



사용 설명서

Application Auto Scaling



Application Auto Scaling: 사용 설명서

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

Amazon의 상표 및 트레이드 드레스는 Amazon 외 제품 또는 서비스와 함께, Amazon 브랜드 이미지를 떨어뜨리거나 고객에게 혼동을 일으킬 수 있는 방식으로 사용할 수 없습니다. Amazon이 소유하지 않은 기타 모든 상표는 Amazon과 제휴 관계이거나 관련이 있거나 후원 관계와 관계없이 해당 소유자의 자산입니다.

Table of Contents

Application Auto Scaling이란?	1
Application Auto Scaling의 기능	2
Application Auto Scaling 작업	2
개념	3
자세히 알아보기	4
통합되는 서비스	5
Amazon WorkSpaces Applications	7
서비스 연결 역할	7
서비스 보안 주체	8
Application Auto Scaling을 사용하여 WorkSpaces 애플리케이션 플릿을 확장 가능 대상으로 등록	8
관련 리소스	9
Amazon Aurora	9
서비스 연결 역할	9
서비스 보안 주체	9
Application Auto Scaling을 통해 Aurora DB 클러스터를 확장 가능 대상으로 등록	10
관련 리소스	11
Amazon Comprehend	11
서비스 연결 역할	11
서비스 보안 주체	11
Application Auto Scaling을 통해 Amazon Comprehend 리소스를 확장 가능 대상으로 등록	11
관련 리소스	13
Amazon DynamoDB	13
서비스 연결 역할	13
서비스 보안 주체	13
Application Auto Scaling을 통해 DynamoDB 리소스를 확장 가능 대상으로 등록	14
관련 리소스	16
Amazon ECS	16
서비스 연결 역할	16
서비스 보안 주체	17
Application Auto Scaling을 통해 ECS 서비스를 확장 가능 대상으로 등록	17
관련 리소스	18
Amazon ElastiCache	18
서비스 연결 역할	18

서비스 보안 주체	19
Application Auto Scaling을 사용하여 ElastiCache 리소스를 확장 가능 대상으로 등록	19
관련 리소스	21
Amazon Keyspaces(Apache Cassandra용)	21
서비스 연결 역할	21
서비스 보안 주체	21
Application Auto Scaling을 통해 Amazon Keyspaces 테이블을 확장 가능 대상으로 등록	22
관련 리소스	23
AWS Lambda	23
서비스 연결 역할	23
서비스 보안 주체	24
Application Auto Scaling을 통해 Lambda 서비스를 확장 가능 대상으로 등록	24
관련 리소스	25
Amazon Managed Streaming for Apache Kafka(MSK)	25
서비스 연결 역할	25
서비스 보안 주체	25
Application Auto Scaling을 통해 Amazon MSK 클러스터 스토리지를 확장 가능 대상으로 등록	26
관련 리소스	27
Amazon Neptune	27
서비스 연결 역할	27
서비스 보안 주체	27
Application Auto Scaling을 통해 Neptune 클러스터를 확장 가능 대상으로 등록	28
관련 리소스	28
Amazon SageMaker AI	29
서비스 연결 역할	29
서비스 보안 주체	29
Application Auto Scaling을 사용하여 SageMaker AI 엔드포인트 변형을 확장 가능 대상으로 등록	29
Application Auto Scaling을 통해 서버리스 엔드포인트의 동시성을 확장 가능 대상으로 등록하기	30
Application Auto Scaling을 통해 추론 구성 요소를 확장 가능 대상으로 등록	31
관련 리소스	32
스팟 플릿(Amazon EC2)	32
서비스 연결 역할	33
서비스 보안 주체	33

Application Auto Scaling을 통해 스팟 플릿을 확장 가능 대상으로 등록	33
관련 리소스	34
Amazon WorkSpaces	34
서비스 연결 역할	34
서비스 보안 주체	35
Application Auto Scaling을 통해 WorkSpaces 풀을 규모 조정 가능 대상으로 등록	35
관련 리소스	36
사용자 지정 리소스	36
서비스 연결 역할	36
서비스 보안 주체	36
Application Auto Scaling을 통해 사용자 지정 리소스를 확장 가능 대상으로 등록	37
관련 리소스	38
를 사용하여 조정 구성 CloudFormation	39
Application Auto Scaling 및 CloudFormation 템플릿	39
예제 템플릿 코드 조각	40
에 대해 자세히 알아보기 CloudFormation	40
예약된 크기 조정	41
예약된 조정 작동 방식	42
작동 방식	42
고려 사항	42
자주 사용되는 명령	43
관련 리소스	43
제한 사항	44
예약된 작업 생성	44
한 번만 발생하는 예약된 작업 생성	45
반복되는 간격으로 실행되는 예약된 작업 만들기	46
반복되는 일정으로 실행되는 예약된 작업 생성	47
시간대를 지정하는 일회성 예약된 작업 만들기	48
시간대를 지정하는 반복 예약 작업 생성	48
예약된 조정 설명	49
서비스에 대한 조정 활동 설명	50
서비스에 대한 예약된 작업 설명	51
규모 조정 가능 대상에 대한 하나 이상의 예약된 작업 설명	53
반복 조정 작업 예약	54
예약된 조정 해제	57
예약된 작업 삭제	58

대상 추적 조정 정책	60
대상 추적 작동 방식	61
작동 방식	61
지표 선택	62
목표 값 정의	63
휴지 기간 정의	63
고려 사항	65
여러 조정 정책	66
자주 사용되는 명령	66
관련 리소스	67
제한 사항	67
대상 추적 조정 정책 생성	67
1단계: 규모 조정 가능 대상 등록	68
2단계: 대상 추적 조정 정책 생성	68
3단계: 대상 추적 조정 정책 설명	71
대상 추적 조정 정책 삭제	72
지표 수학 사용	73
예: 태스크당 Amazon SQS 대기열 백로그	73
제한 사항	78
단계별 조정 정책	79
단계 조정 작동 방식	80
작동 방식	80
단계 조절	81
조정 조절 유형	83
휴지 기간	84
자주 사용되는 명령	84
고려 사항	85
관련 리소스	43
콘솔 액세스	85
단계 조정 정책 삭제	85
1단계: 규모 조정 가능 대상 등록	86
2단계: 단계 조정 정책 생성	86
3단계: 조정 정책을 간접적으로 호출하는 경보 생성	90
단계 조정 정책 설명	91
단계 조정 정책 삭제	93
예측 크기 조정	94

작동 방식	94
최대 용량 제한	95
조정 정책 생성, 관리 및 삭제를 위해 일반적으로 사용되는 명령	95
고려 사항	96
예측 조정 정책 생성	96
예측 재정의	97
1단계: (옵션) 시계열 데이터 분석	98
2단계: 2개의 예약된 작업 생성	99
사용자 정의 지표 사용	100
모범 사례	101
사전 조건	101
사용자 지정 지표를 위한 JSON 구성	102
사용자 정의 지표 사용 시 고려 사항	109
자습서: 과중한 워크로드를 처리하도록 Auto Scaling 구성	111
사전 조건	111
1단계: 확장 가능 대상 등록	112
2단계: 요구 사항에 따라 예약된 작업 설정	113
2단계: 대상 추적 조정 정책 추가	116
4단계: 다음 단계	118
5단계: 정리	119
조정 일시 중지	121
조정 활동	121
조정 활동 일시 중지 및 재개	122
일시 중지된 조정 활동 보기	124
조정 활동 재개	125
조정 활동	127
규모 조정 가능 대상별 조정 활동 조회	127
규모가 조정되지 않은 활동 포함	128
사유 코드	130
모니터링	132
CloudWatch를 사용한 모니터링	133
리소스 사용량 모니터링을 위한 CloudWatch 지표	134
대상 추적 조정 정책을 위해 사전 정의된 지표	146
예측 조정 지표 및 차원	149
CloudTrail을 사용하여 API 호출 로깅	150
CloudTrail의 Application Auto Scaling 관리 이벤트	151

Application Auto Scaling 이벤트 예제	151
CloudWatch에서 Application Auto Scaling RemoveAction 호출	152
Amazon EventBridge	153
Application Auto Scaling 이벤트	153
AWS SDKs 작업	158
코드 예제	160
기본 사항	160
작업	161
태그 지정 지원	199
태그 예제	199
보안을 위한 태그	200
태그에 대한 액세스 통제	201
보안	203
데이터 보호	203
자격 증명 및 액세스 관리	204
액세스 관리	205
Application Auto Scaling에서 IAM을 사용하는 방식	205
AWS 관리형 정책	210
서비스 연결 역할	221
ID 기반 정책 예시	226
문제 해결	240
권한 검증	241
AWS PrivateLink	243
인터페이스 VPC 엔드포인트 생성	243
VPC 엔드포인트 정책 생성	243
복원력	244
인프라 보안	245
규정 준수 확인	245
할당량	246
문서 이력	247
.....	cclvi

Application Auto Scaling이란?

Application Auto Scaling은 [Amazon EC2 Auto Scaling](#) 이외의 개별 서비스에 대해 확장 가능한 리소스를 자동으로 조정하기 위한 솔루션이 필요한 개발자 및 시스템 관리자를 위한 웹 AWS 서비스입니다. Application Auto Scaling을 사용하면 다음 리소스에 대한 자동 조정을 구성할 수 있습니다.

- WorkSpaces 애플리케이션 플릿
- Aurora 복제본
- Amazon Comprehend 문서 분류 및 엔터티 인식기 엔드포인트
- DynamoDB 테이블 및 글로벌 보조 인덱스
- Amazon ECS 서비스
- ElastiCache 복제 그룹(Redis OSS 및 Valkey) 및 Memcached 클러스터
- Amazon EMR 클러스터
- Amazon Keyspaces(Apache Cassandra용) 표
- Lambda 함수의 프로비저닝된 동시성
- Amazon Managed Streaming for Apache Kafka(MSK) 브로커 스토리지
- Amazon Neptune 클러스터
- SageMaker AI 엔드포인트 변형
- SageMaker AI 추론 구성 요소
- SageMaker AI Serverless 프로비저닝된 동시성
- 스팟 플릿 요청
- Amazon WorkSpaces 풀
- 자체 애플리케이션 또는 서비스에서 제공하는 사용자 지정 리소스. 자세한 내용은 [GitHub 리포지토리](#)를 참조하세요.

위에 나열된 AWS 서비스의 리전별 가용성을 보려면 [리전 테이블](#)을 참조하세요.

Auto Scaling 그룹을 사용하여 Amazon EC2 인스턴스 플릿을 조정하는 방법에 대한 자세한 내용은 [Amazon EC2 Auto Scaling 사용 설명서](#)를 참조하세요.

Application Auto Scaling의 기능

Application Auto Scaling을 사용하면 사용자가 정의하는 조건에 맞게 확장 가능한 리소스를 자동으로 조정할 수 있습니다.

- 대상 추적 크기 조정 - 특정 CloudWatch 지표에 대한 대상 값을 기준으로 리소스 크기를 조정합니다.
- 단계 크기 조정 - 경보 위반의 크기에 따라 다른 일련의 크기 조정 조절을 기반으로 리소스 크기를 조정합니다.
- 예약된 크기 조정 - 한 번만 또는 반복되는 일정에 따라 리소스 크기를 조정합니다.
- 예측 조정 - 과거 데이터를 기반으로 예상 로드와 일치하도록 리소스를 사전에 조정합니다.

Application Auto Scaling 작업

크기 조정 중인 리소스에 따라 다음 인터페이스를 사용하여 크기 조정을 구성할 수 있습니다.

- AWS Management Console - 크기 조정을 구성하는 데 사용할 수 있는 웹 인터페이스를 제공합니다. AWS 계정에 가입하고 로그인합니다 AWS Management Console. 그런 다음 소개에 나열된 리소스 중 하나에 대해 서비스 콘솔을 엽니다. 예를 들어 Lambda 함수를 조정하려면 AWS Lambda console. 작업을 리소스 AWS 리전 와 동일한에서 콘솔을 열어야 합니다.

Note

콘솔 액세스는 일부 리소스에서 사용할 수 없습니다. 자세한 내용은 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 단원을 참조하십시오.

- AWS Command Line Interface (AWS CLI) - 광범위한에 대한 명령을 제공하며 Windows AWS 서비스, macOS 및 Linux에서 지원됩니다. 시작하려면 [AWS Command Line Interface](#)을 참조하세요. 명령 목록은 AWS CLI 명령 참조의 [application-autoscaling](#)을 참조하세요.
- AWS Tools for Windows PowerShell – PowerShell 환경에서 스크립트를 작성하는 사용자를 위해 광범위한 AWS 제품 집합에 대한 명령을 제공합니다. 시작하려면 [AWS Tools for PowerShell 사용자 가이드](#)를 참조하세요. 자세한 설명은 [AWS Tools for PowerShell Cmdlet 참조](#)를 참조하세요.
- AWS SDKs- 언어별 API 작업을 제공하고 서명 계산, 요청 재시도 처리, 오류 처리와 같은 많은 연결 세부 정보를 처리합니다. 자세한 내용은 [빌드 기반 도구를 참조하세요 AWS](#).
- HTTPS API - HTTPS 요청을 사용하여 호출하는 하위 수준의 API 작업을 제공합니다. 자세한 내용은 [Application Auto Scaling API Reference](#)(Application Auto Scaling API 레퍼런스)를 참조하세요.

- CloudFormation - CloudFormation 템플릿을 사용하여 크기 조정 구성을 지원합니다. 자세한 내용은 [를 사용하여 Application Auto Scaling 리소스 구성 AWS CloudFormation](#) 단원을 참조하십시오.

에 프로그래밍 방식으로 연결하려면 엔드포인트를 AWS 서비스사용합니다. Application Auto Scaling 호출을 위한 엔드포인트에 대한 자세한 내용은 [Application Auto Scaling 엔드포인트 및 할당량을 AWS](#) 일반 참조참조하세요.

Application Auto Scaling 개념

이 주제에서는 Application Auto Scaling에 대해 알아보고 이를 사용해 시작하는 데 도움이 되는 주요 개념에 대해 설명합니다.

확장 가능 대상

확장하려는 리소스를 지정하기 위해 생성하는 엔터티입니다. 각 확장 가능 대상은 기본 서비스의 일부 용량 차원을 나타내는 서비스 네임스페이스, 리소스 ID 및 확장 가능한 차원으로 고유하게 식별됩니다. 예를 들어, Amazon ECS 서비스는 태스크 수의 Auto scaling을 지원하고, DynamoDB 테이블은 테이블 및 그 글로벌 보조 인덱스의 읽기 및 쓰기 용량 Auto scaling을 지원하며, Aurora 클러스터는 복제본 수의 조정을 지원합니다.

Tip

각 확장 가능 대상에는 최대 및 최소 용량도 있습니다. 조정 정책은 최소-최대 범위보다 높거나 낮지 않습니다. Application Auto Scaling이 알지 못하는 이 범위를 벗어나는 기본 리소스를 직접 대역 외부 변경할 수 있습니다. 그러나 조정 정책을 호출하거나 RegisterScalableTarget API를 호출되면 Application Auto Scaling이 현재 용량을 검색하여 최소 및 최대 용량과 비교합니다. 최소-최대 범위를 벗어나면 설정된 최솟값과 최댓값을 준수하도록 용량이 업데이트됩니다.

축소

Application Auto Scaling이 확장 가능 대상에 대한 용량을 자동으로 줄이면 확장 가능 대상이 축소합니다. 조정 정책이 설정되면 확장 가능 대상을 최소 용량보다 작게 스케일 인할 수 없습니다.

확장

Application Auto Scaling이 확장 가능 대상에 대한 용량을 자동으로 늘이면 확장 가능 대상이 확장합니다. 조정 정책이 설정되면 확장 가능 대상을 최대 용량보다 크게 스케일 아웃할 수 없습니다.

조정 정책

조정 정책은 Application Auto Scaling을 통해 특정 CloudWatch 지표를 추적하도록 지시합니다. 그런 다음 지표가 특정 임계값보다 높거나 낮을 때 수행할 조정 작업을 결정합니다. 예를 들어 클러스터 전체의 CPU 사용량이 증가하기 시작하면 확장하고 다시 떨어지면 축소할 수 있습니다.

Auto scaling에 사용되는 지표는 대상 서비스에서 게시되지만 자체 지표를 CloudWatch에 게시한 다음 조정 정책과 함께 사용할 수도 있습니다.

크기 조정 활동 간의 휴지 기간을 사용하면 다른 크기 조정 활동이 시작되기 전에 리소스가 안정화됩니다. Application Auto Scaling은 휴지 기간에 지표를 계속 평가합니다. 휴지 기간이 끝나면 필요한 경우 조정 정책이 다른 크기 조정 활동을 시작합니다. 휴지 기간이 적용되는 동안 현재 지표 값에 따라 더 큰 확장이 필요한 경우 조정 정책이 즉시 확장됩니다.

예약된 작업

예약된 작업은 특정 날짜 및 시간에 자동으로 리소스의 크기를 조정합니다. 확장 가능 대상에 대한 최소 및 최대 용량을 수정하여 작동하므로 최소 용량을 높게 또는 최대 용량을 낮게 설정하여 일정 에 따라 축소 및 확장하는 데 사용할 수 있습니다. 예를 들어 예약된 작업을 사용하여 금요일에 용량을 줄이고 다음 월요일에 용량을 늘려 주말에 리소스를 사용하지 않는 애플리케이션을 조정할 수 있습니다.

또한 예약된 작업을 사용하여 시간에 따른 최솟값과 최댓값을 최적화하여 일반적인 트래픽보다 높은 상황(예: 마케팅 캠페인 또는 계절적 변동)에 적응할 수 있습니다. 이렇게 하면 용량을 늘리기 위해 더 많이 확장해야 하는 경우 성능을 개선하고 리소스를 적게 사용하는 경우 비용을 절감할 수 있습니다.

자세히 알아보기

[AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) — 이 섹션에서는 확장할 수 있는 서비스를 소개하고 확장 가능 대상을 등록하여 Auto scaling을 설정하도록 돕습니다. 또한 Application Auto Scaling이 대상 서비스의 리소스에 액세스하기 위해 생성하는 각 IAM 서비스 연결 역할에 대해서도 설명합니다.













[Application Auto Scaling의 대상 추적 조정 정책](#) — Application Auto Scaling의 주요 기능 중 하나는 대상 추적 조정 정책입니다. 대상 추적 정책이 원하는 용량을 자동으로 조정하여 구성된 지표 및 대상 값에 따라 일정 수준으로 활용도를 유지하는 방법에 대해 알아보십시오. 예를 들어 스팟 플릿의 평균 CPU 사용률을 50%로 유지하도록 대상 추적을 구성할 수 있습니다. 그러면 Application Auto Scaling이 모든 서버에서 집계된 CPU 사용률을 50%로 유지하는 데 필요한 대로 EC2 인스턴스를 시작하거나 종료합니다.

AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는

















Application Auto Scaling은 다른 AWS 서비스와 통합되어 애플리케이션의 수요에 맞게 조정 기능을 추가할 수 있습니다. Auto Scaling은 서비스의 선택적 기능으로서 거의 모든 경우에 기본적으로 비활성화됩니다.

다음 표에는 Auto Scaling을 구성하는 데 지원되는 방법에 대한 정보를 포함하여 Application Auto Scaling과 함께 사용할 수 있는 AWS 서비스가 나열되어 있습니다. 사용자 지정 리소스와 함께 Application Auto Scaling을 사용할 수도 있습니다.

- 콘솔 액세스 - 대상 서비스의 콘솔에서 조정 정책을 구성하여 자동 크기 조정을 시작하기 위한 호환 AWS 서비스를 구성할 수 있습니다.
- CLI 액세스 - AWS CLI를 사용하여 자동 크기 조정을 시작하기 위한 호환 AWS 서비스를 구성할 수 있습니다.
- SDK 액세스 - SDK를 사용하여 Auto Scaling을 시작하도록 호환되는 AWS 서비스를 구성할 수 있습니다. AWS SDKs
- CloudFormation 액세스 - CloudFormation 스택 템플릿을 사용하여 Auto Scaling을 시작하도록 호환되는 AWS 서비스를 구성할 수 있습니다. 자세한 내용은 [클라우드Formation을 사용하여 Application Auto Scaling 리소스 구성 AWS CloudFormation](#) 단원을 참조하십시오.

AWS 서비스	콘솔 액세스 ¹	CLI 액세스	SDK 액세스	CloudFormation 액세스
WorkSpaces 애플리케이션	 예	 예	 예	 예
Aurora	 예	 예	 예	 예
Amazon Comprehend	 아 니요	 예	 예	 예

AWS 서비스	콘솔 액세스 ¹	CLI 액세스	SDK 액세스	CloudFormation 액세스
Amazon DynamoDB	 예	 예	 예	 예
Amazon ECS	 예	 예	 예	 예
Amazon ElastiCache	 예	 예	 예	 예
Amazon EMR	 예	 예	 예	 예
Amazon Keyspaces	 예	 예	 예	 예
Lambda	 아 니요	 예	 예	 예
Amazon MSK	 예	 예	 예	 예
Amazon Neptune	 아 니요	 예	 예	 예

AWS 서비스	콘솔 액세스 ¹	CLI 액세스	SDK 액세스	CloudFormation 액세스
SageMaker AI	 예	 예	 예	 예
스팟 플릿	 예	 예	 예	 예
WorkSpaces	 예	 예	 예	 예
사용자 정의 리소스	 아 니요	 예	 예	 예

¹ 조정 정책을 구성하기 위한 콘솔 액세스입니다. 대부분의 서비스는 콘솔에서 예약된 조정 구성을 지원하지 않습니다. 현재 Amazon WorkSpaces 애플리케이션, ElastiCache 및 스팟 플릿만 예약된 조정을 위한 콘솔 액세스를 제공합니다.

Amazon WorkSpaces 애플리케이션 및 애플리케이션 Auto Scaling

대상 추적 조정 정책, 단계 조정 정책 및 예약된 조정을 사용하여 WorkSpaces 애플리케이션 플릿을 조정할 수 있습니다.

다음 정보를 사용하여 WorkSpaces 애플리케이션을 Application Auto Scaling과 통합할 수 있습니다.

WorkSpaces 애플리케이션을 위해 생성된 서비스 연결 역할

Application Auto Scaling에서 WorkSpaces 애플리케이션 리소스를 확장 가능한 대상으로 등록할 AWS 계정 때 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_AppStreamFleet`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 맡을 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

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

Application Auto Scaling을 사용하여 WorkSpaces 애플리케이션 플릿을 확장 가능 대상으로 등록

Application Auto Scaling은 WorkSpaces 애플리케이션 플릿에 대한 조정 정책 또는 예약된 작업을 생성하기 전에 확장 가능한 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

WorkSpaces 애플리케이션 콘솔을 사용하여 Auto Scaling을 구성하면 WorkSpaces 애플리케이션이 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

WorkSpaces 애플리케이션 플릿에 대한 [register-scalable-target](#) 명령을 호출합니다. WorkSpaces 다음 예제에서는 `sample-fleet`이라는 플릿의 원하는 용량을 등록합니다. 최소 용량은 플릿 인스턴스 한 개, 최대 용량은 플릿 인스턴스 5개입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 [Amazon WorkSpaces 애플리케이션 관리 안내서의 Amazon WorkSpaces 애플리케이션에 대한 플릿 Auto Scaling](#)을 참조하세요. Amazon WorkSpaces

Amazon Aurora 및 Application Auto Scaling

대상 추적 조정 정책, 단계 조정 정책 및 예약된 조정을 사용하여 Aurora DB 클러스터를 조정할 수 있습니다.

Aurora를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

Aurora에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 Aurora 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- AWSServiceRoleForApplicationAutoScaling_RDSCluster

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 말할 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- rds.application-autoscaling.amazonaws.com

Application Auto Scaling을 통해 Aurora DB 클러스터를 확장 가능 대상으로 등록

Aurora 클러스터에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

Aurora 콘솔을 사용하여 자동 크기 조정을 구성하면 Aurora가 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

Aurora 클러스터에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 `my-db-cluster`라는 클러스터에서 Aurora 복제본의 수를 등록합니다. 최소 용량은 Aurora 복제본 한 개, 최대 용량은 Aurora 복제본 8개입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity` 및 `MaxCapacity`을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 [Aurora용 Amazon RDS 사용 설명서의 Aurora 복제본을 사용한 Amazon Aurora Auto Scaling](#)을 참조하세요.

Amazon Comprehend 및 Application Auto Scaling

대상 추적 조정 정책 및 예약된 조정을 사용하여 Amazon Comprehend 문서 분류 및 엔터티 인식기 엔드포인트를 확장할 수 있습니다.

Amazon Comprehend를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

Amazon Comprehend에 대해 생성된 서비스 연결 역할

Application Auto Scaling을 사용하여 Amazon Comprehend 리소스를 확장 가능한 대상으로 등록할 AWS 계정 때에서 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_ComprehendEndpoint`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 말할 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- `comprehend.application-autoscaling.amazonaws.com`

Application Auto Scaling을 통해 Amazon Comprehend 리소스를 확장 가능한 대상으로 등록

Amazon Comprehend 문서 분류 또는 엔터티 인식기 엔드포인트에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

AWS CLI 또는 AWS SDKs

- AWS CLI:

문서 분류 엔드포인트에 대해 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 엔드포인트의 ARN을 사용하여 문서 분류자 엔드포인트에 대해 모델에서 사용할 추론 단위 수를 등록합니다. 최소 추론 용량은 1, 최대 추론 용량은 3입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

개체 인식기 엔드포인트에 대해 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 엔드포인트의 ARN을 사용하여 엔터티 인식기에 대해 모델에서 사용할 추론 단위 수를 등록합니다. 최소 추론 용량은 1, 최대 추론 용량은 3입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 Amazon Comprehend 개발자 안내서의 [엔드포인트를 사용한 Auto Scaling](#)을 참조하세요.

Amazon DynamoDB 및 Application Auto Scaling

대상 추적 조정 정책 및 예약된 조정을 사용하여 DynamoDB 테이블 및 글로벌 보조 인덱스를 조정할 수 있습니다.

DynamoDB를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

DynamoDB에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 DynamoDB 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에서 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_DynamoDBTable`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 말할 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- `dynamodb.application-autoscaling.amazonaws.com`

Application Auto Scaling을 통해 DynamoDB 리소스를 확장 가능 대상으로 등록

DynamoDB 테이블 또는 글로벌 보조 인덱스에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

DynamoDB 콘솔을 사용하여 자동 크기 조정을 구성하면 DynamoDB가 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

테이블의 쓰기 용량에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 최소 쓰기 용량 단위가 5이고 최대 쓰기 용량 단위 `my-table`가 10인 라는 테이블의 프로비저닝된 쓰기 용량을 등록합니다.

```
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
```

성공하면이 명령은 확장 가능 대상의 ARN을 반환합니다.

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

테이블의 읽기 용량에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 라는 테이블의 프로비저닝된 읽기 용량을 등록합니다. `my-table` 최소 읽기 용량은 5이고 최대 읽기 용량은 10입니다.

```
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
```

성공하면이 명령은 확장 가능 대상의 ARN을 반환합니다.

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

글로벌 보조 인덱스의 쓰기 용량에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서 는 라는 글로벌 보조 인덱스의 프로비저닝된 쓰기 용량을 등록합니다. my-table-index 최소 쓰기 용량은 5이고 최대 쓰기 용량은 10입니다.

```
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
```

성공하면이 명령은 확장 가능 대상의 ARN을 반환합니다.

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

글로벌 보조 인덱스의 읽기 용량에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서 는 라는 글로벌 보조 인덱스의 프로비저닝된 읽기 용량을 등록합니다. my-table-index 최소 읽기 용량은 5이고 최대 읽기 용량은 10입니다.

```
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
```

성공하면이 명령은 확장 가능 대상의 ARN을 반환합니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

Application Auto Scaling을 시작하는 경우 다음 설명서에서 DynamoDB 리소스 조정에 대한 유용한 추가 정보를 찾을 수 있습니다.

- Amazon DynamoDB 개발자 안내서의 [DynamoDB 자동 크기 조정으로 처리 용량 관리](#)
- Amazon DynamoDB 개발자 안내서의 [테이블의 오토 스케일링 설정 평가](#)
- [를 사용하여 블로그의 DynamoDB 테이블 및 인덱스에 대한 Auto Scaling을 CloudFormation 구성하는 방법](#) AWS

Amazon ECS 및 Application Auto Scaling

대상 추적 조정 정책, 예측 조정 정책, 단계 조정 정책 및 예약된 조정을 사용하여 ECS 서비스를 조정할 수 있습니다.

Amazon ECS를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

Amazon ECS에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 Amazon ECS 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에서 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- AWSServiceRoleForApplicationAutoScaling_ECSService

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 맡을 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

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

Application Auto Scaling을 통해 ECS 서비스를 확장 가능 대상으로 등록

Amazon ECS 서비스에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

Amazon ECS 콘솔을 사용하여 자동 크기 조정을 구성하면 Amazon ECS가 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

Amazon ECS 서비스에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 default 클러스터에서 실행되는 sample-app-service라는 서비스에 대한 확장 가능 대상을 등록합니다. 최소 태스크 수는 1, 최대 태스크 수는 10입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

```
}

```

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

Application Auto Scaling을 시작하는 경우 다음 설명서에서 Amazon ECS 리소스 조정에 대한 유용한 추가 정보를 찾을 수 있습니다.

- Amazon Elastic Container Service 개발자 안내서의 [서비스 오토 스케일링](#)
- [Amazon Elastic Container Service 개발자 안내서의 Amazon ECS 서비스 오토 스케일링 최적화](#)

Note

Amazon ECS 배포가 진행되는 동안 스케일 아웃 프로세스를 일시 중지하는 지침은 다음 설명서를 참조하세요.

Amazon Elastic Container Service 개발자 안내서의 [서비스 오토 스케일링 및 배포](#)

ElastiCache 및 Application Auto Scaling

대상 추적 조정 정책 및 예약된 조정을 사용하여 Amazon ElastiCache 복제 그룹(Redis OSS 및 Valkey) 및 Memcached 자체 설계된 클러스터를 수평적으로 조정할 수 있습니다.

ElastiCache를 Application Auto Scaling과 통합하려면 다음 정보를 사용합니다.

ElastiCache 에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 ElastiCache 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- AWSServiceRoleForApplicationAutoScaling_ElastiCacheRG

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 맡을 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- `elasticache.application-autoscaling.amazonaws.com`

Application Auto Scaling을 사용하여 ElastiCache 리소스를 확장 가능 대상으로 등록

ElastiCache 복제 그룹, 클러스터 또는 노드에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능한 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

ElastiCache 콘솔을 사용하여 자동 크기 조정을 구성하면 ElastiCache가 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

ElastiCache 복제 그룹에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 `mycluster1`라는 복제 그룹에 대해 원하는 수의 노드 그룹을 등록합니다. 최소 용량은 1이고 최대 용량은 5입니다.

```
aws application-autoscaling register-scalable-target \
  --service-namespace elasticache \
  --scalable-dimension elasticache:replication-group:NodeGroups \
  --resource-id replication-group/mycluster1 \
  --min-capacity 1 \
  --max-capacity 5
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

```
{
```

```

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

```

다음 예제에서는 mycluster2 최소 용량이 1이고 최대 용량이 5인 라는 복제 그룹에 대해 노드 그룹 당 원하는 수의 복제본을 등록합니다.

```

aws application-autoscaling register-scalable-target \
  --service-namespace elasticache \
  --scalable-dimension elasticache:replication-group:Replicas \
  --resource-id replication-group/mycluster2 \
  --min-capacity 1 \
  --max-capacity 5

```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

```

{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/234abcd56ab78cd901ef1234567890ab1234"
}

```

다음 예제에서는 최소 용량이 20이고 최대 용량이 50 mynode1 인 클러스터에 대해 원하는 수의 노드를 등록합니다.

```

aws application-autoscaling register-scalable-target \
  --service-namespace elasticache \
  --scalable-dimension elasticache:cache-cluster:Nodes \
  --resource-id cache-cluster/mynode1 \
  --min-capacity 20 \
  --max-capacity 50

```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

```

{
  "ScalableTargetARN": "arn:aws:application-autoscaling:region:account-id:scalable-
target/01234abcd56ab78cd901ef1234567890ab12"
}

```

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 Amazon ElastiCache 사용 설명서의 [Auto Scaling Valkey 및 Redis OSS 클러스터와 Memcached용 조정 클러스터](#)를 참조하세요.

Amazon Keyspaces(Apache Cassandra용) 및 Application Auto Scaling

대상 추적 조정 정책 및 예약된 조정을 사용하여 Amazon Keyspaces 테이블을 조정할 수 있습니다.

Amazon Keyspaces를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

Amazon Keyspaces에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 Amazon Keyspaces 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에 서 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_CassandraTable`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 말할 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- `cassandra.application-autoscaling.amazonaws.com`

Application Auto Scaling을 통해 Amazon Keyspaces 테이블을 확장 가능 대상으로 등록

Amazon Keyspaces 테이블에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

Amazon Keyspaces 콘솔을 사용하여 자동 크기 조정을 구성하면 Amazon Keyspaces가 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

Amazon Keyspaces 테이블을 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 mytable이라는 테이블의 프로비저닝된 쓰기 용량을 등록합니다. 최소 쓰기 용량은 5, 최대 쓰기 용량은 10입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

다음 예제에서는 mytable이라는 테이블의 프로비저닝된 읽기 용량을 등록합니다. 최소 읽기 용량은 5, 최대 읽기 용량은 10입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 [Amazon Keyspaces 개발자 안내서의 Amazon Keyspaces Auto Scaling을 사용하여 처리량 용량 자동 관리를 참조하세요.](#)

AWS Lambda 및 Application Auto Scaling

대상 추적 조정 정책 및 예약된 조정을 사용하여 AWS Lambda 프로비저닝된 동시성을 조정할 수 있습니다.

Lambda를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

Lambda에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 Lambda 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에서 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- AWSServiceRoleForApplicationAutoScaling_LambdaConcurrency

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 맡을 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- `lambda.application-autoscaling.amazonaws.com`

Application Auto Scaling을 통해 Lambda 서비스를 확장 가능 대상으로 등록

Lambda 함수에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

AWS CLI 또는 AWS SDKs

- AWS CLI:

Lambda 함수에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 `my-function`이라는 함수, `BLUE`라는 함수 별칭에 대해 프로비저닝된 동시성을 등록합니다. 최소 용량은 0, 최대 용량은 100입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

Application Auto Scaling을 시작하는 경우 다음 설명서에서 Lambda 함수 조정에 대한 유용한 추가 정보를 찾을 수 있습니다.

- AWS Lambda 개발자 가이드의 [프로비저닝된 동시성 구성](#)
- AWS 블로그에서 [반복 피크 사용량에 대한 Lambda 프로비저닝된 동시성 예약](#)

Amazon Managed Streaming for Apache Kafka(MSK) 및 Application Auto Scaling

대상 추적 조정 정책을 사용하여 Amazon MSK 클러스터 스토리지를 확장할 수 있습니다. 대상 추적 정책에 의한 축소가 비활성화되어 있습니다.

Amazon MSK를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

Amazon MSK에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 Amazon MSK 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_KafkaCluster`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 말할 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- `kafka.application-autoscaling.amazonaws.com`

Application Auto Scaling을 통해 Amazon MSK 클러스터 스토리지를 확장 가능 대상으로 등록

Application Auto Scaling에서는 Amazon MSK 클러스터의 브로커당 스토리지 볼륨 크기에 대한 조정 정책을 생성하기 전에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 크기를 조정할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

Amazon MSK 콘솔을 사용하여 자동 크기 조정을 구성하면 Amazon MSK가 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

Amazon MSK 클러스터에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 Amazon MSK 클러스터의 브로커당 스토리지 볼륨 크기를 등록합니다. 최소 용량은 100GiB, 최대 용량은 800GiB입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

Note

Amazon MSK 클러스터가 확장 가능한 대상인 경우 축소가 비활성화되어 활성화할 수 없습니다.

관련 리소스

자세한 내용은 [Amazon Managed Streaming for Apache Kafka 개발자 안내서의 Amazon MSK 클러스터에 대한 자동 조정을 참조하세요.](#)

Amazon Neptune 및 Application Auto Scaling

대상 추적 조정 정책 및 예약된 크기 조정을 사용하여 Neptune 클러스터의 크기를 조정할 수 있습니다.

Neptune을 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

Neptune에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 Neptune 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_NeptuneCluster`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 말할 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

- `neptune.application-autoscaling.amazonaws.com`

Application Auto Scaling을 통해 Neptune 클러스터를 확장 가능 대상으로 등록

Neptune 클러스터에 대한 크기 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

AWS CLI 또는 AWS SDKs

- AWS CLI:

Neptune 클러스터에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 `mycluster`라는 플릿의 원하는 용량을 등록합니다. 최소 용량은 한 개, 최대 용량은 여덟 개입니다.

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

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity` 및 `MaxCapacity`을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 [Neptune 사용 설명서의 Amazon Neptune DB 클러스터의 복제본 수 자동 조정](#)을 참조하세요.

Amazon SageMaker AI 및 Application Auto Scaling

대상 추적 조정 정책, 단계 조정 정책 및 예약된 조정을 사용하여 SageMaker AI 엔드포인트 변형, 서버리스 엔드포인트에 대해 프로비저닝된 동시성 및 추론 구성 요소를 조정할 수 있습니다.

다음 정보를 사용하여 SageMaker AI를 Application Auto Scaling과 통합할 수 있습니다.

SageMaker AI용으로 생성된 서비스 연결 역할

Application Auto Scaling에 SageMaker AI 리소스를 확장 가능 대상으로 등록할 AWS 계정 때 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_SageMakerEndpoint`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 맡을 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

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

Application Auto Scaling을 사용하여 SageMaker AI 엔드포인트 변형을 확장 가능 대상으로 등록

Application Auto Scaling은 SageMaker AI 모델(변종)에 대한 조정 정책 또는 예약된 작업을 생성하기 전에 확장 가능한 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

SageMaker AI 콘솔을 사용하여 Auto Scaling을 구성하면 SageMaker AI가 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

제품 변형에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 my-endpoint 엔드포인트에서 실행되는 my-variant라는 제품 변형에 대해 원하는 인스턴스 수를 등록합니다. 최소 용량은 1개, 최대 용량은 8개입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

Application Auto Scaling을 통해 서버리스 엔드포인트의 동시성을 확장 가능 대상으로 등록하기

서버리스 엔드포인트의 프로비저닝된 동시성에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상도 필요합니다.

SageMaker AI 콘솔을 사용하여 Auto Scaling을 구성하면 SageMaker AI가 자동으로 확장 가능 대상을 등록합니다.

아니면 다음 방법 중 하나를 사용하여 확장 가능 대상을 등록하세요.

- AWS CLI:

제품 변형에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 my-endpoint 엔드포인트에서 실행되는 my-variant(이)라는 제품 변형에 대해 프로비저닝된 동시성을 등록합니다. 최소 용량은 1개이고 최대 용량은 10개입니다.

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

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

Application Auto Scaling을 통해 추론 구성 요소를 확장 가능 대상으로 등록

추론 구성 요소에 대한 크기 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상도 필요합니다.

- AWS CLI:

추론 구성 요소에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 my-inference-component라는 추론 구성 요소에 대해 원하는 복제본 수를 등록합니다. 최소 용량은 0개이고 최대 용량은 3개입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

Application Auto Scaling을 시작하는 경우 Amazon SageMaker AI 개발자 안내서에서 Amazon SageMaker AI 리소스 조정에 대한 유용한 추가 정보를 찾을 수 있습니다.

- [Amazon SageMaker AI 모델 자동 조정](#)
- [서버리스 엔드포인트에 맞게 프로비저닝된 동시성의 오토 스케일링](#)
- [다중 모델 엔드포인트 배포를 위한 오토 스케일링 정책 설정](#)
- [비동기 엔드포인트 오토 스케일링](#)

Note

2023년에 SageMaker AI는 실시간 추론 엔드포인트를 기반으로 구축된 새로운 추론 기능을 도입했습니다. 엔드포인트의 인스턴스 유형과 초기 인스턴스 수를 정의하는 엔드포인트 구성으로 SageMaker AI 엔드포인트를 생성합니다. 그런 다음 엔드포인트에 모델을 배포하는 데 사용할 수 있는 SageMaker AI 호스팅 객체인 추론 구성 요소를 생성합니다. 추론 구성 요소 조정에 대한 자세한 내용은 Amazon [Amazon SageMaker AI가 블로그에서 Amazon SageMaker AI의 최신 기능을 사용하여 파운데이션 모델 배포 비용과 지연 시간을 줄이고 모델 배포 비용을 평균 50% 줄이는 데 도움이 되는 새로운 추론 기능을 추가하는 것을 참조하세요.](#) [Amazon SageMaker](#) AWS

Amazon EC2 스팟 플릿 및 Application Auto Scaling

대상 추적 조정 정책, 단계 조정 정책 및 예약된 조정을 사용하여 스팟 플릿을 조정할 수 있습니다.

스팟 플릿을 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

스팟 플릿에 대해 생성된 서비스 연결 역할

Application Auto Scaling에서 스팟 플릿 리소스를 확장 가능 대상으로 등록할 AWS 계정 때 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_EC2SpotFleetRequest`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 맡을 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

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

Application Auto Scaling을 통해 스팟 플릿을 확장 가능 대상으로 등록

스팟 플릿에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

스팟 플릿 콘솔을 사용하여 자동 크기 조정을 구성하면 스팟 플릿이 자동으로 확장 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

스팟 플릿에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 요청 ID를 사용해 스팟 플릿의 대상 용량을 등록합니다. 최소 용량은 인스턴스 2개, 최대 용량은 인스턴스 10개입니다.

```
aws application-autoscaling register-scalable-target \
  --service-namespace ec2 \
  --scalable-dimension ec2:spot-fleet-request:TargetCapacity \
  --resource-id spot-fleet-request/sfr-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE \
```

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

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 Amazon EC2 사용 설명서의 [스팟 플릿의 자동 조정 이해를 참조하세요](#).

Amazon WorkSpaces 및 Application Auto Scaling

대상 추적 조정 정책, 단계 조정 정책 및 예약된 조정을 사용하여 WorkSpaces 풀의 규모를 조정할 수 있습니다.

WorkSpaces를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

WorkSpaces용으로 생성된 서비스 연결 역할

Application Auto Scaling은 Application Auto Scaling에 WorkSpaces 리소스를 확장 가능 대상으로 등록할 AWS 계정 때 AWSServiceRoleForApplicationAutoScaling_WorkSpacesPool에 라는 서비스 연결 역할을 자동으로 생성합니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할 단원을 참조하십시오](#).

이 서비스 연결 역할은 AWSApplicationAutoscalingWorkSpacesPoolPolicy라는 관리형 정책을 사용합니다. 이 정책은 Application Auto Scaling에 사용자를 대신하여 Amazon WorkSpaces를 직접적으로 호출할 수 있는 권한을 부여합니다. 자세한 내용은 AWS 관리형 정책 참조의 [AWSApplicationAutoscalingWorkSpacesPoolPolicy](#)를 참조하세요.

서비스 연결 역할이 사용하는 서비스 보안 주체

서비스 연결 역할은 그 역할을 위임하기 위해 다음 서비스 위탁자를 신뢰합니다.

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

Application Auto Scaling을 통해 WorkSpaces 풀을 규모 조정 가능 대상으로 등록

WorkSpaces에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 규모 조정 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

WorkSpaces 콘솔을 사용하여 오토 스케일링을 구성하면 WorkSpaces가 자동으로 규모 조정 가능 대상을 등록합니다.

AWS CLI 또는 AWS SDKs 중 하나를 사용하여 Auto Scaling을 구성하려면 다음 옵션을 사용할 수 있습니다.

- AWS CLI:

WorkSpaces 풀에 대한 [register-scalable-target](#) 명령을 직접적으로 호출합니다. 다음 예제에서는 요청 ID를 사용하여 WorkSpaces 풀의 목표 용량을 등록합니다. 최소 용량은 가상 데스크톱 2개이고 최대 용량은 가상 데스크톱 10개입니다.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 ResourceId, ScalableDimension, ServiceNamespace, MinCapacity 및 MaxCapacity을(를) 파라미터로 제공합니다.

관련 리소스

자세한 내용은 Amazon [WorkSpaces 관리 안내서의 WorkSpaces Pools에 대한 Auto Scaling](#)을 참조하세요. Amazon WorkSpaces

사용자 지정 리소스 및 Application Auto Scaling

대상 추적 조정 정책, 단계 조정 정책 및 예약된 조정을 사용하여 사용자 지정 리소스를 조정할 수 있습니다.

사용자 지정 리소스를 Application Auto Scaling과 통합하는 데 도움이 되는 정보는 다음과 같습니다.

사용자 지정 리소스에 대해 생성된 서비스 연결 역할

Application Auto Scaling에 사용자 지정 리소스를 확장 가능 대상으로 등록할 AWS 계정 때에 다음 서비스 연결 역할이 자동으로 생성됩니다. 이 역할을 통해 Application Auto Scaling이 사용자 계정 내에서 지원되는 작업을 수행할 수 있습니다. 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

- `AWSServiceRoleForApplicationAutoScaling_CustomResource`

서비스 연결 역할이 사용하는 서비스 보안 주체

앞부분에서 다른 서비스 연결 역할은 역할에 대해 정의된 신뢰 관계로 권한이 부여되는 서비스 보안 주체만 말할 수 있습니다. Application Auto Scaling이 사용하는 서비스 연결 역할은 다음 서비스 보안 주체에 대한 액세스 권한을 부여합니다.

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

Application Auto Scaling을 통해 사용자 지정 리소스를 확장 가능 대상으로 등록

사용자 지정 리소스에 대한 조정 정책 또는 예약된 작업을 생성하려면 먼저 Application Auto Scaling에 확장 가능 대상이 필요합니다. 확장 가능 대상은 Application Auto Scaling에서 확장하거나 축소할 수 있는 리소스입니다. 확장 가능 대상은 리소스 ID, 확장 가능한 차원 및 네임스페이스의 조합으로 고유하게 식별됩니다.

AWS CLI 또는 AWS SDKs

- AWS CLI:

사용자 지정 리소스에 대한 [register-scalable-target](#) 명령을 호출합니다. 다음 예제에서는 사용자 지정 리소스를 확장 가능한 대상으로 등록합니다. 원하는 최소 용량 수는 1, 원하는 최대 용량 수는 10 개입니다. `custom-resource-id.txt` 파일에는 Amazon API Gateway 엔드포인트를 통해 사용자 지정 리소스의 경로를 나타내는 리소스 ID를 식별하는 문자열이 포함되어 있습니다.

```
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
```

`custom-resource-id.txt`의 콘텐츠:

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

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

- AWS SDK:

[RegisterScalableTarget](#) 작업을 호출하고 `ResourceId`, `ScalableDimension`, `ServiceNamespace`, `MinCapacity` 및 `MaxCapacity`을(를) 파라미터로 제공합니다.

관련 리소스

Application Auto Scaling을 시작하는 경우 다음 설명서에서 사용자 지정 리소스 조정에 대한 유용한 추가 정보를 찾을 수 있습니다.

[GitHub 리포지토리](#)

를 사용하여 Application Auto Scaling 리소스 구성 AWS CloudFormation

Application Auto Scaling은 AWS 리소스 및 인프라를 생성하고 관리하는 데 소요되는 시간을 줄일 수 있도록 리소스를 모델링하고 설정하는 데 도움이 되는 AWS CloudFormation 서비스와 통합됩니다. 원하는 모든 AWS 리소스를 설명하는 템플릿을 생성하면 해당 리소스를 CloudFormation 프로비저닝하고 구성합니다.

를 사용하면 템플릿을 재사용하여 Application Auto Scaling 리소스를 일관되고 반복적으로 설정할 CloudFormation 수 있습니다. 리소스를 한 번 설명한 다음 여러 AWS 계정 및 리전에서 동일한 리소스를 반복적으로 프로비저닝합니다.

Application Auto Scaling 및 CloudFormation 템플릿

Application Auto Scaling 및 관련 서비스에 대한 리소스를 프로비저닝하고 구성하려면 [CloudFormation 템플릿](#)을 이해해야 합니다. 템플릿은 JSON 또는 YAML로 서식 지정된 텍스트 파일입니다. 이러한 템플릿은 CloudFormation 스택에서 프로비저닝하려는 리소스를 설명합니다. JSON 또는 YAML에 익숙하지 않은 경우 CloudFormation Designer를 사용하여 CloudFormation 템플릿을 시작할 수 있습니다. 자세한 내용은 AWS CloudFormation 사용자 안내서에서 [CloudFormation Designer란?](#)을 참조하세요.

Application Auto Scaling 리소스에 대한 스택 템플릿을 생성할 때 다음을 제공해야 합니다.

- 대상 서비스에 대한 네임스페이스(예: **appstream**). 서비스 네임스페이스를 얻으려면 [AWS::ApplicationAutoScaling::ScalableTarget](#) 참조를 참조하세요
- 대상 리소스에 연결된 확장 가능 차원(예: **appstream:fleet:DesiredCapacity**). 확장 가능 차원을 얻으려면 [AWS::ApplicationAutoScaling::ScalableTarget](#) 참조를 참조하세요
- 대상 리소스의 리소스 ID(예: **fleet/sample-fleet**). 특정 리소스 ID의 구문 및 예제에 대한 정보는 [AWS::ApplicationAutoScaling::ScalableTarget](#) 참조를 참조하세요.
- 대상 리소스에 대한 서비스 연결 역할(예: **arn:aws:iam::012345678910:role/aws-service-role/appstream.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_AppStreamFleet**). 역할 ARN을 얻으려면 [서비스 연결 역할 ARN 참조](#) 표를 참조하세요.

Application Auto Scaling 리소스에 대한 자세한 내용은 AWS CloudFormation 사용 설명서의 [Application Auto Scaling](#) 레퍼런스를 참조하세요.

예제 템플릿 코드 조각

AWS CloudFormation 사용 설명서의 다음 섹션에서 CloudFormation 템플릿에 포함할 예제 코드 조각을 찾을 수 있습니다.

- 조정 정책 및 예약된 작업의 예는 [를 사용하여 Application Auto Scaling 리소스 구성을 AWS CloudFormation](#) 참조하세요.
- 조정 정책의 더 많은 예시는 [AWS::ApplicationAutoScaling::ScalingPolicy](#)를 참조하세요.

에 대해 자세히 알아보기 CloudFormation

에 대해 자세히 알아보려면 다음 리소스를 CloudFormation참조하세요.

- [AWS CloudFormation](#)
- [AWS CloudFormation 사용 설명서](#)
- [CloudFormation API Reference](#)
- [AWS CloudFormation 명령줄 인터페이스 사용자 안내서](#)

Application Auto Scaling의 예약된 조정

예약된 조정을 사용하면 특정 시간에 용량을 늘리거나 줄이는 예약된 작업을 생성하여 예측 가능한 부하 변화에 따라 애플리케이션에 대한 Auto Scaling을 설정할 수 있습니다. 이를 통해 예측 가능한 부하 변화에 맞춰 애플리케이션 규모를 사전에 조정할 수 있습니다.

예를 들어, 주중에는 부하가 증가하고 주말에는 부하가 감소하는 주간 트래픽 패턴이 정기적으로 발생한다고 가정해 보겠습니다. Application Auto Scaling에서 이 패턴에 맞게 규모 조정 일정을 구성할 수 있습니다.

- 수요일 아침에는 예약된 작업이 이전에 설정된 확장 가능한 대상의 최소 용량을 늘려 용량을 늘립니다.
- 금요일 저녁에는 예약된 또 다른 작업이 이전에 설정된 확장 가능한 대상의 최대 용량을 줄여 용량을 줄입니다.

이러한 예약된 규모 조정 작업을 통해 비용과 성능을 최적화할 수 있습니다. 애플리케이션은 주중 트래픽 피크를 처리할 수 있을 만큼 충분한 용량을 갖추게 되지만, 다른 시간에 불필요한 용량을 과도하게 프로비저닝하지는 않습니다.

예약된 조정 및 조정 정책을 함께 사용하면 규모 조정에 대한 예방적 및 대응적 접근 방식의 이점을 모두 얻을 수 있습니다. 예약된 작업이 실행된 후 조정 정책은 계속해서 용량을 추가로 조정할지를 결정할 수 있습니다. 이를 통해 애플리케이션의 로드를 처리할 수 있는 충분한 용량을 보유하도록 보장합니다. 애플리케이션이 수요에 맞게 조정되는 동안 현재 용량은 예약된 작업에서 설정한 최소 및 최대 용량 이내여야 합니다.

내용

- [Application Auto Scaling의 예약된 조정 작동 방식](#)
- [를 사용하여 Application Auto Scaling에 예약된 작업 생성 AWS CLI](#)
- [를 사용하여 Application Auto Scaling의 예약된 조정 설명 AWS CLI](#)
- [Application Auto Scaling을 사용하여 반복 조정 작업 예약](#)
- [확장 가능한 대상에 대해 예약된 크기 조정 해제](#)
- [를 사용하여 Application Auto Scaling에 예약된 작업 삭제 AWS CLI](#)

Application Auto Scaling의 예약된 조정 작동 방식

이 주제에서는 예약된 조정의 작동 방식을 설명하고 예약된 조정을 효과적으로 사용하기 위해 이해해야 하는 주요 고려 사항을 소개합니다.

내용

- [작동 방식](#)
- [고려 사항](#)
- [예약된 작업 생성, 관리 및 삭제에 일반적으로 사용되는 명령](#)
- [관련 리소스](#)
- [제한 사항](#)

작동 방식

예약된 조정을 사용하려면 Application Auto Scaling이 특정 시간에 조정 작업을 수행하도록 하는 예약된 작업을 생성할 수 있습니다. 예약 작업을 생성할 때 확장 가능한 대, 조정 활동이 발생할 시간, 최소 용량 및 최대 용량을 지정합니다. 한 번만 조정하거나 반복 일정에 따라 조정되는 예약된 작업을 생성할 수 있습니다.

지정된 시간에 Application Auto Scaling은 현재 용량을 지정된 최소 및 최대 용량과 비교하여 새 용량 값을 기반으로 조정합니다.

- 현재 용량이 지정된 최소 용량보다 적을 경우 Application Auto Scaling이 지정된 최소 용량으로 확장합니다(용량 증가).
- 현재 용량이 지정된 최대 용량보다 클 경우 Application Auto Scaling이 지정된 최대 용량으로 축소합니다(용량 감소).

고려 사항

예약된 작업을 만들 경우, 다음 사항에 유의해야 합니다.

- 예약된 작업은 MinCapacity 및 MaxCapacity를 지정된 날짜와 시간에 예약된 작업에 의해 지정된 값으로 설정합니다. 요청에는 이러한 크기 중 하나만 선택적으로 포함할 수 있습니다. 예를 들어 최소 용량만 지정된 예약된 작업을 생성할 수 있습니다. 그러나 경우에 따라 새 최소 용량이 최대 용량보다 크지 않거나 새 최대 용량이 최소 용량보다 작지 않을 것을 보장하기 위해 두 크기를 모두 포함해야 합니다.

- 기본적으로 사용자가 설정한 반복 일정의 시간대는 UTC(협정 세계시)입니다. 현지 표준 시간대 또는 네트워크의 다른 부분에 대한 표준 시간대와 일치하도록 시간을 변경할 수 있습니다. 일광 절약 시간을 준수하는 시간대를 지정하는 경우, 작업이 DST(일광 절약 시간제)에 맞게 자동으로 조정됩니다. 자세한 내용은 [Application Auto Scaling을 사용하여 반복 조정 작업 예약](#) 단원을 참조하십시오.
- 확장 가능한 대상에 대해 예약된 조정을 일시적으로 해제할 수 있습니다. 이렇게 하면 예약된 작업을 삭제할 필요 없이 활성 상태가 되는 것을 방지할 수 있습니다. 그런 다음 다시 사용하려는 경우, 예약된 조정을 재개할 수 있습니다. 자세한 내용은 [Application Auto Scaling의 조정 일시 중지 및 재개](#) 단원을 참조하십시오.
- 예약 작업의 실행 순서는 확장 가능한 대상 전체가 아니라 동일한 확장 가능한 대상에 대해 보장됩니다.
- 예약된 작업을 성공적으로 완료하려면 지정된 리소스가 대상 서비스에서 확장 가능한 상태여야 합니다. 그렇지 않을 경우 요청이 실패하고 Resource Id [ActualResourceId] is not scalable. Reason: The status of all DB instances must be 'available' or 'incompatible-parameters'와 같은 오류 메시지를 반환합니다.
- Application Auto Scaling과 대상 서비스가 분산되어 있기 때문에 예약된 작업이 트리거 되는 시간과 대상 서비스가 조정 작업을 인식하는 시간 간에는 몇 초의 지연이 있을 수 있습니다. 예약된 작업은 지정된 순서대로 실행되기 때문에, 예약된 작업의 시작 시간이 서로 가까운 경우 실행하는 데 더 많은 시간이 소요될 수 있습니다.

예약된 작업 생성, 관리 및 삭제에 일반적으로 사용되는 명령

일정 조정 작업에 일반적으로 사용되는 명령은 다음과 같습니다.

- [register-scalable-target](#) - AWS 또는 사용자 지정 리소스를 확장 가능 대상(Application Auto Scaling이 확장할 수 있는 리소스)으로 등록하고 조정을 일시 중지 및 재개합니다.
- [put-scheduled-action](#)을 사용하여 기존 확장 가능 대상에 대해 예약된 작업을 추가하거나 수정할 수 있습니다.
- [describe-scaling-activities](#): AWS 리전의 조정 활동에 대한 정보를 반환합니다.
- [describe-scheduled-actions](#): AWS 리전에서 예약된 작업에 대한 정보를 반환합니다.
- [delete-scheduled-action](#)을 사용하여 예약된 작업을 삭제할 수 있습니다.

관련 리소스

예약된 조정을 사용하는 자세한 예는 AWS 컴퓨팅 블로그의 [반복 피크 사용을 위한 AWS Lambda 프로비저닝된 동시성 예약 블로그 게시물](#)을 참조하세요.

Auto Scaling의 예약된 작업 생성에 대한 자세한 내용은 Amazon EC2 Auto Scaling 사용 설명서의 [Amazon EC2 Auto Scaling 예약된 조정](#)을 참조하세요.

제한 사항

다음은 예약된 조정을 사용할 때의 제한 사항입니다.

- 예약된 작업의 이름은 확장 가능한 대상별로 고유해야 합니다.
- Application Auto Scaling은 일정 표현식에 초 단위의 정밀성을 제공하지 않습니다. cron 표현식을 사용해 가장 정밀하게 설정할 수 있는 단위가 1분입니다.
- Amazon MSK 클러스터는 확장 가능한 대상이 될 수 없습니다. Amazon MSK에서는 예약된 조정이 지원되지 않습니다.
- 확장 가능한 리소스에 대한 예약된 작업을 확인, 추가, 업데이트 또는 제거할 수 있는 콘솔 액세스 권한은 사용하는 리소스에 따라 다릅니다. 자세한 내용은 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 단원을 참조하십시오.

를 사용하여 Application Auto Scaling에 예약된 작업 생성 AWS CLI

다음 예제에서는 AWS CLI [put-scheduled-action](#) 명령을 사용하여 예약된 작업을 생성하는 방법을 보여줍니다. 새로운 용량을 지정할 때 최소 용량, 최대 용량 또는 둘 다 지정할 수 있습니다.

이러한 예제에서는 Application Auto Scaling과 통합되는 일부 서비스에 규모 조정 가능 대상을 사용합니다. 다른 규모 조정 가능 대상을 사용하려면 `--service-namespace`에 네임스페이스, `--scalable-dimension`에 규모 조정 가능 차원, `--resource-id`에 리소스 ID를 지정합니다.

를 사용할 때는 명령이 프로파일에 대해 AWS 리전 구성에서 실행된다는 점을 AWS CLI기억하세요. 다른 리전에서 명령을 실행하려는 경우 프로필의 기본 리전을 변경하거나 명령에 `--region` 파라미터를 사용합니다.

예제

- [한 번만 발생하는 예약된 작업 생성](#)
- [반복되는 간격으로 실행되는 예약된 작업 만들기](#)
- [반복되는 일정으로 실행되는 예약된 작업 생성](#)
- [시간대를 지정하는 일회성 예약된 작업 만들기](#)
- [시간대를 지정하는 반복 예약 작업 생성](#)

한 번만 발생하는 예약된 작업 생성

지정된 날짜 및 시간에 확장 가능한 대상을 한 번만 자동으로 조정하려면 `--schedule "at(yyyy-mm-ddThh:mm:ss)"` 옵션을 사용합니다.

Example에: 일회성 스케일 아웃.

다음은 특정 날짜 및 시간에 용량을 확장하기 위해 예약된 작업을 생성하는 예제입니다.

`--schedule(2021년 3월 31일, 오후 10시(UTC 기준))`에 지정된 날짜 및 시간에, `MinCapacity`에 지정된 값이 현재 용량보다 큰 경우 Application Auto Scaling은 `MinCapacity`로 확장합니다.

Linux, macOS 또는 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
```

이 예약된 작업이 실행될 때 최대 용량이 최소 용량에 지정된 값보다 작은 경우 최소 용량뿐만 아니라 새로운 최소 및 최대 용량을 지정해야 합니다.

Example에: 일회성 축소.

다음은 특정 날짜 및 시간에 용량을 축소하기 위해 예약된 작업을 생성하는 예제입니다.

`--schedule(2021년 3월 31일, 오후 10시 30분(UTC 기준))`에 지정된 날짜 및 시간에, `MaxCapacity`에 지정된 값이 현재 용량보다 큰 경우 Application Auto Scaling은 `MaxCapacity`로 축소합니다.

Linux, macOS 또는 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
```

반복되는 간격으로 실행되는 예약된 작업 만들기

반복되는 간격으로 조정을 예약하려면 `--schedule "rate(value unit)"` 옵션을 사용합니다. 값은 양의 정수여야 합니다. 단위는 minute, minutes, hour, hours, day 또는 days가 될 수 있습니다. 자세한 내용은 Amazon EventBridge 사용 설명서의 [Rate 표현식](#)을 참조하세요.

다음은 rate 표현식을 사용하는 예약된 작업의 예제입니다.

지정된 일정에 따라(2021년 1월 30일 오후 12시에 시작하여 2021년 1월 31일 오후 10시(UTC 기준)에 끝나는 5시간마다) MinCapacity에 지정된 값이 현재 용량보다 큰 경우, Application Auto Scaling이 MinCapacity로 확장합니다. MaxCapacity에 지정된 값이 현재 용량보다 작을 경우 Application Auto Scaling은 MaxCapacity로 축소합니다.

Linux, macOS 또는 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
```

반복되는 일정으로 실행되는 예약된 작업 생성

반복되는 일정으로 조정을 예약하려면 `--schedule "cron(fields)"` 옵션을 사용합니다. 자세한 내용은 [Application Auto Scaling을 사용하여 반복 조정 작업 예약](#) 단원을 참조하십시오.

다음은 cron 표현식을 사용하는 예약된 작업의 예제입니다.

지정된 일정(UTC 기준 매일 오전 9시)에 MinCapacity에 지정된 값이 현재 용량보다 큰 경우 Application Auto Scaling은 MinCapacity로 확장합니다. MaxCapacity에 지정된 값이 현재 용량보다 작을 경우 Application Auto Scaling은 MaxCapacity로 축소합니다.

Linux, macOS 또는 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
```

시간대를 지정하는 일회성 예약된 작업 만들기

예약된 작업은 기본적으로 UTC 표준 시간대로 설정됩니다. 다른 시간대를 지정하려면 `--timezone` 옵션을 선택하고 시간대의 정식 이름(예: `America/New_York`)을 지정합니다. 자세한 내용은 <https://www.joda.org/joda-time/timezones.html>을 참조하세요. [put-scheduled-action](#)을 호출할 때 지원되는 IANA 시간대에 대한 정보를 제공합니다.

다음은 특정 날짜 및 시간에 용량을 조정하기 위해 예약된 작업을 생성할 때 `--timezone` 옵션을 사용하는 예제입니다.

`--schedule`(2021년 1월 31일, 오후 5시(현지 시간))에 지정된 날짜 및 시간에, `MinCapacity`에 지정된 값이 현재 용량보다 큰 경우 Application Auto Scaling은 `MinCapacity`로 확장합니다. `MaxCapacity`에 지정된 값이 현재 용량보다 작을 경우 Application Auto Scaling은 `MaxCapacity`로 축소합니다.

Linux, macOS 또는 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
```

시간대를 지정하는 반복 예약 작업 생성

다음은 용량을 조정하기 위해 반복 예약 작업을 생성할 때 `--timezone` 옵션을 사용하는 예입니다. 자세한 내용은 [Application Auto Scaling을 사용하여 반복 조정 작업 예약](#) 단원을 참조하십시오.

지정된 일정(현지 시간 기준 매주 월요일~금요일 오후 6시)에 MinCapacity에 지정된 값이 현재 용량보다 큰 경우 Application Auto Scaling은 MinCapacity로 확장합니다. MaxCapacity에 지정된 값이 현재 용량보다 작을 경우 Application Auto Scaling은 MaxCapacity로 축소합니다.

Linux, macOS 또는 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
```

를 사용하여 Application Auto Scaling의 예약된 조정 설명 AWS CLI

이 예제 AWS CLI 명령은 Application Auto Scaling과 통합되는 서비스의 리소스를 사용하여 조정 활동 및 예약된 작업을 설명합니다. 다른 규모 조정 가능 대상을 지정하려면 --service-namespace에 네임스페이스, --scalable-dimension에 규모 조정 가능 차원, --resource-id에 리소스 ID를 지정합니다.

를 사용할 때는 명령이 프로파일에 대해 AWS 리전 구성원에서 실행된다는 점을 AWS CLI기억하세요. 다른 리전에서 명령을 실행하려는 경우 프로필의 기본 리전을 변경하거나 명령에 --region 파라미터를 사용합니다.

예제

- [서비스에 대한 조정 활동 설명](#)
- [서비스에 대한 예약된 작업 설명](#)
- [규모 조정 가능 대상에 대한 하나 이상의 예약된 작업 설명](#)

서비스에 대한 조정 활동 설명

지정된 서비스 네임스페이스의 모든 확장 가능한 대상에 대한 크기 조정 작업을 보려면 [describe-scaling-activities](#) 명령을 사용합니다.

다음 예제에서는 dynamodb 서비스 네임스페이스와 관련된 크기 조정 활동을 검색합니다.

Linux, macOS 또는 Unix

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

Windows

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

출력

이 명령이 성공하면 다음과 비슷한 출력이 반환됩니다.

```
{
  "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"
  }
]
}

```

확장 가능한 대상 중 하나에 대해서만 조정 활동을 검색하도록 이 명령을 변경하려면 `--resource-id` 옵션을 추가합니다.

서비스에 대한 예약된 작업 설명

지정된 서비스 네임스페이스의 모든 확장 가능한 대상에 대한 크기 조정 작업을 설명하려면 [describe-scheduled-actions](#) 명령을 사용합니다.

다음 예제에서는 ec2 서비스 네임스페이스와 관련된 예약된 작업을 검색합니다.

Linux, macOS 또는 Unix

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

Windows

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

출력

이 명령이 성공하면 다음과 비슷한 출력이 반환됩니다.

```
{
  "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
}
]
}

```

규모 조정 가능 대상에 대한 하나 이상의 예약된 작업 설명

지정된 확장 가능 대상에 대해 예약된 작업에 대한 정보를 검색하려면 [describe-scheduled-actions](#) 명령을 사용하여 예약된 작업을 설명할 때 `--resource-id` 옵션을 추가합니다.

`--scheduled-action-names` 옵션을 포함하고 예약된 작업의 이름을 그 값으로 지정하면, 다음 예제에서처럼 명령이 그 이름이 일치하는 예약된 작업만을 반환합니다.

Linux, macOS 또는 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
```

출력

이 명령이 성공하면 다음과 비슷한 출력이 반환됩니다. `--scheduled-action-names`에 둘 이상의 값이 제공되면 이름이 일치하는 예약된 작업이 모두 출력에 포함됩니다.

```
{
  "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
    }
  ]
}
```

Application Auto Scaling을 사용하여 반복 조정 작업 예약

Important

Amazon EC2 Auto Scaling용 cron 표현식에 대한 도움이 필요한 경우 Amazon EC2 Auto Scaling 사용 설명서의 [반복 일정](#) 주제를 참조하세요. Amazon EC2 Auto Scaling의 경우, Application Auto Scaling에서 사용하는 사용자 지정 cron 구문 대신 기존 cron 구문을 사용합니다.

cron 표현식을 사용하여 반복 일정에 따라 실행되는 예약 작업을 생성할 수 있습니다.

반복 일정을 생성하려면 cron 표현식과 시간대를 지정하여 예약된 작업이 반복되는 시기를 지정합니다. 지원되는 시간대 값은 [Joda-Time](#)에서 지원하는 IANA 표준 시간대의 표준 이름입니다(예: Etc/GMT+9 또는 Pacific/Tahiti). 선택적으로 시작 시간, 해지 시간 또는 두 가지 모두에 대한 날짜 및 시간을 지정할 수 있습니다. 를 사용하여 예약된 작업을 생성하는 예제 명령은 섹션을 참조 AWS CLI 하세요 [시간대를 지정하는 반복 예약 작업 생성](#).

지원되는 cron 표현식 형식은 [Minute] [Hour] [Day_of_Month] [Month_of_Year] [Day_of_Week]와 같이 공백으로 구분된 여섯 개의 필드로 구성됩니다. 예를 들어 cron 표현식 30 6 ? * MON *은(는) 매주 월요일 오전 6:30에 발생하는 예약된 작업을 구성합니다. 별표는 필드의 모든 값을 일치시키기 위한 와일드카드 사용 됩니다.

Application Auto Scaling 예약된 작업에서 지원하는 cron 구문에 대한 자세한 내용은 Amazon EventBridge 사용 설명서의 [Cron 표현식 참조](#) 단원을 참조하십시오.

반복 일정을 생성할 때에는 시작 시간과 종료 시간을 신중하게 선택해야 합니다. 다음 사항에 유의하세요:

- 시작 시간을 지정하면 Application Auto Scaling이 이 시간에 작업을 수행한 다음 지정된 반복에 따라 작업을 수행합니다.
- 해지 시간을 지정하면 이 시간 이후에는 작업이 반복되지 않습니다. Application Auto Scaling은 이전 값을 추적하지 않고 종료 시간 이후에 이전 값으로 되돌립니다.
- AWS CLI 또는 AWS SDKs를 사용하여 예약된 작업을 생성하거나 업데이트할 때는 시작 시간과 종료 시간을 UTC로 설정해야 합니다.

예제

Application Auto Scaling 확장 가능 대상에 대한 반복 일정을 생성하는 경우 다음 표를 참조할 수 있습니다. 다음 예는 Application Auto Scaling을 사용하여 예약된 작업을 생성하거나 업데이트하기 위한 올바른 구문입니다.

분	시간	일	월	요일	연도	의미
0	10	*	*	?	*	매일 오전 10시(UTC)에 실행

분	시간	일	월	요일	연도	의미
15	12	*	*	?	*	매일 오후 12시 15분 (UTC)에 실행
0	18	?	*	월-금	*	매주 월요일부터 금요일까지 오후 6시 (UTC)에 실행
0	8	1	*	?	*	매월 1일 오전 8시 (UTC)에 실행
0/15	*	*	*	?	*	15분마다 실행
0/10	*	?	*	월-금	*	월요일부터 금요일까지 10분마다 실행
0/5	8~17	?	*	월-금	*	월요일부터 금요일까지 오전 8시부터 오후 5시 55분(UTC) 사이에 5분마다 실행

예외

7개의 필드가 포함된 문자열 값을 사용하여 cron 표현식을 만들 수도 있습니다. 이 경우 처음 세 필드를 사용하여 예약된 작업이 실행되어야 하는 시간(초 포함)을 지정할 수 있습니다. 전체 cron 표현식에는 [Seconds] [Minutes] [Hours] [Day_of_Month] [Month] [Day_of_Week] [Year]와 같이 공백으로 구분된 필드가 있습니다. 그러나 이 접근 방식을 사용한다고 해서 예약된 작업이 지정한 정확한 초 단위의 시간에 실행된다는 보장은 없습니다. 또한 일부 서비스 콘솔은 cron 표현식의 초 필드를 지원하지 않을 수 있습니다.

확장 가능한 대상에 대해 예약된 크기 조정 해제

예약된 작업을 삭제하지 않고도 예약된 조정을 일시적으로 해제할 수 있습니다. 자세한 내용은 [Application Auto Scaling의 조정 일시 중지 및 재개](#) 단원을 참조하십시오.

예약된 조정을 일시 중지하려면

다음 예제에서처럼 `--suspended-state` 옵션과 함께 [register-scalable-target](#) 명령을 사용하고 `ScheduledScalingSuspended` 속성의 값으로 `true`를 지정하여 확장 가능 대상에 대한 예약된 작업을 일시 중지합니다.

Linux, macOS 또는 Unix

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

Windows

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

출력

이 명령이 성공하면 규모 조정 가능 대상의 ARN이 반환됩니다. 다음은 예제 출력입니다.

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

```
}
```

예약된 조정을 재개하려면

예약된 조정을 재개하려면 `register-scalable-target` 명령을 다시 실행하고 `ScheduledScalingSuspended` 값으로 `false`를 지정합니다.

를 사용하여 Application Auto Scaling에 예약된 작업 삭제 AWS CLI

예약된 작업을 마치면 이를 삭제할 수 있습니다.

예약된 작업을 삭제하려면

[delete-scheduled-action](#) 명령을 사용합니다. 이 명령이 성공하면 어떤 출력도 반환되지 않습니다.

Linux, macOS 또는 Unix

```
aws application-autoscaling delete-scheduled-action \
  --service-namespace ec2 \
  --scalable-dimension ec2:spot-fleet-request:TargetCapacity \
  --resource-id spot-fleet-request/sfr-73fbd2ce-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-73fbd2ce-aa30-494c-8788-37294EXAMPLE ^
  --scheduled-action-name my-recurring-action
```

확장 가능 대상의 등록을 취소하려면

규모 조정 가능 대상에 대한 작업을 완료한 경우 등록을 취소할 수 있습니다. 다음과 같은 [deregister-scalable-target](#) 명령을 사용합니다. 아직 삭제되지 않은 조정 정책 또는 예약된 작업이 있는 경우에는 이 명령을 통해 삭제됩니다. 이 명령이 성공하면 어떤 출력도 반환되지 않습니다.

Linux, macOS 또는 Unix

```
aws application-autoscaling deregister-scalable-target \
```

```
--service-namespace ec2 \  
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \  
--resource-id spot-fleet-request/sfr-73fbd2ce-aa30-494c-8788-37294EXAMPLE
```

Windows

```
aws application-autoscaling deregister-scalable-target ^  
--service-namespace ec2 ^  
--scalable-dimension ec2:spot-fleet-request:TargetCapacity ^  
--resource-id spot-fleet-request/sfr-73fbd2ce-aa30-494c-8788-37294EXAMPLE
```

Application Auto Scaling의 대상 추적 조정 정책

대상 추적 조정 정책은 대상 지표값을 기준으로 애플리케이션을 자동으로 조정합니다. 이를 통해 애플리케이션은 수동 개입 없이 최적의 성능과 비용 효율성을 유지할 수 있습니다.

대상 추적을 사용할 때는 애플리케이션의 이상적인 평균 사용률 또는 처리량 수준을 나타내는 지표와 목표 값을 선택합니다. Application Auto Scaling은 지표가 대상에서 벗어날 경우 조정 이벤트를 트리거하는 CloudWatch 경보를 생성하고 관리합니다. 이는 온도 조절기가 목표 온도를 유지하는 방법과 비슷합니다.

예를 들어, 현재 스팟 플릿에서 애플리케이션이 실행되고 있고 사용자가 애플리케이션 로드 변경이 있는 경우 플릿의 CPU 사용량을 50% 정도로 유지시키려 한다고 가정해 보겠습니다. 이로 인해 과도한 유휴 리소스를 유지하지 않고도 트래픽 급증을 처리할 수 있는 추가 용량을 확보할 수 있습니다.

평균 CPU 사용률 50%를 목표로 하는 대상 추적 조정 정책을 생성하면 이러한 요건을 충족할 수 있습니다. 그러면 CPU가 50%를 초과하면 Application Auto Scaling이 스케일 아웃(용량 증가)하여 증가된 로드를 처리합니다. CPU가 50% 미만으로 떨어지면 스케일 인(용량 감소)하여 사용률이 낮은 기간 동안 비용을 최적화합니다.

대상 추적 정책을 사용하면 CloudWatch 경보 및 조정 작업을 수동으로 정의할 필요가 없습니다. Application Auto Scaling은 사용자가 설정한 대상에 따라 이를 자동으로 처리합니다.

사전 정의된 지표 또는 사용자 지정 지표를 기준으로 대상 추적 정책을 설정할 수 있습니다.

- 사전 정의된 지표 — 평균 CPU 사용률 또는 대상당 평균 요청 수와 같이 Application Auto Scaling에서 제공하는 지표입니다.
- 사용자 지정 지표 — 지표 계산을 사용하여 지표를 결합하거나, 기존 지표를 활용하거나, CloudWatch에 게시된 자체 사용자 지정 지표를 사용할 수 있습니다.

확장 가능한 대상의 용량 변화에 반비례하여 변경되는 지표를 선택하세요. 따라서 용량을 두 배로 늘리면 지표는 50% 감소합니다. 이렇게 하면 지표 데이터가 비례적 조정 이벤트를 정확하게 트리거할 수 있습니다.

내용

- [Application Auto Scaling의 대상 추적 조정 작동 방식](#)
- [를 사용하여 Application Auto Scaling에 대한 대상 추적 조정 정책 생성 AWS CLI](#)
- [를 사용하여 Application Auto Scaling에 대한 대상 추적 조정 정책 삭제 AWS CLI](#)

- [지표 수학을 사용하여 Application Auto Scaling에서 대상 추적 조정 정책 생성](#)

Application Auto Scaling의 대상 추적 조정 작동 방식

이 주제에서는 대상 추적 조정의 작동 방식을 설명하고 대상 추적 조정 정책의 주요 요소를 소개합니다.

내용

- [작동 방식](#)
- [지표 선택](#)
- [목표 값 정의](#)
- [휴지 기간 정의](#)
- [고려 사항](#)
- [여러 조정 정책](#)
- [조정 정책 생성, 관리 및 삭제를 위해 일반적으로 사용되는 명령](#)
- [관련 리소스](#)
- [제한 사항](#)

작동 방식

대상 추적 조정을 사용하려면 대상 추적 조정 정책을 생성하고 다음을 지정합니다.


- 지표 — 평균 CPU 사용률 또는 대상당 평균 요청 수와 같이 추적할 CloudWatch 지표입니다.
- 대상 값 - 지표의 대상 값(예: CPU 사용률 50% 또는 대상당 분당 1,000개 요청)입니다.

Application Auto Scaling은 조정 정책을 호출하는 CloudWatch 경보를 생성 및 관리하고 지표와 대상 값을 기준으로 조정 조절을 계산합니다. 이는 필요에 따라 용량을 추가 및 제거하여 지표를 지정한 목표값으로, 혹은 목표값에 가깝게 유지합니다.

지표가 목표 값을 초과하면 Application Auto Scaling은 용량을 추가하여 메트릭 값과 대상 값 간의 차이를 줄임으로써 스케일 아웃합니다. 지표가 목표 값보다 낮으면 Application Auto Scaling은 용량을 제거하여 스케일 인합니다.

조정 작업은 용량의 급격한 변동을 방지하기 위해 작업 중간에 휴지 기간을 두고 수행됩니다. 선택적으로 조정 정책에 대한 휴지 기간을 구성할 수 있습니다.

다음 다이어그램은 설정이 완료될 때 대상 추적 조정 정책의 작동에 대한 개요를 보여줍니다.



대상 추적 조정 정책은 사용률이 증가할 때 용량을 추가하는 것이 사용률이 감소할 때 용량을 제거하는 것보다 더 적극적으로 적용된다는 점에 유의하세요. 예를 들어 정책의 지정된 지표가 대상 값에 도달하면 정책은 애플리케이션이 이미 많이 로드된 것으로 가정합니다. 따라서 최대한 빨리 지표 값에 비례하는 용량을 추가하여 응답합니다. 지표가 높을수록 더 많은 용량이 추가됩니다.

지표가 대상 값보다 낮으면 최소 용량 단위를 제거하면 지표가 대상 값보다 높아질 가능성이 높다고 계산되면 정책이 축소되지 않습니다. 이 경우 사용률이 대상 값보다 충분히 낮은 임계값(일반적으로 10% 이상 낮음)에 도달하는 경우에만 사용률이 낮은 것으로 간주되어 용량을 제거하므로 조정 속도가 느려집니다. 이러한 더 보수적인 동작의 목적은 애플리케이션에서 더 이상 이전과 동일한 수준의 수요가 발생하지 않을 때만 용량을 제거하는 것입니다.

지표 선택

사용자 지정 또는 사전 정의된 지표를 사용하여 대상 추적 크기 조정 정책을 생성할 수 있습니다.

사전 정의된 지표 유형을 사용하여 대상 추적 크기 조정 정책을 생성하는 경우 [대상 추적 조정 정책을 위해 사전 정의된 지표](#)에 사전 정의된 지표 목록에서 지표를 하나 선택합니다.

지표를 선택하는 경우, 다음 사항에 유의하세요.

- 모든 사용자 지정 지표를 대상 추적에 사용할 수 있는 것은 아닙니다. 지표는 유효한 사용량 수치로서 확장 가능한 대상의 사용량을 설명해야 합니다. 지표 값은 확장 가능한 대상의 용량과 비례하여 증가하거나 감소해야만 지표 데이터에 따라 확장 가능한 대상을 늘리거나 줄일 수 있습니다.
- ALBRequestCountPerTarget 지표를 사용하려면 ResourceLabel 파라미터를 지정하여 지표와 연관된 대상 그룹을 식별해야 합니다.
- 지표가 CloudWatch에 실제 0 값을 내보내는 경우(예: ALBRequestCountPerTarget) Application Auto Scaling은 유지된 기간 동안 애플리케이션에 대한 트래픽이 없을 때 0으로 스케일 인될 수 있습니다. 확장 가능 대상에 요청이 라우팅되지 않은 경우 대상을 0으로 축소하려면, 확장 가능 대상의 최소 용량을 0으로 설정해야 합니다.

- 조정 정책에 사용할 새 지표를 게시하는 대신 지표 수학을 사용하여 기존 지표를 결합할 수 있습니다. 자세한 내용은 [지표 수학을 사용하여 Application Auto Scaling에서 대상 추적 조정 정책 생성 단원을 참조하십시오](#).
- 사용하는 서비스가 서비스 콘솔에서 사용자 지정 지표 지정을 지원하는지 확인하려면 해당 서비스에 대한 설명서를 참조하세요.
- 사용률 변화에 따라 더 빠르게 조정할 수 있도록 1분 간격으로 제공되는 지표를 사용할 것을 권장합니다. 대상 추적은 사전 정의된 모든 지표와 사용자 지정 지표에 대해 1분 단위로 집계된 지표를 평가하지만, 기본 지표는 데이터를 게시하는 빈도가 낮을 수 있습니다. 예컨대, 모든 Amazon EC2 지표는 기본적으로 5분 간격으로 전송되지만, 1분 간격으로 구성할 수 있습니다(세부 모니터링이라고 함). 이 선택은 개별 서비스에 따라 달라집니다. 대부분의 경우 가능한 가장 짧은 간격을 사용하려고 합니다.

목표 값 정의

대상 추적 조정 정책을 생성할 경우, 목표 값을 지정해야 합니다. 목표 값은 애플리케이션의 최적 평균 사용률 또는 처리량(throughput)을 나타냅니다. 리소스를 비용 효율적으로 사용하려면 예상치 못한 트래픽 증가에 대비하여, 적절한 버퍼를 두고 목표 값을 가능한 한 높게 설정합니다. 애플리케이션이 정상적인 트래픽 흐름을 위해 최적으로 스케일 아웃되면 실제 지표 값은 목표 값과 같거나 그보다 조금 낮아야 합니다.

조정 정책이 Application Load Balancer 대상당 요청 수, 네트워크 I/O 또는 기타 수 지표와 같은 처리량(throughput)을 기반으로 하는 경우 대상 값은 1분 동안 단일 엔터티(예: Application Load Balancer 대상 그룹의 단일 대상)의 최적 평균 처리량(throughput)을 나타냅니다.

휴지 기간 정의

대상 추적 조정 정책에서 휴지 기간을 선택적으로 정의할 수 있습니다.

이전 조정 활동이 적용될 때까지 기다리는 시간을 휴지 기간이라고 합니다.

휴지 기간에는 다음과 같은 두 가지 유형이 있습니다.

- 확장 휴지 기간을 사용하는 경우, 지속적이지만 과도하지는 않게 확장하는 것이 목적입니다. Application Auto Scaling에서 조정 정책을 사용하여 성공적으로 스케일 아웃하면 휴지 기간이 계산되기 시작합니다. 조정 정책은 더 큰 스케일 아웃이 트리거되거나 휴지 기간이 종료되지 않는 한 원하는 용량을 다시 늘리지 않습니다. 확장 휴지 기간이 진행되는 동안 확장 활동을 시작하여 추가된 용량은 다음 확장 활동에 대해 원하는 용량의 일부로 계산됩니다.

- 스케일 인 휴지 기간을 사용하는 경우 애플리케이션의 가용성을 보호하기 위해 보수적으로 확장하므로 스케일 인 휴지 기간이 만료될 때까지 스케일 인 활동이 차단됩니다. 그러나 축소 휴지 기간 중에 다른 경보가 확장 활동을 트리거하면 Application Auto Scaling은 대상을 즉시 확장합니다. 이 경우 스케일 인 휴지 기간이 중지되고 완료되지 않습니다.

각 휴지 기간은 초 단위로 측정되며 정책 관련 조정 활동 조정에만 적용됩니다. 휴지 기간에 예약된 작업이 예약된 시간에 시작되면 휴지 기간이 만료될 때까지 기다리지 않고 조정 활동을 즉시 트리거할 수 있습니다.

나중에 미세 조정할 수 있는 기본값으로 시작할 수 있습니다. 예를 들어 대상 추적 조정 정책이 짧은 기간에 발생하는 변경 사항에 대해 지나치게 공격적이지 않도록 휴지 기간을 늘려야 할 수 있습니다.

기본값

Application Auto Scaling은 ElastiCache의 기본값 600과 다음과 같은 확장 가능한 대상의 기본값 300을 제공합니다.

- WorkSpaces 애플리케이션 플릿
- Aurora DB 클러스터
- ECS 서비스
- Neptune 클러스터
- SageMaker AI 엔드포인트 변형
- SageMaker AI 추론 구성 요소
- SageMaker AI Serverless 프로비저닝된 동시성
- Spot Fleets
- WorkSpaces 풀
- 사용자 지정 리소스

다른 모든 확장 가능한 대상의 경우 기본값은 0 또는 null입니다.

- Amazon Comprehend 문서 분류 및 엔터티 인식기 엔드포인트
- DynamoDB 테이블 및 글로벌 보조 인덱스
- Amazon Keyspaces 테이블
- Lambda 프로비저닝된 동시성
- Amazon MSK 브로커 스토리지

Application Auto Scaling Scaling에서 휴지 기간을 평가할 때 Null 값은 0 값 동일하게 처리됩니다.

null 값을 비롯한 모든 기본값을 업데이트하여 휴지 기간을 직접 설정할 수 있습니다.

고려 사항

대상 추적 조정 정책과 관련한 작업을 수행할 때는 다음 고려 사항이 적용됩니다.

- 대상 추적 조정 정책과 함께 사용되는 CloudWatch 경보는 생성하거나 편집하거나 삭제하지 마세요. Application Auto Scaling은 대상 추적 조정 정책과 연결된 CloudWatch 경보를 생성하고 관리하며, 더 이상 필요하지 않은 경우 자동으로 삭제합니다.
- 지표에 누락된 데이터 포인트가 있는 경우, CloudWatch 경보 상태가 INSUFFICIENT_DATA로 변경됩니다. 이 경우, 새 데이터 포인트를 찾을 때까지 Application Auto Scaling이 확장 가능 대상을 조정할 수 없습니다. 자세한 설명은 Amazon CloudWatch 사용 설명서의 [CloudWatch 경보가 누락된 데이터를 처리하는 방법 구성](#)을 참조하세요.
- 설계상 지표가 드물게 보고되는 경우, 지표 수확이 유용할 수 있습니다. 예를 들어, 가장 최근 값을 사용하려면 m1이 지표에 있는 FILL(m1, REPEAT) 함수를 사용하세요.
- 대상 값과 실제 지표 데이터 포인트 사이에는 차이가 발생할 수 있습니다. Application Auto Scaling이 추가하거나 제거할 용량을 결정할 때마다 항상 반올림 또는 내림을 통해 어림짐작으로 동작하기 때문입니다. 이는 용량을 부족하게 추가하거나 너무 많이 제거하는 일을 방지하기 위해서입니다. 하지만 용량이 작은 확장 가능한 대상의 경우 실제 지표 데이터 포인트는 대상 값과 멀어질 수도 있습니다.

예컨대 CPU 사용률 목표값을 50%로 설정한 후 Auto Scaling 그룹이 목표 값을 초과한다고 가정해 보겠습니다. 1.5개의 인스턴스를 추가하면 CPU 사용률이 50% 가까이 감소할 것을 알 수 있습니다. 하지만 1.5개의 인스턴스를 추가할 수 없기 때문에 반올림을 통해 인스턴스 2개를 추가합니다. 그러면 CPU 사용률이 50% 아래로 떨어지는 동시에 애플리케이션은 리소스를 충분히 확보하게 됩니다. 마찬가지로 인스턴스를 0.5개 줄이면 CPU 사용률이 50%를 초과하게 된다고 판단될 경우, 스케일 인이 진동을 유발하지 않을 만큼 지표가 충분히 낮아질 때까지 스케일 인을 수행하지 않습니다.

용량이 큰 확장 가능한 대상의 경우 용량을 추가 또는 제거하면 대상 값과 실제 지표 데이터 포인트 사이의 차이를 줄일 수 있습니다.

- 대상 추적 조정 정책은 지정한 지표가 목표 값을 초과할 때 한해서 확장을 수행해야 합니다. 대상 추적 조정 정책에서는 지정한 지표가 목표 값보다 작을 때 확장할 수 없습니다.

여러 조정 정책

각각 다른 지표를 사용한다는 전제하에 확장 가능한 대상에 대해 다수의 대상 추적 스케일링 정책을 보유할 수 있습니다. Application Auto Scaling은 항상 가용성을 우선시하므로, 대상 추적 정책이 확장 또는 축소를 허용하는지에 따라 그 동작이 달라집니다. 대상 추적 정책 중 하나라도 확장을 허용할 경우 확장 가능한 대상을 확장하지만 모든 대상 추적 정책(축소 부분이 활성화됨)이 축소를 허용하는 경우에만 대상을 축소합니다.

여러 조정 정책이 확장 가능한 대상에 스케일 아웃 또는 스케일 인을 동시에 지시하는 경우 Application Auto Scaling은 스케일 아웃과 스케일 인 모두에 대해 가장 큰 용량을 제공하는 정책에 따라 조정합니다. 이로써 다양한 시나리오를 수용할 만큼 폭넓은 유연성을 발휘할 뿐만 아니라 워크로드를 처리하는데 필요한 용량을 항상 충분히 확보할 수 있습니다.

대상 추적 조정 정책의 스케일 인 부분을 비활성화하여 스케일 아웃에 사용하는 것보다 다양한 스케일 인 방법을 사용할 수 있습니다. 예를 들어 확장을 위해 대상 추적 조정 정책을 사용하고 축소를 위해 단계 조정 정책을 사용할 수 있습니다.

그러나 대상 추적 조정 정책과 단계별 조정 정책을 함께 사용하는 경우, 정책 간 충돌로 인해 바람직하지 않은 동작이 발생할 수 있으므로 주의해야 합니다. 예를 들어 대상 추적 정책이 축소 준비되기 전에 단계 조정 정책이 축소 활동을 시작하는 경우 축소 활동이 차단되지 않습니다. 축소 작업이 완료된 후 대상 추적 정책이 확장 가능한 대상에 다시 확장하도록 지시할 수 있습니다.

기본적으로 주기적 워크로드의 경우 예약된 조정을 사용하여 일정에 따라 용량 변경을 자동화할 수도 있습니다. 예약된 각 작업에 대해 새 최소 용량 값과 새 최대 용량 값을 정의할 수 있습니다. 이러한 값은 조정 정책의 경계를 형성합니다. 예약된 조정과 대상 추적 조정을 함께 사용하면 용량이 즉시 필요할 때 사용률 수준이 급격히 증가하는 영향을 줄일 수 있습니다.

조정 정책 생성, 관리 및 삭제를 위해 일반적으로 사용되는 명령

조정 정책 작업에 일반적으로 사용되는 명령은 다음과 같습니다.

- [register-scalable-target](#) - AWS 또는 사용자 지정 리소스를 확장 가능 대상(Application Auto Scaling이 확장할 수 있는 리소스)으로 등록하고 조정을 일시 중지 및 재개합니다.
- [put-scaling-policy](#)를 사용하여 기존 확장 가능 대상에 대한 조정 정책을 추가하거나 수정할 수 있습니다.
- [describe-scaling-activities](#): AWS 리전의 조정 활동에 대한 정보를 반환합니다.
- [describe-scaling-activities](#)를 사용하여 조정 정책에 대한 정보를 AWS 리전으로 반환할 수 있습니다.
- [delete-scaling-policy](#)를 사용하여 조정 정책을 삭제할 수 있습니다.

관련 리소스

Auto Scaling의 대상 추적 조정 정책 생성에 대한 자세한 내용은 Amazon EC2 Auto Scaling 사용 설명서의 [Amazon EC2 Auto Scaling 대상 추적 조정 정책](#)을 참조하세요.

제한 사항

대상 추적 조정 정책을 사용할 때의 제한 사항은 다음과 같습니다.

- 확장 가능 대상은 Amazon EMR 클러스터가 될 수 없습니다. Amazon EMR에 대해서는 대상 추적 조정 정책이 지원되지 않습니다.
- Amazon MSK 클러스터가 확장 가능한 대상인 경우 축소가 비활성화되어 활성화할 수 없습니다.
- RegisterScalableTarget 또는 PutScalingPolicy API 작업을 사용하여 AWS Auto Scaling 조정 계획을 업데이트할 수 없습니다.
- 확장 가능한 리소스에 대한 대상 추적 조정 정책을 표시, 추가, 업데이트 또는 제거할 수 있는 콘솔 액세스 권한은 사용하는 리소스에 따라 다릅니다. 자세한 내용은 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 단원을 참조하십시오.

를 사용하여 Application Auto Scaling에 대한 대상 추적 조정 정책 생성 AWS CLI

이 예제에서는 AWS CLI 명령을 사용하여 Amazon EC2 스팟 플릿에 대한 대상 랙킹 정책을 생성합니다. 다른 규모 조정 가능 대상을 지정하려면 `--service-namespace`에 네임스페이스, `--scalable-dimension`에 규모 조정 가능 차원, `--resource-id`에 리소스 ID를 지정합니다.

를 사용할 때는 명령이 프로파일에 대해 AWS 리전 구성된에서 실행된다는 점을 AWS CLI기억하세요. 다른 리전에서 명령을 실행하려는 경우 프로필의 기본 리전을 변경하거나 명령에 `--region` 파라미터를 사용합니다.

작업

- [1단계: 규모 조정 가능 대상 등록](#)
- [2단계: 대상 추적 조정 정책 생성](#)
- [3단계: 대상 추적 조정 정책 설명](#)

1단계: 규모 조정 가능 대상 등록

아직 하지 않았다면 확장 가능 대상을 등록합니다. [register-scalable-target](#) 명령을 사용하여 대상 서비스의 특정 리소스를 확장 가능 대상으로 등록합니다. 다음 예제에서는 Application Auto Scaling으로 스팟 플릿 요청을 등록합니다. Application Auto Scaling에서는 스팟 플릿의 인스턴스 수를 최소 2개와 최대 10개 사이에서 조정할 수 있습니다. *user input placeholder*를 사용자의 정보로 바꿉니다.

Linux, macOS 또는 Unix

```
aws application-autoscaling register-scalable-target --service-namespace ec2 \
  --scalable-dimension ec2:spot-fleet-request:TargetCapacity \
  --resource-id spot-fleet-request/sfr-73fbd2ce-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-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE ^
  --min-capacity 2 --max-capacity 10
```

출력

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다. 다음은 예제 출력입니다.

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

2단계: 대상 추적 조정 정책 생성

대상 추적 조정 정책을 생성하려면 시작하는 데 도움이 되는 다음 예제를 사용할 수 있습니다.

대상 추적 조정 정책을 생성하려면

1. 다음 cat 명령을 사용하여 홈 디렉터리에 config.json라는 이름의 JSON 파일에 조정 정책에 대한 목표값과 사전 정의된 지표 사양을 저장합니다. 다음은 평균 CPU 사용률을 50%로 유지하는 대상 추적 구성의 예입니다.

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

자세한 내용은 Application Auto Scaling API 참조의 [PredefinedMetricSpecification](#)을 참조하세요.

또는 사용자 지정된 지표 사양을 생성하고 CloudWatch의 각 파라미터에 대한 값을 추가하여 조정을 위한 사용자 지정 지표를 사용할 수 있습니다. 다음은 지정된 지표의 평균 사용률을 100으로 유지하는 대상 추적 구성의 예입니다.

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

자세한 내용은 Application Auto Scaling API 참조의 [CustomizedMetricSpecification](#)을 참조하세요.

- 다음 [put-scaling-policy](#) 명령을 생성한 config.json 파일과 함께 사용하여 cpu50-target-tracking-scaling-policy라는 조정 정책을 생성합니다.

Linux, macOS 또는 Unix

```
aws application-autoscaling put-scaling-policy --service-namespace ec2 \
  --scalable-dimension ec2:spot-fleet-request:TargetCapacity \
```

```
--resource-id spot-fleet-request/sfr-73fbd2ce-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-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE ^  
--policy-name cpu50-target-tracking-scaling-policy --policy-type  
TargetTrackingScaling ^  
--target-tracking-scaling-policy-configuration file://config.json
```

출력

이 명령이 성공하면 사용자를 위해 생성된 두 CloudWatch 경보의 ARN과 이름이 반환됩니다. 다음은 예제 출력입니다.

```
{  
  "PolicyARN": "arn:aws:autoscaling:region:account-  
id:scalingPolicy:policy-id:resource/ec2/spot-fleet-request/sfr-73fbd2ce-  
aa30-494c-8788-1cee4EXAMPLE:policyName/cpu50-target-tracking-scaling-policy",  
  "Alarms": [  
    {  
      "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-  
spot-fleet-request/sfr-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-  
b46e-434a-a60f-3b36d653feca",  
      "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fbd2ce-  
aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-b46e-434a-a60f-3b36d653feca"  
    },  
    {  
      "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-  
spot-fleet-request/sfr-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-  
d19b-4a63-a812-6c67aaf2910d",  
      "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fbd2ce-  
aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-d19b-4a63-a812-6c67aaf2910d"  
    }  
  ]  
}
```

3단계: 대상 추적 조정 정책 설명

다음 [describe-scaling-policies](#) 명령을 사용하여 지정된 서비스 네임스페이스에 대한 모든 조정 정책을 설명할 수 있습니다.

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

--query 파라미터를 사용하여 대상 추적 조정 정책으로 결과를 필터링할 수 있습니다. query의 구문에 대한 자세한 내용은 AWS Command Line Interface 사용 설명서의 [AWS CLI의 명령 출력 제어](#)를 참조하세요.

Linux, macOS 또는 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`]"
```

출력

다음은 예제 출력입니다.

```
[
  {
    "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-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE",
    "Alarms": [
```

```

    {
      "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-
spot-fleet-request/sfr-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-
b46e-434a-a60f-3b36d653feca",
      "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fbd2ce-
aa30-494c-8788-1cee4EXAMPLE-AlarmHigh-d4f0770c-b46e-434a-a60f-3b36d653feca"
    },
    {
      "AlarmARN": "arn:aws:cloudwatch:region:account-id:alarm:TargetTracking-
spot-fleet-request/sfr-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-
d19b-4a63-a812-6c67aaf2910d",
      "AlarmName": "TargetTracking-spot-fleet-request/sfr-73fbd2ce-
aa30-494c-8788-1cee4EXAMPLE-AlarmLow-1b437334-d19b-4a63-a812-6c67aaf2910d"
    }
  ],
  "CreationTime": 1515021724.807
}
]

```

를 사용하여 Application Auto Scaling에 대한 대상 추적 조정 정책 삭제 AWS CLI

대상 추적 조정 정책을 완료했다면 [delete-scaling-policy](#) 명령을 사용하여 이를 삭제할 수 있습니다.

다음 명령은 지정된 스폿 플릿 요청에 대해 지정된 대상 추적 조정 정책을 삭제합니다. 또한 Application Auto Scaling이 사용자를 대신하여 생성한 CloudWatch 경보를 삭제합니다.

Linux, macOS 또는 Unix

```

aws application-autoscaling delete-scaling-policy --service-namespace ec2 \
--scalable-dimension ec2:spot-fleet-request:TargetCapacity \
--resource-id spot-fleet-request/sfr-73fbd2ce-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-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE ^
--policy-name cpu50-target-tracking-scaling-policy

```

지표 수학을 사용하여 Application Auto Scaling에서 대상 추적 조정 정책 생성

지표 수식을 사용하면 여러 CloudWatch 지표를 쿼리하고 수학 표현식을 활용함으로써 이러한 지표를 기반으로 새로운 시계열을 만들 수 있습니다. CloudWatch 콘솔에서 결과 시계열을 시각화하고 대시보드에 추가할 수 있습니다. 지표 수학에 대한 자세한 설명은 Amazon CloudWatch 사용자 가이드에서 [지표 수학 사용](#)을 참조하세요.

다음은 지표 수학 표현식에 적용되는 고려 사항입니다.

- 사용 가능한 모든 CloudWatch 지표를 쿼리할 수 있습니다. 각 지표는 지표 이름, 네임스페이스, 0개 이상의 측정기준으로 이루어진 고유한 조합입니다.
- 산술 연산자(+ - * / ^), 통계 함수(예: AVG 또는 SUM) 또는 CloudWatch에서 지원하는 기타 함수를 사용할 수 있습니다.
- 수학 표현식의 공식에서 지표 및 다른 수학 표현식의 결과를 모두 사용할 수 있습니다.
- 지표 사양에 사용된 표현식은 결국 단일 시계열을 반환해야 합니다.
- CloudWatch 콘솔 또는 CloudWatch [GetMetricData](#) API를 사용하여 지표 수학 표현식이 유효한지 확인할 수 있습니다.

주제

- 예: [태스크당 Amazon SQS 대기열 백로그](#)
- [제한 사항](#)

예: 태스크당 Amazon SQS 대기열 백로그

태스크당 Amazon SQS 대기열 백로그를 계산하려면 대기열에서 검색 가능한 대략적인 메시지 수를 가져와 서비스에서 실행 중인 Amazon ECS 태스크의 수로 나눕니다. 자세한 내용은 AWS 컴퓨팅 블로그의 사용자 [지정 지표를 사용한 Amazon Elastic Container Service\(ECS\) Auto Scaling](#)을 참조하세요.

표현식의 로직은 다음과 같습니다.

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

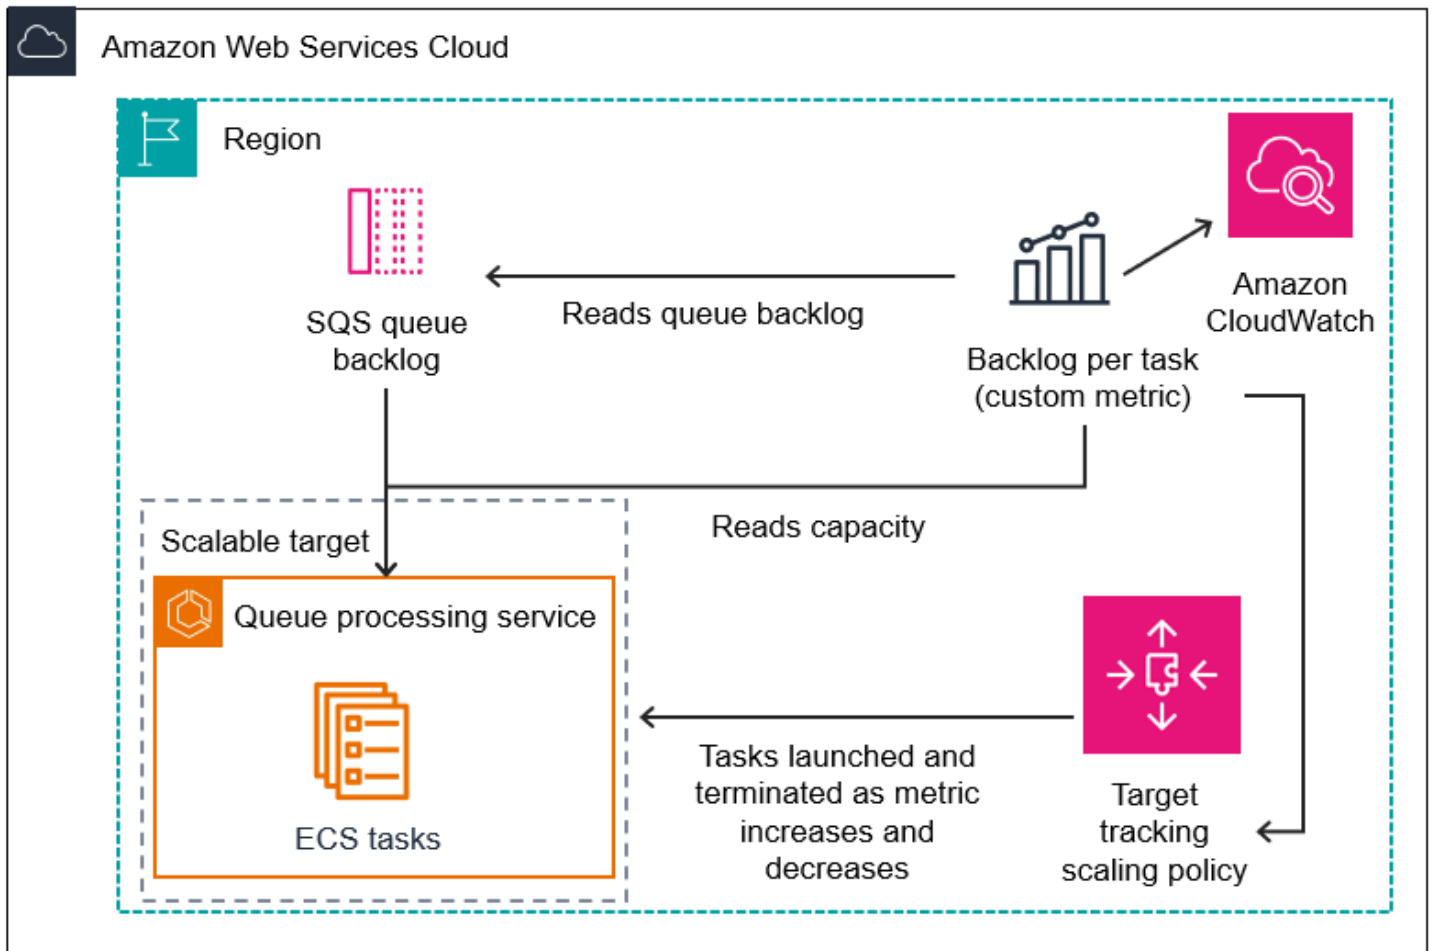
이 경우, CloudWatch 지표 정보는 다음과 같습니다.

ID	CloudWatch 지표	통계	Period
m1	ApproximateNumberOfMessagesVisible	Sum	1분
m2	RunningTaskCount	평균	1분

지표 수식 ID와 표현식은 다음과 같습니다.

ID	표현식
e1	(m1)/(m2)

다음은 이 지표에 대한 아키텍처를 보여주는 다이어그램입니다.



이 지표 수학을 사용하여 대상 추적 조정 정책 생성(AWS CLI)

1. 지표 수학 표현식을 사용자 지정된 지표 사양의 일부로서 config.json이라는 이름의 JSON 파일로 저장합니다.

다음 표가 시작하는 데 도움이 될 수 있습니다. *user input placeholder*를 사용자의 정보로 바꿉니다.

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

```

자세한 내용은 Application Auto Scaling API 참조의 [TargetTrackingScalingPolicyConfiguration](#)을 참조하세요.

Note

다음은 CloudWatch 지표에 대한 지표 이름, 네임스페이스, 차원 및 통계를 찾는 데 도움이 되는 몇 가지 추가 리소스입니다.

- AWS 서비스에 사용할 수 있는 지표에 대한 자세한 내용은 Amazon [AWS CloudWatch 사용 설명서의 CloudWatch 지표를 게시하는 서비스를](#) 참조하세요. Amazon CloudWatch
- 를 사용하여 CloudWatch 지표의 정확한 지표 이름, 네임스페이스 및 차원(해당하는 경우)을 가져오려면 [list-metrics](#)를 AWS CLI참조하세요.

2. 이 정책을 생성하려면 다음 예에 나와 있는 것처럼 JSON 파일을 입력으로 사용하여 [put-scaling-policy](#) 명령을 실행합니다.

```
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
```

이 명령이 성공하면 사용자를 대신하여 생성된 두 CloudWatch 경보의 Amazon 리소스 이름(ARN)과, 정책의 ARN이 반환됩니다.

```
{
  "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

이 명령에서 오류가 발생하면 AWS CLI 로컬에서 최신 버전으로 업데이트했는지 확인합니다.

제한 사항

- 최대 요청 크기는 50KB입니다. 이 크기는 정책 정의에서 지표 수학을 사용할 때 [PutScalingPolicy](#) API 요청에 대한 총 페이로드 크기입니다. 이 한도를 초과할 경우 Application Auto Scaling은 요청을 거부합니다.
- 대상 추적 조정 정책과 함께 지표 수학을 사용할 경우 다음 서비스는 지원되지 않습니다.
 - Amazon Keyspaces(Apache Cassandra용)
 - DynamoDB
 - Amazon EMR
 - Amazon MSK
 - Amazon Neptune

Application Auto Scaling의 단계 조정 정책

단계 조정 정책은 CloudWatch 경보를 기반으로 미리 정의된 단위로 애플리케이션 용량을 증분 조정합니다. 경보 임계값 위반 시 스케일 아웃(용량 증가) 및 스케일 인(용량 감소)을 처리하도록 별도의 조정 정책을 정의할 수 있습니다.

단계 조정 정책을 사용하여 조정 프로세스를 호출하는 경보를 생성하고 관리합니다. 경보 위반이 발생하면 Application Auto Scaling에서 해당 경보와 관련된 조정 정책을 시작합니다.

단계 조정 정책은 단계 조정이라고 하는 일련의 조정을 사용하여 용량을 조정합니다. 조정 크기는 경보 위반 규모에 따라 다릅니다.

- 첫 번째 임계값을 초과한 위반의 경우 Application Auto Scaling은 첫 번째 단계 조정을 적용합니다.
- 두 번째 임계값을 초과한 위반의 경우 Application Auto Scaling은 두 번째 단계 조정을 적용합니다.

이를 통해 조정 정책은 경보 지표의 사소한 변경 및 주요 변경 모두에 적절하게 대응할 수 있습니다.

정책은 규모 조정 작업 진행 중에도 추가 경보 위반에 계속 응답합니다. 즉, Application Auto Scaling은 모든 경보 위반이 발생하는 즉시 이를 평가합니다. 휴지 기간은 여러 개의 경보 위반이 빠르게 연속해서 발생하는 오버스케일링을 방지하는 데 사용됩니다.

대상 추적과 마찬가지로 단계 조정은 트래픽 변화에 따라 애플리케이션 용량을 자동으로 조정하는 데 도움이 될 수 있습니다. 하지만 꾸준한 규모 조정이 필요할 때에는 대상 추적 정책을 구현하고 관리하는 것이 더 쉬운 경향이 있습니다.

지원되는 규모 조정 가능 대상

다음과 같은 확장 가능한 대상에 단계 조정 정책을 사용할 수 있습니다.

- WorkSpaces 애플리케이션 플릿
- Aurora DB 클러스터
- ECS 서비스
- EMR 클러스터
- SageMaker AI 엔드포인트 변형
- SageMaker AI 추론 구성 요소
- SageMaker AI Serverless 프로비저닝된 동시성

- Spot Fleets
- 사용자 지정 리소스

내용

- [Application Auto Scaling의 단계 조정 작동 방식](#)
- [를 사용하여 Application Auto Scaling에 대한 단계 조정 정책 생성 AWS CLI](#)
- [를 사용하여 Application Auto Scaling에 대한 단계 조정 정책 설명 AWS CLI](#)
- [를 사용하여 Application Auto Scaling에 대한 단계 조정 정책 삭제 AWS CLI](#)

Application Auto Scaling의 단계 조정 작동 방식

이 주제에서는 단계 조정의 작동 방식을 설명하고 단계 조정 정책의 주요 요소를 소개합니다.

내용

- [작동 방식](#)
- [단계 조절](#)
- [조정 조절 유형](#)
- [휴지 기간](#)
- [조정 정책 생성, 관리 및 삭제를 위해 일반적으로 사용되는 명령](#)
- [고려 사항](#)
- [관련 리소스](#)
- [콘솔 액세스](#)

작동 방식

단계 조정을 사용하려면 확장 가능한 대상이 있는 지표를 모니터링하는 CloudWatch 경보를 생성해야 합니다. 경보 위반을 결정하는 지표, 임계값, 평가 기간 수를 정의합니다. 또한 경보 임계값 위반 시 용량을 조정하는 방법을 정의하고 이를 확장 가능한 대상과 연결하는 방법을 정의하는 단계 조정 정책을 생성합니다.

정책에 단계 조정을 추가합니다. 경보의 위반 규모에 따라 다양한 단계 조정을 정의할 수 있습니다. 예제:

- 경보 지표가 60%에 도달하면 10개 용량 단위로 스케일 아웃합니다.

- 경보 지표가 75%에 도달하면 30개 용량 단위로 스케일 아웃합니다.
- 경보 지표가 85%에 도달하면 40개 용량 단위로 스케일 아웃합니다.

지정된 수의 평가 기간 동안 경보 임계값이 위반되면 Application Auto Scaling은 정책에 정의된 단계 조정을 적용합니다. 경보 상태가 OK로 돌아갈 때까지 추가 경보 위반에 대해 조정을 계속할 수 있습니다.

조정 작업은 용량의 급격한 변동을 방지하기 위해 작업 중간에 휴지 기간을 두고 수행됩니다. 선택적으로 조정 정책에 대한 휴지 기간을 구성할 수 있습니다.

단계 조절

단계 조정 정책을 생성할 때 경보 위반의 크기에 따라 대상 용량이 동적으로 자동 조정되도록 하나 이상의 단계 조정을 지정합니다. 각 단계별 조정은 다음을 지정합니다.

- 지표 값의 하한값입니다.
- 지표 값의 상한값입니다.
- 조정 유형에 근거하여 축소하거나 스케일 아웃하는 양입니다.

CloudWatch는 CloudWatch 경보와 연결된 지표의 통계를 기반으로 지표 데이터 포인트를 집계합니다. 경보를 위반하면 적절한 조정 정책이 호출됩니다. Application Auto Scaling은 지정된 집계 유형을 CloudWatch의 최근 지표 데이터 포인트에 적용합니다(원시 지표 데이터와 반대). 이 집계된 지표 값을 단계별 조정으로 정의된 상한값 및 하한값과 비교하여 어느 단계의 조정을 수행할 것인지 결정합니다.

위반 임계값과 연계하여 상한값과 하한값을 지정합니다. 예를 들어 지표가 50%를 초과하는 경우에 대한 CloudWatch 경보와 스케일 아웃 정책을 만들었다고 가정해 보겠습니다. 그런 다음 지표가 50% 미만일 때를 대비한 두 번째 경보와 스케일 인 정책을 만들었습니다. 각 정책에 대해 PercentChangeInCapacity 조정 유형을 지정하여 일련의 단계 조정을 설정했습니다.

예: 스케일 아웃 정책에 대한 단계 조절

하한	상한	조절
0	10	0
10	20	10
20	null	30

예: 축소 정책에 대한 단계 조절

하한	상한	조절
-10	0	0
-20	-10	-10
null	-20	-30

이렇게 하면 다음과 같은 조정 구성이 생성됩니다.

Metric value								
-infinity	30%	40%	60%	70%	infinity			

-30%		-10%		Unchanged		+10%		+30%

이제 용량이 10인 확장 가능한 대상에 이 조정 구성을 사용한다고 가정해 보겠습니다. 다음 사항은 확장 가능한 대상의 용량과 관련된 조정 구성의 동작을 요약합니다.

- 원래 용량이 유지되고 집계된 지표 값은 40을 초과하고 60 미만입니다.
- 지표 값이 60에 도달하면 Application Auto Scaling에서 확장 가능한 대상의 용량이 1 증가하여 11이 됩니다. 이는 확장 정책의 두 번째 단계 조절을 기반으로 합니다(10의 10퍼센트). 새로운 용량이 추가되면 Application Auto Scaling은 현재 용량을 11로 늘립니다. 이 용량 증가 후에도 지표 값이 70으로 증가하면 Application Auto Scaling이 대상 용량을 3 증가하여 14가 됩니다. 이는 확장 정책의 세 번째 단계 조절을 기반으로 합니다(11의 30퍼센트인 3.3, 3으로 반내림).
- 지표 값이 40이 될 경우 Application Auto Scaling은 스케일 인 정책의 두 번째 단계 조절에 따라 확장 가능한 대상 용량을 1(14의 10%인 1.4, 1로 반내림) 줄여서 13으로 만듭니다. 이 용량 감소 후에도 지표 값이 30으로 떨어질 경우 Application Auto Scaling은 축소 정책의 세 번째 단계 조절에 따라 대상 용량을 3(13의 30%인 3.9, 3으로 반내림)만큼 더 줄여 10으로 만듭니다.

조정 정책에 대한 단계 조절을 지정할 때는 다음 사항에 유의합니다.

- 단계 조절의 범위는 중복되거나 격차가 있어서는 안 됩니다.
- 1단계 조절에만 null 하한값(negative infinity)이 포함될 수 있습니다. 1단계 조절에 음의 하한값이 포함될 경우, null 하한값으로 단계 조절을 해야 합니다.

- 1단계 조절에만 null 상한값(positive infinity)이 포함될 수 있습니다. 1단계 조절에 양의 상한값이 포함될 경우, null 상한값으로 단계 조절을 해야 합니다.
- 상한 및 하한값은 동일한 단계 조절에서 null이 될 수 없습니다.
- 지표 값이 위반 임계값을 초과할 경우, 하한값은 포함되고 상한값은 제외됩니다. 지표 값이 위반 임계값 미만일 경우, 하한값은 제외되고 상한값은 포함됩니다.

조정 조절 유형

선택한 조정 조절 유형에 따라 최적의 조정 작업을 수행하는 조정 정책을 정의할 수 있습니다. 조절 유형을 확장 가능 대상의 현재 용량의 백분율로 지정하거나 절대 숫자로 지정할 수 있습니다.

Application Auto Scaling은 다음과 같이 단계 조정 정책을 위한 조절 유형을 지원합니다.

- **ChangeInCapacity**—지정된 값만큼 확장 가능 대상의 현재 용량을 늘리거나 줄입니다. 양의 값은 용량을 늘리고, 음의 값은 용량을 줄입니다. 예: 현재 용량이 3이고 조절이 5인 경우 Application Auto Scaling은 용량에 5를 추가하여 총 8로 변경합니다.
- **ExactCapacity**—지정된 값만큼 확장 가능 대상의 현재 용량을 변경합니다. 이 조절 유형에는 음이 아닌 값을 지정합니다. 예: 현재 용량이 3이고 조절이 5인 경우 Application Auto Scaling은 용량을 5로 변경합니다.
- **PercentChangeInCapacity**—지정된 퍼센트만큼 확장 가능 대상의 현재 용량을 늘리거나 줄입니다. 양의 값은 용량을 늘리고, 음의 값은 용량을 줄입니다. 예: 현재 용량이 10이고 조절이 10퍼센트인 경우 Application Auto Scaling은 용량에 1을 추가하여 총 11로 변경합니다.

결과 값이 정수가 아닌 경우 Application Auto Scaling은 다음과 같이 반올림(반내림)합니다.

- 1보다 큰 값은 반내림합니다. 예컨대, 12.7은 12로 반내림합니다.
- 0과 1 사이의 값은 1로 반올림합니다. 예컨대, .67은 1로 반올림합니다.
- 0과 -1 사이의 값은 1로 반내림합니다. 예컨대, -.58은 -1으로 반올림합니다.
- -1보다 작은 값은 반올림합니다. 예를 들어, -6.67은 -6로 반올림합니다.

PercentChangeInCapacity에서 **MinAdjustmentMagnitude** 파라미터를 사용하여 최소 조정량을 지정할 수도 있습니다. 예를 들어 25%를 추가하는 정책을 생성하고 최소량으로 2를 지정한다고 가정해 보십시오. 확장 가능 대상의 용량이 4이고 조정 정책이 실행되는 경우, 4의 25%는 1이 됩니다. 그러나 최소 증분을 2로 지정했기 때문에 Application Auto Scaling은 2를 추가합니다.

휴지 기간

단계 조정 정책에서 휴지 기간을 선택적으로 정의할 수 있습니다.

이전 조정 활동이 적용될 때까지 기다리는 시간을 휴지 기간이라고 합니다.

단계별 조정 구성을 위해 휴지 기간 사용을 계획하는 두 가지 방법은 다음과 같습니다.

- 스케일 아웃 정책을 위한 휴지 기간을 사용하는 경우, 지속적이지만 과도하지는 않게 스케일 아웃하는 것이 목적입니다. Application Auto Scaling에서 조정 정책을 사용하여 성공적으로 스케일 아웃하면 휴지 기간이 계산되기 시작합니다. 조정 정책은 더 큰 스케일 아웃이 트리거되거나 휴지 기간이 종료되지 않는 한 원하는 용량을 다시 늘리지 않습니다. 확장 휴지 기간이 진행되는 동안 확장 활동을 시작하여 추가된 용량은 다음 확장 활동에 대해 원하는 용량의 일부로 계산됩니다.
- 스케일 인 정책을 위한 휴지 기간을 사용하는 경우 애플리케이션의 가용성을 보호하기 위해 보수적으로 확장하므로 스케일 인 휴지 기간이 만료될 때까지 스케일 인 활동이 차단됩니다. 그러나 축소 휴지 기간 중에 다른 경보가 확장 활동을 트리거하면 Application Auto Scaling은 대상을 즉시 확장합니다. 이 경우 스케일 인 휴지 기간이 중지되고 완료되지 않습니다.

예를 들어 트래픽 피크가 발생하면 경보가 트리거되고 Application Auto Scaling은 증가된 부하를 처리할 수 있도록 용량을 자동으로 추가합니다. 스케일 아웃 정책에 대해 휴지 기간을 설정한 경우 경보가 정책을 트리거하여 용량을 2로 늘리면 조정 활동이 성공적으로 완료되고 스케일 아웃 휴지 기간이 시작됩니다. 휴지 기간에 경보가 다시 트리거되지만 더 적극적인 단계 조정(3)에서 발생하는 경우, 이전의 증가치 2는 현재 용량의 일부로 간주됩니다. 따라서 용량은 1만 추가됩니다. 이렇게 하면 필요한 용량보다 더 추가하지 않아도 휴지 기간이 만료될 때까지 기다리는 것보다 빠르게 확장할 수 있습니다.

휴지 기간은 초 단위로 측정되며 정책 관련 조정 활동 조정에만 적용됩니다. 휴지 기간에 예약된 작업이 예약된 시간에 시작되면 휴지 기간이 만료될 때까지 기다리지 않고 조정 활동을 즉시 트리거할 수 있습니다.

값을 지정하지 않을 경우 기본값은 300입니다.

조정 정책 생성, 관리 및 삭제를 위해 일반적으로 사용되는 명령

조정 정책 작업에 일반적으로 사용되는 명령은 다음과 같습니다.

- [register-scalable-target](#) - AWS 또는 사용자 지정 리소스를 확장 가능 대상(Application Auto Scaling이 확장할 수 있는 리소스)으로 등록하고 조정을 일시 중지 및 재개합니다.
- [put-scaling-policy](#)를 사용하여 기존 확장 가능 대상에 대한 조정 정책을 추가하거나 수정할 수 있습니다.

- [describe-scaling-activities](#)를 사용하여 조정 작업에 대한 정보를 AWS 리전으로 반환할 수 있습니다.
- [describe-scaling-activities](#)를 사용하여 조정 정책에 대한 정보를 AWS 리전으로 반환할 수 있습니다.
- [delete-scaling-policy](#)를 사용하여 조정 정책을 삭제할 수 있습니다.

고려 사항

단계 조정 정책과 관련한 작업을 수행할 때는 다음 고려 사항이 적용됩니다.

- 단계 조정을 사용할 수 있을 만큼 애플리케이션의 단계 조정을 정확하게 예측할 수 있는지 생각해 보세요. 조정 지표가 스케일 아웃 가능한 대상의 용량에 비례하여 증가하거나 감소하는 경우, 대상 추적 조정 정책을 대신 사용하는 것이 좋습니다. 단계별 조정을 고급 구성에 대한 추가 정책으로 사용할 수도 있습니다. 예컨대, 사용률이 일정 수준에 도달할 때 더 공격적인 대응을 구성할 수 있습니다.
- 플래핑을 방지하려면 스케일 아웃 임계값과 스케일 인 임계값 사이에서 적절한 마진을 선택해야 합니다. 플래핑은 스케일 인과 스케일 아웃의 무한 루프입니다. 즉, 확장 작업을 진행하면 지표 값이 변경되고 반대 방향으로 다른 확장 작업이 시작됩니다.

관련 리소스

Auto Scaling의 단계 조정 정책 생성에 대한 자세한 내용은 Amazon EC2 Auto Scaling 사용 설명서의 [Amazon EC2 Auto Scaling 단계 및 단순 조정 정책](#)을 참조하세요.

콘솔 액세스

확장 가능한 리소스에 대한 단계 조정 정책을 확인, 추가, 업데이트 또는 제거할 수 있는 콘솔 액세스 권한은 사용하는 리소스에 따라 다릅니다. 자세한 내용은 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 단원을 참조하십시오.

를 사용하여 Application Auto Scaling에 대한 단계 조정 정책 생성 AWS CLI

이 예제에서는 AWS CLI 명령을 사용하여 Amazon ECS 서비스에 대한 단계 조정 정책을 생성합니다. 다른 규모 조정 가능 대상을 지정하려면 `--service-namespace`에 네임스페이스, `--scalable-dimension`에 규모 조정 가능 차원, `--resource-id`에 리소스 ID를 지정합니다.

를 사용할 때는 명령이 프로파일에 대해 AWS 리전 구성에서 실행된다는 점을 AWS CLI기억하세요. 다른 리전에서 명령을 실행하려는 경우 프로필의 기본 리전을 변경하거나 명령에 `--region` 파라미터를 사용합니다.

작업

- [1단계: 규모 조정 가능 대상 등록](#)
- [2단계: 단계 조정 정책 생성](#)
- [3단계: 조정 정책을 간접적으로 호출하는 경보 생성](#)

1단계: 규모 조정 가능 대상 등록

아직 하지 않았다면 확장 가능 대상을 등록합니다. [register-scalable-target](#) 명령을 사용하여 대상 서비스의 특정 리소스를 확장 가능 대상으로 등록합니다. 다음 예제에서는 Application Auto Scaling을 사용하여 Amazon ECS 서비스를 등록합니다. Application Auto Scaling에서는 태스크 수를 최소 2개와 최대 10개 사이에서 조정할 수 있습니다. *user input placeholder*를 사용자의 정보로 바꿉니다.

Linux, macOS 또는 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
```

출력

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다. 다음은 예제 출력입니다.

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

2단계: 단계 조정 정책 생성

규모 조정 가능 대상에 대한 단계 조정 정책을 생성하려면 시작하는 데 도움이 되는 다음 예제를 사용할 수 있습니다.

Scale out

스케일 아웃(용량 증가)을 위한 단계 조정 정책을 생성하려면

1. 다음 `cat` 명령을 사용하여 홈 디렉터리에 `config.json`이라는 JSON 파일에 단계 조정 정책 구성을 저장합니다. 아래는 다음과 같은 단계 조정을 기반으로 규모 조정 가능 대상의 용량을 증가시키는 `PercentChangeInCapacity` 조절 유형이 포함된 예제 구성입니다(CloudWatch 경보 임계값은 70으로 가정).
 - 지표의 값이 70보다 크거나 같지만 85보다 작으면 용량을 10% 증가시킵니다.
 - 지표의 값이 85보다 크거나 같지만 95보다 작으면 용량을 20% 증가시킵니다.
 - 지표의 값이 95보다 크거나 같으면 용량을 30% 증가시킵니다.

```
$ 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
    }
  ]
}
```

자세한 내용은 Application Auto Scaling API 참조의 [StepScalingPolicyConfiguration](#)을 참조하세요.

- 다음 `put-scaling-policy` 명령을 생성한 `config.json` 파일과 함께 사용하여 `my-step-scaling-policy`라는 조정 정책을 생성합니다.

Linux, macOS 또는 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
```

출력

출력에는 해당 정책의 고유 이름 역할을 하는 ARN이 포함됩니다. 정책에 대한 CloudWatch 경보를 생성하는 데 필요합니다. 다음은 예제 출력입니다.

```
{
  "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

스케일 인(용량 감소)을 위한 단계 조정 정책을 생성하려면

- 다음 `cat` 명령을 사용하여 홈 디렉터리에 `config.json`이라는 JSON 파일에 단계 조정 정책 구성을 저장합니다. 아래는 다음과 같은 단계 조절을 기반으로 규모 조정 가능 대상의 용량을 감소시키는 `ChangeInCapacity` 조절 유형이 포함된 예제 구성입니다(CloudWatch 경보 임계값은 50으로 가정).

- 지표 값이 40 이상이고 50 이하이면 용량을 1 감소시킵니다.
- 지표 값이 30 이상이고 40 이하이면 용량을 2 감소시킵니다.
- 지표 값이 30 이상이면 용량을 3 감소시킵니다.

```
$ 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
    }
  ]
}
```

자세한 내용은 Application Auto Scaling API 참조의 [StepScalingPolicyConfiguration](#)을 참조하세요.

2. 다음 [put-scaling-policy](#) 명령을 생성한 config.json 파일과 함께 사용하여 my-step-scaling-policy라는 조정 정책을 생성합니다.

Linux, macOS 또는 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
```

출력

출력에는 해당 정책의 고유 이름 역할을 하는 ARN이 포함됩니다. 정책에 대한 CloudWatch 경보를 생성하는 데 이 ARN이 필요합니다. 다음은 예제 출력입니다.

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

3단계: 조정 정책을 간접적으로 호출하는 경보 생성

마지막으로 다음 CloudWatch [put-metric-alarm](#) 명령을 사용하여 단계적 조정 정책에 사용할 경보를 생성합니다. 이 예제에서는 평균 CPU 사용률을 기반으로 하는 경보를 사용합니다. 이 경보는 최소 2회 이상 연속되는 60초 평가 기간에 70%의 임계값에 도달하면 ALARM 상태가 되도록 구성합니다. 다른 CloudWatch 지표를 지정하거나 사용자 지정 지표를 사용하려면 `--metric-name`에 이름을 지정하고 `--namespace`에 네임스페이스를 지정합니다.

Linux, macOS 또는 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
```

를 사용하여 Application Auto Scaling에 대한 단계 조정 정책 설명 AWS CLI

[describe-scaling-policies](#) 명령을 사용하여 특정 서비스 네임스페이스에 대한 모든 조정 정책을 설명할 수 있습니다. 다음 예제에서는 모든 Amazon ECS 서비스에 대한 모든 조정 정책을 설명합니다. 특정 Amazon ECS 서비스에 대해 나열하려면 `--resource-id` 옵션만 추가합니다.

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

`--query` 파라미터를 사용하여 단계 조정 정책으로 결과를 필터링할 수 있습니다. `query`의 구문에 대한 자세한 내용은 AWS Command Line Interface 사용 설명서의 [AWS CLI의 명령 출력 제어](#)를 참조하세요.

Linux, macOS 또는 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`]"
```

출력

다음은 예제 출력입니다.

```
[
  {
```

```
"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
}
]
```

를 사용하여 Application Auto Scaling에 대한 단계 조정 정책 삭제 AWS CLI

더 이상 필요 없는 단계적 조정 정책은 삭제할 수 있습니다. 조정 정책과 연결된 CloudWatch 경보를 모두 삭제하려면 다음 태스크를 완료합니다.

조정 정책을 삭제하려면

[delete-scaling-policy](#) 명령을 사용합니다.

Linux, macOS 또는 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
```

CloudWatch 경보를 삭제하려면

[delete-alarms](#) 명령을 사용합니다. 한 번에 하나 이상의 경보를 삭제할 수 있습니다. 예컨대, 다음 명령을 사용하여 Step-Scaling-AlarmHigh-ECS:service/my-cluster/my-service 및 Step-Scaling-AlarmLow-ECS:service/my-cluster/my-service 경보를 삭제합니다.

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

Application Auto Scaling의 예측 조정

예측 조정은 애플리케이션을 사전에 조정합니다. 예측 조정은 과거 로드 데이터를 분석하여 트래픽 흐름의 일별 또는 주별 패턴을 감지합니다. 이 정보를 사용하여 예상되는 부하에 맞게 애플리케이션의 용량을 사전에 늘려야 하는 향후 용량을 예측합니다.

예측 조정은 다음과 같은 상황에 매우 적합합니다.

- 주기적 트래픽(예: 정규 업무 시간 동안 리소스 사용량이 많고 저녁 및 주말에는 리소스가 적게 사용되는 경우)
- 배치 처리, 테스트 또는 주기적 데이터 분석과 같은 반복적인 on-and-off 워크로드 패턴.
- 초기화하는 데 시간이 오래 걸려 스케일 아웃 이벤트 중에 애플리케이션 성능에 눈에 띄는 지연 영향을 받는 애플리케이션

내용

- [Application Auto Scaling 예측 조정 작동 방식](#)
- [Application Auto Scaling에 대한 예측 조정 정책 생성](#)
- [예약된 작업을 사용하여 예측 값 재정의](#)
- [사용자 정의 지표를 사용하는 고급 예측 조정 정책](#)

Application Auto Scaling 예측 조정 작동 방식

예측 조정을 사용하려면 모니터링 및 분석할 CloudWatch 지표를 지정하는 예측 조정 정책을 생성합니다. 사전 정의된 지표 또는 사용자 지정 지표를 사용할 수 있습니다. 예측 조정이 미래 값 예측을 시작하려면 이 지표에 24시간 이상의 데이터가 있어야 합니다.

정책을 생성한 후 예측 조정은 패턴을 식별하기 위해 지난 14일까지의 지표 데이터를 분석하기 시작합니다. 이 분석을 사용하여 향후 48시간의 용량 요건에 대한 시간별 예측을 생성합니다. 예측은 최신 CloudWatch 데이터를 사용하여 6시간마다 업데이트됩니다. 새로운 데이터가 들어오면 예측 조정을 통해 향후 예측의 정확도를 지속적으로 개선할 수 있습니다.

먼저 예측 전용 모드에서 예측 조정을 활성화할 수 있습니다. 이 모드에서는 용량 예측을 생성하지만 실제로는 이러한 예측을 기반으로 용량을 조정하지 않습니다. 이를 통해 예측의 정확성과 적합성을 평가할 수 있습니다.

예측 데이터를 검토하고 해당 데이터를 기반으로 조정을 시작하기로 결정한 후에 조정 정책을 예측 및 조정 모드로 전환합니다. 이 모드에서는 다음을 수행합니다.

- 예측에서 부하가 증가할 것으로 예상되는 경우 예측 규모 조정은 용량을 증가시킵니다.
- 예측에서 부하가 감소할 것으로 예상되는 경우 예측 조정은 용량을 제거하기 위해 축소되지 않습니다. 이렇게 하면 예측뿐만 아니라 수요가 실제로 감소할 때만 스케일 인할 수 있습니다. 더 이상 필요하지 않은 용량을 제거하려면 실시간 지표 데이터에 응답하기 때문에 대상 추적 또는 단계 조정 정책을 생성해야 합니다.

기본적으로 예측 조정은 해당 시간에 대한 예측을 기반으로 매 시간 시작 시 확장 가능 대상을 조정합니다. 선택적으로 PutScalingPolicy API 작업에서 SchedulingBufferTime 속성을 사용하여 더 빠른 시작 시간을 지정할 수 있습니다. 이렇게 하면 예상 수요보다 앞서 예상 용량을 시작할 수 있으므로 새 용량이 트래픽을 처리할 준비가 될 충분한 시간을 확보할 수 있습니다.

최대 용량 제한

기본적으로 조정 정책이 설정되면 용량을 최대 용량보다 크게 늘일 수 없습니다.

또는 예측 용량이 확장 가능 대상의 최대 용량에 근접하거나 초과하는 경우 확장 가능 대상의 최대 용량을 자동으로 늘리도록 허용할 수 있습니다. 이 동작을 활성화하려면 PutScalingPolicy API 작업에서 MaxCapacityBreachBehavior 및 MaxCapacityBuffer 속성을 사용하거나 AWS Management Console에서 최대 용량 동작 설정을 사용합니다.

Warning

최대 용량을 자동으로 늘리도록 허용할 때에는 주의해야 합니다. 최대 용량은 원래 최대 용량으로 자동으로 감소하지 않습니다.

조정 정책 생성, 관리 및 삭제를 위해 일반적으로 사용되는 명령

예측 조정 정책 작업에 일반적으로 사용되는 명령은 다음과 같습니다.

- register-scalable-target 확장 가능 대상으로 AWS 또는 사용자 지정 리소스를 등록하고, 조정을 일시 중지하고, 조정을 재개합니다.
- put-scaling-policy 예측 조정 정책을 생성합니다.
- get-predictive-scaling-forecast 예측 조정 정책에 대한 예측 데이터를 검색합니다.

- `describe-scaling-activities`에서 조정 활동에 대한 정보를 반환합니다 AWS 리전.
- `describe-scaling-policies`에서 조정 정책에 대한 정보를 반환합니다 AWS 리전.
- `delete-scaling-policy` 조정 정책을 삭제합니다.

사용자 지정 지표

사용자 지정 지표를 사용하여 애플리케이션에 필요한 용량을 예측할 수 있습니다. 사용자 지정 지표는 사전 정의된 지표가 애플리케이션의 로드를 캡처하기에 충분하지 않을 때 유용합니다.

고려 사항

예측 조정 작업 시 다음 고려 사항이 적용됩니다.

- 예측 조정이 애플리케이션에 적합한지 확인합니다. 애플리케이션은 요일 또는 시간에 특정한 반복 로드 패턴을 보이는 경우 예측 조정에 적합합니다. 예측 규모 조정이 애플리케이션을 적극적으로 확장하도록 하기 전에 예측을 평가합니다.
- 예측 조정이 예상을 시작하려면 최소 24시간 동안의 기록 데이터가 필요합니다. 그러나 기록 데이터가 2주 전체에 걸쳐 있는 경우, 예측이 더 정확합니다.
- 애플리케이션의 전체 로드를 정확하게 나타내고 확장해야 하는 애플리케이션의 측면인 부하 지표를 선택합니다.

Application Auto Scaling에 대한 예측 조정 정책 생성

다음 예제 정책은 AWS CLI 를 사용하여 Amazon ECS 서비스에 대한 예측 조정 정책을 구성합니다. *user input placeholder*를 사용자의 정보로 바꿉니다.

지정 가능한 CloudWatch 지표에 대한 자세한 내용은 Amazon EC2 Auto Scaling API 참조의 [PredictiveScalingMetricSpecification](#)을 참조하세요.

다음은 사전 정의된 메모리 구성이 있는 예제 정책입니다.

```
cat policy.json
{
  "MetricSpecifications": [
    {
      "TargetValue": 40,
      "PredefinedMetricPairSpecification": {
```

```

        "PredefinedMetricType": "ECSServiceMemoryUtilization"
    }
}
],
"SchedulingBufferTime": 3600,
"MaxCapacityBreachBehavior": "HonorMaxCapacity",
"Mode": "ForecastOnly"
}

```

다음 예제에서는 지정된 구성 파일로 [put-scaling-policy](#) 명령을 실행하여 정책을 생성하는 것을 보여줍니다.

```

aws aas put-scaling-policy \
--service-namespace ecs \
--region us-east-1 \
--policy-name predictive-scaling-policy-example \
--resource-id service/MyCluster/test \
--policy-type PredictiveScaling \
--scalable-dimension ecs:service:DesiredCount \
--predictive-scaling-policy-configuration file://policy.json

```

이 명령이 제대로 실행되면 정책의 ARN이 반환됩니다.

```

{
  "PolicyARN": "arn:aws:autoscaling:us-east-1:012345678912:scalingPolicy:d1d72dfe-5fd3-464f-83cf-824f16cb88b7:resource/ecs/service/MyCluster/test:policyName/predictive-scaling-policy-example",
  "Alarms": []
}

```

예약된 작업을 사용하여 예측 값 재정의

경우에 따라 예상 계산에서 고려할 수 없는 향후 애플리케이션 필요량에 대한 추가 정보가 있을 수 있습니다. 예컨대, 예상 계산은 향후 마케팅 이벤트에 필요한 용량을 과소 평가할 수 있습니다. 예약된 작업을 사용하여 미래 기간에 대한 예상을 임시로 재정의할 수 있습니다. 예약된 작업은 반복적으로 실행되거나 일회성 수요 변동이 있는 특정 날짜 및 시간에 실행될 수 있습니다.

예컨대, 예상한 것보다 높은 최소 용량으로 예약된 작업을 생성할 수 있습니다. 실행 시간에 Application Auto Scaling은 확장 가능 대상의 최소 용량을 업데이트합니다. 예측 조정은 용량에 맞게 최적화하므로 최소 용량이 예상 값보다 높은 예약된 작업이 적용됩니다. 이렇게 하면 용량이 예상보다

작아지는 것을 방지할 수 있습니다. 예상 재정의의 중지하려면 두 번째 예약된 작업을 사용하여 최소 용량을 원래 설정으로 되돌립니다.

다음 절차에서는 미래 기간의 예상을 재정의하는 단계를 간략하게 설명합니다.

주제

- [1단계: \(옵션\) 시계열 데이터 분석](#)
- [2단계: 2개의 예약된 작업 생성](#)

Important

이 주제에서는 예측보다 더 큰 용량으로 확장하기 위해 예측을 재정의한다고 가정합니다. 예측 조정 정책의 간섭 없이 일시적으로 용량을 줄여야 하는 경우 예측 전용 모드를 대신 사용합니다. 예측 전용 모드에서 예측 조정은 계속 예측을 생성하지만 용량이 자동으로 증가하지는 않습니다. 그런 다음 리소스 사용률을 모니터링하고 필요에 따라 그룹의 크기를 수동으로 줄일 수 있습니다.

1단계: (옵션) 시계열 데이터 분석

예상 시계열 데이터 분석으로 시작합니다. 이 단계는 선택 사항이지만 예상의 세부 정보를 파악하려는 경우, 유용합니다.

1. 예상 검색

예상이 생성되면 예상에서 특정 기간을 쿼리할 수 있습니다. 쿼리의 목표는 특정 기간에 대한 시계열 데이터의 전체 보기를 얻는 것입니다.

쿼리에는 최대 2일간의 미래 예상 데이터가 포함될 수 있습니다. 예측 조정을 잠시 사용한 경우에도 과거 예상 데이터에 액세스할 수 있습니다. 그러나 시작 시간과 해지 시간 사이의 최대 기간은 30일입니다.

예측을 검색하려면 [get-predictive-scaling-forecast](#) 명령을 사용합니다. 다음 예시에서는 Amazon ECS 서비스에 대한 예측 조정 예측을 가져옵니다.

```
aws application-autoscaling get-predictive-scaling-forecast --service-namespace ecs \
  --scalable-dimension ecs:service:DesiredCount \
  --resource-id 1234567890abcdef0
```

```
--policy-name predictive-scaling-policy \  
--start-time "2021-05-19T17:00:00Z" \  
--end-time "2021-05-19T23:00:00Z"
```

응답에는 LoadForecast 및의 두 가지 예측이 포함됩니다CapacityForecast.는 시간별 로드 예측을 LoadForecast 보여줍니다.는 지정된를 유지하면서 예측된 로드를 처리하는 데 시간별로 필요한 용량의 예측 값을 CapacityForecast 보여줍니다TargetValue.

2. 대상 기간 식별

일회성 수요 변동이 발생해야 하는 시간을 식별합니다. 예상에 표시된 날짜와 시간은 UTC입니다.

2단계: 2개의 예약된 작업 생성

다음으로, 애플리케이션의 예상 로드보다 높은 특정 기간에 대해 2개의 예약된 작업을 생성합니다. 예컨대, 제한된 기간에 사이트에 대한 트래픽을 높이는 마케팅 이벤트가 있는 경우, 이벤트 시작 시 최소 용량을 업데이트하는 일회성 작업을 예약할 수 있습니다. 그런 다음 이벤트가 해지 시 최소 용량을 원래 설정으로 되돌리도록 다른 작업을 예약합니다.

일회성 이벤트에 대해 2개의 예약된 작업을 생성하려면(AWS CLI)

예약된 작업을 생성하려면 [put-scheduled-action](#) 명령을 사용합니다.

다음 예제에서는 5월 19일 오후 5시에 8시간 동안 인스턴스 3개의 최소 용량을 유지하는 Amazon EC2 Auto Scaling 일정을 정의합니다. 다음 명령은 이 시나리오를 구현하는 방법을 보여 줍니다.

첫 번째 [put-scheduled-update-group-action](#) 명령은 2021년 5월 19일 오후 5시(UTC)에 지정된 Auto Scaling 그룹의 최소 용량을 업데이트하도록 Amazon EC2 Auto Scaling에 지시합니다.

```
aws autoscaling put-scheduled-update-group-action --scheduled-action-name my-event-start \  
--auto-scaling-group-name my-asg --start-time "2021-05-19T17:00:00Z" --minimum-capacity 3
```

두 번째 명령은 그룹의 최소 용량을 2021년 5월 20일 오전 1시(UTC)의 용량으로 설정하도록 Amazon EC2 Auto Scaling에 지시합니다.

```
aws autoscaling put-scheduled-update-group-action --scheduled-action-name my-event-end \  
--auto-scaling-group-name my-asg --start-time "2021-05-20T01:00:00Z" --minimum-capacity 1
```

이러한 예약된 작업을 Auto Scaling 그룹에 추가하면 Amazon EC2 Auto Scaling은 다음을 수행합니다.

- 2021년 5월 19일 오후 5시(UTC)에 첫 번째 예약된 작업이 실행됩니다. 현재 해당 그룹에 인스턴스가 3개 미만 있는 경우, 그룹은 인스턴스 3개로 스케일 아웃됩니다. 이 시간과 향후 8시간 동안 예측 용량이 실제 용량보다 높거나 동적 조정 정책이 적용되는 경우, Amazon EC2 Auto Scaling이 계속 스케일 아웃을 수행할 수 있습니다.
- 2021년 5월 20일 오전 1시(UTC)에 두 번째 예약된 작업이 실행됩니다. 이렇게 하면 이벤트 해지 시 최소 용량이 원래 설정으로 돌아갑니다.

반복 일정에 따라 크기 조정

매주 동일한 기간에 대한 예상을 재정의하려면 두 개의 예약된 작업을 생성하고 cron 표현식을 사용하여 시간 및 날짜 로직을 제공합니다.

cron 표현식 형식은 다음과 같이 공백으로 구분된 다섯 개의 필드로 구성됩니다. [Minute] [Hour] [Day_of_Month] [Month_of_Year] [Day_of_Week]. 필드에는 특수 문자를 포함하여 허용되는 모든 값을 포함할 수 있습니다.

예컨대, 다음 cron 표현식은 매주 화요일 오전 6시 30분에 작업을 실행합니다. 별표는 필드의 모든 값을 일치시키기 위한 와일드카드로 사용됩니다.

```
30 6 * * 2
```

사용자 정의 지표를 사용하는 고급 예측 조정 정책

예측적 조정 정책에서는 미리 정의된 지표나 사용자 정의 지표를 사용할 수 있습니다. 사용자 지정 지표는 사전 정의된 지표가 애플리케이션 로드를 충분히 설명하지 못하는 경우에 유용합니다.

사용자 지정 지표를 사용하여 예측 조정 정책을 생성할 때에서 제공하는 다른 CloudWatch 지표를 지정 AWS하거나 직접 정의하고 게시하는 지표를 지정할 수 있습니다. 지표 수학을 사용하여 기존 지표를 집계하고 자동으로 추적되지 AWS 않는 새 시계열로 변환할 수도 있습니다. 예컨대, 새 합계 또는 평균을 계산하여 데이터의 값을 결합하는 것을 집계라고 합니다. 결과 데이터를 집계라고 합니다.

다음 섹션에는 정책의 JSON 구조를 구성하는 방법에 대한 모범 사례와 예가 나와 있습니다.

주제

- [모범 사례](#)

- [사전 조건](#)
- [사용자 지정 지표를 위한 JSON 구성](#)
- [예측 조정 정책에서 사용자 정의 지표 사용 시 고려 사항](#)

모범 사례

다음 모범 사례는 사용자 정의 지표를 보다 효과적으로 사용하는 데 도움이 될 수 있습니다.

- 로드 지표 사양의 경우 가장 유용한 지표는 애플리케이션의 로드를 나타내는 지표입니다.
- 조정 지표는 용량에 반비례해야 합니다. 즉, 확장 가능 대상이 증가하면 조정 지표가 거의 동일한 비율로 감소해야 합니다. 예측적 조정이 예상대로 작동하게 하려면 로드 지표와 조정 지표도 서로 밀접한 상관 관계가 있어야 합니다.
- 목표 사용률은 조정 지표 유형과 일치해야 합니다. CPU 사용률을 사용하는 정책 구성의 경우, 이는 목표 백분율입니다. 요청 또는 메시지 수와 같이 처리량을 사용하는 정책 구성의 경우, 이는 1분 간격 동안 인스턴스당 요청 또는 메시지의 대상 수입니다.
- 이러한 권장 사항을 따르지 않으면 시계열의 예측된 미래 값이 정확하지 않을 수 있습니다. 데이터가 올바른지 검증하기 위해 예측된 값을 볼 수 있습니다. 또는 예측적 조정 정책을 생성한 후 [GetPredictiveScalingForecast](#) API 호출에서 반환된 LoadForecast 및 CapacityForecast 객체를 검사합니다.
- 예측적 조정이 능동적으로 용량 조정을 시작하기 전에 예상을 평가할 수 있게 예상 전용 모드에서 예측적 조정을 구성하는 것이 좋습니다.

사전 조건

정책에서 사용자 지정 지표를 지정하려면 `cloudwatch:GetMetricData` 권한이 있어야 합니다.

에서 AWS 제공하는 지표 대신 자체 지표를 지정하려면 먼저 지표를 CloudWatch에 게시해야 합니다. 자세한 설명은 Amazon CloudWatch 사용 설명서의 [사용자 정의 지표 게시](#)를 참조하세요.

자체 지표를 게시하는 경우, 최소 5분 간격으로 데이터 요소를 게시해야 합니다. Application Auto Scaling은 필요한 기간 길이를 기준으로 CloudWatch에서 데이터 포인트를 검색합니다. 예컨대, 로드 지표 사양은 시간별 지표를 사용하여 애플리케이션의 로드를 측정합니다. CloudWatch는 게시된 지표 데이터로 각 1시간 기간에 속하는 타임스탬프가 있는 모든 데이터 요소를 집계하여 1시간 기간 동안 단일 데이터 값을 제공합니다.

사용자 지정 지표를 위한 JSON 구성

다음 섹션에는 Amazon EC2 Auto Scaling용 CloudWatch에서 데이터를 쿼리하도록 예측 조정을 구성하는 방법에 대한 예제가 포함되어 있습니다. 이 옵션을 구성하는 방법에는 두 가지가 있으며 선택하는 방법에 따라 예측 조정 정책에 사용할 JSON을 구성하는 데 사용하는 형식이 달라집니다. 지표 수학을 사용하는 경우, JSON의 형식은 수행되는 지표 수학에 따라 더 달라집니다.

1. 에서 제공하는 다른 CloudWatch 지표 AWS 또는 CloudWatch에 게시하는 지표에서 직접 데이터를 가져오는 정책을 생성하려면 섹션을 참조하세요 [사용자 지정 로드 및 조정 지표가 있는 예측 조정 정책의 예\(AWS CLI\)](#).
2. 여러 CloudWatch 지표를 쿼리하고 수학 표현식을 사용하여 이러한 지표에 근거하여 새 시계열을 생성할 수 있는 정책을 생성하려면 [지표 수학 표현식 사용](#)를 참조하세요.

사용자 지정 로드 및 조정 지표가 있는 예측 조정 정책의 예(AWS CLI)

를 사용하여 사용자 지정 로드 및 조정 지표를 사용하여 예측 조정 정책을 생성하려면 라는 JSON 파일에 `--predictive-scaling-configuration`에 대한 인수를 AWS CLI저장합니다 `config.json`.

다음 예에서 교체 가능한 값을 지표 및 목표 사용률의 값으로 교체하여 사용자 지정 지표를 추가하기 시작합니다.

```
{
  "MetricSpecifications": [
    {
      "TargetValue": 50,
      "CustomizedScalingMetricSpecification": {
        "MetricDataQueries": [
          {
            "Id": "scaling_metric",
            "MetricStat": {
              "Metric": {
                "MetricName": "MyUtilizationMetric",
                "Namespace": "MyNameSpace",
                "Dimensions": [
                  {
                    "Name": "MyOptionalMetricDimensionName",
                    "Value": "MyOptionalMetricDimensionValue"
                  }
                ]
              }
            }
          }
        ]
      }
    }
  ],
}
```

```

        "Stat": "Average"
      }
    }
  ],
  "CustomizedLoadMetricSpecification": {
    "MetricDataQueries": [
      {
        "Id": "load_metric",
        "MetricStat": {
          "Metric": {
            "MetricName": "MyLoadMetric",
            "Namespace": "MyNameSpace",
            "Dimensions": [
              {
                "Name": "MyOptionalMetricDimensionName",
                "Value": "MyOptionalMetricDimensionValue"
              }
            ]
          },
          "Stat": "Sum"
        }
      }
    ]
  }
}

```

자세한 설명은 Amazon EC2 Auto Scaling API 참조의 [MetricDataQuery](#)를 참조하세요.

Note

다음은 CloudWatch 지표에 대한 지표 이름, 네임스페이스, 차원 및 통계를 찾는 데 도움이 되는 몇 가지 추가 리소스입니다.

- AWS 서비스에 사용할 수 있는 지표에 대한 자세한 내용은 Amazon [AWS CloudWatch 사용 설명서의 CloudWatch 지표를 게시하는 서비스를](#) 참조하세요. Amazon CloudWatch 를 사용하여 CloudWatch 지표의 정확한 지표 이름, 네임스페이스 및 차원(해당하는 경우)을 가져오려면 [list-metrics](#)를 AWS CLI참조하세요.

이 정책을 생성하려면 다음 예에 나와 있는 것처럼 JSON 파일을 입력으로 사용하여 [put-scaling-policy](#) 명령을 실행합니다.

```
aws autoscaling put-scaling-policy --policy-name my-predictive-scaling-policy \
  --auto-scaling-group-name my-asg --policy-type PredictiveScaling \
  --predictive-scaling-configuration file://config.json
```

이 명령이 제대로 실행되면 정책의 Amazon 리소스 이름(ARN)을 반환합니다.

```
{
  "PolicyARN": "arn:aws:autoscaling:region:account-id:scalingPolicy:2f4f5048-d8a8-4d14-b13a-d1905620f345:autoScalingGroupName/my-asg:policyName/my-predictive-scaling-policy",
  "Alarms": []
}
```

지표 수학 표현식 사용

다음 섹션에서는 정책에서 지표 수학을 사용하는 방법을 보여 주는 예측 조정 정책의 정보와 예를 제공합니다.

주제

- [지표 수학 이해](#)
- [지표 수학을 사용하여 지표를 결합하는 Amazon EC2 Auto Scaling에 대한 예측 조정 정책 예제 \(AWS CLI\)](#)
- [블루/그린 배치 시나리오에서 사용할 예측 조정 정책의 예\(AWS CLI\)](#)

지표 수학 이해

기존 지표 데이터를 집계하기만 하면 CloudWatch 지표 수학을 통해 CloudWatch에 다른 지표를 게시하는 데 드는 노력과 비용을 절약할 수 있습니다. 에서 AWS 제공하는 모든 지표를 사용할 수 있으며 애플리케이션의 일부로 정의한 지표를 사용할 수도 있습니다.

자세한 설명은 Amazon CloudWatch 사용 설명서의 [지표 수학 사용](#)을 참조하세요.

예측적 조정 정책에서 지표 수학 표현식을 사용하기로 선택한 경우, 다음 사항을 고려하세요.

- 지표 수학 연산은 고유한 조합의 지표 이름, 네임스페이스 및 지표의 차원 키/값 페어의 데이터 요소를 사용합니다.

- 산술 연산자(+ - * / ^), 통계 함수(예: AVG 또는 SUM) 또는 CloudWatch에서 지원하는 기타 함수를 사용할 수 있습니다.
- 수학 표현식의 공식에서 지표 및 다른 수학 표현식의 결과를 모두 사용할 수 있습니다.
- 지표 수학 표현식은 다양한 집계로 구성될 수 있습니다. 그러나 최종 집계 결과에서 조정 지표에는 Average를 사용하고 로드 지표에는 Sum을 사용하는 것이 가장 좋습니다.
- 지표 사양에 사용된 표현식은 결국 단일 시계열을 반환해야 합니다.

지표 수학을 사용하려면 다음을 수행합니다.

- 하나 이상의 CloudWatch 지표를 선택합니다. 그런 다음 표현식을 생성합니다. 자세한 설명은 Amazon CloudWatch 사용자 가이드의 [지표 수학 사용](#)을 참조하세요.
- CloudWatch 콘솔 또는 CloudWatch [GetMetricData](#) API를 사용하여 지표 수학 표현식이 유효한지 확인합니다.

지표 수학을 사용하여 지표를 결합하는 Amazon EC2 Auto Scaling에 대한 예측 조정 정책 예제(AWS CLI)

지표를 직접 지정하는 대신 어떤 방식으로든 해당 데이터를 먼저 처리해야 하는 경우가 있습니다. 예컨대, Amazon SQS 대기열에서 작업을 가져오는 애플리케이션이 있고 대기열의 항목 수를 예측적 조정의 기준으로 사용할 수 있습니다. 대기열의 메시지 수가 필요한 인스턴스 수를 단독으로 정의하지 않습니다. 따라서 인스턴스당 백로그를 계산하는 데 사용할 수 있는 지표를 생성하려면 더 많은 작업이 필요합니다.

다음은 이 시나리오에 대한 예측적 조정 정책의 예입니다. 대기열에서 검색할 수 있는 메시지 수인 Amazon SQS ApproximateNumberOfMessagesVisible 지표를 기준으로 하는 조정 및 로드 지표를 지정합니다. 또한 Amazon EC2 Auto Scaling GroupInServiceInstances 지표와 수학 표현식을 사용하여 조정 지표에 대한 인스턴스당 백로그를 계산합니다.

```
aws autoscaling put-scaling-policy --policy-name my-sqs-custom-metrics-policy \
  --auto-scaling-group-name my-asg --policy-type PredictiveScaling \
  --predictive-scaling-configuration file://config.json
{
  "MetricSpecifications": [
    {
      "TargetValue": 100,
      "CustomizedScalingMetricSpecification": {
        "MetricDataQueries": [
          {
```

```

    "Label": "Get the queue size (the number of messages waiting to be
processed)",
    "Id": "queue_size",
    "MetricStat": {
      "Metric": {
        "MetricName": "ApproximateNumberOfMessagesVisible",
        "Namespace": "AWS/SQS",
        "Dimensions": [
          {
            "Name": "QueueName",
            "Value": "my-queue"
          }
        ]
      },
      "Stat": "Sum"
    },
    "ReturnData": false
  },
  {
    "Label": "Get the group size (the number of running instances)",
    "Id": "running_capacity",
    "MetricStat": {
      "Metric": {
        "MetricName": "GroupInServiceInstances",
        "Namespace": "AWS/AutoScaling",
        "Dimensions": [
          {
            "Name": "AutoScalingGroupName",
            "Value": "my-asg"
          }
        ]
      },
      "Stat": "Sum"
    },
    "ReturnData": false
  },
  {
    "Label": "Calculate the backlog per instance",
    "Id": "scaling_metric",
    "Expression": "queue_size / running_capacity",
    "ReturnData": true
  }
]
},

```

```

    "CustomizedLoadMetricSpecification": {
      "MetricDataQueries": [
        {
          "Id": "load_metric",
          "MetricStat": {
            "Metric": {
              "MetricName": "ApproximateNumberOfMessagesVisible",
              "Namespace": "AWS/SQS",
              "Dimensions": [
                {
                  "Name": "QueueName",
                  "Value": "my-queue"
                }
              ],
            },
            "Stat": "Sum"
          },
          "ReturnData": true
        }
      ]
    }
  ]
}

```

이 예에서는 정책의 ARN을 반환합니다.

```

{
  "PolicyARN": "arn:aws:autoscaling:region:account-id:scalingPolicy:2f4f5048-d8a8-4d14-b13a-d1905620f345:autoScalingGroupName/my-asg:policyName/my-sqs-custom-metrics-policy",
  "Alarms": []
}

```

블루/그린 배치 시나리오에서 사용할 예측 조정 정책의 예(AWS CLI)

검색 표현식은 여러 Auto Scaling 그룹에서 지표를 쿼리하고 이에 대해 수학 표현식을 수행할 수 있는 고급 옵션을 제공합니다. 이는 특히 블루/그린 배치에 유용합니다.

Note

블루/그린 배치는 두 개의 별개이지만 동일한 Auto Scaling 그룹을 생성하는 배치 방법입니다. 그룹 중 하나만 프로덕션 트래픽을 수신합니다. 사용자 트래픽은 초기에 이전("블루") Auto

Scaling 그룹으로 전달되는 반면 새 그룹("그린")은 새 버전의 애플리케이션 또는 서비스를 테스트하고 평가하는 데 사용됩니다. 새 배치가 테스트되고 수락되면 사용자 트래픽이 그린 Auto Scaling 그룹으로 이동됩니다. 그런 다음 배치가 성공한 후 블루 그룹을 삭제할 수 있습니다.

새로운 Auto Scaling 그룹이 블루/그린 배치의 일부로 생성되면 해당 지표 사양을 변경하지 않고도 각 그룹의 지표 기록이 예측적 조정 정책에 자동으로 포함될 수 있습니다. 자세한 내용은 AWS 컴퓨팅 블로그의 [블루/그린 배포에서 EC2 Auto Scaling 예측 조정 정책 사용을 참조하세요](#).

다음 예 정책은 이를 수행하는 방법을 보여줍니다. 이 예에서 정책은 Amazon EC2에서 내보낸 CPUUtilization 지표를 사용합니다. Amazon EC2 Auto Scaling GroupInServiceInstances 지표와 수학 표현식을 사용하여 인스턴스당 조정 지표 값을 계산합니다. 또한 GroupInServiceInstances 지표를 가져오기 위한 용량 지표 사양을 지정합니다.

검색 표현식은 지정된 검색 기준에 따라 여러 Auto Scaling 그룹에서 인스턴스의 CPUUtilization을 찾습니다. 나중에 동일한 검색 기준과 일치하는 새 Auto Scaling 그룹을 생성하면 새 Auto Scaling 그룹에 있는 인스턴스의 CPUUtilization이 자동으로 포함됩니다.

```
aws autoscaling put-scaling-policy --policy-name my-blue-green-predictive-scaling-policy \
  --auto-scaling-group-name my-asg --policy-type PredictiveScaling \
  --predictive-scaling-configuration file://config.json
{
  "MetricSpecifications": [
    {
      "TargetValue": 25,
      "CustomizedScalingMetricSpecification": {
        "MetricDataQueries": [
          {
            "Id": "load_sum",
            "Expression": "SUM(SEARCH('{AWS/EC2,AutoScalingGroupName} MetricName=
\"CPUUtilization\" ASG-myapp', 'Sum', 300))",
            "ReturnData": false
          },
          {
            "Id": "capacity_sum",
            "Expression": "SUM(SEARCH('{AWS/AutoScaling,AutoScalingGroupName}
MetricName=\"GroupInServiceInstances\" ASG-myapp', 'Average', 300))",
            "ReturnData": false
          },
          {
```


- 표현식을 미리 검증하지 않은 경우 [put-scaling-policy](#) 명령은 조정 정책을 생성할 때 해당 표현식을 검증합니다. 그러나 이 명령이 발견된 오류의 정확한 원인을 식별하지 못할 수도 있습니다. 문제를 해결하려면 [get-metric-data](#) 명령에 대한 요청의 응답에서 수신하는 오류를 해결합니다. CloudWatch 콘솔에서 표현식의 문제를 해결할 수도 있습니다.
- MetricDataQueries가 SUM()과 같은 수학 함수 없이 자체적으로 SEARCH() 함수를 지정하는 경우, ReturnData에 대해 false를 지정해야 합니다. 이는 검색 표현식이 여러 시계열을 반환할 수 있고 표현식에 근거하여 하는 지표 사양이 하나의 시계열만 반환할 수 있기 때문입니다.
- 검색 표현식과 관련된 모든 지표는 해상도가 동일해야 합니다.

제한 사항

다음과 같은 제한이 적용됩니다.

- 하나의 지표 사양에서 최대 10개 지표의 데이터 요소를 쿼리할 수 있습니다.
- 이 제한을 위해 하나의 표현식이 하나의 지표로 계산됩니다.

자습서: 과중한 워크로드를 처리하도록 Auto Scaling 구성

이 자습서에서는 애플리케이션이 보통의 워크로드보다 과부하 상황일 때 시간 범위를 기준으로 확장 및 축소하는 방법에 대해 알아봅니다. 이 기능은 정기적으로 또는 계절에 따라 갑자기 많은 수의 방문자가 발생할 수 있는 애플리케이션이 있는 경우에 유용합니다.

예약된 조정과 함께 대상 추적 조정 정책을 사용하여 추가 로드를 처리할 수 있습니다. 예약된 조정은 지정한 일정에 따라 사용자를 대신하여 자동으로 MinCapacity 및 MaxCapacity를 변경합니다. 대상 추적 조정 정책이 리소스에서 활성화되면 새로운 최소 및 최대 용량 범위 내에서 현재 리소스 사용률에 따라 동적으로 확장될 수 있습니다.

이 자습서를 완료하면 다음을 수행하는 방법을 알 수 있습니다.

- 예약된 조정을 사용하여 과부하가 발생하기 전에 용량을 추가한 다음 더 이상 필요하지 않을 때 추가 용량을 제거합니다.
- 대상 추적 조정 정책을 사용하여 현재 리소스 사용률에 따라 애플리케이션을 조정합니다.

내용

- [사전 조건](#)
- [1단계: 확장 가능 대상 등록](#)
- [2단계: 요구 사항에 따라 예약된 작업 설정](#)
- [2단계: 대상 추적 조정 정책 추가](#)
- [4단계: 다음 단계](#)
- [5단계: 정리](#)

사전 조건

이 자습서에서는 다음을 이미 완료했다고 가정합니다.

- 를 생성했습니다 AWS 계정.
- 를 설치 및 구성했습니다 AWS CLI.
- Application Auto Scaling을 사용하여 규모 조정 가능 대상으로 리소스를 등록하고 등록 취소하는 데 필요한 권한이 부여되었습니다. 또한 조정 정책 및 예약된 작업을 만드는 데 필요한 권한이 부여되었

습니다. 자세한 내용은 [Application Auto Scaling에 사용되는 Identity and Access Management 단원을 참조하십시오.](#)

- 이 자습서에 사용할 수 있는 비프로덕션 환경에서 지원되는 리소스를 생성했습니다. 아직 없는 경우 지금 하나 만듭니다. Application Auto Scaling과 함께 작동하는 AWS 서비스 및 리소스에 대한 자세한 내용은 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 섹션을 참조하세요.

Note

이 자습서를 완료하는 동안 리소스의 최소 및 최대 용량 값을 0으로 설정하여 현재 용량을 0으로 재설정하는 두 가지 단계가 있습니다. Application Auto Scaling과 함께 사용 중인 리소스에 따라 이 단계에서 현재 용량을 0으로 재설정하지 못할 수 있습니다. 문제를 해결하는 데 도움이 되도록 출력의 메시지는 최소 용량이 지정된 값보다 작을 수 없음을 나타내며 AWS 리소스가 수락할 수 있는 최소 용량 값을 제공합니다.

1단계: 확장 가능 대상 등록

Application Auto Scaling에서 확장 가능 대상으로서 리소스를 등록하는 것부터 시작합니다. 규모 조정 가능 대상은 Application Auto Scaling에서 스케일 아웃 및 스케일 인할 수 있는 리소스입니다.

Application Auto Scaling을 통해 확장 가능 대상을 등록하려면

- 다음 [register-scalable-target](#) 명령을 사용하여 새로운 확장 가능 대상을 등록합니다. `--min-capacity` 및 `--max-capacity` 값을 0으로 설정하여 현재 용량을 0으로 재설정합니다.

`--service-namespace`의 샘플 텍스트를 Application Auto Scaling과 함께 사용 중인 AWS 서비스의 네임스페이스로, `--scalable-dimension`을 등록하려는 리소스와 연결된 확장 가능한 차원으로, `--resource-id`를 리소스의 식별자로 바꿉니다. 이러한 값은 사용되는 리소스와 리소스 ID가 구성되는 방식에 따라 다릅니다. 자세한 내용은 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 섹션의 주제를 참조하세요. 이러한 주제에는 Application Auto Scaling에 확장 가능 대상을 등록하는 방법을 보여주는 예제 명령이 포함되어 있습니다.

Linux, macOS 또는 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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

2단계: 요구 사항에 따라 예약된 작업 설정

[put-scheduled-action](#) 명령을 사용하여 비즈니스 요구에 맞게 구성된 예약된 작업을 만들 수 있습니다. 이 자습서에서는 용량을 0으로 줄임으로써 근무 시간 외에 리소스 소비를 중지하는 구성에 중점을 둡니다.

아침에 확장하는 예약된 작업을 만들려면

1. 확장 가능한 대상을 확장하려면 다음 [put-scheduled-action](#) 명령을 사용합니다. cron 표현식을 사용한 반복되는 일정(UTC 기준)의 --schedule 파라미터를 포함합니다.

지정된 일정(매일 오전 9시(UTC 기준))에 따라 Application Auto Scaling은 MinCapacity 및 MaxCapacity 값을 1~5 용량 단위의 원하는 범위로 업데이트합니다.

Linux, macOS 또는 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
```

이 명령이 제대로 실행되면 어떤 출력도 반환하지 않습니다.

2. 예약된 작업이 있는지 확인하려면 다음 [describe-scheduled-actions](#)을 사용합니다.

Linux, macOS 또는 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`]"
```

다음은 예제 출력입니다.

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

밤에 축소하는 예약된 작업을 만들려면

1. 앞의 절차를 반복하여 하루가 끝날 때 Application Auto Scaling에서 축소하는 데 사용하는 또 다른 예약된 작업을 생성합니다.

다음 [put-scheduled-action](#) 명령에서 지시한 바와 같이, 지정된 스케줄에 따라(매일 오후 8:00(UTC 기준)) Application Auto Scaling이 대상의 MinCapacity 및 MaxCapacity를 0으로 업데이트합니다.

Linux, macOS 또는 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
```

2. 예약된 작업이 있는지 확인하려면 다음 [describe-scheduled-actions](#)을 사용합니다.

Linux, macOS 또는 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`]"
```

다음은 예제 출력입니다.

```
[
  {
    "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
    },
    ...
  }
]
```

2단계: 대상 추적 조정 정책 추가

기본 일정을 준비했으므로 현재 리소스 사용률에 따라 확장할 대상 추적 조정 정책을 추가합니다.

대상 추적을 사용하면 Application Auto Scaling이 정책의 대상 값을 지정된 지표의 현재 값과 비교합니다. 값이 일정 기간에 동일하지 않은 경우 Application Auto Scaling은 안정적인 성능을 유지하기 위해 용량을 추가하거나 제거합니다. 애플리케이션의 로드와 지표 값이 증가함에 따라 Application Auto Scaling은 MaxCapacity를 초과하지 않고 가능한 한 빨리 용량을 추가합니다. 로드가 최소이기 때문에 Application Auto Scaling이 용량을 제거하는 경우 MinCapacity 이하로 떨어지지 않고 용량을 제거할 수 있습니다. 사용량에 따라 용량을 조정하여 애플리케이션에 필요한 만큼만 요금을 지불합니다.

애플리케이션에 로드가 없기 때문에 지표에 데이터가 충분하지 않은 경우 Application Auto Scaling은 용량을 추가하거나 제거하지 않습니다. 즉, Application Auto Scaling은 정보가 충분하지 않은 상황에서 가용성을 우선시합니다.

여러 조정 정책을 추가할 수 있지만 충돌하는 단계 조정 정책을 추가하지 않아야 합니다. 이로 인해 바람직하지 않은 동작이 발생할 수 있습니다. 예컨대, 대상 추적 정책이 축소 준비되기 전에 단계별 조정

정책이 축소 활동을 시작하는 경우, 축소 활동이 차단되지 않습니다. 축소 작업이 완료된 후 대상 추적 정책이 Application Auto Scaling에 다시 확장하도록 지시할 수 있습니다.

대상 추적 조정 정책을 생성하려면

1. [put-scaling-policy](#) 명령을 사용하여 정책을 생성합니다.

대상 추적에 가장 자주 사용되는 지표는 미리 정의되어 있으며 CloudWatch에서 전체 지표 사양을 제공하지 않고도 사용할 수 있습니다. 사용 가능한 미리 정의된 지표에 대한 자세한 내용은 [Application Auto Scaling의 대상 추적 조정 정책](#) 섹션을 참조하세요.

이 명령을 실행하기 전에 미리 정의된 지표가 대상 값을 기대하는지 확인합니다. 예를 들어 CPU 사용률이 50%에 도달하면 확장하도록 대상 값을 50.0으로 지정합니다. 또는 사용률이 70%에 도달했을 때 Lambda 프로비저닝된 동시성을 확장하려면 대상 값을 0.7로 지정합니다. 특정 리소스의 대상 값에 대한 자세한 내용은 대상 추적을 구성하는 방법에 대해 서비스에서 제공하는 설명서를 참조하세요. 자세한 내용은 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 섹션을 참조하세요.

Linux, macOS 또는 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\" } }"
```

이 명령이 성공하면 사용자를 위해 생성된 두 CloudWatch 경보의 ARN과 이름이 반환됩니다.

2. 예약된 작업이 있는지 확인하려면 다음 [describe-scaling-policies](#) 명령을 사용합니다.

Linux, macOS 또는 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`]"
```

다음은 예제 출력입니다.

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

4단계: 다음 단계

크기 조정 활동이 발생하면 확장 가능 대상에 대한 조정 활동의 출력에서 이에 대한 레코드를 볼 수 있습니다. 예를 들면 다음과 같습니다.

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

Application Auto Scaling을 사용하여 크기 조정 활동을 모니터링하려면 다음 [describe-scaling-activities](#) 명령을 사용합니다.

Linux, macOS 또는 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
```

5단계: 정리

적극적으로 조정하는 동안 생성된 자원에 대한 요금이 계정에서 발생하지 않도록 하려면 다음과 같이 연결된 조정 구성을 정리할 수 있습니다.

조정 구성을 삭제해도 기본 AWS 리소스는 삭제되지 않습니다. 또한 원래 용량으로 반환하지 않습니다. 리소스를 생성한 서비스 콘솔을 사용하여 리소스를 삭제하거나 리소스 용량을 조정할 수 있습니다.

예약된 작업을 삭제하려면

다음 [delete-scheduled-action](#) 명령은 지정된 예약된 작업을 삭제합니다. 생성한 예약된 작업을 나중에도 계속 사용하고 싶은 경우에는 이 단계를 건너뛸 수 있습니다.

Linux, macOS 또는 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
```

조정 정책을 삭제하려면

다음 [delete-scaling-policy](#) 명령은 지정된 대상 추적 조정 정책을 삭제합니다. 생성한 조정 정책을 나중에 계속 사용하고 싶은 경우에는 이 단계를 건너뛸 수 있습니다.

Linux, macOS 또는 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
```

확장 가능 대상의 등록을 취소하려면

다음 [deregister-scalable-target](#) 명령을 사용하여 확장 가능 대상의 등록을 취소합니다. 이미 생성한 조정 정책이 있거나 아직 삭제되지 않은 예약된 작업이 있는 경우에는 이 명령을 통해 삭제됩니다. 확장 가능 대상을 나중에 사용할 수 있도록 등록 상태로 유지하고 싶은 경우에는 이 단계를 건너뛸 수 있습니다.

Linux, macOS 또는 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
```

Application Auto Scaling의 조정 일시 중지 및 재개

이 주제에서는 애플리케이션의 조정 가능 대상에 대한 조정 활동을 하나 이상 일시 중지한 후 재개하는 방법을 설명합니다. 이러한 일시 중지-재개 기능은 조정 정책 및 예약 작업에 의해 트리거된 조정 활동을 일시적으로 중지하는 데 사용됩니다. 예를 들어 변경을 수행하거나 구성 문제를 조사하는 동안 자동 조정 작업이 방해받지 않도록 하려는 경우에 유용합니다. 조정 정책 및 예약 작업을 보관해 두었다가, 준비되었을 때 조정 활동을 재개할 수 있습니다.

다음 예제 CLI 명령에서는 config.json 파일에 다음과 같은 JSON 형식 파라미터를 전달합니다. JSON 데이터 구조를 묶을 따옴표를 사용하여 명령줄에 이러한 파라미터를 전달할 수도 있습니다. 자세한 내용은 AWS Command Line Interface 사용 설명서의 [AWS CLI에서 문자열에 따옴표 사용](#)을 참조하세요.

내용

- [조정 활동](#)
- [조정 활동 일시 중지 및 재개](#)

Note

Amazon ECS 배포가 진행되는 동안 스케일 아웃 프로세스를 일시 중지하는 지침은 다음 설명서를 참조하세요.

Amazon Elastic Container Service 개발자 안내서의 [서비스 오토 스케일링 및 배포](#)

조정 활동

Application Auto Scaling은 다음과 같은 조정 활동을 일시 중지된 상태로 유지하도록 지원합니다.

- 조정 정책에 의해 트리거되는 모든 축소 활동.
- 조정 정책에 의해 트리거되는 모든 확장 활동.
- 예약된 작업을 포함하는 모든 조정 활동.

다음은 개별 조정 활동이 일시 중지될 때 어떤 일이 발생하는지에 대해 설명합니다. 각 조정 활동이 개별적으로 일시 중지되고 재개될 수 있습니다. 조정 활동을 일시 중지하는 이유에 따라 여러 조정 활동을 함께 일시 중지해야 할 수도 있습니다.

DynamicScalingInSuspended

- Application Auto Scaling은 대상 추적 조정 정책 또는 단계 조정 정책이 트리거될 때 용량을 제거하지 않습니다. 이렇게 하면 조정 정책 또는 연결된 CloudWatch 경보를 삭제하지 않고 조정 정책과 연결된 축소 활동을 일시적으로 비활성화할 수 있습니다. 축소를 재개하면 Application Auto Scaling이 현재 위반된 경보 임계값으로 정책을 평가합니다.

DynamicScalingOutSuspended

- Application Auto Scaling은 대상 추적 조정 정책 또는 단계 조정 정책이 트리거될 때 용량을 추가하지 않습니다. 이렇게 하면 조정 정책 또는 연결된 CloudWatch 경보를 삭제하지 않고 조정 정책과 연결된 확장 활동을 일시적으로 비활성화할 수 있습니다. 확장을 재개하면 Application Auto Scaling이 현재 위반된 경보 임계값으로 정책을 평가합니다.

ScheduledScalingSuspended

- Application Auto Scaling은 일시 중지 기간에 실행되도록 예약된 조정 작업을 시작하지 않습니다. 예약된 조정을 재개하면 Application Auto Scaling은 실행 시간이 아직 경과하지 않은 예약된 작업만 평가합니다.

조정 활동 일시 중지 및 재개

Application Auto Scaling 확장 가능 대상에 대한 개별 조정 활동 또는 모든 조정 활동을 일시 중지 및 재개할 수 있습니다.

Note

간략하게 나타내기 위해 이 예에서는 DynamoDB 테이블의 조정을 일시 중지 및 재개하는 방법을 보여줍니다. 다른 확장 가능 대상을 지정하려면 `--service-namespace`에 네임스페이스, `--scalable-dimension`에 확장 가능 차원, `--resource-id`에 리소스 ID를 지정합니다. 각 서비스에 대한 자세한 내용과 예는 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#)의 주제를 참조하세요.

조정 활동을 일시 중지하려면

다음과 같이 명령줄 창을 열고 [register-scalable-target](#) 명령을 `--suspended-state` 옵션과 함께 사용합니다.

Linux, macOS 또는 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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

조정 정책에 의해 트리거되는 축소 활동만 일시 중지하려면 다음을 config.json에 지정합니다.

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

조정 정책에 의해 트리거되는 확장 활동만 일시 중지하려면 다음을 config.json에 지정합니다.

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

예약된 작업을 포함하는 조정 활동만 일시 중지하려면 다음을 config.json에 지정합니다.

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

모든 조정 활동을 일시 중지하려면

다음과 같이 [register-scalable-target](#) 명령을 `--suspended-state` 옵션과 함께 사용합니다.

Linux, macOS 또는 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
```

이 예제에서는 config.json 파일에 다음과 같은 JSON 형식 파라미터가 포함된 것으로 가정합니다.

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

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

일시 중지된 조정 활동 보기

[describe-scalable-targets](#) 명령을 사용하여 확장 가능 대상에 대해 일시 중지된 상태인 조정 활동을 확인합니다.

Linux, macOS 또는 Unix

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

Windows

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

다음은 예제 출력입니다.

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

조정 활동 재개

조정 활동을 재개할 준비가 되면 [register-scalable-target](#) 명령을 사용하여 재개할 수 있습니다.

다음과 같은 예제 명령은 지정된 확장 가능 대상에 대한 모든 조정 활동을 재개합니다.

Linux, macOS 또는 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
```

이 예제에서는 config.json 파일에 다음과 같은 JSON 형식 파라미터가 포함된 것으로 가정합니다.

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

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

Application Auto Scaling 확장 활동

Application Auto Scaling에서는 확장 정책의 CloudWatch 지표를 모니터링하며 임계값을 초과하면 확장 활동을 시작합니다. 또한 사용자가 확장 가능 대상의 최대 또는 최소 크기를 수정하면 수동으로 또는 일정에 따라 확장 활동을 시작합니다.

확장 활동이 발생하면 Application Auto Scaling에서는 다음 중 하나를 수행합니다.

- 확장 가능 대상의 용량 늘리기(스케일 아웃이라고 함)
- 확장 가능 대상의 용량 줄이기(스케일 인이라고 함)

최근 6주 동안의 확장 활동을 조회할 수 있습니다.

규모 조정 가능 대상별 조정 활동 조회

특정 확장 가능 대상에 대한 확장 활동을 확인하려면 다음 [describe-scaling-activities](#) 명령을 사용합니다.

Linux, macOS 또는 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
```

다음은 StatusCode에 활동의 현재 상태가 있고 StatusMessage에 확장 활동의 상태가 있는 응답의 예입니다.

```
{
  "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"
    }
]
}

```

응답의 필드에 대한 설명은 Application Auto Scaling API 참조의 [ScalingActivity](#)를 참조하세요.

다음 상태 코드는 확장 활동이 발생하는 활동 이벤트가 언제 완료됨 상태에 도달하는지를 나타냅니다.

- Successful – 확장이 완료되었음
- Overridden – 더 새로운 확장 이벤트를 통해 원하는 용량으로 업데이트되었음
- Unfulfilled – 확장 시간을 초과했거나 대상 서비스에서 요청을 이행할 수 없음
- Failed – 예외가 발생하여 확장 실패

Note

확장 활동에 Pending 또는 InProgress의 상태가 있을 수도 있습니다. 대상 서비스에서 응답하기 전에 모든 확장 활동에 Pending 상태가 있습니다. 대상에서 응답하면 확장 활동의 상태가 InProgress로 변경됩니다.

규모가 조정되지 않은 활동 포함

기본적으로 확장 활동에는 Application Auto Scaling에서 확장 여부를 결정하는 시간이 반영되지 않습니다.

주어진 지정된 지표의 최대 임계값을 Amazon ECS 서비스에서 초과하는데 작업 수가 이미 허용되는 최대 작업 수에 도달한 예를 가정하겠습니다. 이 경우에는 원하는 태스크 수를 Application Auto Scaling에서 스케일 아웃하지 않습니다.


확장되지 않은 활동(확장된 활동 아님)을 응답에 포함하려면 [describe-scaling-activities](#) 명령에 `--include-not-scaled-activities` 옵션을 추가합니다.

Linux, macOS 또는 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

이 명령에서 오류가 발생하면 AWS CLI 로컬에서 최신 버전으로 업데이트했는지 확인합니다.

확장되지 않은 활동이 응답에 포함되는지 확인하도록 전부는 아니지만 일부 실패한 확장 활동에 대한 출력에 `NotScaledReasons` 요소가 표시됩니다.

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

```
    ]
}
```

응답의 필드에 대한 설명은 Application Auto Scaling API 참조의 [ScalingActivity](#)를 참조하세요.

확장되지 않은 활동이 반환되는 경우 Code에 나열된 사유 코드에 따라 CurrentCapacity, MaxCapacity, MinCapacity 등의 속성이 응답에 표시될 수도 있습니다.

대량의 중복 항목을 방지하기 위해 규모가 조정되지 않은 첫 번째 활동만 조정 활동 기록에 기록됩니다. 규모가 조정되지 않은 후속 활동에 대해서는 규모 미조정 이유가 변경되지 않는 한 새 항목이 생성되지 않습니다.

사유 코드

다음은 확장되지 않은 활동의 사유 코드입니다.

사유 코드	정의			
AutoScalingAnticipatedFlapping	플래핑이 발생하기 때문에 자동 확장 알고리즘에서 확장 작업을 진행하지 않기로 결정했습니다. 플래핑은 스케일 인과 스케일 아웃의 무한 루프입니다. 즉, 확장 작업을 진행하면 지표 값이 변경되어 반대 방향으로 다른 확장 작업이 시작됩니다.			
TargetServicePutResourceAsInscalable	대상 서비스가 리소스를 일시적으로 확장할 수 없는 상태로 전환했습니다. Application Auto			

사유 코드	정의			
	Scaling은 조정 정책에 지정된 자동 조정 조건이 충족되면 다시 조정을 시도합니다.			
AlreadyAtMaxCapacity	사용자가 지정한 최대 용량에 따라 확장이 차단되었습니다. Application Auto Scaling에서 스케일 아웃하려면 최대 용량을 늘려야 합니다.			
AlreadyAtMinCapacity	사용자가 지정한 최소 용량에 따라 확장이 차단되었습니다. Application Auto Scaling에서 스케일 인하려면 최소 용량을 줄여야 합니다.			
AlreadyAtDesiredCapacity	수정한 용량이 현재 용량이 동일하다고 자동 확장 알고리즘에서 계산했습니다.			

Application Auto Scaling 모니터링

모니터링은 Application Auto Scaling 및 기타 AWS 솔루션의 안정성, 가용성 및 성능을 유지하는 데 중요한 부분입니다. 다중 지점 장애가 발생할 경우 보다 쉽게 디버깅할 수 있도록 AWS 솔루션의 모든 부분에서 모니터링 데이터를 수집해야 합니다. Application Auto Scaling을 모니터링하고, 이상이 있을 때 이를 보고하고, 필요한 경우 자동 조치를 취할 수 있는 모니터링 도구를 AWS 제공합니다.

다음 기능을 사용하여 AWS 리소스를 관리할 수 있습니다.

AWS CloudTrail

를 사용하면에 의해 또는를 대신하여 Application Auto Scaling API에 대한 호출을 추적할 AWS CloudTrail수 있습니다 AWS 계정. CloudTrail은 지정하는 Amazon S3 버킷의 로그 파일에 정보를 저장합니다. 어떤 사용자 및 계정이 Application Auto Scaling을 호출했는지, 어떤 소스 IP 주소에 호출이 이루어졌는지, 언제 호출이 발생했는지 확인할 수 있습니다. 자세한 내용은 [를 사용하여 Application Auto Scaling API 호출 로깅 AWS CloudTrail](#) 단원을 참조하십시오.

Note

워크로드에 대한 데이터를 로깅하고 수집하는 데 도움이 되는 다른 AWS 서비스에 대한 자세한 내용은 AWS 권장 [가이드의 애플리케이션 소유자를 위한 로깅 및 모니터링 가이드](#)를 참조하세요.

Amazon CloudWatch

Amazon CloudWatch를 사용하면 AWS 리소스 및 호스팅된 애플리케이션의 로그를 분석하고 측정치를 실시간으로 모니터링할 수 있습니다. 지표를 수집 및 추적하고, 사용자 지정 대시보드를 생성할 수 있으며, 지정된 지표가 지정된 임계값에 도달하면 사용자에게 알리거나 조치를 취하도록 경보를 설정할 수 있습니다. 예를 들어 CloudWatch는 리소스 사용률을 추적하고 사용률이 매우 높거나 지표의 경보가 INSUFFICIENT_DATA 상태가 되면 알려주도록 할 수 있습니다. 자세한 내용은 [CloudWatch를 사용하여 규모 조정 가능 리소스 사용 모니터링](#) 단원을 참조하십시오.

CloudWatch는 Application Auto Scaling에 대한 AWS API 사용량 지표도 추적합니다. 이러한 지표를 사용하여 API 호출량이 정의한 임계값을 위반할 때 경고하는 경보를 구성할 수 있습니다. 자세한 내용은 Amazon CloudWatch 사용 설명서에서 [AWS 사용량 지표](#)를 참조하세요.

Amazon EventBridge

Amazon EventBridge: 애플리케이션을 다양한 소스의 데이터와 쉽게 연결할 수 있는 서버리스 이벤트 버스 서비스입니다. EventBridge는 자체 애플리케이션, Software-as-a-Service(SaaS) 애플리케이션 및 AWS 서비스의 실시간 데이터 스트림을 제공하고 해당 데이터를 Lambda와 같은 대상으로 라우팅합니다. 이 방법을 통해 서비스에서 발생하는 이벤트를 모니터링하고 이벤트 기반 아키텍처를 구축할 수 있습니다. 자세한 내용은 [Amazon EventBridge를 사용한 Application Auto Scaling 이벤트 모니터링](#) 단원을 참조하십시오.

AWS Health Dashboard

Health Dashboard (PHD)는 정보를 표시하고 AWS 리소스 상태 변경으로 인해 호출되는 알림도 제공합니다. 이 정보는 최근 이벤트와 예정된 이벤트를 카테고리별로 보여주는 대시보드와 지난 90 일간의 모든 이벤트를 보여주는 전체 이벤트 로그의 두 가지 방법으로 표시됩니다. 자세한 내용은 [Health Dashboard 시작하기](#)를 참조하세요.

CloudWatch를 사용하여 규모 조정 가능 리소스 사용 모니터링

Amazon CloudWatch를 사용하면 확장 가능한 리소스 전반에서 애플리케이션을 거의 지속적으로 확인할 수 있습니다. CloudWatch는 AWS 리소스에 대한 모니터링 서비스입니다. CloudWatch를 사용하여 지표를 수집 및 추적하고, AWS 리소스의 변경 사항에 자동으로 대응할 수 있습니다. 또한 대시보드를 생성하여 필요한 특정 지표 또는 지표 집합을 모니터링할 수 있습니다.

사용자가 Application Auto Scaling과 통합되는 서비스와 상호 작용할 때 서비스에서는 다음 표에 나와 있는 지표를 CloudWatch로 보냅니다. CloudWatch에서 지표는 먼저 서비스 네임스페이스별로 그룹화된 다음, 각 네임스페이스 내에서 다양한 차원 조합별로 그룹화됩니다. 이러한 지표는 리소스 사용량을 모니터링하고 애플리케이션의 용량을 계획하는 데 도움이 될 수 있습니다. 애플리케이션의 워크로드가 일정하지 않은 경우, 이는 Auto Scaling 사용을 고려해야 한다는 뜻입니다. 이러한 지표에 대한 자세한 설명은 관심 지표에 대한 설명서를 참조하세요.

내용

- [리소스 사용량 모니터링을 위한 CloudWatch 지표](#)
- [대상 추적 조정 정책을 위해 사전 정의된 지표](#)
- [예측 조정 지표 및 차원](#)

리소스 사용량 모니터링을 위한 CloudWatch 지표

다음 표에는 리소스 사용량 모니터링을 지원하는 데 사용할 수 있는 CloudWatch 지표가 나와 있습니다. 목록이 완전하지는 않지만 좋은 출발점이 될 것입니다. CloudWatch 콘솔에 이러한 지표가 표시되지 않으면 리소스 설정을 완료했는지 확인합니다. 자세한 내용은 [Amazon CloudWatch 사용 설명서](#)를 참조하세요.

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
WorkSpaces 애플리케이션			
플릿	AWS/AppStream	이름: Available Capacity 차원: 플릿	WorkSpaces 애플리케이션 지표
플릿	AWS/AppStream	이름: CapacityUtilization 차원: 플릿	WorkSpaces 애플리케이션 지표
Aurora			
복제본	AWS/RDS	이름: CPUUtilization 차원: DBClusterIdentifier, 역할(리더)	Aurora 클러스터 수준 지표

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
복제본	AWS/RDS	이름: DatabaseConnections 차원: DBClusterIdentifier, 역할(리더)	Aurora 클러스터 수준 지표
Amazon Comprehend			
문서 분류 엔드포인트	AWS/Comprehend	이름: InferenceUtilization 차원: EndpointArn	Amazon Comprehend 엔드포인트 지표
엔터티 인식기 엔드포인트	AWS/Comprehend	이름: InferenceUtilization 차원: EndpointArn	Amazon Comprehend 엔드포인트 지표
DynamoDB			

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
테이블 및 전역 보조 인덱스	AWS/ DynamoDB	이름: ProvisionedReadCapacityUnits 측정 항목: TableName , GlobalSecondaryIndexName	DynamoDB 지표
테이블 및 전역 보조 인덱스	AWS/ DynamoDB	이름: ProvisionedWriteCapacityUnits 측정 항목: TableName , GlobalSecondaryIndexName	DynamoDB 지표

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
테이블 및 전역 보조 인덱스	AWS/ DynamoDB	이름: ConsumedReadCapacityUnits 측정 항목: TableName , GlobalSecondaryIndexName	DynamoDB 지표
테이블 및 전역 보조 인덱스	AWS/ DynamoDB	이름: ConsumedWriteCapacityUnits 측정 항목: TableName , GlobalSecondaryIndexName	DynamoDB 지표
Amazon ECS			

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
서비스	AWS/ECS	이름: CPUUtilization 측정 기준: ClusterName, ServiceName	Amazon ECS 지표
서비스	AWS/ECS	이름: MemoryUtilization 측정 기준: ClusterName, ServiceName	Amazon ECS 지표
서비스	AWS/ApplicationELB	이름: RequestCountPerTarget 차원: TargetGroup	Application Load Balancer 지표
ElastiCache			

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
클러스터(복제 그룹)	AWS/ Elast iCache	이름: DatabaseMemoryUsageCountedForEvictPercentage 차원: ReplicationGroupId	ElastiCache Valkey 및 Redis OSS 지표
클러스터(복제 그룹)	AWS/ Elast iCache	이름: DatabaseCapacityUsageCountedForEvictPercentage 차원: ReplicationGroupId	ElastiCache Valkey 및 Redis OSS 지표
클러스터(복제 그룹)	AWS/ Elast iCache	이름: EngineCPUUtilization 차원: ReplicationGroupId, 역할(기본)	ElastiCache Valkey 및 Redis OSS 지표

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
클러스터(복제 그룹)	AWS/ElastiCache	이름: EngineCPUUtilization 차원: ReplicationGroupId, 역할(복제본)	ElastiCache Valkey 및 Redis OSS 지표
클러스터(캐시)	AWS/ElastiCache	이름: EngineCPUUtilization 차원: CacheClusterId, 노드	ElastiCache Memcached 지표
클러스터(캐시)	AWS/ElastiCache	이름: DatabaseCapacityMemoryUsagePercentage 측정 기준: CacheClusterId	ElastiCache Memcached 지표
Amazon EMR			

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
클러스터	AWS/ElasticMapReduce	이름: YARNMemoryAvailablePercentage 차원: ClusterId	Amazon EMR 지표
Amazon Keyspaces			
테이블	AWS/Cassandra	이름: ProvisionedReadCapacityUnits 차원: Keyspace, TableName	Amazon Keyspaces 지표
테이블	AWS/Cassandra	이름: ProvisionedWriteCapacityUnits 차원: Keyspace, TableName	Amazon Keyspaces 지표

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
테이블	AWS/Cassandra	이름: ConsumedReadCapacityUnits 차원: Keyspace, TableName	Amazon Keyspaces 지표
테이블	AWS/Cassandra	이름: ConsumedWriteCapacityUnits 차원: Keyspace, TableName	Amazon Keyspaces 지표
Lambda			
프로비저닝된 동시성	AWS/Lambda	이름: ProvisionedConcurrencyUtilization 차원: FunctionName, 리소스	Lambda 함수 지표
Amazon MSK			

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
브로커 스토리지	AWS/ Kafka	이름: KafkaData LogsDiskUsed 차원: 클러스터 이름	Amazon MSK 지표
브로커 스토리지	AWS/ Kafka	이름: KafkaData LogsDiskUsed 차원: 클러스터 이름, 브로커 ID	Amazon MSK 지표
Neptune			
클러스터	AWS/ Neptune	이름: CPUUtilization 차원: DBClusterIdentifier, 역할(리더)	Neptune 지표
SageMaker AI			

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
엔드포인트 변형	AWS/SageMaker	이름: InvocationsPerInstance 차원: EndpointName, VariantName	호출 지표
추론 구성 요소	AWS/SageMaker	이름: InferencesPerCopy 차원: InferenceComponentName	호출 지표
서버리스 엔드포인트의 프로비저닝된 동시성	AWS/SageMaker	이름: ServerlessProvisionedConcurrencyUtilization 차원: EndpointName, VariantName	서버리스 엔드포인트 지표
스팟 플릿(Amazon EC2)			

확장 가능한 리소스	네임스페이스	CloudWatch 지표	설명서 링크
Spot Fleets	AWS/EC2Spot	이름: CPUUtilization 차원: FleetRequestId	스팟 플릿 지표
Spot Fleets	AWS/EC2Spot	이름: NetworkIn 차원: FleetRequestId	스팟 플릿 지표
Spot Fleets	AWS/EC2Spot	이름: NetworkOut 차원: FleetRequestId	스팟 플릿 지표
Spot Fleets	AWS/ApplicationELB	이름: RequestCountPerTarget 차원: TargetGroup	Application Load Balancer 지표

대상 추적 조정 정책을 위해 사전 정의된 지표

다음 표에는 [Application Auto Scaling API 참조](#)에서 사전 정의된 지표의 유형과 해당 CloudWatch 지표 이름이 나와 있습니다. 사전 정의된 각 지표는 기본 CloudWatch 지표 값을 집계한 것입니다. 별도로 명시되지 않는 한 결과는 1분 동안의 평균 리소스 사용량을 백분율로 표시합니다. 사전 정의된 지표는 대상 추적 조정 정책을 설정하는 컨텍스트 내에서만 사용됩니다.

이러한 지표에 대한 자세한 내용은 서비스의 설명서([리소스 사용량 모니터링을 위한 CloudWatch 지표](#)의 표에서 확인 가능)를 참조하세요.

사전 정의된 지표 유형	CloudWatch 지표 이름
WorkSpaces 애플리케이션	
AppStreamAverageCapacityUtilization	CapacityUtilization
Aurora	
RDSReaderAverageCPUUtilization	CPUUtilization
RDSReaderAverageDatabaseConnections	DatabaseConnections ¹
Amazon Comprehend	
ComprehendInferenceUtilization	InferenceUtilization
DynamoDB	
DynamoDBReadCapacityUtilization	ProvisionedWriteCapacityUnits, ConsumedWriteCapacityUnits ²
DynamoDBWriteCapacityUtilization	ProvisionedWriteCapacityUnits, ConsumedWriteCapacityUnits ²
Amazon ECS	
ECSServiceAverageCPUUtilization	CPUUtilization

사전 정의된 지표 유형	CloudWatch 지표 이름
ECSServiceAverageMemoryUtilization	MemoryUtilization
ALBRequestCountPerTarget	RequestCountPerTarget ¹
ElastiCache	
ElastiCacheDatabaseMemoryUsageCountedForEvictPercentage	DatabaseMemoryUsageCountedForEvictPercentage
ElastiCacheDatabaseCapacityUsageCountedForEvictPercentage	DatabaseCapacityUsageCountedForEvictPercentage
ElastiCachePrimaryEngineCPUUtilization	EngineCPUUtilization
ElastiCacheReplicaEngineCPUUtilization	EngineCPUUtilization
ElastiCacheEngineCPUUtilization	EngineCPUUtilization
ElastiCacheDatabaseMemoryUsagePercentage	DatabaseMemoryUsagePercentage
Amazon Keyspaces	
CassandraReadCapacityUtilization	ProvisionedReadCapacityUnits, ConsumedReadCapacityUnits ²
CassandraWriteCapacityUtilization	ProvisionedWriteCapacityUnits, ConsumedWriteCapacityUnits ²
Lambda	
LambdaProvisionedConcurrencyUtilization	ProvisionedConcurrencyUtilization
Amazon MSK	

사전 정의된 지표 유형	CloudWatch 지표 이름
KafkaBrokerStorageUtilization	KafkaDataLogsDiskUsed
Neptune	
NeptuneReaderAverageCPUUtilization	CPUUtilization
SageMaker AI	
SageMakerVariantInvocationsPerInstance	InvocationsPerInstance ¹
SageMakerInferenceComponentInvocationsPerCopy	InvocationsPerCopy ¹
SageMakerVariantProvisionedConcurrencyUtilization	ServerlessProvisionedConcurrencyUtilization
SageMakerInferenceComponentConcurrentRequestsPerCopyHighResolution	ConcurrentRequestsPerCopy
SageMakerVariantConcurrentRequestsPerModelHighResolution	ConcurrentRequestsPerModel
스팟 플릿	
EC2SpotFleetRequestAverageCPUUtilization	CPUUtilization ³
EC2SpotFleetRequestAverageNetworkIn ³	NetworkIn ^{1 3}
EC2SpotFleetRequestAverageNetworkOut ³	NetworkOut ^{1 3}
ALBRequestCountPerTarget	RequestCountPerTarget ¹

¹ 지표는 백분율이 아닌 개수를 기반으로 합니다.

² DynamoDB 및 Amazon Keyspaces의 경우, 사전 정의된 지표는 프로비저닝된 처리 소비량을 기반으로 한 확장을 지원하는 두 CloudWatch 지표의 집합입니다.

³ 확장 가능한 최상의 성능을 얻으려면 Amazon EC2 세부 모니터링을 사용해야 합니다.

예측 조정 지표 및 차원

AWS/ApplicationAutoScaling 네임스페이스에는 예측 조정 정책에 대한 다음 지표가 포함되어 있습니다. 이러한 지표는 1시간의 해상도로 사용할 수 있으며 예측 값을 실제 값과 비교하여 예측 정확도를 평가하는 데 도움이 될 수 있습니다.

지표	설명	측정 기준
PredictiveScalingLoadForecast	<p>애플리케이션에서 생성될 것으로 예상되는 로드 의 양입니다.</p> <p>Average, Minimum 및 Maximum 통계는 유용 하지만 Sum 통계는 유용하지 않습니다.</p> <p>보고 기준: 초기 예측이 생성된 후에 보고됩니 다.</p>	ResourceId, ServiceNamespace, PolicyName, ScalableDimension, PairIndex
PredictiveScalingCapacityForecast	<p>애플리케이션 수요를 충족하는 데 필요할 것으 로 예상되는 용량입니다. 이는 Application Auto Scaling 리소스를 유지하려는 로드 예측 및 목표 사용률 수준을 기반으로 합니다.</p> <p>Average, Minimum 및 Maximum 통계는 유용 하지만 Sum 통계는 유용하지 않습니다.</p> <p>보고 기준: 초기 예측이 생성된 후에 보고됩니 다.</p>	ResourceId, ServiceNamespace, PolicyName, ScalableDimension
PredictiveScalingMetricPairCorrelation	<p>조정 지표와 로드 지표의 인스턴스당 평균 사이 의 상관 관계입니다. 예측적 조정은 높은 상관 관계를 가정합니다. 따라서 이 지표의 값이 낮은 경우, 지표 페어를 사용하지 않는 것이 좋습니 다.</p>	ResourceId, ServiceNamespace, PolicyName

지표	설명	측정 기준
	Average, Minimum 및 Maximum 통계는 유용하지만 Sum 통계는 유용하지 않습니다. 보고 기준: 초기 예측이 생성된 후에 보고됩니다.	e , ScalableDimension , PairIndex

를 사용하여 Application Auto Scaling API 호출 로깅 AWS CloudTrail

Application Auto Scaling은 사용자, 역할 또는 AWS 서비스가 수행한 작업 기록을 제공하는 서비스인 [AWS CloudTrail](#)과 통합됩니다. CloudTrail은 Application Auto Scaling에 대한 API 직접 호출을 이벤트로 캡처합니다. 캡처되는 호출에는 AWS Management Console의 직접 호출과 Application Auto Scaling API 작업에 대한 코드 직접 호출이 포함됩니다. CloudTrail이 수집한 정보를 사용하여 Application Auto Scaling에 수행된 요청, 요청이 수행된 IP 주소, 요청이 수행된 시간, 추가 세부 정보를 확인할 수 있습니다.

모든 이벤트 또는 로그 항목에는 요청을 생성했던 사용자에게 관한 정보가 포함됩니다. 자격 증명을 이용하면 다음을 쉽게 판단할 수 있습니다.

- 요청을 루트 사용자로 했는지 사용자 보안 인증으로 했는지 여부.
- IAM Identity Center 사용자를 대신하여 요청이 이루어졌는지 여부입니다.
- 역할 또는 페더레이션 사용자의 임시 자격 증명을 사용하여 요청이 생성되었는지 여부.
- 다른 AWS 서비스에서 요청했는지 여부

CloudTrail은 계정을 생성할 AWS 계정 때에서 활성화되며 CloudTrail 이벤트 기록에 자동으로 액세스할 수 있습니다. CloudTrail 이벤트 기록은 지난 90일 간 AWS 리전의 관리 이벤트에 대해 보기, 검색 및 다운로드가 가능하고, 수정이 불가능한 레코드를 제공합니다. 자세한 설명은 [AWS CloudTrail 사용 설명서의 CloudTrail 이벤트 기록 작업을 참조](#)하세요. 이벤트 기록 보기는 CloudTrail 요금이 부과되지 않습니다.

AWS 계정 지난 90일 동안의 이벤트를 지속적으로 기록하려면 추적을 생성합니다.

CloudTrail 추적

CloudTrail은 추적을 사용하여 Amazon S3 버킷으로 로그 파일을 전송할 수 있습니다. 를 사용하여 생성된 모든 추적 AWS Management Console 은 다중 리전입니다. AWS CLI를 사용하여 단일 리전 또는 다중 리전 추적을 생성할 수 있습니다. 계정의 모든에서 활동을 캡처하므로 다중 리전 추적 AWS 리전 을 생성하는 것이 좋습니다. 단일 리전 추적을 생성하는 경우 추적의 AWS 리전에 로깅된 이벤트만 볼 수 있습니다. 추적에 대한 자세한 내용은 AWS CloudTrail 사용 설명서의 [AWS 계정 에 대한 추적 생성 및 조직에 대한 추적 생성](#)을 참조하세요.

CloudTrail에서 추적을 생성하여 진행 중인 관리 이벤트의 사본 하나를 Amazon S3 버킷으로 무료로 전송할 수는 있지만, Amazon S3 스토리지 요금이 부과됩니다. CloudTrail 요금에 관한 자세한 내용은 [AWS CloudTrail 요금](#)을 참조하세요. Amazon S3 요금에 관한 자세한 내용은 [Amazon S3 요금](#)을 참조하세요.

CloudTrail의 Application Auto Scaling 관리 이벤트

[관리 이벤트](#)는의 리소스에서 수행되는 관리 작업에 대한 정보를 제공합니다 AWS 계정. 이를 컨트롤 플레인 작업이라고도 합니다. 기본적으로 CloudTrail은 관리 이벤트를 로깅합니다.

Application Auto Scaling은 모든 Application Auto Scaling 컨트롤 플레인 작업을 관리 이벤트로 로깅합니다. Application Auto Scaling이 CloudTrail 로깅하는 Application Auto Scaling 컨트롤 플레인 작업 목록은 [Application Auto Scaling API 참조](#)를 참조하세요.

Application Auto Scaling 이벤트 예제

이벤트는 모든 소스로부터의 단일 요청을 나타내며 요청된 API 작업, 작업 날짜와 시간, 요청 파라미터 등에 관한 정보가 들어 있습니다. CloudTrail 로그 파일은 퍼블릭 API 직접 호출의 주문 스택 추적이 아니므로 이벤트가 특정 순서로 표시되지 않습니다.

다음 예제는 DescribeScalableTargets 작업을 시연하는 CloudTrail 이벤트를 보여줍니다.

```
{
  "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"
  }
}

```

CloudTrail 레코드 콘텐츠에 관한 자세한 내용은 AWS CloudTrail 사용 설명서의 [CloudTrail 레코드 콘텐츠](#)를 참조하세요.

CloudWatch에서 Application Auto Scaling RemoveAction 호출

Application Auto Scaling이 경보에서 자동 조정 작업을 제거하도록 CloudWatch에 지시할 때 Application Auto Scaling이 CloudWatch RemoveAction API를 호출한다고 AWS CloudTrail 로그에 표시될 수 있습니다. 이는 확장 가능한 대상을 등록 해제하거나 규모 조정 정책을 삭제한 경우, 또는 알람이 존재하지 않는 규모 조정 정책을 간접적으로 호출한 경우 발생할 수 있습니다.

Amazon EventBridge를 사용한 Application Auto Scaling 이벤트 모니터링

Amazon EventBridge(이전 명칭: CloudWatch Events)를 사용하면 Application Auto Scaling과 관련된 이벤트를 모니터링하고 다른 AWS 서비스를 사용하는 대상 작업을 시작할 수 있습니다. 이 이벤트는 AWS 서비스는 거의 실시간으로 EventBridge로 전달됩니다.

EventBridge를 사용하면 수신 이벤트를 확인한 후 처리 대상으로 라우팅하는 규칙을 생성할 수 있습니다.

자세한 내용은 Amazon EventBridge 사용 설명서의 [Amazon EventBridge 시작하기](#)를 참조하세요.

Application Auto Scaling 이벤트

다음 예제에서는 Application Auto Scaling에 대한 이벤트를 보여줍니다. 이벤트는 최선의 작업에 근거하여 생성됩니다.

현재 CloudTrail을 통한 최대 조정된 이벤트 및 API 호출만 Application Auto Scaling에 사용할 수 있습니다.

이벤트 유형

- [상태 변경 이벤트: 최대 용량으로 조정](#)
- [CloudTrail을 통한 API 호출 이벤트](#)

상태 변경 이벤트: 최대 용량으로 조정

다음 예제 이벤트는 Application Auto Scaling이 확장 가능 대상의 용량을 최대 크기 한도까지 증가(스케일 아웃)했음을 보여줍니다. 수요가 다시 증가하면 대상이 이미 최대 크기로 조정되었기 때문에 Application Auto Scaling에서 더 큰 크기로 조정할 수 없습니다.

detail 객체에서 resourceId,serviceNamespace 및scalableDimension 속성은 확장 가능 대상을 식별합니다. newDesiredCapacity 및 oldDesiredCapacity 속성의 값은 스케일 아웃 이벤트 후의 새 용량과 스케일 아웃 이벤트 전의 원래 용량을 나타냅니다. maxCapacity는 확장 가능 대상의 최대 크기 한도입니다.

```
{
  "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",
  "serviceName": "dynamodb",
  "statusCode": "Successful",
  "scaledToMax": true,
  "direction": "scale-out"
}

```

모든 확장 가능 대상의 모든 scaledToMax 상태 변경 이벤트를 캡처하는 규칙을 생성하려면 다음 샘플 이벤트 패턴을 사용합니다.

```

{
  "source": [
    "aws.application-autoscaling"
  ],
  "detail-type": [
    "Application Auto Scaling Scaling Activity State Change"
  ],
  "detail": {
    "scaledToMax": [
      true
    ]
  }
}

```

CloudTrail을 통한 API 호출 이벤트

추적을 AWS CloudTrail 사용하여 이벤트를 Amazon S3 버킷에 로그 파일로 전달하는 구성입니다. CloudTrail 로그 파일에는 로그 항목이 포함됩니다. 이벤트는 개별 로그 항목을 나타내며 요청된 작

업, 작업 날짜 및 시간, 요청 파라미터에 대한 정보를 포함합니다. CloudTrail을 시작하는 방법은 AWS CloudTrail 사용 설명서의 [추적 생성](#)을 참조하세요.

CloudTrail을 통해 전달되는 모든 이벤트는 detail-type의 값이 AWS API Call via CloudTrail입니다.

다음 예제 이벤트는 콘솔 사용자가 Application Auto Scaling [RegisterScalableTarget](#) 작업을 호출했음을 보여주는 CloudTrail 로그 파일 항목을 나타냅니다.

```
{
  "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-73fbd2ce-aa30-494c-8788-1cee4EXAMPLE",
  "serviceName": "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"
}
}

```

모든 확장 가능 대상의 모든 [DeleteScalingPolicy](#) 및 [DeregisterScalableTarget](#) API 호출을 기반으로 규칙을 생성하려면 다음 샘플 이벤트 패턴을 사용합니다.

```

{
  "source": [
    "aws.autoscaling"
  ],
  "detail-type": [
    "AWS API Call via CloudTrail"
  ],
  "detail": {
    "eventSource": [
      "autoscaling.amazonaws.com"
    ],
    "eventName": [
      "DeleteScalingPolicy",
      "DeregisterScalableTarget"
    ]
  }
}

```

```
    ],  
    "additionalEventData": {  
      "service": [  
        "application-autoscaling"  
      ]  
    }  
  }  
}
```

CloudTrail 사용에 관한 자세한 내용은 [클 사용하여 Application Auto Scaling API 호출 로깅 AWS CloudTrail](#) 섹션을 참조하세요.

AWS SDK에서이 서비스 사용

AWS 소프트웨어 개발 키트(SDKs)는 널리 사용되는 많은 프로그래밍 언어에 사용할 수 있습니다. 각 SDK는 개발자가 선호하는 언어로 애플리케이션을 쉽게 구축할 수 있도록 하는 API, 코드 예제 및 설명서를 제공합니다.

SDK 설명서	코드 예제
AWS SDK for C++	AWS SDK for C++ 코드 예제
AWS CLI	AWS CLI 코드 예제
AWS SDK for Go	AWS SDK for Go 코드 예제
AWS SDK for Java	AWS SDK for Java 코드 예제
AWS SDK for JavaScript	AWS SDK for JavaScript 코드 예제
AWS SDK for Kotlin	AWS SDK for Kotlin 코드 예제
AWS SDK for .NET	AWS SDK for .NET 코드 예제
AWS SDK for PHP	AWS SDK for PHP 코드 예제
AWS Tools for PowerShell	AWS Tools for PowerShell 코드 예제
AWS SDK for Python (Boto3)	AWS SDK for Python (Boto3) 코드 예제
AWS SDK for Ruby	AWS SDK for Ruby 코드 예제
AWS SDK for Rust	AWS SDK for Rust 코드 예제
AWS SDK for SAP ABAP	AWS SDK for SAP ABAP 코드 예제
AWS SDK for Swift	AWS SDK for Swift 코드 예제

i 예제 사용 가능 여부

필요한 예제를 찾을 수 없습니까? 이 페이지 하단의 피드백 제공 링크를 사용하여 코드 예제를 요청합니다.

AWS SDKs를 사용한 Application Auto Scaling 코드 예제

다음 코드 예제에서는 AWS 소프트웨어 개발 키트(SDK)와 함께 Application Auto Scaling을 사용하는 방법을 보여줍니다.

작업은 대규모 프로그램에서 발췌한 코드이며 컨텍스트에 맞춰 실행해야 합니다. 작업은 개별 서비스 함수를 직접 호출하는 방법을 보여주며, 관련 시나리오의 컨텍스트에 맞는 작업을 볼 수 있습니다.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#) [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

코드 예시

- [AWS SDKs를 사용한 Application Auto Scaling의 기본 예제](#)
 - [AWS SDKs를 사용한 Application Auto Scaling 작업](#)
 - [AWS SDK 또는 CLI와 DeleteScalingPolicy 함께 사용](#)
 - [CLI로 DeleteScheduledAction 사용](#)
 - [CLI로 DeregisterScalableTarget 사용](#)
 - [CLI로 DescribeScalableTargets 사용](#)
 - [CLI로 DescribeScalingActivities 사용](#)
 - [AWS SDK 또는 CLI와 DescribeScalingPolicies 함께 사용](#)
 - [CLI로 DescribeScheduledActions 사용](#)
 - [CLI로 PutScalingPolicy 사용](#)
 - [CLI로 PutScheduledAction 사용](#)
 - [AWS SDK 또는 CLI와 RegisterScalableTarget 함께 사용](#)

AWS SDKs를 사용한 Application Auto Scaling의 기본 예제

다음 코드 예제에서는 Application Auto Scaling의 기본 기능을 AWS SDK와 함께 사용하는 방법을 보여줍니다.

예제

- [AWS SDKs를 사용한 Application Auto Scaling 작업](#)
 - [AWS SDK 또는 CLI와 DeleteScalingPolicy 함께 사용](#)
 - [CLI로 DeleteScheduledAction 사용](#)

- [CLI로 DeregisterScalableTarget 사용](#)
- [CLI로 DescribeScalableTargets 사용](#)
- [CLI로 DescribeScalingActivities 사용](#)
- [AWS SDK 또는 CLI와 DescribeScalingPolicies 함께 사용](#)
- [CLI로 DescribeScheduledActions 사용](#)
- [CLI로 PutScalingPolicy 사용](#)
- [CLI로 PutScheduledAction 사용](#)
- [AWS SDK 또는 CLI와 RegisterScalableTarget 함께 사용](#)

AWS SDKs를 사용한 Application Auto Scaling 작업

다음 코드 예제에서는 AWS SDKs를 사용하여 개별 Application Auto Scaling 작업을 수행하는 방법을 보여줍니다. 각 예시에는 GitHub에 대한 링크가 포함되어 있습니다. 여기에서 코드 설정 및 실행에 대한 지침을 찾을 수 있습니다.

다음 예제에는 가장 일반적으로 사용되는 작업만 포함되어 있습니다. 전체 목록은 [Application Auto Scaling API 참조](#)를 참조하세요.

예제

- [AWS SDK 또는 CLI와 DeleteScalingPolicy 함께 사용](#)
- [CLI로 DeleteScheduledAction 사용](#)
- [CLI로 DeregisterScalableTarget 사용](#)
- [CLI로 DescribeScalableTargets 사용](#)
- [CLI로 DescribeScalingActivities 사용](#)
- [AWS SDK 또는 CLI와 DescribeScalingPolicies 함께 사용](#)
- [CLI로 DescribeScheduledActions 사용](#)
- [CLI로 PutScalingPolicy 사용](#)
- [CLI로 PutScheduledAction 사용](#)
- [AWS SDK 또는 CLI와 RegisterScalableTarget 함께 사용](#)

AWS SDK 또는 CLI와 **DeleteScalingPolicy** 함께 사용

다음 코드 예시는 DeleteScalingPolicy의 사용 방법을 보여 줍니다.

CLI

AWS CLI

조정 정책을 삭제하는 방법

이 예제에서는 기본 클러스터에서 실행되는 Amazon ECS 서비스 웹앱에 대한 조정 정책을 삭제합니다.

명령:

```
aws application-autoscaling delete-scaling-policy --policy-name web-app-cpu-lt-25
--scalable-dimension ecs:service:DesiredCount --resource-id service/default/web-app
--service-namespace ecs
```

- API 세부 정보는 AWS CLI 명령 참조의 [DeleteScalingPolicy](#)를 참조하세요.

Java

SDK for Java 2.x

Note

GitHub에 더 많은 내용이 있습니다. [AWS 코드 예 리포지토리](#)에서 전체 예를 찾고 설정 및 실행하는 방법을 배우보세요.

```
import software.amazon.awssdk.regions.Region;
import
    software.amazon.awssdk.services.applicationautoscaling.ApplicationAutoScalingClient;
import
    software.amazon.awssdk.services.applicationautoscaling.model.ApplicationAutoScalingException;
import
    software.amazon.awssdk.services.applicationautoscaling.model.DeleteScalingPolicyRequest;
import
    software.amazon.awssdk.services.applicationautoscaling.model.DeregisterScalableTargetRequest;
import
    software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalableTargetsRequest;
import
    software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalableTargetsResponse;
import
    software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalingPoliciesRequest;
```

```
import
    software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalingPoliciesResponse;
import
    software.amazon.awssdk.services.applicationautoscaling.model.ScalableDimension;
import
    software.amazon.awssdk.services.applicationautoscaling.model.ServiceNamespace;

/**
 * Before running this Java V2 code example, set up your development environment,
 * including your credentials.
 *
 * For more information, see the following documentation topic:
 *
 * https://docs.aws.amazon.com/sdk-for-java/latest/developer-guide/get-started.html
 */

public class DisableDynamoDBAutoscaling {
    public static void main(String[] args) {
        final String usage = ""

            Usage:
                <tableId> <policyName>\s

            Where:
                tableId - The table Id value (for example, table/Music).\s
                policyName - The name of the policy (for example, $Music5-scaling-
policy).

            """;
        if (args.length != 2) {
            System.out.println(usage);
            System.exit(1);
        }

        ApplicationAutoScalingClient appAutoScalingClient =
ApplicationAutoScalingClient.builder()
            .region(Region.US_EAST_1)
            .build();

        ServiceNamespace ns = ServiceNamespace.DYNAMODB;
        ScalableDimension tableWCUs =
ScalableDimension.DYNAMODB_TABLE_WRITE_CAPACITY_UNITS;
        String tableId = args[0];
```

```
String policyName = args[1];

deletePolicy(appAutoScalingClient, policyName, tableWCUs, ns, tableId);
verifyScalingPolicies(appAutoScalingClient, tableId, ns, tableWCUs);
deregisterScalableTarget(appAutoScalingClient, tableId, ns, tableWCUs);
verifyTarget(appAutoScalingClient, tableId, ns, tableWCUs);
}

public static void deletePolicy(ApplicationAutoScalingClient
appAutoScalingClient, String policyName, ScalableDimension tableWCUs,
ServiceNamespace ns, String tableId) {
    try {
        DeleteScalingPolicyRequest delSPRequest =
DeleteScalingPolicyRequest.builder()
        .policyName(policyName)
        .scalableDimension(tableWCUs)
        .serviceNamespace(ns)
        .resourceId(tableId)
        .build();

        appAutoScalingClient.deleteScalingPolicy(delSPRequest);
        System.out.println(policyName + " was deleted successfully.");

    } catch (ApplicationAutoScalingException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
    }
}

// Verify that the scaling policy was deleted
public static void verifyScalingPolicies(ApplicationAutoScalingClient
appAutoScalingClient, String tableId, ServiceNamespace ns, ScalableDimension
tableWCUs) {
    DescribeScalingPoliciesRequest dscRequest =
DescribeScalingPoliciesRequest.builder()
    .scalableDimension(tableWCUs)
    .serviceNamespace(ns)
    .resourceId(tableId)
    .build();

    DescribeScalingPoliciesResponse response =
appAutoScalingClient.describeScalingPolicies(dscRequest);
    System.out.println("DescribeScalableTargets result: ");
    System.out.println(response);
}
```

```
public static void deregisterScalableTarget(ApplicationAutoScalingClient
appAutoScalingClient, String tableId, ServiceNamespace ns, ScalableDimension
tableWCUs) {
    try {
        DeregisterScalableTargetRequest targetRequest =
DeregisterScalableTargetRequest.builder()
            .scalableDimension(tableWCUs)
            .serviceNamespace(ns)
            .resourceId(tableId)
            .build();

        appAutoScalingClient.deregisterScalableTarget(targetRequest);
        System.out.println("The scalable target was deregistered.");

    } catch (ApplicationAutoScalingException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
    }
}

public static void verifyTarget(ApplicationAutoScalingClient
appAutoScalingClient, String tableId, ServiceNamespace ns, ScalableDimension
tableWCUs) {
    DescribeScalableTargetsRequest dscRequest =
DescribeScalableTargetsRequest.builder()
        .scalableDimension(tableWCUs)
        .serviceNamespace(ns)
        .resourceIds(tableId)
        .build();

    DescribeScalableTargetsResponse response =
appAutoScalingClient.describeScalableTargets(dscRequest);
    System.out.println("DescribeScalableTargets result: ");
    System.out.println(response);
}
}
```

- API 세부 정보는 AWS SDK for Java 2.x API 참조의 [DeleteScalingPolicy](#)를 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 cmdlet은 Application Auto Scaling 규모 조정 가능 대상에 대해 지정된 조정 정책을 삭제합니다.

```
Remove-AASScalingPolicy -ServiceNamespace AppStream -PolicyName "default-scale-out" -ResourceId fleet/Test -ScalableDimension appstream:fleet:DesiredCapacity
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [DeleteScalingPolicy](#)를 참조하세요.

Tools for PowerShell V5

예제 1: 이 cmdlet은 Application Auto Scaling 규모 조정 가능 대상에 대해 지정된 조정 정책을 삭제합니다.

```
Remove-AASScalingPolicy -ServiceNamespace AppStream -PolicyName "default-scale-out" -ResourceId fleet/Test -ScalableDimension appstream:fleet:DesiredCapacity
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [DeleteScalingPolicy](#)를 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#) [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

CLI로 DeleteScheduledAction 사용

다음 코드 예시는 DeleteScheduledAction의 사용 방법을 보여 줍니다.

CLI

AWS CLI

예약된 작업을 삭제하는 방법

다음 delete-scheduled-action 예시에서는 지정된 Amazon AppStream 2.0 플릿에서 지정된 예약된 작업을 삭제합니다.

```
aws application-autoscaling delete-scheduled-action \
```

```
--service-namespace appstream \  
--scalable-dimension appstream:fleet:DesiredCapacity \  
--resource-id fleet/sample-fleet \  
--scheduled-action-name my-recurring-action
```

이 명령은 출력을 생성하지 않습니다.

자세한 내용은 <https://docs.aws.amazon.com/autoscaling/application/userguide/application-auto-scaling-scheduled-scaling.html> Application Auto Scaling 사용 설명서의 예약된 조정을 참조하세요.

- API 세부 정보는 AWS CLI 명령 참조의 [DeleteScheduledAction](#)을 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 cmdlet은 Application Auto Scaling 규모 조정 가능 대상에 대해 지정된 예약된 작업을 삭제합니다.

```
Remove-AASScheduledAction -ServiceNamespace AppStream -ScheduledActionName  
WeekDaysFleetScaling -ResourceId fleet/MyFleet -ScalableDimension  
appstream:fleet:DesiredCapacity
```

출력:

```
Confirm  
Are you sure you want to perform this action?  
Performing the operation "Remove-AASScheduledAction (DeleteScheduledAction)" on  
target "WeekDaysFleetScaling".  
[Y] Yes [A] Yes to All [N] No [L] No to All [S] Suspend [?] Help (default is  
"Y"): Y
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [DeleteScheduledAction](#)을 참조하세요.

Tools for PowerShell V5

예제 1: 이 cmdlet은 Application Auto Scaling 규모 조정 가능 대상에 대해 지정된 예약된 작업을 삭제합니다.

```
Remove-AASScheduledAction -ServiceNamespace AppStream -ScheduledActionName
WeekDaysFleetScaling -ResourceId fleet/MyFleet -ScalableDimension
appstream:fleet:DesiredCapacity
```

출력:

```
Confirm
Are you sure you want to perform this action?
Performing the operation "Remove-AASScheduledAction (DeleteScheduledAction)" on
target "WeekDaysFleetScaling".
[Y] Yes [A] Yes to All [N] No [L] No to All [S] Suspend [?] Help (default is
"Y"): Y
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [DeleteScheduledAction](#)을 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 섹션을 참조하세요 [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

CLI로 **DeregisterScalableTarget** 사용

다음 코드 예시는 DeregisterScalableTarget의 사용 방법을 보여 줍니다.

CLI

AWS CLI

규모 조정 가능 대상을 등록 취소하는 방법

이 예제에서는 기본 클러스터에서 실행 중인 웹앱이라고 하는 Amazon ECS 서비스에 대한 확장 가능 대상의 등록을 취소합니다.

명령:

```
aws application-autoscaling deregister-scalable-target --service-namespace ecs --
scalable-dimension ecs:service:DesiredCount --resource-id service/default/web-app
```

이 예제에서는 사용자 지정 리소스에 대한 확장 가능 대상의 등록을 취소합니다. custom-resource-id.txt 파일에는 리소스 ID를 식별하는 문자열이 포함되어 있으며 이는 사용자 지정 리소스의 경우 Amazon API Gateway 엔드포인트를 통하는 사용자 지정 리소스에 대한 경로입니다.

명령:

```
aws application-autoscaling deregister-scalable-target --
service-namespace custom-resource --scalable-dimension custom-
resource:ResourceType:Property --resource-id file://~/custom-resource-id.txt
```

custom-resource-id.txt 파일의 콘텐츠:

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

- API 세부 정보는 AWS CLI 명령 참조의 [DeregisterScalableTarget](#)을 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 cmdlet에서는 Application Auto Scaling 규모 조정 가능 대상의 등록을 취소합니다. 규모 조정 가능 대상의 등록을 취소하면 연결된 조정 정책이 삭제됩니다.

```
Remove-AASScalableTarget -ResourceId fleet/MyFleet -ScalableDimension
appstream:fleet:DesiredCapacity -ServiceNamespace AppStream
```

출력:

```
Confirm
Are you sure you want to perform this action?
Performing the operation "Remove-AASScalableTarget (DeregisterScalableTarget)" on
target "fleet/MyFleet".
[Y] Yes [A] Yes to All [N] No [L] No to All [S] Suspend [?] Help (default is
"Y"): Y
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [DeregisterScalableTarget](#)을 참조하세요.

Tools for PowerShell V5

예제 1: 이 cmdlet에서는 Application Auto Scaling 규모 조정 가능 대상의 등록을 취소합니다. 규모 조정 가능 대상의 등록을 취소하면 연결된 조정 정책이 삭제됩니다.

```
Remove-AAScalableTarget -ResourceId fleet/MyFleet -ScalableDimension
  appstream:fleet:DesiredCapacity -ServiceNamespace AppStream
```

출력:

```
Confirm
Are you sure you want to perform this action?
Performing the operation "Remove-AAScalableTarget (DeregisterScalableTarget)" on
target "fleet/MyFleet".
[Y] Yes [A] Yes to All [N] No [L] No to All [S] Suspend [?] Help (default is
"Y"): Y
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [DeregisterScalableTarget](#)을 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#) [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

CLI로 DescribeScalableTargets 사용

다음 코드 예시는 DescribeScalableTargets의 사용 방법을 보여 줍니다.

CLI**AWS CLI**

규모 조정 가능 대상을 설명하는 방법

다음 describe-scalable-targets 예제에서는 ecs 서비스 네임스페이스에 대한 확장 가능 대상을 설명합니다.

```
aws application-autoscaling describe-scalable-targets \
  --service-namespace ecs
```

출력:

```
{
  "ScalableTargets": [
    {
      "ServiceNamespace": "ecs",
```

```

        "ScalableDimension": "ecs:service:DesiredCount",
        "ResourceId": "service/default/web-app",
        "MinCapacity": 1,
        "MaxCapacity": 10,
        "RoleARN": "arn:aws:iam::123456789012:role/
aws-service-role/ecs.application-autoscaling.amazonaws.com/
AWSServiceRoleForApplicationAutoScaling_ECSService",
        "CreationTime": 1462558906.199,
        "SuspendedState": {
            "DynamicScalingOutSuspended": false,
            "ScheduledScalingSuspended": false,
            "DynamicScalingInSuspended": false
        },
        "ScalableTargetARN": "arn:aws:application-autoscaling:us-
west-2:123456789012:scalable-target/1234abcd56ab78cd901ef1234567890ab123"
    }
]
}

```

자세한 내용은 Application Auto Scaling 사용 설명서의 [Application Auto Scaling과 함께 사용할 수 있는 AWS 서비스](#)를 참조하세요.

- API 세부 정보는 AWS CLI 명령 참조의 [DescribeScalableTargets](#)를 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 예제에서는 지정된 네임스페이스의 Application Auto Scaling 규모 조정 가능 대상에 대한 정보를 제공합니다.

```
Get-AASScalableTarget -ServiceNamespace "AppStream"
```

출력:

```

CreationTime      : 11/7/2019 2:30:03 AM
MaxCapacity       : 5
MinCapacity       : 1
ResourceId        : fleet/Test
RoleARN           : arn:aws:iam::012345678912:role/aws-
service-role/appstream.application-autoscaling.amazonaws.com/
AWSServiceRoleForApplicationAutoScaling_AppStreamFleet

```

```
ScalableDimension : appstream:fleet:DesiredCapacity
ServiceNamespace  : appstream
SuspendedState    : Amazon.ApplicationAutoScaling.Model.SuspendedState
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [DescribeScalableTargets](#)을 참조하세요.

Tools for PowerShell V5

예제 1: 이 예제에서는 지정된 네임스페이스의 Application Auto Scaling 규모 조정 가능 대상에 대한 정보를 제공합니다.

```
Get-AASScalableTarget -ServiceNamespace "AppStream"
```

출력:

```
CreationTime      : 11/7/2019 2:30:03 AM
MaxCapacity       : 5
MinCapacity       : 1
ResourceId        : fleet/Test
RoleARN           : arn:aws:iam::012345678912:role/aws-
service-role/appstream.application-autoscaling.amazonaws.com/
AWSServiceRoleForApplicationAutoScaling_AppStreamFleet
ScalableDimension : appstream:fleet:DesiredCapacity
ServiceNamespace  : appstream
SuspendedState    : Amazon.ApplicationAutoScaling.Model.SuspendedState
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [DescribeScalableTargets](#)을 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#)[AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

CLI로 **DescribeScalingActivities** 사용

다음 코드 예시는 DescribeScalingActivities의 사용 방법을 보여 줍니다.

CLI

AWS CLI

예제 1: 지정된 Amazon ECS 서비스에 대한 조정 활동을 설명하는 방법

다음 describe-scaling-activities 예제에서는 default 클러스터에서 실행 중인 web-app이라고 하는 Amazon ECS 서비스에 대한 스케일링 활동을 설명합니다. 출력은 조정 정책에 의해 시작되는 스케일링 활동을 표시합니다.

```
aws application-autoscaling describe-scaling-activities \
  --service-namespace ecs \
  --resource-id service/default/web-app
```

출력:

```
{
  "ScalingActivities": [
    {
      "ScalableDimension": "ecs:service:DesiredCount",
      "Description": "Setting desired count to 1.",
      "ResourceId": "service/default/web-app",
      "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"
    }
  ]
}
```

자세한 내용은 Application Auto Scaling 사용 설명서의 [Application Auto Scaling에 대한 스케일링 활동](#)을 참조하세요.

예제 2: 지정된 DynamoDB 테이블에 대한 스케일링 활동을 설명하는 방법

다음 describe-scaling-activities 예제에서는 TestTable이라고 하는 DynamoDB에 대한 스케일링 활동을 설명합니다. 출력은 두 가지 다른 예약된 작업에 의해 시작되는 스케일링 활동을 표시합니다.

```
aws application-autoscaling describe-scaling-activities \
  --service-namespace dynamodb \
  --resource-id table/TestTable
```

출력:

```
{
  "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"
    }
]
}

```

자세한 내용은 Application Auto Scaling 사용 설명서의 [Application Auto Scaling에 대한 스케일링 활동](#)을 참조하세요.

- API 세부 정보는 AWS CLI 명령 참조의 [DescribeScalingActivities](#)를 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이전 6주 동안 지정된 서비스 네임스페이스의 조정 활동에 대한 설명이 포함된 정보를 제공합니다.

```
Get-AASScalingActivity -ServiceNamespace AppStream
```

출력:

```

ActivityId      : 2827409f-b639-4cdb-a957-8055d5d07434
Cause           : monitor alarm Appstream2-MyFleet-default-scale-in-Alarm in
                  state ALARM triggered policy default-scale-in
Description     : Setting desired capacity to 2.
Details         :
EndTime        : 12/14/2019 11:32:49 AM
ResourceId      : fleet/MyFleet
ScalableDimension : appstream:fleet:DesiredCapacity
ServiceNamespace : appstream
StartTime       : 12/14/2019 11:32:14 AM
StatusCode      : Successful

```

```
StatusMessage      : Successfully set desired capacity to 2. Change successfully fulfilled by appstream.
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [DescribeScalingActivities](#)를 참조하세요.

Tools for PowerShell V5

예제 1: 이전 6주 동안 지정된 서비스 네임스페이스의 조정 활동에 대한 설명이 포함된 정보를 제공합니다.

```
Get-AASScalingActivity -ServiceNamespace AppStream
```

출력:

```
ActivityId          : 2827409f-b639-4cdb-a957-8055d5d07434
Cause               : monitor alarm Appstream2-MyFleet-default-scale-in-Alarm in state ALARM triggered policy default-scale-in
Description         : Setting desired capacity to 2.
Details            :
EndTime            : 12/14/2019 11:32:49 AM
ResourceId          : fleet/MyFleet
ScalableDimension  : appstream:fleet:DesiredCapacity
ServiceNamespace   : appstream
StartTime          : 12/14/2019 11:32:14 AM
StatusCode          : Successful
StatusMessage      : Successfully set desired capacity to 2. Change successfully fulfilled by appstream.
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [DescribeScalingActivities](#)를 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#) [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

AWS SDK 또는 CLI와 **DescribeScalingPolicies** 함께 사용

다음 코드 예시는 DescribeScalingPolicies의 사용 방법을 보여 줍니다.

CLI

AWS CLI

조정 정책을 설명하는 방법

이 예제 명령은 ECS 서비스 네임스페이스에 대한 조정 정책을 설명합니다.

명령:

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

출력:

```
{
  "ScalingPolicies": [
    {
      "PolicyName": "web-app-cpu-gt-75",
      "ScalableDimension": "ecs:service:DesiredCount",
      "ResourceId": "service/default/web-app",
      "CreationTime": 1462561899.23,
      "StepScalingPolicyConfiguration": {
        "Cooldown": 60,
        "StepAdjustments": [
          {
            "ScalingAdjustment": 200,
            "MetricIntervalLowerBound": 0.0
          }
        ],
        "AdjustmentType": "PercentChangeInCapacity"
      },
      "PolicyARN": "arn:aws:autoscaling:us-west-2:012345678910:scalingPolicy:6d8972f3-efc8-437c-92d1-6270f29a66e7:resource/ecs/service/default/web-app:policyName/web-app-cpu-gt-75",
      "PolicyType": "StepScaling",
      "Alarms": [
        {
          "AlarmName": "web-app-cpu-gt-75",
          "AlarmARN": "arn:aws:cloudwatch:us-west-2:012345678910:alarm:web-app-cpu-gt-75"
        }
      ],
      "ServiceNamespace": "ecs"
    }
  ]
}
```

```

    },
    {
      "PolicyName": "web-app-cpu-1t-25",
      "ScalableDimension": "ecs:service:DesiredCount",
      "ResourceId": "service/default/web-app",
      "CreationTime": 1462562575.099,
      "StepScalingPolicyConfiguration": {
        "Cooldown": 1,
        "StepAdjustments": [
          {
            "ScalingAdjustment": -50,
            "MetricIntervalUpperBound": 0.0
          }
        ],
        "AdjustmentType": "PercentChangeInCapacity"
      },
      "PolicyARN": "arn:aws:autoscaling:us-
west-2:012345678910:scalingPolicy:6d8972f3-efc8-437c-92d1-6270f29a66e7:resource/
ecs/service/default/web-app:policyName/web-app-cpu-1t-25",
      "PolicyType": "StepScaling",
      "Alarms": [
        {
          "AlarmName": "web-app-cpu-1t-25",
          "AlarmARN": "arn:aws:cloudwatch:us-
west-2:012345678910:alarm:web-app-cpu-1t-25"
        }
      ],
      "ServiceNamespace": "ecs"
    }
  ]
}

```

- API 세부 정보는 AWS CLI 명령 참조의 [DescribeScalingPolicies](#)를 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 cmdlet에서는 지정된 서비스 네임스페이스에 대한 Application Auto Scaling 조정 정책을 설명합니다.

```
Get-AASScalingPolicy -ServiceNamespace AppStream
```

출력:

```

Alarms                               : {Appstream2-LabFleet-default-scale-
out-Alarm}
CreationTime                         : 9/3/2019 2:48:15 AM
PolicyARN                            : arn:aws:autoscaling:us-
west-2:012345678912:scalingPolicy:5659b069-b5cd-4af1-9f7f-3e956d36233e:resource/
appstream/fleet/LabFleet:
                                     policyName/default-scale-out
PolicyName                           : default-scale-out
PolicyType                           : StepScaling
ResourceId                           : fleet/LabFleet
ScalableDimension                   : appstream:fleet:DesiredCapacity
ServiceNamespace                    : appstream
StepScalingPolicyConfiguration       :
  Amazon.ApplicationAutoScaling.Model.StepScalingPolicyConfiguration
TargetTrackingScalingPolicyConfiguration :

Alarms                               : {Appstream2-LabFleet-default-scale-in-
Alarm}
CreationTime                         : 9/3/2019 2:48:15 AM
PolicyARN                            : arn:aws:autoscaling:us-
west-2:012345678912:scalingPolicy:5659b069-b5cd-4af1-9f7f-3e956d36233e:resource/
appstream/fleet/LabFleet:
                                     policyName/default-scale-in
PolicyName                           : default-scale-in
PolicyType                           : StepScaling
ResourceId                           : fleet/LabFleet
ScalableDimension                   : appstream:fleet:DesiredCapacity
ServiceNamespace                    : appstream
StepScalingPolicyConfiguration       :
  Amazon.ApplicationAutoScaling.Model.StepScalingPolicyConfiguration
TargetTrackingScalingPolicyConfiguration :

```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [DescribeScalingPolicies](#)를 참조하세요.

Tools for PowerShell V5

예제 1: 이 cmdlet에서는 지정된 서비스 네임스페이스에 대한 Application Auto Scaling 조정 정책을 설명합니다.

```
Get-AASScalingPolicy -ServiceNamespace AppStream
```

출력:

```

Alarms                               : {Appstream2-LabFleet-default-scale-
out-Alarm}
CreationTime                         : 9/3/2019 2:48:15 AM
PolicyARN                            : arn:aws:autoscaling:us-
west-2:012345678912:scalingPolicy:5659b069-b5cd-4af1-9f7f-3e956d36233e:resource/
appstream/fleet/LabFleet:
                                     policyName/default-scale-out
PolicyName                           : default-scale-out
PolicyType                           : StepScaling
ResourceId                           : fleet/LabFleet
ScalableDimension                    : appstream:fleet:DesiredCapacity
ServiceNamespace                     : appstream
StepScalingPolicyConfiguration       :
  Amazon.ApplicationAutoScaling.Model.StepScalingPolicyConfiguration
TargetTrackingScalingPolicyConfiguration :

Alarms                               : {Appstream2-LabFleet-default-scale-in-
Alarm}
CreationTime                         : 9/3/2019 2:48:15 AM
PolicyARN                            : arn:aws:autoscaling:us-
west-2:012345678912:scalingPolicy:5659b069-b5cd-4af1-9f7f-3e956d36233e:resource/
appstream/fleet/LabFleet:
                                     policyName/default-scale-in
PolicyName                           : default-scale-in
PolicyType                           : StepScaling
ResourceId                           : fleet/LabFleet
ScalableDimension                    : appstream:fleet:DesiredCapacity
ServiceNamespace                     : appstream
StepScalingPolicyConfiguration       :
  Amazon.ApplicationAutoScaling.Model.StepScalingPolicyConfiguration
TargetTrackingScalingPolicyConfiguration :

```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [DescribeScalingPolicies](#)를 참조하세요.

Rust

SDK for Rust

Note

GitHub에 더 많은 내용이 있습니다. [AWS 코드 예 리포지토리](#)에서 전체 예를 찾고 설정 및 실행하는 방법을 배워보세요.

```
async fn show_policies(client: &Client) -> Result<(), Error> {
    let response = client
        .describe_scaling_policies()
        .service_namespace(ServiceNamespace::Ec2)
        .send()
        .await?;
    println!("Auto Scaling Policies:");
    for policy in response.scaling_policies() {
        println!("{:?}\n", policy);
    }
    println!("Next token: {:?}", response.next_token());

    Ok(())
}
```

- API 세부 정보는 AWS SDK for Rust API 참조의 [DescribeScalingPolicies](#)를 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#) [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

CLI로 **DescribeScheduledActions** 사용

다음 코드 예시는 DescribeScheduledActions의 사용 방법을 보여 줍니다.

CLI

AWS CLI

예약된 작업을 설명하는 방법

다음 `describe-scheduled-actions` 예제에서는 지정된 서비스 네임스페이스에 대한 예약된 작업의 세부 정보를 표시합니다.

```
aws application-autoscaling describe-scheduled-actions \  
--service-namespace dynamodb
```

출력:

```
{  
  "ScheduledActions": [  
    {  
      "ScalableDimension": "dynamodb:table:WriteCapacityUnits",  
      "Schedule": "at(2019-05-20T18:35:00)",  
      "ResourceId": "table/my-table",  
      "CreationTime": 1561571888.361,  
      "ScheduledActionARN": "arn:aws:autoscaling:us-  
west-2:123456789012:scheduledAction:2d36aa3b-cdf9-4565-  
b290-81db519b227d:resource/dynamodb/table/my-table:scheduledActionName/my-first-  
scheduled-action",  
      "ScalableTargetAction": {  
        "MinCapacity": 15,  
        "MaxCapacity": 20  
      },  
      "ScheduledActionName": "my-first-scheduled-action",  
      "ServiceNamespace": "dynamodb"  
    },  
    {  
      "ScalableDimension": "dynamodb:table:WriteCapacityUnits",  
      "Schedule": "at(2019-05-20T18:40:00)",  
      "ResourceId": "table/my-table",  
      "CreationTime": 1561571946.021,  
      "ScheduledActionARN": "arn:aws:autoscaling:us-  
west-2:123456789012:scheduledAction:2d36aa3b-cdf9-4565-  
b290-81db519b227d:resource/dynamodb/table/my-table:scheduledActionName/my-second-  
scheduled-action",  
      "ScalableTargetAction": {  
        "MinCapacity": 5,  
        "MaxCapacity": 10  
      },  
      "ScheduledActionName": "my-second-scheduled-action",  
      "ServiceNamespace": "dynamodb"  
    }  
  ]  
}
```

```
}

```

자세한 내용은 <https://docs.aws.amazon.com/autoscaling/application/userguide/application-auto-scaling-scheduled-scaling.html> Application Auto Scaling 사용 설명서의 예약된 조정을 참조하세요.

- API 세부 정보는 AWS CLI 명령 참조의 [DescribeScheduledActions](#) 섹션을 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 cmdlet에서는 실행되지 않았거나 종료 시간에 도달하지 않은 Auto Scaling 그룹에 예약된 작업을 나열합니다.

```
Get-AASScheduledAction -ServiceNamespace AppStream
```

출력:

```
CreationTime      : 12/22/2019 9:25:52 AM
EndTime          : 1/1/0001 12:00:00 AM
ResourceId       : fleet/MyFleet
ScalableDimension : appstream:fleet:DesiredCapacity
ScalableTargetAction : Amazon.ApplicationAutoScaling.Model.ScalableTargetAction
Schedule         : cron(0 0 8 ? * MON-FRI *)
ScheduledActionARN : arn:aws:autoscaling:us-west-2:012345678912:scheduledAction:4897ca24-3caa-4bf1-8484-851a089b243c:resource/appstream/fleet/MyFleet:scheduledActionName/WeekDaysFleetScaling
ScheduledActionName : WeekDaysFleetScaling
ServiceNamespace  : appstream
StartTime        : 1/1/0001 12:00:00 AM
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [DescribeScheduledActions](#)을 참조하세요.

Tools for PowerShell V5

예제 1: 이 cmdlet에서는 실행되지 않았거나 종료 시간에 도달하지 않은 Auto Scaling 그룹에 예약된 작업을 나열합니다.

```
Get-AASScheduledAction -ServiceNamespace AppStream
```

출력:

```

CreationTime      : 12/22/2019 9:25:52 AM
EndTime          : 1/1/0001 12:00:00 AM
ResourceId       : fleet/MyFleet
ScalableDimension : appstream:fleet:DesiredCapacity
ScalableTargetAction : Amazon.ApplicationAutoScaling.Model.ScalableTargetAction
Schedule         : cron(0 0 8 ? * MON-FRI *)
ScheduledActionARN : arn:aws:autoscaling:us-
west-2:012345678912:scheduledAction:4897ca24-3caa-4bf1-8484-851a089b243c:resource/
appstream/fleet/MyFleet:scheduledActionName
                  /WeekDaysFleetScaling
ScheduledActionName : WeekDaysFleetScaling
ServiceNamespace  : appstream
StartTime         : 1/1/0001 12:00:00 AM

```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [DescribeScheduledActions](#)을 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 섹션을 참조하세요 [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

CLI로 PutScalingPolicy 사용

다음 코드 예시는 PutScalingPolicy의 사용 방법을 보여 줍니다.

CLI

AWS CLI

예 1: 사전 정의된 지표 사양을 사용하여 대상 추적 조정 정책 적용

다음 put-scaling-policy 예제에서는 기본 클러스터에서 미리 정의된 지표 사양이 있는 대상 추적 조정 정책을 웹앱이라고 하는 Amazon ECS 서비스에 적용합니다. 이 정책은 60초의 스케일 아웃 및 스케일 인 휴지 기간을 사용하여 서비스의 평균 CPU 사용률을 75%로 유지합니다. 출력에는 ARN과 사용자를 대신하여 생성된 두 개의 CloudWatch 경보 이름이 포함됩니다.

```

aws application-autoscaling put-scaling-policy --service-namespace ecs \
--scalable-dimension ecs:service:DesiredCount \
--resource-id service/default/web-app \
--policy-name cpu75-target-tracking-scaling-policy --policy-
type TargetTrackingScaling \

```

```
--target-tracking-scaling-policy-configuration file://config.json
```

이 예제에서는 현재 디렉터리에 다음 콘텐츠가 포함된 config.json 파일이 있다고 가정합니다.

```
{
  "TargetValue": 75.0,
  "PredefinedMetricSpecification": {
    "PredefinedMetricType": "ECSServiceAverageCPUUtilization"
  },
  "ScaleOutCooldown": 60,
  "ScaleInCooldown": 60
}
```

출력:

```
{
  "PolicyARN": "arn:aws:autoscaling:us-west-2:012345678910:scalingPolicy:6d8972f3-efc8-437c-92d1-6270f29a66e7:resource/ecs/service/default/web-app:policyName/cpu75-target-tracking-scaling-policy",
  "Alarms": [
    {
      "AlarmARN": "arn:aws:cloudwatch:us-west-2:012345678910:alarm:TargetTracking-service/default/web-app-AlarmHigh-d4f0770c-b46e-434a-a60f-3b36d653feca",
      "AlarmName": "TargetTracking-service/default/web-app-AlarmHigh-d4f0770c-b46e-434a-a60f-3b36d653feca"
    },
    {
      "AlarmARN": "arn:aws:cloudwatch:us-west-2:012345678910:alarm:TargetTracking-service/default/web-app-AlarmLow-1b437334-d19b-4a63-a812-6c67aaf2910d",
      "AlarmName": "TargetTracking-service/default/web-app-AlarmLow-1b437334-d19b-4a63-a812-6c67aaf2910d"
    }
  ]
}
```

예 2: 사용자 지정된 지표 사양을 사용하여 대상 추적 조정 정책 적용

다음 put-scaling-policy 예제에서는 기본 클러스터에서 사용자 지정 지표 사양이 있는 대상 추적 조정 정책을 웹앱이라고 하는 Amazon ECS 서비스에 적용합니다. 이 정책은 60초의 스

케일 아웃 및 스케일 인 휴지 기간을 사용하여 서비스의 평균 사용률을 75%로 유지합니다. 출력에는 ARN과 사용자를 대신하여 생성된 두 개의 CloudWatch 경보 이름이 포함됩니다.

```
aws application-autoscaling put-scaling-policy --service-namespace ecs \
--scalable-dimension ecs:service:DesiredCount \
--resource-id service/default/web-app \
--policy-name cms75-target-tracking-scaling-policy \
--policy-type TargetTrackingScaling \
--target-tracking-scaling-policy-configuration file://config.json
```

이 예제에서는 현재 디렉토리에 다음 콘텐츠가 포함된 config.json 파일이 있다고 가정합니다.

```
{
  "TargetValue":75.0,
  "CustomizedMetricSpecification":{
    "MetricName":"MyUtilizationMetric",
    "Namespace":"MyNamespace",
    "Dimensions": [
      {
        "Name":"MyOptionalMetricDimensionName",
        "Value":"MyOptionalMetricDimensionValue"
      }
    ],
    "Statistic":"Average",
    "Unit":"Percent"
  },
  "ScaleOutCooldown": 60,
  "ScaleInCooldown": 60
}
```

출력:

```
{
  "PolicyARN": "arn:aws:autoscaling:us-west-2:012345678910:scalingPolicy:8784a896-b2ba-47a1-b08c-27301cc499a1:resource/ecs/service/default/web-app:policyName/cms75-target-tracking-scaling-policy",
  "Alarms": [
    {
      "AlarmARN": "arn:aws:cloudwatch:us-west-2:012345678910:alarm:TargetTracking-service/default/web-app-AlarmHigh-9bc77b56-0571-4276-ba0f-d4178882e0a0",
```

```

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

```

예 3: 스케일 아웃을 위한 대상 추적 조정 정책 적용

다음 `put-scaling-policy` 예제에서는 기본 클러스터에서 대상 추적 조정 정책을 `web-app`이라고 하는 Amazon ECS 서비스에 적용합니다. 정책은 Application Load Balancer의 `RequestCountPerTarget` 지표가 임계값을 초과할 때 ECS 서비스를 스케일 아웃하는 데 사용됩니다. 출력에는 ARN과 사용자를 대신하여 생성된 CloudWatch 경보 이름이 포함됩니다.

```

aws application-autoscaling put-scaling-policy \
  --service-namespace ecs \
  --scalable-dimension ecs:service:DesiredCount \
  --resource-id service/default/web-app \
  --policy-name alb-scale-out-target-tracking-scaling-policy \
  --policy-type TargetTrackingScaling \
  --target-tracking-scaling-policy-configuration file://config.json

```

`config.json`의 콘텐츠:

```

{
  "TargetValue": 1000.0,
  "PredefinedMetricSpecification": {
    "PredefinedMetricType": "ALBRequestCountPerTarget",
    "ResourceLabel": "app/EC2Co-EcsE1-1TKLTMITMM0E0/f37c06a68c1748aa/
targetgroup/EC2Co-Defau-LDNM7Q3ZH1ZN/6d4ea56ca2d6a18d"
  },
  "ScaleOutCooldown": 60,
  "ScaleInCooldown": 60,
  "DisableScaleIn": true
}

```

출력:

```
{
  "PolicyARN": "arn:aws:autoscaling:us-
west-2:123456789012:scalingPolicy:6d8972f3-efc8-437c-92d1-6270f29a66e7:resource/
ecs/service/default/web-app:policyName/alb-scale-out-target-tracking-scaling-
policy",
  "Alarms": [
    {
      "AlarmName": "TargetTracking-service/default/web-app-AlarmHigh-
d4f0770c-b46e-434a-a60f-3b36d653feca",
      "AlarmARN": "arn:aws:cloudwatch:us-
west-2:123456789012:alarm:TargetTracking-service/default/web-app-AlarmHigh-
d4f0770c-b46e-434a-a60f-3b36d653feca"
    }
  ]
}
```

자세한 내용은 AWS Application Auto Scaling 사용 설명서의 [Application Auto Scaling에 대한 대상 추적 조정 정책](#)을 참조하세요.

- API 세부 정보는 AWS CLI 명령 참조의 [PutScalingPolicy](#)를 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 cmdlet에서는 Application Auto Scaling 규모 조정 가능 대상에 대한 정책을 생성 또는 업데이트합니다. 각 규모 조정 가능 대상은 서비스 네임스페이스, 리소스 ID 및 규모 조정 가능 차원으로 식별됩니다.

```
Set-AASScalingPolicy -ServiceNamespace AppStream -PolicyName ASFleetScaleInPolicy
-PolicyType StepScaling -ResourceId fleet/MyFleet -ScalableDimension
appstream:fleet:DesiredCapacity -StepScalingPolicyConfiguration_AdjustmentType
ChangeInCapacity -StepScalingPolicyConfiguration_Cooldown 360
-StepScalingPolicyConfiguration_MetricAggregationType Average -
StepScalingPolicyConfiguration_StepAdjustments @{ScalingAdjustment = -1;
MetricIntervalUpperBound = 0}
```

출력:

```
Alarms    PolicyARN
```

```

-----
{}      arn:aws:autoscaling:us-
west-2:012345678912:scalingPolicy:4897ca24-3caa-4bf1-8484-851a089b243c:resource/
appstream/fleet/MyFleet:policyName/ASFleetScaleInPolicy

```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [PutScalingPolicy](#)를 참조하세요.

Tools for PowerShell V5

예제 1: 이 cmdlet에서는 Application Auto Scaling 규모 조정 가능 대상에 대한 정책을 생성 또는 업데이트합니다. 각 규모 조정 가능 대상은 서비스 네임스페이스, 리소스 ID 및 규모 조정 가능 차원으로 식별됩니다.

```

Set-AASScalingPolicy -ServiceNamespace AppStream -PolicyName ASFleetScaleInPolicy
-PolicyType StepScaling -ResourceId fleet/MyFleet -ScalableDimension
appstream:fleet:DesiredCapacity -StepScalingPolicyConfiguration_AdjustmentType
ChangeInCapacity -StepScalingPolicyConfiguration_Cooldown 360
-StepScalingPolicyConfiguration_MetricAggregationType Average -
StepScalingPolicyConfiguration_StepAdjustments @{ScalingAdjustment = -1;
MetricIntervalUpperBound = 0}

```

출력:

```

Alarms      PolicyARN
-----
{}      arn:aws:autoscaling:us-
west-2:012345678912:scalingPolicy:4897ca24-3caa-4bf1-8484-851a089b243c:resource/
appstream/fleet/MyFleet:policyName/ASFleetScaleInPolicy

```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [PutScalingPolicy](#)를 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#) [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

CLI로 PutScheduledAction 사용

다음 코드 예시는 PutScheduledAction의 사용 방법을 보여 줍니다.

CLI

AWS CLI

DynamoDB 테이블에 예약된 작업을 추가하는 방법

이 예제에서는 TestTable이라고 하는 DynamoDB 테이블에 예약된 작업을 추가하여 반복 일정으로 스케일 아웃합니다. 지정된 일정(UTC 기준 매일 오후 12시 15분)에서 현재 용량이 MinCapacity에 대해 지정된 값보다 작은 경우 Application Auto Scaling은 MinCapacity에 의해 지정된 값으로 스케일 아웃됩니다.

명령:

```
aws application-autoscaling put-scheduled-action --service-namespace dynamodb --scheduled-action-name my-recurring-action --schedule "cron(15 12 * * ? *)" --resource-id table/TestTable --scalable-dimension dynamodb:table:WriteCapacityUnits --scalable-target-action MinCapacity=6
```

자세한 내용은 Application Auto Scaling 사용 설명서의 예약된 조정을 참조하세요.

- API 세부 정보는 AWS CLI 명령 참조의 [PutScheduledAction](#)을 참조하세요.

PowerShell

Tools for PowerShell V4

예제 1: 이 cmdlet에서는 Application Auto Scaling 규모 조정 가능 대상에 대한 예약된 작업을 생성 또는 업데이트합니다. 각 규모 조정 가능 대상은 서비스 네임스페이스, 리소스 ID 및 규모 조정 가능 차원으로 식별됩니다.

```
Set-AASScheduledAction -ServiceNamespace AppStream -ResourceId fleet/MyFleet -Schedule "cron(0 0 8 ? * MON-FRI *)" -ScalableDimension appstream:fleet:DesiredCapacity -ScheduledActionName WeekDaysFleetScaling -ScalableTargetAction_MinCapacity 5 -ScalableTargetAction_MaxCapacity 10
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V4)의 [PutScheduledAction](#)을 참조하세요.

Tools for PowerShell V5

예제 1: 이 cmdlet에서는 Application Auto Scaling 규모 조정 가능 대상에 대한 예약된 작업을 생성 또는 업데이트합니다. 각 규모 조정 가능 대상은 서비스 네임스페이스, 리소스 ID 및 규모 조정 가능 차원으로 식별됩니다.

```
Set-AASScheduledAction -ServiceNamespace AppStream -ResourceId fleet/
MyFleet -Schedule "cron(0 0 8 ? * MON-FRI *)" -ScalableDimension
  appstream:fleet:DesiredCapacity -ScheduledActionName WeekDaysFleetScaling -
ScalableTargetAction_MinCapacity 5 -ScalableTargetAction_MaxCapacity 10
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [PutScheduledAction](#)을 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#) [AWS SDK에서 이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

AWS SDK 또는 CLI와 **RegisterScalableTarget** 함께 사용

다음 코드 예시는 RegisterScalableTarget의 사용 방법을 보여 줍니다.

CLI

AWS CLI

예제 1: ECS 서비스를 규모 조정 가능 대상으로 등록하는 방법

다음 register-scalable-target 예제에서는 Application Auto Scaling에 Amazon ECS 서비스를 등록합니다. 또한 키 이름 environment 및 production 값을 갖는 태그를 확장 가능 대상에 추가합니다.

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

출력:

```
{
```

```
"ScalableTargetARN": "arn:aws:application-autoscaling:us-west-2:123456789012:scalable-target/1234abcd56ab78cd901ef1234567890ab123"
}
```

다른 AWS 서비스 및 사용자 지정 리소스에 대한 예제는 [AWS Application Auto Scaling 사용 설명서의 Application Auto Scaling과 함께 사용할 수 있는 서비스의](#) 주제를 참조하세요. Auto Scaling

예제 2: 확장 가능 대상에 대한 스케일링 활동을 중단하는 방법

다음 register-scalable-target 예제에서는 기존 확장 가능 대상에 대한 조정 활동을 중단합니다.

```
aws application-autoscaling register-scalable-target \
  --service-namespace dynamodb \
  --scalable-dimension dynamodb:table:ReadCapacityUnits \
  --resource-id table/my-table \
  --suspended-
state DynamicScalingInSuspended=true,DynamicScalingOutSuspended=true,ScheduledScalingSusp
```

출력:

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:us-west-2:123456789012:scalable-target/1234abcd56ab78cd901ef1234567890ab123"
}
```

자세한 내용은 Application Auto Scaling 사용 설명서의 [Application Auto Scaling에 대한 스케일링 중단 및 재개](#)를 참조하세요.

예제 3: 확장 가능 대상에 대한 스케일링 활동을 재개하는 방법

다음 register-scalable-target 예제에서는 기존 확장 가능 대상에 대한 조정 활동을 재개합니다.

```
aws application-autoscaling register-scalable-target \
  --service-namespace dynamodb \
  --scalable-dimension dynamodb:table:ReadCapacityUnits \
  --resource-id table/my-table \
  --suspended-
state DynamicScalingInSuspended=false,DynamicScalingOutSuspended=false,ScheduledScalingSu
```

출력:

```
{
  "ScalableTargetARN": "arn:aws:application-autoscaling:us-
west-2:123456789012:scalable-target/1234abcd56ab78cd901ef1234567890ab123"
}
```

자세한 내용은 Application Auto Scaling 사용 설명서의 [Application Auto Scaling에 대한 스케일링 중단 및 재개](#)를 참조하세요.

- API 세부 정보는 AWS CLI 명령 참조의 [RegisterScalableTarget](#)을 참조하세요.

Java

SDK for Java 2.x

Note

GitHub에 더 많은 내용이 있습니다. [AWS 코드 예 리포지토리](#)에서 전체 예를 찾고 설정 및 실행하는 방법을 배우보세요.

```
import software.amazon.awssdk.regions.Region;
import
  software.amazon.awssdk.services.applicationautoscaling.ApplicationAutoScalingClient;
import
  software.amazon.awssdk.services.applicationautoscaling.model.ApplicationAutoScalingExcepti
import
  software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalableTargetsRequ
import
  software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalableTargetsResp
import
  software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalingPoliciesRequ
import
  software.amazon.awssdk.services.applicationautoscaling.model.DescribeScalingPoliciesResp
import software.amazon.awssdk.services.applicationautoscaling.model.PolicyType;
import
  software.amazon.awssdk.services.applicationautoscaling.model.PredefinedMetricSpecificati
import
  software.amazon.awssdk.services.applicationautoscaling.model.PutScalingPolicyRequest;
import
  software.amazon.awssdk.services.applicationautoscaling.model.RegisterScalableTargetReque
```

```
import
    software.amazon.awssdk.services.applicationautoscaling.model.ScalingPolicy;
import
    software.amazon.awssdk.services.applicationautoscaling.model.ServiceNamespace;
import
    software.amazon.awssdk.services.applicationautoscaling.model.ScalableDimension;
import software.amazon.awssdk.services.applicationautoscaling.model.MetricType;
import
    software.amazon.awssdk.services.applicationautoscaling.model.TargetTrackingScalingPolicy;
import java.util.List;

/**
 * Before running this Java V2 code example, set up your development environment,
 * including your credentials.
 *
 * For more information, see the following documentation topic:
 *
 * https://docs.aws.amazon.com/sdk-for-java/latest/developer-guide/get-started.html
 */
public class EnableDynamoDBAutoscaling {
    public static void main(String[] args) {
        final String usage = ""

            Usage:
                <tableId> <roleARN> <policyName>\s

            Where:
                tableId - The table Id value (for example, table/Music).
                roleARN - The ARN of the role that has ApplicationAutoScaling
permissions.
                policyName - The name of the policy to create.

            """;

        if (args.length != 3) {
            System.out.println(usage);
            System.exit(1);
        }

        System.out.println("This example registers an Amazon DynamoDB table,
which is the resource to scale.");
        String tableId = args[0];
        String roleARN = args[1];
```

```
String policyName = args[2];
ServiceNamespace ns = ServiceNamespace.DYNAMODB;
ScalableDimension tableWCUs =
ScalableDimension.DYNAMODB_TABLE_WRITE_CAPACITY_UNITS;
ApplicationAutoScalingClient appAutoScalingClient =
ApplicationAutoScalingClient.builder()
    .region(Region.US_EAST_1)
    .build();

    registerScalableTarget(appAutoScalingClient, tableId, roleARN, ns,
tableWCUs);
    verifyTarget(appAutoScalingClient, tableId, ns, tableWCUs);
    configureScalingPolicy(appAutoScalingClient, tableId, ns, tableWCUs,
policyName);
}

public static void registerScalableTarget(ApplicationAutoScalingClient
appAutoScalingClient, String tableId, String roleARN, ServiceNamespace ns,
ScalableDimension tableWCUs) {
    try {
        RegisterScalableTargetRequest targetRequest =
RegisterScalableTargetRequest.builder()
            .serviceNamespace(ns)
            .scalableDimension(tableWCUs)
            .resourceId(tableId)
            .roleARN(roleARN)
            .minCapacity(5)
            .maxCapacity(10)
            .build();

        appAutoScalingClient.registerScalableTarget(targetRequest);
        System.out.println("You have registered " + tableId);

    } catch (ApplicationAutoScalingException e) {
        System.err.println(e.awsErrorDetails().errorMessage());
    }
}

// Verify that the target was created.
public static void verifyTarget(ApplicationAutoScalingClient
appAutoScalingClient, String tableId, ServiceNamespace ns, ScalableDimension
tableWCUs) {
    DescribeScalableTargetsRequest dscRequest =
DescribeScalableTargetsRequest.builder()
```

```
        .scalableDimension(tableWCUs)
        .serviceNamespace(ns)
        .resourceIds(tableId)
        .build();

    DescribeScalableTargetsResponse response =
appAutoScalingClient.describeScalableTargets(dscRequest);
    System.out.println("DescribeScalableTargets result: ");
    System.out.println(response);
}

// Configure a scaling policy.
public static void configureScalingPolicy(ApplicationAutoScalingClient
appAutoScalingClient, String tableId, ServiceNamespace ns, ScalableDimension
tableWCUs, String policyName) {
    // Check if the policy exists before creating a new one.
    DescribeScalingPoliciesResponse describeScalingPoliciesResponse =
appAutoScalingClient.describeScalingPolicies(DescribeScalingPoliciesRequest.builder()
        .serviceNamespace(ns)
        .resourceId(tableId)
        .scalableDimension(tableWCUs)
        .build());

    if (!describeScalingPoliciesResponse.scalingPolicies().isEmpty()) {
        // If policies exist, consider updating an existing policy instead of
creating a new one.
        System.out.println("Policy already exists. Consider updating it
instead.");
        List<ScalingPolicy> polList =
describeScalingPoliciesResponse.scalingPolicies();
        for (ScalingPolicy pol : polList) {
            System.out.println("Policy name:" +pol.policyName());
        }
    } else {
        // If no policies exist, proceed with creating a new policy.
        PredefinedMetricSpecification specification =
PredefinedMetricSpecification.builder()

        .predefinedMetricType(MetricType.DYNAMO_DB_WRITE_CAPACITY_UTILIZATION)
        .build();

        TargetTrackingScalingPolicyConfiguration policyConfiguration =
TargetTrackingScalingPolicyConfiguration.builder()
        .predefinedMetricSpecification(specification)
```


Tools for PowerShell V5

예제 1: 이 cmdlet에서는 규모 조정 가능 대상을 등록하거나 업데이트합니다. 규모 조정 가능 대상은 Application Auto Scaling에서 스케일 아웃 및 스케일 인할 수 있는 리소스입니다.

```
Add-AASScalableTarget -ServiceNamespace AppStream -ResourceId fleet/MyFleet -ScalableDimension appstream:fleet:DesiredCapacity -MinCapacity 2 -MaxCapacity 10
```

- API 세부 정보는 AWS Tools for PowerShell Cmdlet 참조(V5)의 [RegisterScalableTarget](#)을 참조하세요.

AWS SDK 개발자 안내서 및 코드 예제의 전체 목록은 [섹션을 참조하세요](#)[AWS SDK에서이 서비스 사용](#). 이 주제에는 시작하기에 대한 정보와 이전 SDK 버전에 대한 세부 정보도 포함되어 있습니다.

Application Auto Scaling에 대한 태그 지정 지원

AWS CLI 또는 SDK를 사용하여 Application Auto Scaling 확장 가능 대상에 태그를 지정할 수 있습니다. 확장 가능 대상은 Application Auto Scaling이 확장할 수 있는 AWS 또는 사용자 지정 리소스를 나타내는 엔터티입니다.

각 태그는 Application Auto Scaling API를 사용하는 사용자 정의 키와 값으로 구성된 레이블입니다. 태그를 지정하면 조직의 요구에 따라 특정 확장 가능 대상에 세분화된 액세스를 구성할 수 있습니다. 자세한 내용은 [Application Auto Scaling 작업을 사용한 ABAC 단원을 참조하십시오](#).

새 확장 가능 대상을 등록할 때 태그를 추가하거나 기존 확장 가능 대상에 태그를 추가할 수 있습니다.

태그 관리에 일반적으로 사용되는 명령은 다음과 같습니다.

- [register-scalable-target](#)은 새로운 확장 가능 대상을 등록할 때 태그를 지정하는 데 사용합니다.
- [tag-resource](#)는 기존 확장 가능 대상에 태그를 추가할 때 사용합니다.
- [list-tags-for-resource](#)는 확장 가능 대상의 태그를 반환할 때 사용합니다.
- [untag-resource](#)는 태그를 삭제할 때 사용합니다.

태그 예제

다음과 같이 [register-scalable-target](#) 명령을 `--tags` 옵션과 함께 사용합니다. 이 예제에서는 확장 가능 대상에 2개의 태그, 즉 태그 키 이름이 **environment**이고 태그 값이 **production**인 태그와 태그 키 이름이 **iscontainerbased**이고 태그 값이 **true**인 태그를 지정합니다.

`--min-capacity` 및 `--max-capacity`의 샘플 값과 `--service-namespace`의 샘플 텍스트를 Application Auto Scaling에서 사용 중인 AWS 서비스의 네임스페이스 `--scalable-dimension`, 등록 중인 리소스와 연결된 확장 가능한 차원, 리소스의 식별자 `--resource-id`로 바꿉니다. 각 서비스에 대한 자세한 내용과 예는 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#)의 주제를 참조하세요.

```
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
```

이 명령이 성공하면 확장 가능 대상의 ARN이 반환됩니다.

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

Note

이 명령에서 오류가 발생하면 AWS CLI 로컬에서 최신 버전으로 업데이트했는지 확인합니다.

보안을 위한 태그

태그를 사용하여 요청자(예: IAM 사용자 또는 역할)에게 특정 작업을 수행할 권한이 있는지 확인합니다. 다음 조건 키를 하나 이상 사용하여 IAM 정책의 조건 요소에 태그 정보를 제공합니다.

- 특정 태그가 있는 확장 가능 대상에 대한 사용자 작업을 허용(또는 거부)하려면 `aws:ResourceTag/tag-key: tag-value`를 사용합니다.
- 요청에 특정 태그가 존재하도록 (또는 존재하지 않도록) 요구하려면 `aws:RequestTag/tag-key: tag-value`를 사용합니다.
- 요청에 특정 태그 키가 존재하도록 (또는 존재하지 않도록) 요구하려면 `aws:TagKeys [tag-key, ...]`를 사용합니다.

예를 들어 다음의 IAM 정책은 사용자에게 `DeregisterScalableTarget`, `DeleteScalingPolicy` 및 `DeleteScheduledAction` 작업에 대한 권한을 부여합니다. 그러나 적용되는 확장 가능 대상에 `environment=production` 태그가 있는 경우 작업을 거부하기도 합니다.

JSON

```
{
  "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"
      }
    }
  }
]
}

```

태그에 대한 액세스 통제

태그를 사용하여 요청자(예: IAM 사용자 또는 역할)에게 확장 가능 대상에 대한 태그를 추가, 수정 또는 삭제할 수 있는 권한이 있는지 확인합니다.

예를 들어 확장 가능 대상에서 **temporary** 키가 지정된 태그만 제거하도록 허용하는 IAM 정책을 생성할 수 있습니다.

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": "application-autoscaling:UntagResource",
      "Resource": "*",
      "Condition": {
        "ForAllValues:StringEquals": { "aws:TagKeys": ["temporary"] }
      }
    }
  ]
}

```

```
}  
  }  
] }  
}
```

Application Auto Scaling의 보안

의 클라우드 보안 AWS 이 최우선 순위입니다. AWS 고객은 보안에 가장 민감한 조직의 요구 사항을 충족하도록 구축된 데이터 센터 및 네트워크 아키텍처의 이점을 누릴 수 있습니다.

보안은 AWS 와 사용자 간의 공동 책임입니다. [공동 책임 모델](#)은 이 사항을 클라우드의 보안 및 클라우드 내 보안으로 설명합니다.

- 클라우드 보안 - AWS 는 AWS 클라우드에서 AWS 서비스를 실행하는 인프라를 보호할 책임이 있습니다. AWS 또한 안전하게 사용할 수 있는 서비스를 제공합니다. 타사 감사자는 규정 [AWS 준수 프로그램](#) 일환으로 보안의 효과를 정기적으로 테스트하고 확인합니다. Application Auto Scaling에 적용되는 규정 준수 프로그램에 대한 자세한 내용은 규정 준수 [AWS 프로그램 제공 범위 내 서비스 규정 준수](#).
- 클라우드의 보안 - 사용자의 책임은 사용하는 AWS 서비스에 따라 결정됩니다. 또한 귀하는 데이터의 민감도, 회사 요구 사항, 관련 법률 및 규정을 비롯한 기타 요소에 대해서도 책임이 있습니다.

이 설명서는 Application Auto Scaling 사용 시 책임 분담 모델을 적용하는 방법을 이해하는 데 도움이 됩니다. 다음 항목에서는 보안 및 규정 준수 목표를 충족하도록 Application Auto Scaling을 구성하는 방법을 보여줍니다. 또한 Application Auto Scaling 리소스를 모니터링하고 보호하는 데 도움이 되는 다른 AWS 서비스를 사용하는 방법을 알아봅니다.

내용

- [Application Auto Scaling의 데이터 보호](#)
- [Application Auto Scaling에 사용되는 Identity and Access Management](#)
- [인터페이스 VPC 엔드포인트를 사용하여 Application Auto Scaling 액세스](#)
- [Application Auto Scaling의 복원성](#)
- [Application Auto Scaling의 인프라 보안](#)
- [Application Auto Scaling의 규정 준수 확인](#)

Application Auto Scaling의 데이터 보호

AWS [공동 책임 모델](#) Application Auto Scaling의 데이터 보호에 적용됩니다. 이 모델에 설명된 대로 AWS 는 모드를 실행하는 글로벌 인프라를 보호할 책임이 있습니다 AWS 클라우드. 사용자는 이 인프라에 호스팅되는 콘텐츠에 대한 통제 권한을 유지할 책임이 있습니다. 사용하는 AWS 서비스 의 보안

구성과 관리 태스크에 대한 책임도 사용자에게 있습니다. 데이터 프라이버시에 관한 자세한 내용은 [데이터 프라이버시 FAQ](#)를 참조하세요. 유럽의 데이터 보호에 대한 자세한 내용은 AWS 보안 블로그의 [AWS 공동 책임 모델 및 GDPR](#) 블로그 게시물을 참조하세요.

데이터 보호를 위해 자격 증명을 보호하고 AWS 계정 AWS IAM Identity Center 또는 AWS Identity and Access Management (IAM)를 사용하여 개별 사용자를 설정하는 것이 좋습니다. 이렇게 하면 개별 사용자에게 자신의 직무를 충실히 이행하는 데 필요한 권한만 부여됩니다. 또한 다음과 같은 방법으로 데이터를 보호하는 것이 좋습니다.

- 각 계정에 다중 인증(MFA)을 사용합니다.
- SSL/TLS를 사용하여 AWS 리소스와 통신합니다. TLS 1.2는 필수이며 TLS 1.3을 권장합니다.
- 를 사용하여 API 및 사용자 활동 로깅을 설정합니다 AWS CloudTrail. CloudTrail 추적을 사용하여 AWS 활동을 캡처하는 방법에 대한 자세한 내용은 AWS CloudTrail 사용 설명서의 [CloudTrail 추적 작업을 참조하세요](#).
- AWS 암호화 솔루션과 내부의 모든 기본 보안 제어를 사용합니다 AWS 서비스.
- Amazon S3에 저장된 민감한 데이터를 검색하고 보호하는 데 도움이 되는 Amazon Macie와 같은 고급 관리형 보안 서비스를 사용합니다.
- 명령줄 인터페이스 또는 API를 AWS 통해 액세스할 때 FIPS 140-3 검증 암호화 모듈이 필요한 경우 FIPS 엔드포인트를 사용합니다. 사용 가능한 FIPS 엔드포인트에 대한 자세한 내용은 [연방 정보 처리 표준\(FIPS\) 140-3](#)을 참조하세요.

고객의 이메일 주소와 같은 기밀 정보나 중요한 정보는 태그나 이름 필드와 같은 자유 형식 텍스트 필드에 입력하지 않는 것이 좋습니다. 여기에는 Application Auto Scaling 또는 기타 AWS 서비스에서 콘솔 AWS CLI, API 또는 AWS SDKs를 사용하여 작업하는 경우가 포함됩니다. 이름에 사용되는 태그 또는 자유 형식 텍스트 필드에 입력하는 모든 데이터는 청구 또는 진단 로그에 사용될 수 있습니다. 외부 서버에 URL을 제공할 때 해당 서버에 대한 요청을 검증하기 위해 자격 증명을 URL에 포함해서는 안 됩니다.

Application Auto Scaling에 사용되는 Identity and Access Management

AWS Identity and Access Management (IAM)는 관리자가 AWS 리소스에 대한 액세스를 안전하게 제어하는 데 도움이 되는 AWS 서비스입니다. IAM 관리자는 어떤 사용자가 Application Auto Scaling 리소스를 사용할 수 있는 인증(로그인) 및 권한(권한 있음)을 받을 수 있는지를 제어합니다. IAM은 추가 비용 없이 사용할 수 있는 AWS 서비스입니다.

IAM 설명서 전체 내용은 [IAM 사용 설명서](#)를 참조하세요.

액세스 관리

요청을 인증하는 데 유효한 자격 증명이 있더라도 권한이 없다면 Application Auto Scaling 리소스를 생성하거나 액세스할 수 없습니다. 예를 들어 조정 정책을 생성하고 예약된 조정을 구성하는 등의 권한이 있어야 합니다.

다음 섹션에서는 IAM 관리자가 Application Auto Scaling API 작업을 수행할 수 있는 사용자를 제어하여 IAM을 사용하여 AWS 리소스를 보호하는 방법에 대한 세부 정보를 제공합니다.

내용

- [Application Auto Scaling에서 IAM을 사용하는 방식](#)
- [AWS Application Auto Scaling에 대한 관리형 정책](#)
- [Application Auto Scaling에 대한 서비스 연결 역할](#)
- [Application Auto Scaling 자격 증명 기반 정책 예제](#)
- [Application Auto Scaling 액세스 문제 해결](#)
- [대상 리소스에서 Application Auto Scaling API 직접 호출에 대한 권한 유효성 검사](#)

Application Auto Scaling에서 IAM을 사용하는 방식

Note

2017년 12월에 Application Auto Scaling 통합 서비스에 여러 서비스 연결 역할을 사용할 수 있도록 하는 Application Auto Scaling 업데이트가 있었습니다. 사용자가 조정을 구성할 수 있도록 특정 IAM 권한 및 Application Auto Scaling 서비스 연결 역할(또는 Amazon EMR 자동 크기 조정의 서비스 역할)이 필요합니다.

IAM을 사용하여 Application Auto Scaling에 대한 액세스를 관리하려면 먼저 어떤 IAM 기능을 Application Auto Scaling에 사용할 수 있는지를 학습하세요.

Application Auto Scaling에서 사용할 수 있는 IAM 기능

IAM 특성	Application Auto Scaling 지원
자격 증명 기반 정책	예

IAM 특성	Application Auto Scaling 지원
정책 작업	예
정책 리소스	예
정책 조건 키(서비스별)	예
리소스 기반 정책	아니요
ACL	아니요
ABAC(정책 내 태그)	부분적
임시 자격 증명	예
서비스 역할	예
서비스 연결 역할	예

Application Auto Scaling 및 기타에서 대부분의 IAM 기능을 AWS 서비스 사용하는 방법을 전체적으로 알아보려면 IAM 사용 설명서의 [AWS 서비스 IAM으로 작업하는](#) 섹션을 참조하세요.

Application Auto Scaling 자격 증명 기반 정책

ID 기반 정책 지원: 예

ID 기반 정책은 IAM 사용자, 사용자 그룹 또는 역할과 같은 ID에 연결할 수 있는 JSON 권한 정책 문서입니다. 이러한 정책은 사용자 및 역할이 어떤 리소스와 어떤 조건에서 어떤 작업을 수행할 수 있는지를 제어합니다. 자격 증명 기반 정책을 생성하는 방법을 알아보려면 IAM 사용 설명서에서 [고객 관리형 정책으로 사용자 지정 IAM 권한 정의](#)를 참조하세요.

IAM ID 기반 정책을 사용하면 허용되거나 거부되는 작업과 리소스뿐 아니라 작업이 허용되거나 거부되는 조건을 지정할 수 있습니다. JSON 정책에서 사용할 수 있는 모든 요소에 대해 알아보려면 IAM 사용 설명서의 [IAM JSON 정책 요소 참조](#)를 참조하세요.

Application Auto Scaling의 자격 증명 기반 정책 예제

Application Auto Scaling 자격 증명 기반 정책 예제를 보려면 [Application Auto Scaling 자격 증명 기반 정책 예제](#) 섹션을 참조하세요.

작업

정책 작업 지원: 예

IAM 정책 구문에는 IAM을 지원하는 모든 서비스의 모든 API 작업을 지정할 수 있습니다. Application Auto Scaling의 경우 접두사와 함께 API 작업 이름 application-autoscaling:을 (를) 사용합니다. 예를 들어, application-autoscaling:RegisterScalableTarget, application-autoscaling:PutScalingPolicy 및 application-autoscaling:DeregisterScalableTarget입니다.

단일 명령문에서 여러 작업을 지정하려면 다음 예시와 같이 쉼표로 구분합니다.

```
"Action": [
    "application-autoscaling:DescribeScalingPolicies",
    "application-autoscaling:DescribeScalingActivities"
```

와일드카드(*)를 사용하여 여러 작업을 지정할 수 있습니다. 예를 들어, Describe라는 단어로 시작하는 모든 작업을 지정하려면 다음 작업을 포함합니다.

```
"Action": "application-autoscaling:Describe*"
```

Application Auto Scaling 작업 목록은 서비스 승인 참조의 [AWS Application Auto Scaling에서 정의한 작업을](#) 참조하세요.

리소스

정책 리소스 지원: 예

IAM 정책 구문에서 Resource 요소는 명령문이 다루는 하나 이상의 객체를 지정합니다. Application Auto Scaling의 경우 Amazon 리소스 이름(ARN)을 사용하여 지정한 확장 가능 대상에 각 IAM 정책 구문이 적용됩니다.

확장 가능 대상을 위한 ARN 리소스 형식:

```
arn:aws:application-autoscaling:region:account-id:scalable-target/unique-identifier
```

예를 들어 구문에서 다음과 같이 ARN을 사용하여 특정 확장 가능 대상을 나타낼 수 있습니다. 고유 ID(1234abcd56ab78cd901ef1234567890ab123)는 Application Auto Scaling을 통해 확장 가능 대상에 할당된 값입니다.

```
"Resource": "arn:aws:application-autoscaling:us-east-1:123456789012:scalable-target/1234abcd56ab78cd901ef1234567890ab123"
```

다음과 같이 고유 식별자를 와일드카드(*)로 대체하여 특정 계정에 속하는 모든 인스턴스를 지정할 수 있습니다.

```
"Resource": "arn:aws:application-autoscaling:us-east-1:123456789012:scalable-target/*"
```

모든 리소스를 지정하려 하거나 특정 API 작업이 ARN을 지원하지 않는 경우 다음과 같이 와일드카드(*)를 Resource 요소로 사용합니다.

```
"Resource": "*"
```

자세한 내용은 서비스 승인 참조의 [AWS Application Auto Scaling에서 정의한 리소스 유형](#)을 참조하세요.

조건 키

서비스별 정책 조건 키 지원: 예

IAM 정책에 Application Auto Scaling 리소스에 대한 액세스를 제어하는 조건을 지정할 수 있습니다. 이 정책문은 조건이 true일 때만 유효합니다.

Application Auto Scaling은 자격 증명 기반 정책에서 Application Auto Scaling API 작업을 수행 가능한 사용자를 결정하는 데 사용할 수 있는 다음과 같은 서비스 정의 조건 키를 지원합니다.

- application-autoscaling:scalable-dimension
- application-autoscaling:service-namespace

조건 키를 사용할 수 있는 Application Auto Scaling API 작업을 알아보려면 서비스 권한 부여 참조의 [AWS Application Auto Scaling에서 정의한 작업을](#) 참조하세요. Application Auto Scaling 조건 키 사용에 대한 자세한 내용은 [AWS Application Auto Scaling의 조건 키](#)를 참조하세요.

모든 서비스에 사용할 수 있는 글로벌 조건 키를 보려면 IAM 사용 설명서의 [AWS 글로벌 조건 컨텍스트 키](#)를 참조하세요.

리소스 기반 정책

리소스 기반 정책 지원: 아니요

Amazon Simple Storage Service와 같은 다른 AWS 서비스는 리소스 기반 권한 정책을 지원합니다. 예를 들어, 권한 정책을 S3 버킷에 연결하여 해당 버킷에 대한 액세스 권한을 관리할 수 있습니다.

Application Auto Scaling은 리소스 기반 정책을 지원하지 않습니다.

액세스 제어 목록(ACL)

ACL 지원: 아니요

Application Auto Scaling은 액세스 제어 목록(ACL)을 지원하지 않습니다.

Application Auto Scaling 작업을 사용한 ABAC

ABAC 지원(정책의 태그): 부분적

속성 기반 액세스 제어(ABAC)는 속성에 근거하여 권한을 정의하는 권한 부여 전략입니다. 여기서 AWS이러한 속성을 태그라고 합니다. IAM 엔터티(사용자 또는 역할) 및 많은 AWS 리소스에 태그를 연결할 수 있습니다. ABAC의 첫 번째 단계로 개체 및 리소스에 태그를 지정합니다. 그런 다음 위탁자의 태그가 액세스하려는 리소스의 태그와 일치할 때 작업을 허용하도록 ABAC 정책을 설계합니다.

ABAC는 빠르게 성장하는 환경에서 유용하며 정책 관리가 번거로운 상황에 도움이 됩니다.

태그에 근거하여 액세스를 제어하려면 `aws:ResourceTag/key-name`, `aws:RequestTag/key-name` 또는 `aws:TagKeys` 조건 키를 사용하여 정책의 [조건 요소](#)에 태그 정보를 제공합니다.

태그를 지원하는 리소스에는 ABAC를 사용할 수 있지만 모든 리소스가 태그를 지원하는 것은 아닙니다. 예약된 작업 및 크기 조정 정책은 태그를 지원하지 않지만, 확장 가능 대상은 태그를 지원합니다. 자세한 내용은 [Application Auto Scaling에 대한 태그 지정 지원](#) 단원을 참조하십시오.

ABAC에 대한 자세한 정보는 IAM 사용 설명서의 [ABAC란 무엇입니까?](#)를 참조하십시오. ABAC 설정 단계가 포함된 자습서를 보려면 IAM 사용 설명서의 [속성 기반 액세스 제어\(ABAC\) 사용](#)을 참조하십시오.

Application Auto Scaling과 함께 임시 자격 증명 사용

임시 자격 증명 지원: 예

임시 자격 증명은 AWS 리소스에 대한 단기 액세스를 제공하며 페더레이션을 사용하거나 역할을 전환할 때 자동으로 생성됩니다. 장기 액세스 키를 사용하는 대신 임시 자격 증명을 동적으로 생성하는 것이 AWS 좋습니다. 자세한 내용은 IAM 사용 설명서의 [IAM의 임시 보안 자격 증명](#) 및 [IAM으로 작업하는 AWS 서비스](#) 섹션을 참조하세요.

서비스 역할

서비스 역할 지원: 예

Amazon EMR 클러스터에서 자동 크기 조정을 사용하는 경우 이 기능을 사용하면 Application Auto Scaling이 사용자를 대신하여 서비스 역할을 수임할 수 있습니다. 서비스 연결 역할과 마찬가지로, 서비스 역할을 사용하면 서비스가 다른 서비스의 리소스에 액세스하고 사용자를 대신하여 작업을 완료할 수 있습니다. 서비스 역할은 IAM 계정에 나타나고, 해당 계정이 소유합니다. 즉, IAM 관리자가 이 역할에 대한 권한을 변경할 수 있습니다. 그러나 권한을 변경하면 서비스의 기능이 손상될 수 있습니다.

Application Auto Scaling은 Amazon EMR에 대해서만 서비스 역할을 지원합니다. EMR 서비스 역할에 대한 설명서는 Amazon EMR 관리 가이드의 [인스턴스 그룹에 대한 사용자 지정 정책과 함께 자동 크기 조정 사용](#)을 참조하세요.

Note

서비스 연결 역할이 도입됨에 따라 Amazon ECS 및 스팟 플릿과 같은 여러 레거시 서비스 역할이 더 이상 필요하지 않습니다.

서비스 연결 역할

서비스 연결 역할 지원: 예

서비스 연결 역할은 연결된 서비스 역할의 한 유형입니다. AWS 서비스. 서비스는 사용자를 대신하여 작업을 수행하기 위해 역할을 수임할 수 있습니다. 서비스 연결 역할은 나타나 AWS 계정 및 서비스가 소유합니다. IAM 관리자는 서비스 연결 역할의 권한을 볼 수 있지만 편집은 할 수 없습니다.

자세한 정보는 Application Auto Scaling 서비스 연결 역할에 대한 자세한 정보는 [Application Auto Scaling에 대한 서비스 연결 역할](#)(를) 참조하세요.

AWS Application Auto Scaling에 대한 관리형 정책

AWS 관리형 정책은에서 생성하고 관리하는 독립 실행형 정책입니다. AWS. AWS 관리형 정책은 사용자, 그룹 및 역할에 권한 할당을 시작할 수 있도록 많은 일반적인 사용 사례에 대한 권한을 제공하도록 설계되었습니다.

AWS 관리형 정책은 모든 AWS 고객이 사용할 수 있으므로 특정 사용 사례에 대해 최소 권한 권한을 부여하지 않을 수 있습니다. 사용 사례에 고유한 [고객 관리형 정책](#)을 정의하여 권한을 줄이는 것이 좋습니다.

AWS 관리형 정책에 정의된 권한은 변경할 수 없습니다. 가 관리형 정책에 정의된 권한을 AWS 업데이트하는 AWS 경우 업데이트는 정책이 연결된 모든 보안 주체 자격 증명(사용자, 그룹 및 역할)에 영향을 미칩니다. AWS AWS 서비스는 새가 시작되거나 기존 서비스에 새 API 작업을 사용할 수 있게 될 때 AWS 관리형 정책을 업데이트할 가능성이 높습니다.

자세한 내용은 IAM 사용자 가이드의 [AWS 관리형 정책](#)을 참조하세요.

AWS 관리형 정책: WorkSpaces 애플리케이션 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingAppStreamFleetPolicy](#)

이 정책은 Application Auto Scaling이 Amazon AppStream 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_AppStreamFleet](#)이라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: appstream:DescribeFleets
- 작업: appstream:UpdateFleet
- 작업: cloudwatch:DescribeAlarms
- 작업: cloudwatch:PutMetricAlarm
- 작업: cloudwatch>DeleteAlarms

AWS 관리형 정책: Aurora 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingRDSClusterPolicy](#)

이 정책은 Application Auto Scaling이 Aurora 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_RDSCluster](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: rds:AddTagsToResource

- 작업: rds:CreateDBInstance
- 작업: rds>DeleteDBInstance
- 작업: rds:DescribeDBClusters
- 작업: rds:DescribeDBInstance
- 작업: cloudwatch:DescribeAlarms
- 작업: cloudwatch:PutMetricAlarm
- 작업: cloudwatch>DeleteAlarms

AWS 관리형 정책: Amazon Comprehend 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingComprehendEndpointPolicy](#)

이 정책은 Application Auto Scaling이 Amazon Comprehend 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_ComprehendEndpoint](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다(“리소스”: “*”).

- 작업: comprehend:UpdateEndpoint
- 작업: comprehend:DescribeEndpoint
- 작업: cloudwatch:DescribeAlarms
- 작업: cloudwatch:PutMetricAlarm
- 작업: cloudwatch>DeleteAlarms

AWS 관리형 정책: DynamoDB 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingDynamoDBTablePolicy](#)

이 정책은 Application Auto Scaling이 DynamoDB 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_DynamoDBTable](#)이라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: dynamodb:DescribeTable
- 작업: dynamodb:UpdateTable
- 작업: cloudwatch:DescribeAlarms
- 작업: cloudwatch:PutMetricAlarm
- 작업: cloudwatch>DeleteAlarms

AWS 관리형 정책: Amazon ECS 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingECSServicePolicy](#)

이 정책은 Application Auto Scaling이 Amazon ECS 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_ECSService](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: ecs:DescribeServices
- 작업: ecs:UpdateService
- 작업: cloudwatch:PutMetricAlarm
- 작업: cloudwatch:DescribeAlarms
- 작업: cloudwatch:GetMetricData
- 작업: cloudwatch>DeleteAlarms

AWS 관리형 정책: ElastiCache 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingElastiCacheRGPPolicy](#)

이 정책은 Application Auto Scaling이 ElastiCache 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_ElastiCacheRG](#)라

는 서비스 연결 역할에 연결됩니다. 이 서비스 연결 역할은 ElastiCache Memcached, Redis OSS 및 Valkey에 사용할 수 있습니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 지정된 리소스에서 다음 작업을 완료하도록 허용합니다.

- 작업: 모든 리소스에 대한 elasticache:DescribeReplicationGroups
- 작업: 모든 리소스에 대한 elasticache:ModifyReplicationGroupShardConfiguration
- 작업: 모든 리소스에 대한 elasticache:IncreaseReplicaCount
- 작업: 모든 리소스에 대한 elasticache:DecreaseReplicaCount
- 작업: 모든 리소스에 대한 elasticache:DescribeCacheClusters
- 작업: 모든 리소스에 대한 elasticache:DescribeCacheParameters
- 작업: 모든 리소스에 대한 elasticache:ModifyCacheCluster
- 작업: arn:aws:cloudwatch:*:*:alarm:* 리소스에 대한 cloudwatch:DescribeAlarms
- 작업: arn:aws:cloudwatch:*:*:alarm:TargetTracking* 리소스에 대한 cloudwatch:PutMetricAlarm
- 작업: arn:aws:cloudwatch:*:*:alarm:TargetTracking* 리소스에 대한 cloudwatch>DeleteAlarms

AWS 관리형 정책: Amazon Keyspaces 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingCassandraTablePolicy](#)

이 정책은 Application Auto Scaling이 Amazon Keyspaces 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_CassandraTable](#)이라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 지정된 리소스에서 다음 작업을 완료하도록 허용합니다.

- 작업: 다음 리소스에 대한 cassandra:Select:
 - arn:*:cassandra:*:*:/keyspace/system/table/*
 - arn:*:cassandra:*:*:/keyspace/system_schema/table/*
 - arn:*:cassandra:*:*:/keyspace/system_schema_mcs/table/*
- 작업: 모든 리소스에 대한 cassandra:Alter

- 작업: 모든 리소스에 대한 `cloudwatch:DescribeAlarms`
- 작업: 모든 리소스에 대한 `cloudwatch:PutMetricAlarm`
- 작업: 모든 리소스에 대한 `cloudwatch>DeleteAlarms`

AWS 관리형 정책: Lambda 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingLambdaConcurrencyPolicy](#)

이 정책은 Application Auto Scaling이 Lambda 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_LambdaConcurrency](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: `lambda:PutProvisionedConcurrencyConfig`
- 작업: `lambda:GetProvisionedConcurrencyConfig`
- 작업: `lambda>DeleteProvisionedConcurrencyConfig`
- 작업: `cloudwatch:DescribeAlarms`
- 작업: `cloudwatch:PutMetricAlarm`
- 작업: `cloudwatch>DeleteAlarms`

AWS 관리형 정책: Amazon MSK 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingKafkaClusterPolicy](#)

이 정책은 Application Auto Scaling이 Amazon MSK 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_KafkaCluster](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: `kafka:DescribeCluster`

- 작업: kafka:DescribeClusterOperation
- 작업: kafka:UpdateBrokerStorage
- 작업: cloudwatch:DescribeAlarms
- 작업: cloudwatch:PutMetricAlarm
- 작업: cloudwatch>DeleteAlarms

AWS 관리형 정책: Neptune 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingNeptuneClusterPolicy](#)

이 정책은 Application Auto Scaling이 Neptune 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_NeptuneCluster](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 지정된 리소스에서 다음 작업을 완료하도록 허용합니다.

- 작업: 모든 리소스에 대한 rds:ListTagsForResource
- 작업: 모든 리소스에 대한 rds:DescribeDBInstances
- 작업: 모든 리소스에 대한 rds:DescribeDBClusters
- 작업: 모든 리소스에 대한 rds:DescribeDBClusterParameters
- 작업: 모든 리소스에 대한 cloudwatch:DescribeAlarms
- 작업: Amazon Neptune 데이터베이스 엔진에 접두사 autoscaled-reader가 있는 리소스에 대해 rds:AddTagsToResource("Condition":{"StringEquals":{"rds:DatabaseEngine":"neptune"}})
- 작업: Amazon Neptune 데이터베이스 엔진의 모든 DB 클러스터(rds:CreateDBInstance)에 접두사 autoscaled-reader가 있는 리소스에 대해 "Resource":"arn:*:rds:*:*:db:autoscaled-reader*", "arn:aws:rds:*:*:cluster:*"("Condition":{"StringEquals":{"rds:DatabaseEngine":"neptune"}})
- 작업: arn:aws:rds:*:*:db:autoscaled-reader* 리소스에 대한 rds>DeleteDBInstance
- 작업: arn:aws:cloudwatch:*:*:alarm:TargetTracking* 리소스에 대한 cloudwatch:PutMetricAlarm
- 작업: arn:aws:cloudwatch:*:*:alarm:TargetTracking* 리소스에 대한 cloudwatch>DeleteAlarms

AWS 관리형 정책: SageMaker AI 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingSageMakerEndpointPolicy](#)

이 정책은 Application Auto Scaling이 SageMaker AI 및 CloudWatch를 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_SageMakerEndpoint](#)라는 서비스 연결 역할에 연결됩니다. SageMaker CloudWatch

권한 세부 정보

권한 정책은 Application Auto Scaling이 지정된 리소스에서 다음 작업을 완료하도록 허용합니다.

- 작업: 모든 리소스에 대한 `sagemaker:DescribeEndpoint`
- 작업: 모든 리소스에 대한 `sagemaker:DescribeEndpointConfig`
- 작업: 모든 리소스에 대한 `sagemaker:DescribeInferenceComponent`
- 작업: 모든 리소스에 대한 `sagemaker:UpdateEndpointWeightsAndCapacities`
- 작업: 모든 리소스에 대한 `sagemaker:UpdateInferenceComponentRuntimeConfig`
- 작업: 모든 리소스에 대한 `cloudwatch:DescribeAlarms`
- 작업: 모든 리소스에 대한 `cloudwatch:GetMetricData`
- 작업: `arn:aws:cloudwatch:*:*:alarm:TargetTracking*` 리소스에 대한 `cloudwatch:PutMetricAlarm`
- 작업: `arn:aws:cloudwatch:*:*:alarm:TargetTracking*` 리소스에 대한 `cloudwatch>DeleteAlarms`

AWS 관리형 정책: EC2 스팟 플릿 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingEC2SpotFleetRequestPolicy](#)

이 정책은 Application Auto Scaling이 Amazon EC2 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_EC2SpotFleetRequest](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: `ec2:DescribeSpotFleetRequests`
- 작업: `ec2:ModifySpotFleetRequest`
- 작업: `cloudwatch:DescribeAlarms`
- 작업: `cloudwatch:PutMetricAlarm`
- 작업: `cloudwatch>DeleteAlarms`

AWS 관리형 정책: WorkSpaces 및 CloudWatch

정책 이름: [AWSApplicationAutoscalingWorkSpacesPoolPolicy](#)

이 정책은 Application Auto Scaling이 WorkSpaces 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_WorkSpacesPool](#)이라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 지정된 리소스에서 다음 작업을 완료하도록 허용합니다.

- 작업: SLR과 동일한 계정의 모든 리소스에 대한 `workspaces:DescribeWorkspacesPools`
- 작업: SLR과 동일한 계정의 모든 리소스에 대한 `workspaces:UpdateWorkspacesPool`
- 작업: SLR과 동일한 계정의 모든 경보에 대한 `cloudwatch:DescribeAlarms`
- 작업: SLR과 동일한 계정의 경보 이름이 TargetTracking으로 시작하는 모든 경보에 대한 `cloudwatch:PutMetricAlarm`
- 작업: SLR과 동일한 계정의 경보 이름이 TargetTracking으로 시작하는 모든 경보에 대한 `cloudwatch>DeleteAlarms`

AWS 관리형 정책: 사용자 지정 리소스 및 CloudWatch

정책 이름: [AWSApplicationAutoScalingCustomResourcePolicy](#)

이 정책은 Application Auto Scaling이 API Gateway 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 [AWSServiceRoleForApplicationAutoScaling_CustomResource](#)라는 서비스 연결 역할에 연결됩니다.

권한 세부 정보

권한 정책은 Application Auto Scaling이 모든 관련 리소스에서 다음 작업을 수행하도록 허용합니다("리소스": "*").

- 작업: `execute-api:Invoke`
- 작업: `cloudwatch:DescribeAlarms`
- 작업: `cloudwatch:PutMetricAlarm`
- 작업: `cloudwatch>DeleteAlarms`

AWS 관리형 정책에 대한 Application Auto Scaling 업데이트

이 서비스가 이러한 변경 사항을 추적하기 시작한 이후부터 Application Auto Scaling의 AWS 관리형 정책 업데이트에 대한 세부 정보를 봅니다. 이 페이지의 변경 사항에 대한 자동 알림을 받아보려면 Application Auto Scaling 문서 기록 페이지에서 RSS 피드를 구독하세요.

변경	설명	Date
AWSApplicationAutoscalingElastiCacheRGPolicy - 기존 정책 업데이트	Memcached 자동 조정을 지원하기 위해 ElastiCache ModifyCacheCluster API 작업을 호출할 수 있는 권한이 추가되었습니다.	2025년 4월 10일
AWSApplicationAutoScalingECSServicePolicy - 기존 정책 업데이트	예측 조정을 지원하기 위해 CloudWatch GetMetricData API 작업을 호출할 수 있는 권한이 추가되었습니다.	2024년 11월 21일
AWSApplicationAutoScalingWorkSpacesPoolPolicy - 새 정책	Amazon WorkSpaces에 대한 관리형 정책을 추가했습니다. 이 정책은 Application Auto Scaling이 WorkSpaces 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 크기 조정을 수행할 수 있도록 서비스 연결 역할 에 연결됩니다.	2024년 6월 24일
AWSApplicationAutoscalingSageMakerEndpointPolicy - 기존 정책 업데이트	향후 통합을 위한 SageMaker AI 리소스의 오토 스케일링 호환성을 지원하기 위해	2023년 11월 13일

변경	설명	Date
	<p>SageMaker AI DescribeInferenceComponent 및 UpdateInferenceComponentRuntimeConfig API 작업을 호출할 수 있는 권한이 추가되었습니다. 또한 이 정책은 이제 PutMetricAlarm CloudWatch 및 DeleteAlarms API 작업을 대상 추적 조정 정책과 함께 사용되는 CloudWatch 경보로 제한합니다.</p>	
<p>AWSApplicationAutoscalingNeptuneClusterPolicy – 새 정책</p>	<p>Neptune에 대한 새 관리형 정책을 추가했습니다. 이 정책은 Application Auto Scaling이 Neptune 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 크기 조정을 수행할 수 있도록 서비스 연결 역할에 연결됩니다.</p>	<p>2021년 10월 6일</p>
<p>AWSApplicationAutoscalingRDSClusterPolicy – 새 정책</p>	<p>ElastiCache에 대한 관리형 정책을 추가했습니다. 이 정책은 Application Auto Scaling이 ElastiCache 및 CloudWatch를 직접적으로 호출하고 사용자를 대신하여 조정을 수행할 수 있도록 서비스 연결 역할에 연결됩니다.</p>	<p>2021년 8월 19일</p>
<p>Application Auto Scaling에서 변경 내용 추적 시작</p>	<p>Application Auto Scaling이 AWS 관리형 정책에 대한 변경 사항 추적을 시작했습니다.</p>	<p>2021년 8월 19일</p>

Application Auto Scaling에 대한 서비스 연결 역할

Application Auto Scaling은 사용자를 대신하여 다른 서비스를 호출하는 데 필요한 권한에 AWS 서비스 [연결 역할](#)을 사용합니다. 서비스 연결 역할은 AWS 서비스에 직접 연결된 고유한 유형의 AWS Identity and Access Management (IAM) 역할입니다. 서비스 연결 역할은 연결된 AWS 서비스만 서비스 연결 역할을 수입할 수 있으므로 서비스에 권한을 위임하는 안전한 방법을 제공합니다.

Application Auto Scaling과 통합되는 서비스의 경우 Application Auto Scaling은 사용자를 위한 서비스 연결 역할을 생성합니다. 각 서비스에는 서비스 연결 역할이 하나씩 있습니다. 각각의 서비스 연결 역할은 그 역할을 맡도록 지정된 서비스 주체를 신뢰합니다. 자세한 내용은 [서비스 연결 역할 ARN 참조](#) 단원을 참조하십시오.

Application Auto Scaling은 서비스 연결 역할에 필요한 모든 권한을 포함합니다. 이러한 관리형 권한은 Application Auto Scaling에서 생성 및 관리되며 각 리소스 유형에 대해 허용되는 작업을 정의합니다. 각 역할이 부여하는 권한에 대한 자세한 내용은 [AWS Application Auto Scaling에 대한 관리형 정책](#) 섹션을 참조하십시오.

내용

- [서비스 연결 역할 생성에 필요한 권한](#)
- [서비스 연결 역할 생성\(자동\)](#)
- [서비스 연결 역할 생성\(수동\)](#)
- [서비스 연결 역할 편집](#)
- [서비스 연결 역할 삭제](#)
- [Application Auto Scaling 서비스 연결 역할 지원 리전](#)
- [서비스 연결 역할 ARN 참조](#)

서비스 연결 역할 생성에 필요한 권한

Application Auto Scaling에는의 사용자가 지정된 서비스에 RegisterScalableTarget 대해 처음 AWS 계정 호출할 때 서비스 연결 역할을 생성할 수 있는 권한이 필요합니다. 역할이 이미 존재하지 않으면, Application Auto Scaling이 사용자의 계정에 대상 서비스에 대한 서비스 연결 역할을 생성합니다. 서비스 연결 역할은 사용자를 대신하여 대상 서비스를 호출할 수 있도록 Application Auto Scaling에 권한을 부여합니다.

역할 자동 생성이 성공하려면 사용자가 iam:CreateServiceLinkedRole 작업에 대한 권한을 보유해야 합니다.

```
"Action": "iam:CreateServiceLinkedRole"
```

다음은 스팟 플릿에 대한 서비스 연결 역할을 생성하는 권한을 부여하는 자격 증명 기반 정책입니다. 다음과 같이 정책 Resource 필드의 서비스 연결 역할을 ARN으로 지정하고 서비스 연결 역할에 대한 서비스 보안 주체를 조건으로 지정할 수 있습니다. 각 서비스에 대한 ARN은 [서비스 연결 역할 ARN 참조](#) 섹션을 참조하세요.

JSON

```
{
  "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

iam:AWSServiceName IAM 조건 키는 역할이 연결된 서비스 보안 주체(이 예제 정책에서는 *ec2.application-autoscaling.amazonaws.com*)를 지정합니다. 서비스 보안 주체를 알기 어렵습니다. 서비스에 대한 서비스 보안 주체를 보려면 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 섹션을 참조하세요.

서비스 연결 역할 생성(자동)

서비스 연결 역할은 수동으로 생성할 필요가 없습니다. RegisterScalableTarget을 호출하면 Application Auto Scaling이 적절한 서비스 연결 역할을 자동으로 생성합니다. 예를 들어 Amazon ECS 서비스에 대해 자동 조정을 설정하면 Application Auto Scaling이 AWSServiceRoleForApplicationAutoScaling_ECSService 역할을 생성합니다.

서비스 연결 역할 생성(수동)

서비스 연결 역할을 생성하려면 IAM 콘솔 AWS CLI 또는 IAM API를 사용할 수 있습니다. 자세한 내용은 IAM 사용 설명서의 [서비스 연결 역할 생성](#)을 참조하세요.

서비스 연결 역할을 만들려면(AWS CLI)

다음 [create-service-linked-role](#) 명령을 사용하여 Application Auto Scaling 서비스 연결 역할을 생성합니다. 요청에서 서비스 이름 “prefix”를 지정합니다.

서비스 이름 접두사를 찾으려면 [AWS 서비스 Application Auto Scaling과 함께 사용할 수 있는](#) 단원에서 각 서비스에 대한 서비스 연결 역할의 서비스 보안 주체에 대한 정보를 참조하세요. 서비스 이름과 서비스 보안 주체는 동일한 접두사를 공유합니다. 예를 들어 AWS Lambda 서비스 연결 역할을 생성하려면 `lambda.application-autoscaling.amazonaws.com`을 사용합니다.

```
aws iam create-service-linked-role --aws-service-name prefix.application-autoscaling.amazonaws.com
```

서비스 연결 역할 편집

Application Auto Scaling이 생성한 서비스 연결 역할로는 설명만 편집할 수 있습니다. 자세한 내용은 IAM 사용 설명서의 [서비스 연결 역할 설명 편집](#)을 참조하세요.

서비스 연결 역할 삭제

지원되는 서비스에서 Application Auto Scaling을 더 이상 사용하지 않는 경우 해당 서비스 연결 역할을 삭제하는 것이 좋습니다.

먼저 관련 AWS 리소스를 삭제한 후에만 서비스 연결 역할을 삭제할 수 있습니다. 따라서 리소스에 대한 Application Auto Scaling 권한을 실수로 취소하는 것을 방지할 수 있습니다. 자세한 정보는 확장 가능한 리소스의 [설명서](#)를 참조하세요. 예를 들어 Amazon ECS 서비스를 삭제하려면 Amazon Elastic Container Service 개발자 안내서의 [Amazon ECS 서비스 삭제](#)를 참조하세요.

IAM을 사용하여 서비스 연결 역할을 삭제할 수 있습니다. 자세한 내용은 IAM 사용 설명서의 [서비스 연결 역할 삭제](#)를 참조하세요.

서비스 연결 역할을 삭제한 후 RegisterScalableTarget을 호출하면 Application Auto Scaling이 그 역할을 다시 생성합니다.

Application Auto Scaling 서비스 연결 역할 지원 리전

Application Auto Scaling은 서비스를 사용할 수 있는 모든 AWS 리전에서 서비스 연결 역할 사용을 지원합니다.

서비스 연결 역할 ARN 참조

다음 표에는 Application Auto Scaling에서 작동하는 각에 대한 서비스 연결 역할의 Amazon 리소스 이름(ARN) AWS 서비스 이 나열되어 있습니다.

서비스	ARN
AppStream 2.0	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/appstream.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_AppStreamFleet
Aurora	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/rds.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_RDSCluster
Comprehend	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/comprehend.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_ComprehendEndpoint
DynamoDB	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/dynamodb.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_DynamoDBTable

서비스	ARN
ECS	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/ecs.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_ECSService
ElastiCache	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/elasticache.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_ElastiCacheRG
Keyspaces	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/cassandra.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_CassandraTable
Lambda	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/lambda.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_LambdaConcurrency
MSK	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/kafka.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_KafkaCluster
Neptune	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/neptune.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_NeptuneCluster
SageMaker AI	arn:aws:iam:: <i>012345678910</i> :role/aws-service-role/sagemaker.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_SageMakerEndpoint

서비스	ARN
Spot Fleets	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
사용자 지정 리소스	arn:aws:iam:: 012345678910 :role/aws-service-role/custom-resource.application-autoscaling.amazonaws.com/AWSServiceRoleForApplicationAutoScaling_CustomResource

Note

지정된 서비스 연결 역할이 아직 존재하지 않더라도 CloudFormation 스택 템플릿에서 [AWS::ApplicationAutoScaling::ScalableTarget](#) 리소스의 RoleARN 속성에 대한 서비스 연결 역할의 ARN을 지정할 수 있습니다. Application Auto Scaling이 자동으로 역할을 생성합니다.

Application Auto Scaling 자격 증명 기반 정책 예제

기본적으로 새 사용자는 어떤 작업도 수행할 권한이 AWS 계정 없습니다. IAM 관리자는 Application Auto Scaling API 작업을 수행할 수 있는 IAM 자격 증명(예: 사용자 또는 역할) 권한을 부여하는 IAM 정책을 생성하고 할당해야 합니다.

다음 예제 JSON 정책 문서를 사용하여 IAM 정책을 생성하는 방법을 알아보려면 IAM 사용 설명서의 [JSON 탭에서 정책 생성](#)을 참조하세요.

내용

- [Application Auto Scaling API 작업에 필요한 권한](#)
- [대상 서비스 및 CloudWatch에 대한 API 작업에 필요한 권한](#)
- [에서 작업할 수 있는 권한 AWS Management Console](#)

Application Auto Scaling API 작업에 필요한 권한

다음 정책은 Application Auto Scaling API를 호출할 때 일반적인 사용 사례에 대한 권한을 부여합니다. 자격 증명 기반 정책을 작성할 때 이 섹션을 참조하세요. 각 정책은 Application Auto Scaling API 작업의 모두 또는 일부에 대한 권한을 부여합니다. 또한 최종 사용자에게 대상 서비스 및 CloudWatch에 대한 권한이 있는지 확인해야 합니다(자세한 내용은 다음 섹션 참조).

다음 자격 증명 기반 정책에서는 모든 Application Auto Scaling API 작업에 대한 권한을 부여합니다.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "application-autoscaling:*"
      ],
      "Resource": "*"
    }
  ]
}
```

다음 자격 증명 기반 정책에서는 예약된 작업이 아니라 확장 정책을 구성하는 데 필요한 모든 Application Auto Scaling API 작업에 대한 권한을 부여합니다.

JSON

```
{
  "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": "*"
}
]
}

```

다음 자격 증명 기반 정책에서는 확장 정책이 아니라 예약된 작업을 구성하는 데 필요한 모든 Application Auto Scaling API 작업에 대한 권한을 부여합니다.

JSON

```

{
  "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": "*"
    }
  ]
}

```

대상 서비스 및 CloudWatch에 대한 API 작업에 필요한 권한

대상 서비스에서 Application Auto Scaling을 구성하고 사용하려면 최종 사용자에게 Amazon CloudWatch 및 확장을 구성할 각 대상 서비스에 대한 권한이 부여되어야 합니다. 다음 정책을 사용하여 대상 서비스 및 CloudWatch로 작업하는 데 필요한 최소 권한을 부여합니다.

내용

- [AppStream 2.0 플릿](#)
- [Aurora 복제본](#)
- [Amazon Comprehend 문서 분류 및 엔터티 인식기 엔드포인트](#)
- [DynamoDB 테이블 및 글로벌 보조 인덱스](#)
- [ECS 서비스](#)
- [ElastiCache 복제 그룹](#)
- [Amazon EMR 클러스터](#)
- [Amazon Keyspaces 테이블](#)
- [Lambda 함수](#)
- [Amazon Managed Streaming for Apache Kafka\(MSK\) 브로커 스토리지](#)
- [Neptune 클러스터](#)
- [SageMaker AI 엔드포인트](#)
- [스팟 플릿\(Amazon EC2\)](#)
- [사용자 지정 리소스](#)

AppStream 2.0 플릿

다음 자격 증명 기반 정책에서는 모든 AppStream 2.0 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "appstream:DescribeFleets",
        "appstream:UpdateFleet",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch>DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}
```

```
    ]
  }
}
```

Aurora 복제본

다음 자격 증명 기반 정책에서는 모든 Aurora 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```
{
  "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": "*"
    }
  ]
}
```

Amazon Comprehend 문서 분류 및 엔터티 인식기 엔드포인트

다음 자격 증명 기반 정책에서는 모든 Amazon Comprehend 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

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

```

        "Effect": "Allow",
        "Action": [
            "comprehend:UpdateEndpoint",
            "comprehend:DescribeEndpoint",
            "cloudwatch:DescribeAlarms",
            "cloudwatch:PutMetricAlarm",
            "cloudwatch>DeleteAlarms"
        ],
        "Resource": "*"
    }
]
}

```

DynamoDB 테이블 및 글로벌 보조 인덱스

다음 자격 증명 기반 정책에서는 모든 DynamoDB 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "dynamodb:DescribeTable",
        "dynamodb:UpdateTable",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch>DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}

```

ECS 서비스

다음 자격 증명 기반 정책에서는 모든 ECS 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "ecs:DescribeServices",
        "ecs:UpdateService",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch:DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}
```

ElastiCache 복제 그룹

다음 자격 증명 기반 정책에서는 모든 ElastiCache 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```
{
  "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": "*"
  }
]
}

```

Amazon EMR 클러스터

다음 자격 증명 기반 정책에서는 모든 Amazon EMR 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "elasticmapreduce:ModifyInstanceGroups",
        "elasticmapreduce:ListInstanceGroups",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch>DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}

```

Amazon Keyspaces 테이블

다음 자격 증명 기반 정책에서는 모든 Amazon Keyspaces 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```

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

```

```

    "Statement": [
      {
        "Effect": "Allow",
        "Action": [
          "cassandra:Select",
          "cassandra:Alter",
          "cloudwatch:DescribeAlarms",
          "cloudwatch:PutMetricAlarm",
          "cloudwatch>DeleteAlarms"
        ],
        "Resource": "*"
      }
    ]
  }
}

```

Lambda 함수

다음 자격 증명 기반 정책에서는 모든 Lambda 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```

{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "lambda:PutProvisionedConcurrencyConfig",
        "lambda:GetProvisionedConcurrencyConfig",
        "lambda>DeleteProvisionedConcurrencyConfig",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch>DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}

```

Amazon Managed Streaming for Apache Kafka(MSK) 브로커 스토리지

다음 자격 증명 기반 정책에서는 모든 Amazon MSK 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "kafka:DescribeCluster",
        "kafka:DescribeClusterOperation",
        "kafka:UpdateBrokerStorage",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch>DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}
```

Neptune 클러스터

다음 자격 증명 기반 정책에서는 모든 Neptune 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```
{
  "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 AI 엔드포인트

다음 자격 증명 기반 정책은 필요한 모든 SageMaker AI 및 CloudWatch API 작업에 권한을 부여합니다.

JSON

```

{
  "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": "*"
    }
  ]
}

```

스팟 플릿(Amazon EC2)

다음 자격 증명 기반 정책에서는 모든 스팟 플릿 및 CloudWatch API 작업에 필요한 권한을 부여합니다.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "ec2:DescribeSpotFleetRequests",
        "ec2:ModifySpotFleetRequest",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",
        "cloudwatch>DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}
```

사용자 지정 리소스

다음 자격 증명 기반 정책에서는 API Gateway API 실행 작업에 대한 권한을 부여합니다. 이 정책에서는 모든 CloudWatch 작업에 필요한 권한도 부여합니다.

JSON

```
{
  "Version": "2012-10-17",
  "Statement": [
    {
      "Effect": "Allow",
      "Action": [
        "execute-api:Invoke",
        "cloudwatch:DescribeAlarms",
        "cloudwatch:PutMetricAlarm",

```

```

        "cloudwatch:DeleteAlarms"
      ],
      "Resource": "*"
    }
  ]
}

```

에서 작업할 수 있는 권한 AWS Management Console

독립형 Application Auto Scaling 콘솔은 없습니다. Application Auto Scaling과 통합되는 대부분의 서비스에는 콘솔에서 조정을 구성하는 데 도움이 되는 전용 기능이 있습니다.

대부분의 경우 각 서비스는 콘솔에 대한 액세스를 정의하는 AWS 관리형(미리 정의된) IAM 정책을 제공하며, 여기에는 Application Auto Scaling API 작업에 대한 권한이 포함됩니다. 자세한 내용은 콘솔을 사용할 서비스에 대한 설명서를 참조하세요.

또한 사용자 지정 IAM 정책을 생성하여 AWS Management Console에서 특정 Application Auto Scaling API 작업을 보고 작업할 수 있는 세분화된 권한을 사용자에게 제공할 수 있습니다. 이전 섹션의 예제 정책을 사용할 수 있지만 또는 AWS CLI SDK로 이루어진 요청을 위해 설계되었습니다. 콘솔에서는 추가적인 API 작업을 통해 해당 기능을 구현하므로 이러한 정책이 예상과 다르게 작동할 수 있습니다. 예를 들어, 단계 조정을 구성하려면 사용자는 CloudWatch 경보를 생성하고 관리하기 위한 추가 권한이 필요할 수 있습니다.

Tip

콘솔에서 작업을 수행하는 데 필요한 API 작업을 파악하려는 경우 AWS CloudTrail 등의 서비스를 사용할 수 있습니다. 자세한 내용은 [AWS CloudTrail 사용 설명서](#)를 참조하십시오.

다음 자격 증명 기반 정책에서는 스팟 플릿에 대한 확장 정책을 구성하는 권한을 부여합니다. 스팟 플릿에 대한 IAM 권한 외에, Amazon EC2 콘솔에서 플릿 확장 설정에 액세스하는 콘솔 사용자에게 동적 확장을 지원하는 서비스에 대한 적절한 권한이 있어야 합니다.

JSON

```

{
  "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"
      }
    }
  }
]
}

```

이 정책을 통해 콘솔 사용자가 Amazon EC2 콘솔에서 조정 정책을 보며 수정하고, CloudWatch 콘솔에서 CloudWatch 경보를 생성하고 관리할 수 있습니다.

API 작업을 조정하여 사용자 액세스를 제한할 수 있습니다. 예를 들어, `application-autoscaling:*`을 `application-autoscaling:Describe*`로 바꾸면 사용자는 읽기 전용 액세스 권한을 갖게 됩니다.

필요에 따라 CloudWatch 권한을 조정하여 CloudWatch 기능에 대한 사용자 액세스를 제한할 수도 있습니다. 자세한 내용은 Amazon CloudWatch 사용 설명서의 [CloudWatch 콘솔에 필요한 권한](#)을 참조하세요.

Application Auto Scaling 액세스 문제 해결

`AccessDeniedException` 또는 Application Auto Scaling으로 작업할 때 이와 유사한 어려움이 있으면 이 단원의 정보를 참조하세요.

Application Auto Scaling에서 작업을 수행할 권한이 없음

AWS API 작업을 호출할 `AccessDeniedException` 때를 수신하면 사용 중인 AWS Identity and Access Management (IAM) 자격 증명에 해당 호출에 필요한 권한이 없음을 의미합니다.

다음 예제 오류는 `mateojackson` 사용자가 확장 가능 대상에 대한 세부 정보를 보려고 하지만, `application-autoscaling:DescribeScalableTargets` 권한이 없는 경우에 발생합니다.

```
An error occurred (AccessDeniedException) when calling the DescribeScalableTargets operation: User: arn:aws:iam::123456789012:user/mateojackson is not authorized to perform: application-autoscaling:DescribeScalableTargets
```

이 오류 또는 이와 유사한 오류가 발생하면 관리자에게 문의하여 도움을 받아야 합니다.

계정의 관리자는 Application Auto Scaling에서 대상 서비스 및 CloudWatch의 리소스에 액세스하는 데 사용하는 모든 API 작업에 액세스하는 권한이 사용자에게 있는지 확인해야 합니다. 작업 중인 리소스에 따라 다른 권한이 필요합니다. 또한 Application Auto Scaling에서는 사용자가 해당 리소스에 대해 조정을 처음 구성할 때 서비스 연결 역할을 생성할 수 있는 권한이 필요합니다.

관리자인데, IAM 정책에서 오류를 반환했거나 예상대로 작동하지 않음

Application Auto Scaling 작업 외에도 IAM 정책은 대상 서비스 및 CloudWatch를 호출할 수 있는 권한을 부여해야 합니다. 사용자 또는 애플리케이션에 이러한 추가 권한이 없는 경우 액세스가 예기치 않게 거부될 수 있습니다. 계정에서 사용자 및 애플리케이션에 대한 IAM 정책을 작성하려면 [Application Auto Scaling 자격 증명 기반 정책 예제](#)의 정보를 참조하세요.

유효성 검사가 수행되는 방법에 대한 자세한 내용은 [대상 리소스에서 Application Auto Scaling API 직접 호출에 대한 권한 유효성 검사](#) 섹션을 참조하세요.

일부 권한 문제는 Application Auto Scaling에서 사용하는 서비스 연결 역할을 생성하는 문제로 인해 발생할 수도 있습니다. 이러한 서비스 연결 역할 생성에 대한 자세한 내용은 [Application Auto Scaling에 대한 서비스 연결 역할](#) 섹션을 참조하세요.

대상 리소스에서 Application Auto Scaling API 직접 호출에 대한 권한 유효성 검사

Application Auto Scaling API 작업에 대한 권한 있는 요청을 수행하려면 API 호출자에게 대상 서비스 및 CloudWatch의 AWS 리소스에 액세스할 수 있는 권한이 있어야 합니다. Application Auto Scaling은 요청을 진행하기 전에 대상 서비스 및 CloudWatch 모두와 연결된 요청에 대한 권한을 검증합니다. 이를 위해 일련의 호출을 실행하여 대상 리소스에 대한 IAM 권한을 검증합니다. 응답이 반환되면 Application Auto Scaling이 읽습니다. IAM 권한이 지정된 작업을 허용하지 않는 경우 Application Auto Scaling은 요청에 실패하고 누락된 권한에 대한 정보가 포함된 오류를 사용자에게 반환합니다. 이렇게 하면 사용자가 배포하려는 조정 구성이 의도한 대로 작동하고 요청이 실패하면 유용한 오류가 반환됩니다.

이 작동 방식의 예로, 다음 정보는 Application Auto Scaling이 Aurora 및 CloudWatch를 사용하여 권한 검증을 수행하는 방법에 대한 세부 정보를 제공합니다.

사용자가 Aurora DB 클러스터에 대해 RegisterScalableTarget API를 호출하는 경우 Application Auto Scaling에서는 다음과 같은 검사를 모두 수행하여 IAM 사용자에게 필수 권한(굵게 표시)이 있는지 확인합니다.

- **rds:CreateDBInstance**: 사용자에게 이 권한이 있는지를 확인하기 위해 CreateDBInstance API 작업으로 요청을 보내, 사용자가 지정한 Aurora DB 클러스터에 잘못된 파라미터(빈 인스턴스 ID)가 있는 DB 인스턴스를 생성하려고 합니다. 권한이 부여된 사용자의 경우 API가 요청을 감사한 후 InvalidParameterValue 오류 코드 응답을 반환합니다. 그러나 권한이 없는 사용자의 경우 AccessDenied 오류가 발생하고 Application Auto Scaling 요청에 실패합니다. 누락된 권한이 나열된 ValidationException 오류가 사용자에게 제공됩니다.
- **rds>DeleteDBInstance**: 빈 인스턴스 ID를 DeleteDBInstance API 작업에 보냅니다. 권한이 부여된 사용자의 경우 이 요청으로 InvalidParameterValue 오류가 발생합니다. 권한이 없는 사용자의 경우 AccessDenied가 발생하고 사용자에게 유효성 검사 예외를 보냅니다(첫 번째 글머리 기호에 설명된 것과 동일한 처리).
- **rds:AddTagsToResource**: AddTagsToResource API 작업에는 Amazon 리소스 이름(ARN)이 필요하기 때문에, ARN을 구성하려면 유효하지 않은 계정 ID(12345)와 더미 인스턴스 ID(non-existing-db)를 사용하여 “더미” 리소스를 지정해야 합니다(arn:aws:rds:us-east-1:12345:db:non-existing-db). 권한이 부여된 사용자의 경우 이 요청으로 InvalidParameterValue 오류가 발

생합니다. 권한이 없는 사용자의 경우 AccessDenied가 발생하고 사용자에게 유효성 검사 예외를 보냅니다.

- `rds:DescribeDBClusters`: Auto Scaling을 위해 등록되는 리소스의 클러스터 이름을 설명합니다. 권한이 부여된 사용자의 경우 유효한 설명 결과를 얻습니다. 권한이 없는 사용자의 경우 AccessDenied가 발생하고 사용자에게 유효성 검사 예외를 보냅니다.
- `rds:DescribeDBInstances`: 규모 조정 가능 대상을 등록하기 위해 사용자가 제공한 클러스터 이름을 필터링하는 `db-cluster-id` 필터로 `DescribeDBInstances` API를 직접적으로 호출합니다. 권한이 부여된 사용자의 경우 DB 클러스터의 모든 DB 인스턴스를 설명할 수 있습니다. 권한이 없는 사용자의 경우 이 호출로 AccessDenied가 발생하고 사용자에게 유효성 검사 예외를 보냅니다.
- `cloudwatch:PutMetricAlarm`: 파라미터 없이 `PutMetricAlarm` API를 호출합니다. 경보 이름이 누락되기 때문에 요청으로 권한이 부여된 사용자에게 `ValidationError`가 발생합니다. 권한이 없는 사용자의 경우 AccessDenied가 발생하고 사용자에게 유효성 검사 예외를 보냅니다.
- `cloudwatch:DescribeAlarms`: 1로 설정된 최대 레코드 수로 `DescribeAlarms` API를 호출합니다. 권한 있는 사용자의 경우 응답에서 하나의 경보에 대한 정보가 예상됩니다. 권한이 없는 사용자의 경우 이 호출로 AccessDenied가 발생하고 사용자에게 유효성 검사 예외를 보냅니다.
- `cloudwatch>DeleteAlarms`: 상기 `PutMetricAlarm`과 마찬가지로 `DeleteAlarms` 요청에 대한 파라미터를 제공하지 않습니다. 요청에서 경보 이름이 누락되었기 때문에 이 호출은 권한이 부여된 사용자에 대해 `ValidationError`로 실패합니다. 권한이 없는 사용자의 경우 AccessDenied가 발생하고 사용자에게 유효성 검사 예외를 보냅니다.

이러한 유효성 검사 예외 중 하나가 발생할 때마다 기록됩니다. 를 사용하여 검증에 실패한 호출을 수동으로 식별하는 단계를 수행할 수 있습니다 AWS CloudTrail. 자세한 내용은 [AWS CloudTrail 사용 설명서](#)를 참조하십시오.

Note

CloudTrail을 사용하여 Application Auto Scaling 이벤트에 대한 알림을 받는 경우, 이러한 알림에는 기본적으로 사용자 권한을 검증하는 Application Auto Scaling 호출이 포함됩니다. 이러한 알림을 필터링하려면 이러한 유효성 검사를 위한 `application-autoscaling.amazonaws.com`을 포함할 `invokedBy` 필드를 사용합니다.

인터페이스 VPC 엔드포인트를 사용하여 Application Auto Scaling 액세스

AWS PrivateLink 를 사용하여 VPC와 Application Auto Scaling 간에 프라이빗 연결을 생성할 수 있습니다. 인터넷 게이트웨이, NAT 디바이스, VPN 연결 또는 Direct Connect 연결을 사용하지 않고 VPC에 있는 것처럼 Application Auto Scaling에 액세스할 수 있습니다. VPC의 인스턴스에서 Application Auto Scaling에 액세스하는 데는 퍼블릭 IP 주소가 필요하지 않습니다.

AWS PrivateLink에서 제공되는 인터페이스 엔드포인트를 생성하여 이 프라이빗 연결을 설정합니다. 인터페이스 엔드포인트에 대해 사용 설정하는 각 서브넷에서 엔드포인트 네트워크 인터페이스를 생성합니다. 이는 Application Auto Scaling으로 향하는 트래픽의 진입점 역할을 하는 요청자 관리형 네트워크 인터페이스입니다.

자세한 내용은 AWS PrivateLink 가이드의 [AWS 서비스 통한 액세스를 AWS PrivateLink](#) 참조하세요.

내용

- [인터페이스 VPC 엔드포인트 생성](#)
- [VPC 엔드포인트 정책 생성](#)

인터페이스 VPC 엔드포인트 생성

다음 서비스 이름을 사용하여 Application Auto Scaling에 대한 엔드포인트를 생성합니다.

```
com.amazonaws.region.application-autoscaling
```

자세한 내용은 AWS PrivateLink 가이드의 [인터페이스 VPC 엔드포인트를 사용하여 AWS 서비스 액세스](#)를 참조하세요.

다른 설정은 변경할 필요가 없습니다. Application Auto Scaling은 AWS 서비스 엔드포인트 또는 프라이빗 인터페이스 VPC 엔드포인트 중 사용 중인 엔드포인트를 사용하여 다른 서비스를 호출합니다.

VPC 엔드포인트 정책 생성

VPC 엔드포인트에 정책을 연결하여 Application Auto Scaling API에 대한 액세스를 제어할 수 있습니다. 이 정책은 다음을 지정합니다.

- 작업을 수행할 수 있는 보안 주체.
- 수행할 수 있는 작업.
- 작업을 수행할 수 있는 리소스.

다음 예에서는 엔드포인트를 통해 조정 정책을 삭제할 수 있는 모든 사용자 권한을 거부하는 VPC 엔드포인트 정책을 보여줍니다. 또한 이 정책 예에서는 모든 사용자에게 다른 모든 작업을 수행할 수 있는 권한을 부여합니다.

```
{
  "Statement": [
    {
      "Action": "*",
      "Effect": "Allow",
      "Resource": "*",
      "Principal": "*"
    },
    {
      "Action": "application-autoscaling:DeleteScalingPolicy",
      "Effect": "Deny",
      "Resource": "*",
      "Principal": "*"
    }
  ]
}
```

자세한 정보는 AWS PrivateLink 가이드의 [VPC 엔드포인트 정책](#)을 참조하세요.

Application Auto Scaling의 복원성

AWS 글로벌 인프라는 AWS 리전 및 가용 영역을 중심으로 구축됩니다.

AWS 리전은 물리적으로 분리되고 격리된 여러 가용 영역을 제공하며, 이 가용 영역은 지연 시간이 짧고 처리량이 높으며 중복성이 높은 네트워킹과 연결됩니다.

가용 영역을 사용하면 중단 없이 영역 간에 자동으로 장애 극복 조치가 이루어지는 애플리케이션 및 데이터베이스를 설계하고 운영할 수 있습니다. 가용 영역은 기존의 단일 또는 다중 데이터 센터 인프라보다 가용성, 내결함성, 확장성이 뛰어납니다.

AWS 리전 및 가용 영역에 대한 자세한 내용은 [AWS 글로벌 인프라](#)를 참조하세요.

Application Auto Scaling의 인프라 보안

관리형 서비스인 Application Auto Scaling은 AWS 글로벌 네트워크 보안으로 보호됩니다. AWS 보안 서비스 및가 인프라를 AWS 보호하는 방법에 대한 자세한 내용은 [AWS 클라우드 보안을](#) 참조하세요. 인프라 보안 모범 사례를 사용하여 환경을 설계하려면 보안 원칙 AWS Well-Architected Framework의 [인프라 보호를](#) 참조하세요 AWS .

AWS 에서 게시한 API 호출을 사용하여 네트워크를 통해 Application Auto Scaling에 액세스합니다. 클라이언트는 다음을 지원해야 합니다.

- Transport Layer Security(TLS). TLS 1.2는 필수이며 TLS 1.3을 권장합니다.
- DHE(Ephemeral Diffie-Hellman) 또는 ECDHE(Elliptic Curve Ephemeral Diffie-Hellman)와 같은 완전 전송 보안(PFS)이 포함된 암호 제품군. Java 7 이상의 최신 시스템은 대부분 이러한 모드를 지원합니다.

Application Auto Scaling의 규정 준수 확인

AWS 서비스 가 특정 규정 준수 프로그램의 범위 내에 있는지 알아보려면 [AWS 서비스 규정 준수 프로그램 범위 내](#)를 참조하고 관심 있는 규정 준수 프로그램을 선택합니다. 일반 정보는 [AWS 규정 준수 프로그램](#).

를 사용하여 타사 감사 보고서를 다운로드할 수 있습니다 AWS Artifact. 자세한 내용은 [Downloading Reports inDownloading AWS Artifact](#)을 참조하세요.

사용 시 규정 준수 책임은 데이터의 민감도, 회사의 규정 준수 목표 및 관련 법률과 규정에 따라 AWS 서비스 결정됩니다. 사용 시 규정 준수 책임에 대한 자세한 내용은 [AWS 보안 설명서를](#) AWS 서비스참조하세요.

Application Auto Scaling에 대한 할당량

AWS 계정에는 각각에 대해 이전에 제한이라고 하는 기본 할당량이 있습니다. 다르게 표시되지 않는 한 리전별로 각 할당량이 적용됩니다. 일부 할당량에 대한 증가를 요청할 수 있으며 다른 할당량은 늘릴 수 없습니다.

Application Auto Scaling에 대한 할당량을 보려면 [Service Quotas 콘솔](#)을 엽니다. 탐색 창에서 AWS 서비스를 선택하고 Application Auto Scaling을 선택합니다.

할당량 증가를 요청하려면 Service Quotas 사용 설명서의 [할당량 증가 요청](#)을 참조하세요.

AWS 계정에는 Application Auto Scaling과 관련된 다음과 같은 할당량이 있습니다.

명칭	기본값	조정 가능
리소스 유형당 규모 조정 가능 대상 수	Amazon DynamoDB: 5,000 Amazon ECS: 3,000 Amazon Keyspaces: 1,500 기타 리소스 유형: 500	예
규모 조정 가능 대상당 조정 정책(단계 조정 정책과 대상 추적 정책 모두)	50	아니요
확장 가능한 대상별 예약된 작업	200	아니요
조정 정책 단계당 단계별 조정	20	예

워크로드를 조정할 때 서비스 할당량을 염두에 두세요. 예를 들어, 서비스에서 허용되는 최대 용량 단위 수에 도달하면 확장이 중지됩니다. 수요가 감소하고 현재 용량이 감소하면 Application Auto Scaling이 다시 확장할 수 있습니다. 이 용량 한도에 다시 도달하지 않도록 증가를 요청할 수 있습니다. 각 서비스에는 리소스의 최대 용량에 대한 자체 기본 할당량이 있습니다. 다른 Amazon Web Services의 기본 할당량에 대한 자세한 내용은 Amazon Web Services 일반 참조의 [서비스 엔드포인트 및 할당량](#)을 참조하세요.

Application Auto Scaling에 대한 문서 기록

다음 표에서는 2018년 1월 이후의 Application Auto Scaling 설명서에 대한 중요 추가 사항을 설명합니다. 이 설명서에 대한 업데이트 알림을 받으려면 RSS 피드에 가입하면 됩니다.

변경 사항	설명	날짜
ElastiCache Memcached 클러스터에 대한 지원 추가	Application Auto Scaling을 사용하여 Memcached 클러스터의 노드 수를 수평적으로 조정합니다. 자세한 내용은 ElastiCache 및 Application Auto Scaling 을 참조하세요.	2025년 4월 10일
AWS 관리형 정책 업데이트	Application Auto Scaling에서 AWSApplicationAutoScalingElastiCacheRGPolicy 정책을 업데이트했습니다.	2025년 4월 10일
설명서 변경 사항	Application Auto Scaling 사용 설명서의 새 주제는 Application Auto Scaling과 함께 예측 조정 사용을 시작하는 데 도움이 됩니다. Application Auto Scaling 예측 조정 을 참조하세요.	2024년 11월 21일
AWS 관리형 정책 업데이트	Application Auto Scaling에서 AWSApplicationAutoScalingECSServicePolicy 정책을 업데이트했습니다.	2024년 11월 21일
WorkSpaces 풀에 대한 지원 추가	Application Auto Scaling을 사용하여 WorkSpaces 풀의 규모를 조정합니다. 자세한 내용은 Amazon WorkSpaces	2024년 6월 27일

[및 Application Auto Scaling](#)을 참조하세요. 주제 [Application Auto Scaling의 AWS 관리형 정책 업데이트](#)가 WorkSpaces와의 통합을 위한 새로운 관리형 정책을 나열하도록 업데이트되었습니다.

[설명서 변경 사항](#)

할당량 설명서의 리소스 유형당 최대 확장 가능 대상 수 항목을 업데이트했습니다. [Application Auto Scaling에 대한 할당량을](#) 참조하세요.

2024년 1월 16일

[SageMaker AI 추론 구성 요소 지원](#)

Application Auto Scaling을 사용하여 추론 구성 요소의 복사본 규모를 조정합니다.

2023년 11월 29일

[AWS 관리형 정책 업데이트](#)

Application Auto Scaling에서 AWSApplicationAutoScalingSageMakerEndpointPolicy 정책을 업데이트했습니다.

2023년 11월 13일

[SageMaker AI Serverless 프로비저닝된 동시성 지원](#)

Application Auto Scaling을 사용하여 서버리스 엔드포인트의 프로비저닝된 동시성을 조정합니다.

2023년 5월 9일

[태그를 사용하여 확장 가능 대상 분류](#)

이제 Application Auto Scaling 확장 가능 대상에 태그 형식으로 메타데이터를 지정할 수 있습니다. [Application Auto Scaling에 대한 태그 지정 지원](#)을 참조하세요.

2023년 3월 20일

<u>CloudWatch 지표 수학적 지원</u>	이제 대상 추적 조정 정책을 생성할 때 지표 수학을 사용할 수 있습니다. 지표 수학을 사용하면 여러 CloudWatch 지표를 쿼리하고 수학적 표현식을 활용함으로써 이러한 지표에 근거하여 새로운 시계열을 만들 수 있습니다. <u>지표 수학을 사용하여 Application Auto Scaling에서 대상 추적 조정 정책 생성을 참조하세요.</u>	2023년 3월 14일
<u>확장하지 않는 이유</u>	이제 Application Auto Scaling에서 Application Auto Scaling API를 사용하여 리소스를 확장하지 않는 머신 판독 가능한 이유를 검색할 수 있습니다. <u>Application Auto Scaling 확장 활동을 참조하세요.</u>	2023년 1월 4일
<u>설명서 변경 사항</u>	할당량 설명서의 리소스 유형당 최대 확장 가능 대상 수 항목을 업데이트했습니다. <u>Application Auto Scaling에 대한 할당량을 참조하세요.</u>	2022년 5월 6일
<u>Amazon Neptune 클러스터에 대한 지원 추가</u>	Application Auto Scaling을 사용하여 Amazon Neptune DB 클러스터의 복제본 수를 조정할 수 있습니다. 자세한 내용은 <u>Amazon Neptune 및 Application Auto Scaling을 참조하세요.</u> 주제 <u>Application Auto Scaling의 AWS 관리형 정책 업데이트가 Neptune과의 통합을 위한 새로운 관리형 정책을 나열하도록 업데이트되었습니다.</u>	2021년 10월 6일

[이제 Application Auto Scaling에서 AWS 관리형 정책에 대한 변경 사항을 보고합니다.](#)

2021년 8월 19일부터 관리형 정책에 대한 변경 사항이 [Application Auto Scaling 관리 AWS 형 정책에 대한 업데이트](#) 주제에 보고됩니다. 나열된 첫 번째 변경 사항은 ElastiCache(Redis OSS)에 필요한 권한을 추가하는 것입니다.

2021년 8월 19일

[ElastiCache\(Redis OSS\) 복제 그룹에 대한 지원 추가](#)

Application Auto Scaling을 사용하여 ElastiCache(Redis OSS) 복제 그룹(클러스터)에 대한 노드 그룹 수와 노드 그룹당 복제본 수를 조정합니다. 자세한 내용은 [ElastiCache\(Redis OSS\) 및 Application Auto Scaling](#)을 참조하세요.

2021년 8월 19일

[설명서 변경 사항](#)

Application Auto Scaling 사용 설명서의 새로운 IAM 주제는 Application Auto Scaling에 대한 액세스 문제를 해결하는 데 도움이 됩니다. 자세한 내용은 [Application Auto Scaling에 사용되는 Identity and Access Management](#)를 참조하세요. 또한 대상 서비스 및 Amazon CloudWatch에서의 작업에 대한 새로운 IAM 권한 정책 예제가 추가되었습니다. 자세한 내용은 [AWS CLI 또는 SDK 작업에 대한 정책 예제를 참조하세요.](#)

2021년 2월 23일

<u>현지 시간대 지원 추가</u>	이제 현지 시간대에서 예약된 작업을 만들 수 있습니다. 일광 절약 시간을 준수하는 경우 DST(일광 절약 시간제)에 맞게 자동으로 조정됩니다. 자세한 내용은 <u>예약된 조정</u> 을 참조하세요.	2021년 2월 2일
<u>설명서 변경 사항</u>	Application Auto Scaling 사용 설명서의 새로운 <u>자습서</u> 는 Application Auto Scaling을 사용할 때 대상 추적 조정 정책 및 예약된 조정을 사용하여 애플리케이션의 가용성을 높이는 방법을 이해하는 데 도움이 됩니다.	2020년 10월 15일
<u>Amazon Managed Streaming for Apache Kafka 클러스터 스토리지에 대한 지원 추가</u>	대상 추적 조정 정책을 사용하여 Amazon MSK 클러스터와 연결된 브로커 스토리지의 양을 조정합니다.	2020년 9월 30일
<u>Amazon Comprehend 엔터티 인식기 엔드포인트에 대한 지원 추가</u>	Application Auto Scaling을 사용하여 Amazon Comprehend 엔터티 인식기 엔드포인트에 프로비저닝된 추론 단위 수를 조정합니다.	2020년 9월 28일
<u>Amazon Keyspaces(Apache Cassandra용) 표에 대한 지원 추가</u>	Application Auto Scaling을 사용하여, Amazon Keyspaces 테이블의 프로비저닝된 처리량(읽기 및 쓰기 용량)을 조정합니다.	2020년 4월 23일

<u>새로운 “보안” 장</u>	Application Auto Scaling 사용 설명서의 새로운 <u>보안</u> 장은 Systems Manager를 사용할 때 <u>공동 책임 모델</u> 을 적용하는 방법을 이해하는 데 도움이 됩니다. 이번 업데이트에서는 사용 설명서의 "인증 및 액세스 제어" 장이 새롭고 더욱 유용한 내용인 <u>Application Auto Scaling의 Identity and Access Management</u> 단원으로 대체되었습니다.	2020년 1월 16일
<u>마이너 업데이트</u>	다양한 개선 및 수정 사항입니다.	2020년 1월 15일
<u>알림 기능 추가</u>	Application Auto Scaling은 이제 Amazon EventBridge에 이벤트를 보내고 특정 작업이 발생할 AWS Health Dashboard 때에 알림을 보냅니다. 자세한 내용은 <u>Application Auto Scaling 모니터링</u> 섹션을 참조하세요.	2019년 12월 20일
<u>AWS Lambda 함수에 대한 지원 추가</u>	Application Auto Scaling을 사용하여 Lambda 함수의 프로비저닝된 동시성을 조정합니다.	2019년 12월 3일
<u>Amazon Comprehend 문서 분류 엔드포인트에 대한 지원 추가</u>	Application Auto Scaling을 사용하여 Amazon Comprehend 문서 분류 엔드포인트의 처리 용량을 조정합니다.	2019년 11월 25일
<u>대상 추적 조정 정책에 대한 WorkSpaces 애플리케이션 지원 추가</u>	대상 추적 조정 정책을 사용하여 WorkSpaces 애플리케이션 플릿의 크기를 조정합니다.	2019년 11월 25일

Amazon VPC 엔드포인트에 대한 지원	이제 VPC와 Application Auto Scaling 간에 프라이빗 연결을 설정할 수 있습니다. 마이그레이션 고려 사항 및 지침은 Application Auto Scaling 및 인터페이스 VPC 엔드포인트 를 참조하세요.	2019년 11월 22일
조정 일시 중지 및 재개	조정 일시 중지 및 재개에 대한 지원이 추가되었습니다. 자세한 내용은 Application Auto Scaling의 조정 일시 중지 및 재개 를 참조하세요.	2019년 8월 29일
설명서 변경 사항	Application Auto Scaling 설명서의 예약된 조정 , 단계 조정 정책 및 대상 추적 조정 정책 섹션이 개선되었습니다.	2019년 3월 11일
사용자 지정 리소스에 대한 지원 추가	Application Auto Scaling을 사용하여 자체 애플리케이션 또는 서비스에서 제공하는 사용자 지정 리소스를 조정합니다. 자세한 내용은 GitHub 리포지토리 를 참조하세요.	2018년 7월 9일
SageMaker AI 엔드포인트 변형에 대한 지원 추가	Application Auto Scaling을 사용해 변형을 위해 제공되는 엔드포인트 인스턴스 수를 조정합니다.	2018년 2월 28일

다음 표에서는 2018년 1월 이전에 Application Auto Scaling 설명서에서 변경된 중요 사항에 대해 설명합니다.

변경	설명	Date
Aurora 복제본 지원 추가	Application Auto Scaling을 사용하여 원하는 수로 조정합니다. 자세한 내용은 Amazon RDS 사용 설명서의 Aurora 복제본에 Amazon Aurora Auto Scaling 사용 을 참조하세요.	2017년 11월 17일
예약된 조정에 대한 지원 추가	예약된 조정을 사용하여 미리 설정된 시간 또는 간격에 따라 리소스를 조정합니다. 자세한 내용은 Application Auto Scaling의 예약된 조정 을 참조하세요.	2017년 11월 8일
대상 추적 조정 정책에 대한 지원 추가	대상 추적 조정 정책을 사용하여 몇 가지 단계를 통해 애플리케이션에 대한 동적 조정을 설정합니다. 자세한 내용은 Application Auto Scaling의 대상 추적 조정 정책 을 참조하세요.	2017년 7월 12일
DynamoDB 테이블 및 글로벌 보조 인덱스에 대해 프로비저닝된 읽기 및 쓰기 용량 지원 추가	Application Auto Scaling을 사용하여 프로비저닝된 처리량(읽기 및 쓰기 용량)을 조정합니다. 자세한 내용은 Amazon DynamoDB 개발자 안내서의 Auto Scaling으로 처리 용량 관리 를 참조하세요.	2017년 6월 14일
WorkSpaces 애플리케이션 플릿에 대한 지원 추가	Application Auto Scaling을 사용하여 플릿의 크기를 조정합니다. 자세한 내용은 Amazon WorkSpaces 애플리케이션 관리 안내서 의 Workspace	2017년 3월 23일

변경	설명	Date
	<p>s 애플리케이션을 위한 플릿 Auto Scaling을 참조하세요. Amazon WorkSpaces</p>	
<p>Amazon EMR 클러스터에 대한 지원 추가</p>	<p>Application Auto Scaling을 사용하여 코어 및 태스크 노드를 조정합니다. 자세한 내용은 Amazon EMR 관리 안내서의 Amazon EMR에서 자동 조정 사용을 참조하세요.</p>	<p>2016년 11월 18일</p>
<p>스팟 플릿에 대한 지원 추가</p>	<p>Application Auto Scaling을 사용하여 대상 용량을 조정합니다. 자세한 내용은 Amazon EC2 사용 설명서의 스팟 플릿의 자동 조정을 참조하세요.</p>	<p>2016년 9월 1일</p>
<p>Amazon ECS 서비스에 대한 지원 추가</p>	<p>Application Auto Scaling을 사용하여 원하는 수로 조정합니다. 자세한 내용은 Amazon Elastic Container Service 개발자 안내서의 서비스 Auto Scaling을 참조하세요.</p>	<p>2016년 8월 9일</p>

기계 번역으로 제공되는 번역입니다. 제공된 번역과 원본 영어의 내용이 상충하는 경우에는 영어 버전이 우선합니다.