreateDBInstance` API operasi, mencoba membuat instance DB dengan

parameter tidak valid (ID instance kosong) di cluster Aurora DB yang ditentukan pengguna. Untuk pengguna yang berwenang, API mengembalikan respons kode `InvalidParameterValue` kesalahan setelah mengaudit permintaan. Namun, untuk pengguna yang tidak sah, kami mendapatkan kesalahan `AccessDenied` dan menggagalkan permintaan Application Auto Scaling dengan kesalahan `ValidationException` untuk pengguna yang mencantumkan izin yang hilang.

- RDS: `DeleteDBInstance`: Kami mengirim ID instance kosong ke operasi `DeleteDBInstance` API. Untuk pengguna yang berwenang, permintaan ini menghasilkan kesalahan `InvalidParameterValue`. Untuk pengguna yang tidak sah, menghasilkan `AccessDenied` dan mengirimkan pengecualian validasi kepada pengguna (perlakuan yang sama seperti yang dijelaskan dalam titik peluru pertama).
- rds: `AddTagsToResource`: Karena `AddTagsToResource` API operasi memerlukan Amazon Resource Name (ARN), maka perlu untuk menentukan sumber daya “dummy” menggunakan ID akun yang tidak valid (12345) dan ID instance dummy () untuk membuat (non-existing-db). ARN `arn:aws:rds:us-east-1:12345:db:non-existing-db` Untuk pengguna yang berwenang, permintaan ini menghasilkan kesalahan `InvalidParameterValue`. Untuk pengguna yang tidak sah, menghasilkan `AccessDenied` dan mengirimkan pengecualian validasi kepada pengguna.
- RDS: `DescribeDBCluster`: Kami menjelaskan nama cluster untuk sumber daya yang terdaftar untuk penskalaan otomatis. Untuk pengguna yang berwenang, kami mendapatkan hasil menggambarkan valid. Untuk pengguna yang tidak sah, menghasilkan `AccessDenied` dan mengirimkan pengecualian validasi kepada pengguna.
- RDS `DescribeDBInstance`: Kami memanggil `DescribeDBInstance` API dengan `db-cluster-id` filter yang memfilter pada nama cluster yang disediakan oleh pengguna untuk mendaftarkan target yang dapat diskalakan. Untuk pengguna yang berwenang, kami diizinkan untuk menjelaskan semua instans DB dalam klaster DB. Untuk pengguna yang tidak sah, panggilan ini menghasilkan `AccessDenied` dan mengirimkan pengecualian validasi kepada pengguna.
- cloudwatch: `PutMetricAlarm`: Kami memanggil `PutMetricAlarm` API tanpa parameter apa pun. Karena nama alarm hilang, permintaan mengakibatkan `ValidationError` untuk pengguna yang berwenang. Untuk pengguna yang tidak sah, menghasilkan `AccessDenied` dan mengirimkan pengecualian validasi kepada pengguna.
- cloudwatch: `DescribeAlarms`: Kami memanggil `DescribeAlarms` API dengan jumlah maksimum nilai rekaman yang disetel ke 1. Untuk pengguna yang berwenang, kami mengharapkan informasi tentang satu alarm dalam respons. Untuk pengguna yang tidak sah, panggilan ini menghasilkan `AccessDenied` dan mengirimkan pengecualian validasi kepada pengguna.

- cloudwatch:DeleteAlarms: Mirip dengan PutMetricAlarm di atas, kami tidak menyediakan parameter untuk DeleteAlarms diminta. Karena nama alarm hilang dari permintaan, panggilan ini gagal dengan ValidationError untuk pengguna yang berwenang. Untuk pengguna yang tidak sah, menghasilkan AccessDenied dan mengirimkan pengecualian validasi kepada pengguna.

Setiap kali salah satu dari pengecualian validasi ini terjadi, itu dicatat. Anda dapat mengambil langkah-langkah untuk secara manual mengidentifikasi panggilan mana yang gagal validasi dengan menggunakan AWS CloudTrail. Untuk informasi selengkapnya, lihat [Panduan Pengguna AWS CloudTrail](#).

 Note

Jika Anda menerima peringatan untuk acara Application Auto Scaling yang CloudTrail digunakan, peringatan ini akan menyertakan panggilan Application Auto Scaling untuk memvalidasi izin pengguna secara default. Untuk memfilter peringatan ini, gunakan invokedBy bidang, yang akan berisi application-autoscaling.amazonaws.com untuk pemeriksaan validasi ini.

Akses Application Auto Scaling menggunakan endpoint antarmuka VPC

Anda dapat menggunakan AWS PrivateLink untuk membuat koneksi pribadi antara Application Auto Scaling VPC dan Application Auto Scaling. Anda dapat mengakses Application Auto Scaling seolah-olah itu ada di AndaVPC, tanpa menggunakan gateway internet, NAT perangkat, VPN koneksi, atau AWS Direct Connect koneksi. Instans di Anda VPC tidak memerlukan alamat IP publik untuk mengakses Application Auto Scaling.

Anda membuat koneksi pribadi ini dengan membuat titik akhir antarmuka, yang didukung oleh AWS PrivateLink. Kami membuat antarmuka jaringan endpoint di setiap subnet yang Anda aktifkan untuk titik akhir antarmuka. Ini adalah antarmuka jaringan yang dikelola pemohon yang berfungsi sebagai titik masuk untuk lalu lintas yang ditujukan untuk Application Auto Scaling.

Untuk informasi selengkapnya, lihat [Akses Layanan AWS melalui AWS PrivateLink](#) di AWS PrivateLink Panduan.

Daftar Isi

- [Buat titik VPC akhir antarmuka](#)
- [Buat kebijakan VPC endpoint](#)

Buat titik VPC akhir antarmuka

Buat titik akhir untuk Application Auto Scaling menggunakan nama layanan berikut:

```
com.amazonaws.region.application-autoscaling
```

Untuk informasi selengkapnya, lihat [Mengakses AWS layanan menggunakan VPC titik akhir antarmuka](#) di AWS PrivateLink Panduan.

Anda tidak perlu mengubah pengaturan lainnya. Application Auto Scaling memanggil AWS layanan lain menggunakan titik akhir layanan atau VPC titik akhir antarmuka pribadi, mana saja yang digunakan.

Buat kebijakan VPC endpoint

Anda dapat melampirkan kebijakan ke VPC titik akhir untuk mengontrol akses ke Application Auto API Scaling. Kebijakan menentukan:

- Prinsipal yang dapat melakukan tindakan.
- Tindakan yang dapat dilakukan.
- Sumber daya yang padanya tindakan dapat dilakukan.

Contoh berikut menunjukkan kebijakan VPC titik akhir yang menolak izin semua orang untuk menghapus kebijakan penskalaan melalui titik akhir. Kebijakan contoh juga memberikan izin kepada semua orang untuk melakukan semua tindakan lainnya.

```
{  
    "Statement": [  
        {  
            "Action": "*",  
            "Effect": "Allow",  
            "Resource": "*",  
            "Principal": "*"  
        },  
        {  
            "Action": "AWSLambdaVPCExecutionRole>DeletePermission",  
            "Effect": "Deny",  
            "Resource": "*"  
        }  
    ]  
}
```

```
{  
    "Action": "application-autoscaling:DeleteScalingPolicy",  
    "Effect": "Deny",  
    "Resource": "*",  
    "Principal": "*"  
}  
]  
}
```

Untuk informasi selengkapnya, lihat [kebijakan VPC titik akhir](#) di AWS PrivateLink Panduan.

Ketahanan dalam Application Auto Scaling

Infrastruktur AWS global dibangun di sekitar AWS Wilayah dan Zona Ketersediaan.

AWS Wilayah menyediakan beberapa Availability Zone yang terpisah secara fisik dan terisolasi, yang terhubung dengan latensi rendah, throughput tinggi, dan jaringan yang sangat redundan.

Dengan Availability Zone, Anda dapat mendesain dan mengoperasikan aplikasi dan basis data yang secara otomatis mengalami kegagalan di antara zona tanpa gangguan. Zona Ketersediaan memiliki ketersediaan dan toleransi kesalahan yang lebih baik, dan dapat diskalakan dibandingkan infrastruktur pusat data tunggal atau multi tradisional.

Untuk informasi selengkapnya tentang AWS Wilayah dan Availability Zone, lihat [infrastruktur AWS global](#).

Keamanan infrastruktur dalam Application Auto Scaling

Sebagai layanan terkelola, Application Auto Scaling dilindungi oleh keamanan jaringan AWS global. Untuk informasi tentang layanan AWS keamanan dan cara AWS melindungi infrastruktur, lihat [Keamanan AWS Cloud](#). Untuk mendesain AWS lingkungan Anda menggunakan praktik terbaik untuk keamanan infrastruktur, lihat [Perlindungan Infrastruktur dalam Kerangka Kerja](#) yang AWS Diarsiteksikan dengan Baik Pilar Keamanan.

Anda menggunakan API panggilan yang AWS dipublikasikan untuk mengakses Application Auto Scaling melalui jaringan. Klien harus mendukung hal-hal berikut:

- Keamanan Lapisan Transportasi (TLS). Kami membutuhkan TLS 1.2 dan merekomendasikan TLS 1.3.

- Suite cipher dengan kerahasiaan maju yang sempurna (PFS) seperti (Ephemeral Diffie-Hellman) atau DHE (Elliptic Curve Ephemeral Diffie-Hellman). ECDHE Sebagian besar sistem modern seperti Java 7 dan versi lebih baru mendukung mode-mode ini.

Selain itu, permintaan harus ditandatangani dengan menggunakan ID kunci akses dan kunci akses rahasia yang terkait dengan IAM prinsipal. Atau Anda dapat menggunakan [AWS Security Token Service](#) (AWS STS) untuk menghasilkan kredensial keamanan sementara untuk menandatangani permintaan.

Validasi kepatuhan untuk Application Auto Scaling

Untuk mempelajari apakah an Layanan AWS berada dalam lingkup program kepatuhan tertentu, lihat [Layanan AWS di Lingkup oleh Program Kepatuhan Layanan AWS](#) dan pilih program kepatuhan yang Anda minati. Untuk informasi umum, lihat [Program AWS Kepatuhan Program AWS](#).

Anda dapat mengunduh laporan audit pihak ketiga menggunakan AWS Artifact. Untuk informasi selengkapnya, lihat [Mengunduh Laporan di AWS Artifact](#).

Tanggung jawab kepatuhan Anda saat menggunakan Layanan AWS ditentukan oleh sensitivitas data Anda, tujuan kepatuhan perusahaan Anda, dan hukum dan peraturan yang berlaku. AWS menyediakan sumber daya berikut untuk membantu kepatuhan:

- [Panduan Memulai Cepat Keamanan dan Kepatuhan — Panduan](#) penerapan ini membahas pertimbangan arsitektur dan memberikan langkah-langkah untuk menerapkan lingkungan dasar AWS yang berfokus pada keamanan dan kepatuhan.
- [Arsitektur untuk HIPAA Keamanan dan Kepatuhan di Amazon Web Services](#) — Whitepaper ini menjelaskan bagaimana perusahaan dapat menggunakan AWS untuk membuat HIPAA aplikasi yang memenuhi syarat.



Note

Tidak semua Layanan AWS HIPAA memenuhi syarat. Untuk informasi selengkapnya, lihat [Referensi Layanan yang HIPAA Memenuhi Syarat](#).

- [AWS Sumber Daya AWS](#) — Kumpulan buku kerja dan panduan ini mungkin berlaku untuk industri dan lokasi Anda.
- [AWS Panduan Kepatuhan Pelanggan](#) - Memahami model tanggung jawab bersama melalui lensa kepatuhan. Panduan ini merangkum praktik terbaik untuk mengamankan Layanan AWS

dan memetakan panduan untuk kontrol keamanan di berbagai kerangka kerja (termasuk Institut Standar dan Teknologi Nasional (NIST), Dewan Standar Keamanan Industri Kartu Pembayaran (PCI), dan Organisasi Internasional untuk Standardisasi ()). ISO

- [Mengevaluasi Sumber Daya dengan Aturan](#) dalam Panduan AWS Config Pengembang — AWS Config Layanan menilai seberapa baik konfigurasi sumber daya Anda mematuhi praktik internal, pedoman industri, dan peraturan.
- [AWS Security Hub](#) — Ini Layanan AWS memberikan pandangan komprehensif tentang keadaan keamanan Anda di dalamnya AWS. Security Hub menggunakan kontrol keamanan untuk sumber daya AWS Anda serta untuk memeriksa kepatuhan Anda terhadap standar industri keamanan dan praktik terbaik. Untuk daftar layanan dan kontrol yang didukung, lihat [Referensi kontrol Security Hub](#).
- [Amazon GuardDuty](#) — Ini Layanan AWS mendeteksi potensi ancaman terhadap beban kerja Akun AWS, kontainer, dan data Anda dengan memantau lingkungan Anda untuk aktivitas mencurigakan dan berbahaya. GuardDuty dapat membantu Anda mengatasi berbagai persyaratan kepatuhan, seperti PCI DSS, dengan memenuhi persyaratan deteksi intrusi yang diamanatkan oleh kerangka kerja kepatuhan tertentu.
- [AWS Audit Manager](#) — Ini Layanan AWS membantu Anda terus mengaudit AWS penggunaan Anda untuk menyederhanakan cara Anda mengelola risiko dan kepatuhan terhadap peraturan dan standar industri.

Kuota untuk Application Auto Scaling

Anda Akun AWS memiliki kuota default, sebelumnya disebut sebagai batas, untuk masing-masing. Layanan AWS Kecuali dinyatakan lain, setiap kuota bersifat khusus per Wilayah. Anda dapat meminta peningkatan untuk beberapa kuota dan kuota lainnya tidak dapat ditingkatkan.

Untuk melihat kuota Application Auto Scaling, buka konsol Service [Quotas](#). Di panel navigasi, pilih AWS layanan dan pilih Application Auto Scaling.

Untuk meminta peningkatan kuota, lihat [Meminta Peningkatan Kuota](#) dalam Panduan Pengguna Service Quotas.

Anda Akun AWS memiliki kuota berikut yang terkait dengan Application Auto Scaling.

Nama	Default	Dapat disesuaikan
Target yang dapat diskalakan per jenis sumber daya	Amazon DynamoDB: 5.000 Amazon ECS: 3.000 Amazon Keyspaces: 1.500 Jenis sumber daya lainnya: 500	Ya
Kebijakan penskalaan per target yang dapat diskalakan (baik kebijakan penskalaan langkah maupun pelacakan target)	50	Tidak
Tindakan terjadwal per target yang dapat diskalakan	200	Tidak
Penyesuaian langkah per kebijakan penskalaan langkah	20	Tidak

Selalu ingat kuota layanan saat Anda meningkatkan beban kerja Anda. Misalnya, ketika Anda mencapai jumlah maksimum unit kapasitas yang diizinkan oleh layanan, penskalaan akan berhenti. Jika permintaan dan kapasitas saat ini menurun, Application Auto Scaling dapat ditingkatkan lagi. Untuk menghindari mencapai batas kapasitas ini lagi, Anda dapat meminta peningkatan. Setiap

layanan memiliki kuota default sendiri untuk kapasitas maksimum sumber daya. Untuk informasi tentang kuota default untuk Amazon Web Services lainnya, lihat [Titik akhir dan kuota layanan](#) di Referensi Umum Amazon Web Services

Riwayat dokumen untuk Application Auto Scaling

Tabel berikut menjelaskan tambahan penting pada dokumentasi Application Auto Scaling, yang dimulai pada Januari 2018. Untuk pemberitahuan tentang pembaruan dokumentasi ini, Anda dapat berlangganan RSS umpan.

Perubahan	Deskripsi	Tanggal
<u>Tambahkan dukungan untuk kumpulan WorkSpaces</u>	Gunakan Application Auto Scaling untuk menskalakan kumpulan WorkSpaces. Untuk informasi selengkapnya, lihat <u>Amazon WorkSpaces dan Application Auto Scaling</u> . Topik <u>Pembaruan Application Auto Scaling ke kebijakan AWS terkelola</u> telah diperbarui untuk mencantumkan kebijakan terkelola baru untuk integrasi WorkSpaces	Juni 27, 2024
<u>Perubahan panduan</u>	Memperbarui jumlah maksimum target yang dapat diskalakan per entri jenis sumber daya dalam dokumentasi kuota. Lihat <u>Kuota untuk Application Auto Scaling</u> .	Januari 16, 2024
<u>Support untuk SageMaker komponen inferensi</u>	Gunakan Application Auto Scaling untuk menskalakan salinan komponen inferensi.	November 29, 2023
<u>Memperbarui ke IAM izin peran terkait layanan</u>	Application Auto Scaling memperbarui kebijakan AWSApplicationAuto scalingSageMakerEn	13 November 2023

`dpointPolicy` Untuk informasi selengkapnya, lihat [pembaruan Application Auto Scaling ke kebijakan AWS terkelola](#).

[Support untuk konkurensi yang SageMaker disediakan Tanpa Server](#)

Gunakan Application Auto Scaling untuk menskalakan konkurensi yang disediakan dari titik akhir tanpa server.

9 Mei 2023

[Kategorikan target skalabel Anda menggunakan tag](#)

Anda sekarang dapat menetapkan metadata ke target scalable Application Auto Scaling Anda dalam bentuk tag. Lihat [Dukungan penandaan untuk Application Auto Scaling](#).

20 Maret 2023

[Support untuk matematika CloudWatch metrik](#)

Sekarang Anda dapat menggunakan matematik a metrik saat membuat kebijakan penskalaan pelacakan target. Dengan matematika metrik, Anda dapat menanyakan beberapa CloudWatch metrik dan menggunakan ekspresi matematika untuk membuat deret waktu baru berdasarkan metrik ini. Lihat [Membuat kebijakan penskalaan pelacakan target untuk Application Auto Scaling menggunakan matematika metrik](#).

14 Maret 2023

Perubahan panduan

Topik baru dalam Panduan Pengguna Application Auto Scaling membantu Anda mulai menggunakan AWS CloudShell Application Auto Scaling. Lihat [Gunakan AWS CloudShell untuk bekerja dengan Application Auto Scaling dari baris perintah](#).

Alasan untuk tidak menskalakan
an

Anda sekarang dapat mengambil alasan yang dapat dibaca mesin untuk Application Auto Scaling tidak menskalakan sumber daya Anda menggunakan Application Auto Scaling. API Lihat [Aktivitas penskalaan untuk Application Auto Scaling](#).

Perubahan panduan

Memperbarui jumlah maksimum target yang dapat diskalakan per entri jenis sumber daya dalam dokumentasi kuota. Lihat [Kuota untuk Application Auto Scaling](#).

17 Februari 2023

4 Januari 2023

6 Mei 2022

<u>Tambahkan dukungan untuk cluster Amazon Neptunus</u>	Gunakan Application Auto Scaling untuk menskalakan jumlah replika di kluster Amazon Neptunus DB. Untuk informasi selengkapnya, lihat Amazon Neptunus dan Application Auto Scaling . Topik Pembaruan Application Auto Scaling ke kebijakan AWS terkelola telah diperbarui untuk mencantumkan kebijakan terkelola baru untuk integrasi dengan Neptunus.	Oktober 6, 2021
<u>Application Auto Scaling sekarang melaporkan perubahan pada kebijakan yang dikelola AWS</u>	Mulai 19 Agustus 2021, perubahan kebijakan terkelola dilaporkan dalam topik Pembaruan Application Auto Scaling ke kebijakan AWS terkelola . Perubahan pertama yang tercantum adalah penambahan izin yang diperlukan untuk ElastiCache (RedisOSS).	19 Agustus 2021
<u>Tambahkan dukungan untuk grup replikasi ElastiCache (RedisOSS)</u>	Gunakan Application Auto Scaling untuk menskalakan jumlah grup node dan jumlah replika per grup node untuk grup replikasi ElastiCache (RedisOSS) (cluster). Untuk informasi selengkapnya, lihat ElastiCache (RedisOSS) dan Application Auto Scaling .	19 Agustus 2021

Perubahan panduan

IAMTopik baru dalam Panduan Pengguna Application Auto Scaling membantu Anda memecahkan masalah akses ke Application Auto Scaling. Untuk informasi selengkapnya, lihat [Identity and Access Management untuk Application Auto Scaling](#). Juga menambahkan kebijakan IAM izin contoh baru untuk tindakan pada layanan target dan Amazon CloudWatch. Untuk informasi selengkapnya, lihat [Contoh kebijakan untuk bekerja dengan AWS CLI atau SDK](#).

23 Februari 2021

Tambahkan dukungan untuk zona waktu lokal

Anda sekarang dapat membuat tindakan terjadwal di zona waktu lokal. Jika zona waktu Anda mengamati waktu musim panas, maka secara otomatis menyesuaikan Daylight Saving Time (. DST). Untuk informasi selengkapnya, lihat [Penskalaan terjadwal](#).

2 Februari 2021

Perubahan panduan

	<p>Tutorial baru dalam Panduan Pengguna Application Auto Scaling membantu Anda memahami cara menggunakan kebijakan penskalaan pelacakan target dan penskalaan terjadwal untuk meningkatkan ketersediaan aplikasi Anda saat menggunakan Application Auto Scaling. Juga, topik baru menjelaskan cara memicu pemberitahuan ketika CloudWatch telah mendeteksi masalah yang mungkin memerlukan perhatian Anda.</p>	15 Oktober 2020
<u>Tambahkan dukungan untuk Amazon Managed Streaming untuk Apache Kafka Kafka Cluster Storage</u>	Gunakan kebijakan penskalaan pelacakan target untuk mengukur jumlah penyimpanan broker yang terkait dengan MSK klaster Amazon.	Rabu, 30 September 2020
<u>Tambahkan dukungan untuk titik akhir pengenal entitas Amazon Comprehend</u>	Menggunakan Application Auto Scaling untuk menskalakan jumlah unit inferensi yang disediakan untuk titik akhir pengenal entitas Amazon Comprehend Anda.	Senin, 28 September 2020
<u>Tambahkan dukungan untuk Amazon Keyspaces (untuk Apache Cassandra) tabel</u>	Menggunakan Application Auto Scaling untuk menskalakan hasil yang disediakan (kapasitas baca dan tulis) dari tabel Amazon Keyspaces.	Kamis, 23 April 2020

<u>Bab "Keamanan" baru</u>	Bab <u>Keamanan</u> baru di Panduan Pengguna Application Auto Scaling membantu Anda memahami cara menerapkan <u>model tanggung jawab bersama</u> saat menggunakan Application Auto Scaling. Sebagai bagian dari pembaruan ini, bab panduan pengguna "Autentikasi dan Kontrol Akses" telah diganti dengan bagian baru yang lebih berguna, <u>Identity and Access Management</u> untuk Application Auto Scaling.	Kamis, 16 Januari 2020
<u>Pembaruan kecil</u>	Berbagai perbaikan dan koreksi.	Rabu, 15 Januari 2020
<u>Tambahkan fungsionalitas notifikasi</u>	Application Auto Scaling sekarang mengirimkan peristiwa ke Amazon EventBridge dan pemberitahuan kepada Anda AWS Health Dashboard ketika tindakan tertentu terjadi. Untuk informasi lebih lanjut, lihat <u>pemantauan Application Auto Scaling</u> .	20 Desember 2019
<u>Tambahkan dukungan untuk AWS Lambda fungsi</u>	Gunakan Application Auto Scaling untuk menskalakan ketersediaan konkurensi fungsi Lambda.	3 Desember 2019

<u>Tambahkan dukungan untuk titik akhir klasifikasi dokumen Amazon Comprehend</u>	Gunakan Application Auto Scaling untuk menskalakan kapasitas throughput titik akhir klasifikasi dokumen Amazon Comprehend.	Senin, 25 November 2019
<u>Tambahkan dukungan AppStream 2.0 untuk kebijakan penskalaan pelacakan target</u>	Gunakan kebijakan penskalaan pelacakan target untuk menskalakan ukuran armada AppStream 2.0.	25 November 2019
<u>Dukungan untuk titik VPC akhir Amazon</u>	Anda sekarang dapat membuat koneksi pribadi antara Application Auto Scaling VPC dan Application Auto Scaling. Untuk pertimbangan dan instruksi migrasi, lihat <u>Application Auto Scaling dan VPC</u> titik akhir antarmuka.	Jumat, 22 November 2019
<u>Tangguhkan dan lanjutkan penskalaan</u>	Dukungan tambahan untuk menangguhkan dan melanjutkan penskalaan. Untuk informasi lebih lanjut, lihat <u>Menangguhkan dan melanjutkan penskalaan untuk Application Auto Scaling</u> .	Kamis, 29 Agustus 2019
<u>Bagian baru</u>	Bagian <u>Menyiapkan</u> telah ditambahkan ke dokumentasi Application Auto Scaling. Peningkatan dan perbaikan kecil telah dilakukan di seluruh panduan pengguna.	Jumat, 28 Juni 2019

<u>Perubahan panduan</u>	Meningkatkan dokumentasi Application Auto Scaling dalam bagian <u>Penskalaan terjadwal</u> , <u>Kebijakan penskalaan langkah</u> , dan <u>Kebijakan penskalaan pelacakan target</u> .	Senin, 11 Maret 2019
<u>Tambahkan dukungan untuk sumber daya khusus</u>	Menggunakan Application Auto Scaling untuk menskalakan sumber daya kustom yang disediakan oleh aplikasi atau layanan Anda sendiri. Untuk informasi lebih lanjut, lihat <u>GitHub repository</u> kami.	9 Juli 2018
<u>Tambahkan dukungan untuk varian SageMaker endpoint</u>	Gunakan Application Auto Scaling untuk menskalakan jumlah instans titik akhir yang disediakan untuk varian.	Rabu, 28 Februari 2018

Tabel berikut menjelaskan perubahan penting pada dokumentasi Application Auto Scaling sebelum Januari 2018.

Perubahan	Deskripsi	Tanggal
Menambahkan dukungan untuk Replika Aurora	Menggunakan Application Auto Scaling untuk menskalakan jumlah yang diinginkan. Untuk informasi selengkapnya, lihat <u>Menggunakan Auto Scaling Amazon Aurora dengan replika Aurora</u> di Panduan Pengguna Amazon RDS	Jumat, 17 November 2017

Perubahan	Deskripsi	Tanggal
Menambahkan dukungan untuk penskalaan terjadwal	Menggunakan penskalaan terjadwal untuk menskalakan sumber daya pada waktu atau interval yang telah ditentukan sebelumnya. Untuk informasi lebih lanjut, lihat Penskalaan terjadwal untuk Application Auto Scaling .	Rabu, 08 November 2017
Menambahkan dukungan untuk kebijakan penskalaan pelacakan target	Menggunakan kebijakan penskalaan pelacakan target untuk mengatur penskalaan dinamis untuk aplikasi Anda hanya dalam beberapa langkah sederhana. Untuk informasi lebih lanjut, lihat Kebijakan penskalaan pelacakan target untuk Application Auto Scaling .	Rabu, 12 Juli 2017
Menambahkan dukungan untuk kapasitas baca dan tulis yang disediakan untuk tabel DynamoDB dan indeks sekunder global	Menggunakan Application Auto Scaling untuk menskalakan hasil yang disediakan (kapasitas baca dan tulis). Untuk informasi lebih lanjut, lihat Mengelola kapasitas throughput dengan DynamoDB Auto Scaling di Panduan Developer Amazon DynamoDB.	Rabu, 14 Juni 2017

Perubahan	Deskripsi	Tanggal
Tambahkan dukungan untuk armada AppStream 2.0	Menggunakan Application Auto Scaling untuk menskalakan ukuran armada. Untuk informasi selengkapnya, lihat Auto Scaling Armada untuk AppStream 2.0 di Panduan Administrasi Amazon AppStream 2.0.	Kamis, 23 Maret 2017
Tambahkan dukungan untuk EMR klaster Amazon	Menggunakan Application Auto Scaling untuk menskalakan node inti dan tugas. Untuk informasi selengkapnya, lihat Menggunakan penskalaan otomatis di Amazon EMR dalam Panduan EMR Manajemen Amazon.	Jumat, 18 November 2016
Menambahkan dukungan untuk Spot Fleet	Gunakan Application Auto Scaling untuk menskalakan kapasitas target. Untuk informasi selengkapnya, lihat Penskalaan otomatis untuk armada Spot di Panduan EC2 Pengguna Amazon.	1 September 2016
Tambahkan dukungan untuk ECS layanan Amazon	Menggunakan Application Auto Scaling untuk menskalakan jumlah yang diinginkan. Untuk informasi lebih lanjut, lihat Service Auto Scaling dalam Panduan Pengembangan Layanan Amazon Elastic Container.	Selasa, 09 Agustus 2016

Terjemahan disediakan oleh mesin penerjemah. Jika konten terjemahan yang diberikan bertentangan dengan versi bahasa Inggris aslinya, utamakan versi bahasa Inggris.