



OpenShift Container Platform 4.12

ノード

OpenShift Container Platform でのノードの設定および管理

OpenShift Container Platform 4.12 ノード

OpenShift Container Platform でのノードの設定および管理

Legal Notice

Copyright © 2025 Red Hat, Inc.

The text of and illustrations in this document are licensed by Red Hat under a Creative Commons Attribution–Share Alike 3.0 Unported license ("CC-BY-SA"). An explanation of CC-BY-SA is available at

<http://creativecommons.org/licenses/by-sa/3.0/>

. In accordance with CC-BY-SA, if you distribute this document or an adaptation of it, you must provide the URL for the original version.

Red Hat, as the licensor of this document, waives the right to enforce, and agrees not to assert, Section 4d of CC-BY-SA to the fullest extent permitted by applicable law.

Red Hat, Red Hat Enterprise Linux, the Shadowman logo, the Red Hat logo, JBoss, OpenShift, Fedora, the Infinity logo, and RHCE are trademarks of Red Hat, Inc., registered in the United States and other countries.

Linux[®] is the registered trademark of Linus Torvalds in the United States and other countries.

Java[®] is a registered trademark of Oracle and/or its affiliates.

XFS[®] is a trademark of Silicon Graphics International Corp. or its subsidiaries in the United States and/or other countries.

MySQL[®] is a registered trademark of MySQL AB in the United States, the European Union and other countries.

Node.js[®] is an official trademark of Joyent. Red Hat is not formally related to or endorsed by the official Joyent Node.js open source or commercial project.

The OpenStack[®] Word Mark and OpenStack logo are either registered trademarks/service marks or trademarks/service marks of the OpenStack Foundation, in the United States and other countries and are used with the OpenStack Foundation's permission. We are not affiliated with, endorsed or sponsored by the OpenStack Foundation, or the OpenStack community.

All other trademarks are the property of their respective owners.

Abstract

このドキュメントでは、クラスターのノード、Pod、コンテナを設定し管理する方法を説明します。また、Pod のスケジューリングや配置の設定方法、ジョブや DaemonSet を使用してタスクを自動化する方法やクラスターを効率化するための他のタスクなどに関する情報も提供します。

Table of Contents

第1章 ノードの概要	4
1.1. ノードについて	4
1.2. POD について	6
1.3. コンテナについて	8
1.4. ノードでの POD の自動スケーリング	8
1.5. OPENSIFT CONTAINER PLATFORM のノードの一般用語集	9
第2章 POD の使用	11
2.1. POD の使用	11
2.2. POD の表示	15
2.3. OPENSIFT CONTAINER PLATFORM クラスターでの POD の設定	18
2.4. HORIZONTAL POD AUTOSCALER での POD の自動スケーリング	23
2.5. VERTICAL POD AUTOSCALER を使用した POD リソースレベルの自動調整	46
2.6. POD への機密性の高いデータの提供	63
2.7. 設定マップの作成および使用	79
2.8. POD で外部リソースにアクセスするためのデバイスプラグインの使用	90
2.9. POD スケジューリングの決定に POD の優先順位を含める	94
2.10. ノードセクターの使用による特定ノードへの POD の配置	98
第3章 CUSTOM METRICS AUTOSCALER OPERATOR を使用した POD の自動スケーリング	103
3.1. リリースノート	103
3.2. CUSTOM METRICS AUTOSCALER OPERATOR の概要	113
3.3. カスタムメトリクスオートスケーラーのインストール	115
3.4. カスタムメトリクスオートスケーラートリガーについて	119
3.5. カスタムメトリクスオートスケーラートリガー認証について	130
3.6. カスタムメトリクスオートスケーラーの追加方法について	138
3.7. スケーリングされたオブジェクトのカスタムメトリクスオートスケーラーの一時停止	146
3.8. 監査ログの収集	147
3.9. デバッグデータの収集	151
3.10. OPERATOR メトリクスの表示	154
3.11. CUSTOM METRICS AUTOSCALER OPERATOR の削除	155
第4章 POD のノードへの配置の制御 (スケジューリング)	158
4.1. スケジューラーによる POD 配置の制御	158
4.2. スケジューラープロファイルを使用した POD のスケジューリング	160
4.3. アフィニティルールとアンチアフィニティルールを使用して、他の POD を基準にして POD を配置する	161
4.4. ノードのアフィニティルールを使用してノードへの POD の配置を制御する	171
4.5. POD のオーバーコミットノードへの配置	181
4.6. ノード TAINT を使用した POD 配置の制御	182
4.7. ノードセクターの使用による特定ノードへの POD の配置	197
4.8. POD トポロジー分散制約を使用した POD 配置の制御	212
4.9. DESCHEDULER を使用した POD のエビクト	216
4.10. セカンダリースケジューラー	224
第5章 ジョブと DAEMONSET の使用	232
5.1. デモンセットによるノード上でのバックグラウンドタスクの自動的な実行	232
5.2. ジョブの使用による POD でのタスクの実行	235
第6章 ノードの使用	243
6.1. OPENSIFT CONTAINER PLATFORM クラスター内のノードの閲覧とリスト表示	243
6.2. ノードの使用	249
6.3. ノードの管理	255

6.4. ノードあたりの POD の最大数の管理	266
6.5. NODE TUNING OPERATOR の使用	269
6.6. ノードの修復、フェンシング、メンテナンス	277
6.7. ノードの再起動について	277
6.8. ガベージコレクションを使用しているノードリソースの解放	281
6.9. OPENSIFT CONTAINER PLATFORM クラスター内のノードへのリソース割り当て	286
6.10. クラスター内のノードに特定の CPU を割り当てる	293
6.11. KUBELET の TLS セキュリティプロファイルの有効化	294
6.12. MACHINE CONFIG DAEMON メトリック	298
6.13. インフラストラクチャーノードの作成	301
第7章 コンテナの使用	305
7.1. コンテナについて	305
7.2. POD のデプロイ前の、INIT コンテナの使用によるタスクの実行	306
7.3. ボリュームの使用によるコンテナデータの永続化	309
7.4. PROJECTED ボリュームによるボリュームのマッピング	321
7.5. コンテナによる API オブジェクト使用の許可	329
7.6. OPENSIFT CONTAINER PLATFORM コンテナへの/からのファイルのコピー	338
7.7. OPENSIFT CONTAINER PLATFORM コンテナでのリモートコマンドの実行	340
7.8. コンテナ内のアプリケーションにアクセスするためのポート転送の使用	342
7.9. コンテナでの SYSCTL の使用	344
第8章 クラスターの操作	359
8.1. OPENSIFT CONTAINER PLATFORM クラスター内のシステムイベント情報の表示	359
8.2. OPENSIFT CONTAINER PLATFORM のノードが保持できる POD の数の見積り	368
8.3. 制限範囲によるリソース消費の制限	374
8.4. コンテナメモリーとリスク要件を満たすためのクラスターメモリーの設定	382
8.5. オーバーコミットされたノード上に POD を配置するためのクラスターの設定	389
8.6. LINUX コントロールグループバージョン 2(CGROUP V2)の有効化	404
8.7. フィーチャーゲートを使用した機能の有効化	408
8.8. ワーカーレイテンシープロファイルを使用したレイテンシーの高い環境でのクラスターの安定性の向上	415
第9章 ネットワークエッジ上にあるリモートワーカーノード	421
9.1. ネットワークエッジでのリモートワーカーノードの使用	421
第10章 シングルノード OPENSIFT クラスター用のワーカーノード	430
10.1. 単一ノードの OPENSIFT クラスターへのワーカーノードの追加	430

第1章 ノードの概要

1.1. ノードについて

ノードは、Kubernetes クラスター内の仮想マシンまたはベアメタルマシンです。ワーカーノードは、Pod としてグループ化されたアプリケーションコンテナをホストします。コントロールプレーンノードは、Kubernetes クラスターを制御するために必要なサービスを実行します。OpenShift Container Platform では、コントロールプレーンノードには、OpenShift Container Platform クラスターを管理するための Kubernetes サービス以上のものが含まれています。

クラスター内に安定した正常なノードを持つことは、ホストされたアプリケーションがスムーズに機能するための基本です。OpenShift Container Platform では、ノードを表す Node オブジェクトを介して **Node** にアクセス、管理、およびモニターできます。OpenShift CLI (**oc**) または Web コンソールを使用して、ノードで以下の操作を実行できます。

ノードの次のコンポーネントは、Pod の実行を維持し、Kubernetes ランタイム環境を提供するロールを果たします。

コンテナランタイム

コンテナランタイムはコンテナの実行を担当します。OpenShift Container Platform は、クラスター内の各 Red Hat Enterprise Linux CoreOS (RHCOS) ノードに CRI-O コンテナランタイムをデプロイします。Windows Machine Config Operator (WMCO) は、Windows ノードに containerd ランタイムをデプロイします。

Kubelet

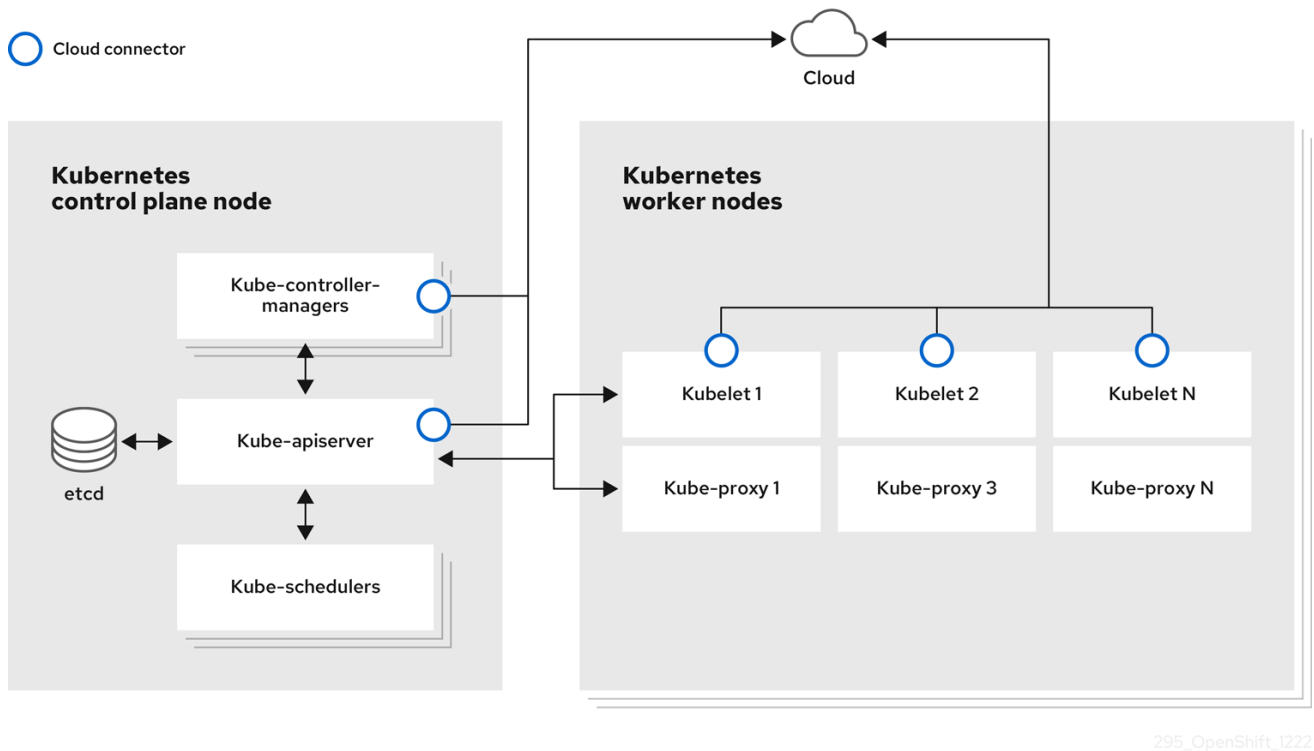
Kubelet はノード上で実行され、コンテナマニフェストを読み取ります。定義されたコンテナが開始され、実行されていることを確認します。kubelet プロセスは、作業の状態とノードサーバーを維持します。Kubelet は、ネットワークルールとポートフォワーディングを管理します。kubelet は、Kubernetes によってのみ作成されたコンテナを管理します。

Kube-proxy

Kube-proxy は、クラスター内のすべてのノードで実行され、Kubernetes リソース間のネットワークトラフィックを維持します。Kube-proxy は、ネットワーク環境の分離を実現するとともに、アクセス可能性を確保します。

DNS

クラスター DNS は、Kubernetes サービスの DNS レコードを提供する DNS サーバーです。Kubernetes により開始したコンテナは、DNS 検索にこの DNS サーバーを自動的に含めます。



295_OpenShift_1222

読み取り操作

読み取り操作により、管理者または開発者は OpenShift Container Platform クラスター内のノードに関する情報を取得できます。

- クラスター内のすべてのノードを一覧表示します。
- メモリーと CPU の使用率、ヘルス、ステータス、経過時間など、ノードに関する情報を取得します。
- ノードで実行されている Pod を一覧表示します。

管理操作

管理者は、次のいくつかのタスクを通じて、OpenShift Container Platform クラスター内のノードを簡単に管理できます。

- ノードラベルを追加または更新します。ラベルは、**Node** オブジェクトに適用されるキーと値のペアです。ラベルを使用して Pod のスケジュールを制御できます。
- カスタムリソース定義 (CRD) または **kubeletConfig** オブジェクトを使用してノード設定を変更します。
- Pod のスケジューリングを許可または禁止するようにノードを設定します。**Ready** ステータスの正常なワーカーノードでは、デフォルトで Pod の配置が許可されますが、コントロールプレーンノードでは許可されません。このデフォルトの動作は、**ワーカーノードをスケジュール不可に設定し、コントロールプレーンノードをスケジュール可能に** 設定することで変更できます。
- システム予約 設定を使用して、**ノードにリソースを割り当てます**。OpenShift Container Platform がノードに最適な **system-reserved** CPU およびメモリーリソースを自動的に決定できるようにするか、ノードに最適なリソースを手動で決定および設定することができます。
- ノード上のプロセッサコアの数、ハードリミット、またはその両方に基づいて **ノード上で実行できる Pod の数を設定** します。

- [pod anti-affinity](#) を使用してノードを正常に再起動します。
- コンピュートマシンセットを使用してクラスターをスケールダウンすることにより、[クラスターからノードを削除します](#)。ベアメタルクラスターからノードを削除するには、最初にノード上のすべての Pod をドレインしてから、手動でノードを削除する必要があります。

エンハンスメント操作

OpenShift Container Platform を使用すると、ノードへのアクセスと管理以上のことができます。管理者は、ノードで次のタスクを実行して、クラスターをより効率的でアプリケーションに適したものにし、開発者により良い環境を提供できます。

- [Node Tuning Operator](#) を使用して、ある程度のカーネルチューニングを必要とする高性能アプリケーションのノードレベルのチューニングを管理します。
- ノードで TLS セキュリティプロファイルを有効にして、kubelet と Kubernetes API サーバー間の通信を保護します。
- [デーモンセット](#)を使用して、ノードでバックグラウンドタスクを自動的に実行します。デーモンセットを作成して使用し、共有ストレージを作成したり、すべてのノードでロギング Pod を実行したり、すべてのノードに監視エージェントをデプロイしたりできます。
- [ガベージコレクション](#)を使用してノードリソースを解放します。終了したコンテナと、実行中の Pod によって参照されていないイメージを削除することで、ノードが効率的に実行されていることを確認できます。
- [ノードのセットにカーネル引数を追加します](#)。
- ネットワークエッジにワーカーノード (リモートワーカーノード) を持つように OpenShift Container Platform クラスターを設定します。OpenShift Container Platform クラスターにリモートワーカーノードを配置する際の課題と、リモートワーカーノードで Pod を管理するための推奨されるアプローチは、[ネットワークエッジでのリモートワーカーノードの使用](#) を参照してください。

1.2. POD について

Pod は、ノードと一緒にデプロイされる 1 つ以上のコンテナです。クラスター管理者は、Pod を定義し、スケジューリングの準備ができている正常なノードで実行するように割り当て、管理することができます。コンテナが実行されている限り、Pod は実行されます。Pod を定義して実行すると、Pod を変更することはできません。Pod を操作するときに行える操作は次のとおりです。

読み取り操作

管理者は、次のタスクを通じてプロジェクト内の Pod に関する情報を取得できます。

- レプリカと再起動の数、現在のステータス、経過時間などの情報を含む、[プロジェクトに関連付けられている Pod を一覧表示](#) します。
- CPU、メモリー、ストレージ消費量などの [Pod 使用状況の統計を表示](#) します。

管理操作

以下のタスクのリストは、管理者が OpenShift Container Platform クラスターで Pod を管理する方法の概要を示しています。

- OpenShift Container Platform で利用可能な高度なスケジューリング機能を使用して、Pod のスケジューリングを制御します。

- Pod アフィニティー、ノードアフィニティー、アンチアフィニティーなどのノードと Pod 間のバインディングルール。
- ノードラベルとセレクター。
- taint および toleration。
- Pod トポロジー分散制約。
- 二次スケジューリング。
- スケジューラーが Pod をより適切なノードに再スケジューリングできるように、特定の戦略に基づいて Pod を削除するように descheduler を設定します。
- Pod コントローラーと再起動ポリシーを使用して、再起動後の Pod の動作を設定します。
- Pod で送信トラフィックと受信トラフィックの両方を制限します。
- Pod テンプレートを持つ任意のオブジェクトにボリュームを追加および削除します。ボリュームは、Pod 内のすべてのコンテナで使用できるマウントされたファイルシステムです。コンテナストレージは一時的なものです。ボリュームを使用すると、コンテナデータを永続化できます。

エンハンスメント操作

OpenShift Container Platform で利用可能なさまざまなツールと機能を使用して、Pod をより簡単かつ効率的に操作できます。次の操作では、これらのツールと機能を使用して Pod をより適切に管理します。

操作	ユーザー	詳細情報
Horizontal Pod Autoscaler を作成して使用。	開発者	Horizontal Pod Autoscaler を使用して、実行する Pod の最小数と最大数、および Pod がターゲットとする CPU 使用率またはメモリ使用率を指定できます。Horizontal Pod Autoscaler を使用すると、Pod を自動的にスケーリングできます。
垂直 Pod オートスケーラーをインストールして使用します。	管理者および開発者	<p>管理者は、垂直 Pod オートスケーラーを使用して、リソースとワークロードのリソース要件を監視することにより、クラスターリソースをより適切に使用します。</p> <p>開発者は、垂直 Pod オートスケーラーを使用して、各 Pod に十分なリソースがあるノードに Pod をスケジューリングすることにより、需要が高い時に Pod が稼働し続けるようにします。</p>

操作	ユーザー	詳細情報
デバイスプラグインを使用して外部リソースへのアクセスを提供。	管理者	デバイスプラグイン は、ノード (kubelet の外部) で実行される gRPC サービスであり、特定のハードウェアリソースを管理します。 デバイスプラグインをデプロイ して、クラスター間でハードウェアデバイスを使用するための一貫性のある移植可能なソリューションを提供できます。
Secret オブジェクト を使用して Pod に機密データを提供します。	管理者	一部のアプリケーションでは、パスワードやユーザー名などの機密情報が必要です。 Secret オブジェクト を使用して、そのような情報をアプリケーション Pod に提供できます。

1.3. コンテナについて

コンテナは、OpenShift Container Platform アプリケーションの基本ユニットであり、依存関係、ライブラリー、およびバイナリーとともにパッケージ化されたアプリケーションコードで構成されます。コンテナは、複数の環境、および物理サーバー、仮想マシン (VM)、およびプライベートまたはパブリッククラウドなどの複数のデプロイメントターゲット間に一貫性をもたらします。

Linux コンテナテクノロジーは、実行中のプロセスを分離し、指定されたリソースのみへのアクセスを制限するための軽量メカニズムです。管理者は、Linux コンテナで次のようなさまざまなタスクを実行できます。

- [コンテナとの間でファイルをコピーします。](#)
- [コンテナが API オブジェクトを使用できるようにします。](#)
- [コンテナでリモートコマンドを実行します。](#)
- [コンテナ内のアプリケーションにアクセスするには、ポートフォワーディングを使用します。](#)

OpenShift Container Platform は、[Init コンテナ](#) と呼ばれる特殊なコンテナを提供します。Init コンテナは、アプリケーションコンテナの前に実行され、アプリケーションイメージに存在しないユーティリティまたはセットアップスクリプトを含めることができます。Pod の残りの部分がデプロイされる前に、Init コンテナを使用してタスクを実行できます。

ノード、Pod、およびコンテナで特定のタスクを実行する以外に、OpenShift Container Platform クラスター全体を操作して、クラスターの効率とアプリケーション Pod の高可用性を維持できます。

1.4. ノードでの POD の自動スケーリング

OpenShift Container Platform には、ノード上の Pod の数と Pod に割り当てられたリソースの自動スケーリングに使用できる 3 つのツールがあります。

Horizontal Pod Autoscaler

Horizontal Pod Autoscaler (HPA) は、レプリケーションコントローラーまたはデプロイメント設定のスケールを、そのレプリケーションコントローラーまたはデプロイメント設定に属する Pod から収集されたメトリクスに基づき自動的に増減できます。

詳細は、[Horizontal Pod Autoscaler を使用した Pod の自動スケーリング](#) を参照してください。

カスタムメトリクスオートスケーラー

カスタムメトリクスオートスケーラーは、CPU やメモリーに基づくだけではないカスタムメトリクスに基づき、デプロイメント、ステートフルセット、カスタムリソース、またはジョブの Pod 数を自動的に増減できます。

詳細は、[Custom Metrics Autoscaler Operator の概要](#) を参照してください。

Vertical Pod Autoscaler

Vertical Pod Autoscaler (VPA) は、Pod 内のコンテナの履歴および現在の CPU とメモリーリソースを自動的に確認し、確認された使用値に基づいてリソース制限および要求を更新できます。

詳細は、[vertical pod autoscaler を使用した Pod リソースレベルの自動調整](#) を参照してください。

1.5. OPENSIFT CONTAINER PLATFORM のノードの一般用語集

この用語集では、ノードのコンテンツで使用される一般的な用語を定義しています。

コンテナ

これは、ソフトウェアとそのすべての依存関係を構成する軽量で実行可能なイメージです。コンテナはオペレーティングシステムを仮想化するため、データセンターからパブリックまたはプライベートクラウド、さらには開発者のラップトップまで、どこでもコンテナを実行できます。

デーモンセット

Pod のレプリカが OpenShift Container Platform クラスター内の対象となるノードで実行されるようにします。

egress

Pod からのネットワークのアウトバウンドトラフィックを介して外部とデータを共有するプロセス。

ガベージコレクション

終了したコンテナや実行中の Pod によって参照されていないイメージなどのクラスターリソースをクリーンアップするプロセス。

Horizontal Pod Autoscaler (HPA)

Kubernetes API リソースおよびコントローラーとして実装されます。HPA を使用して、実行する Pod の最小数と最大数を指定できます。Pod がターゲットとする CPU またはメモリーの使用率を指定することもできます。HPA は、特定の CPU またはメモリーのしきい値を超えると、Pod をスケールアウトおよびスケールインします。

Ingress

Pod への着信トラフィック。

ジョブ

完了するまで実行されるプロセス。ジョブは1つ以上の Pod オブジェクトを作成し、指定された Pod が正常に完了するようにします。

ラベル

キーと値のペアであるラベルを使用して、Pod などのオブジェクトのサブセットを整理および選択できます。

Node

OpenShift Container Platform クラスター内のワーカーマシン。ノードは、仮想マシン (VM) または物理マシンのいずれかになります。

Node Tuning Operator

Node Tuning Operator を使用すると、TuneD デーモンを使用してノードレベルのチューニングを管理できます。これにより、カスタムチューニング仕様が、デーモンが認識する形式でクラスターで実行されるすべてのコンテナ化された TuneD デーモンに渡されます。デーモンは、ノードごとに 1 つずつ、クラスターのすべてのノードで実行されます。

Self Node Remediation Operator

Operator はクラスターノードで実行され、異常なノードを特定して再起動します。

Pod

OpenShift Container Platform クラスターで実行されている、ボリュームや IP アドレスなどの共有リソースを持つ 1 つ以上のコンテナ。Pod は、定義、デプロイ、および管理される最小のコンピュータ単位です。

toleration

taint が一致するノードまたはノードグループで Pod をスケジュールできる (必須ではない) ことを示します。toleration を使用して、スケジューラーが一致する taint を持つ Pod をスケジュールできるようにすることができます。

taint

キー、値、および Effect で構成されるコアオブジェクト。taint と toleration が連携して、Pod が無関係なノードでスケジュールされないようにします。

第2章 POD の使用

2.1. POD の使用

Pod は1つのホストにデプロイされる1つ以上のコンテナであり、定義され、デプロイされ、管理される最小のコンピュータ単位です。

2.1.1. Pod について

Pod はコンテナに対してマシンインスタンス (物理または仮想) とほぼ同じ機能を持ちます。各 Pod は独自の内部 IP アドレスで割り当てられるため、そのポートスペース全体を所有し、Pod 内のコンテナはそれらのローカルストレージおよびネットワークを共有できます。

Pod にはライフサイクルがあります。それらは定義された後にノードで実行されるために割り当てられ、コンテナが終了するまで実行されるか、その他の理由でコンテナが削除されるまで実行されます。ポリシーおよび終了コードによっては、Pod は終了後に削除されるか、コンテナのログへのアクセスを有効にするために保持される可能性があります。

OpenShift Container Platform は Pod をほとんどがイミュータブルなものとして処理します。Pod が実行中の場合は Pod に変更を加えることができません。OpenShift Container Platform は既存 Pod を終了し、これを変更された設定、ベースイメージのいずれかまたはその両方で再作成して変更を実装します。Pod は拡張可能なものとしても処理されますが、再作成時に状態を維持しません。そのため、Pod はユーザーが直接管理するのではなく、通常は上位レベルのコントローラーによって管理される必要があります。



注記

OpenShift Container Platform ノードホストごとの Pod の最大数については、クラスターの制限を参照してください。



警告

レプリケーションコントローラーによって管理されないベア Pod はノードの中断時に再スケジュールされません。

2.1.2. Pod 設定の例

OpenShift Container Platform は、**Pod** の Kubernetes の概念を活用しています。これはホスト上に共にデプロイされる1つ以上のコンテナであり、定義され、デプロイされ、管理される最小のコンピュータ単位です。

以下は、Rails アプリケーションからの Pod の定義例です。これは数多くの Pod の機能を示していますが、それらのほとんどは他のトピックで説明されるため、ここではこれらについて簡単に説明します。

Pod オブジェクト定義 (YAML)

```
kind: Pod
apiVersion: v1
metadata:
```

```

name: example
namespace: default
selfLink: /api/v1/namespaces/default/pods/example
uid: 5cc30063-0265780783bc
resourceVersion: '165032'
creationTimestamp: '2019-02-13T20:31:37Z'
labels:
  app: hello-openshift ❶
annotations:
  openshift.io/scc: anyuid
spec:
  restartPolicy: Always ❷
  serviceAccountName: default
  imagePullSecrets:
    - name: default-dockercfg-5zrhb
  priority: 0
  schedulerName: default-scheduler
  terminationGracePeriodSeconds: 30
  nodeName: ip-10-0-140-16.us-east-2.compute.internal
  securityContext: ❸
    seLinuxOptions:
      level: 's0:c11,c10'
  containers: ❹
    - resources: {}
      terminationMessagePath: /dev/termination-log
      name: hello-openshift
      securityContext:
        capabilities:
          drop:
            - MKNOD
        procMount: Default
      ports:
        - containerPort: 8080
          protocol: TCP
      imagePullPolicy: Always
      volumeMounts: ❺
        - name: default-token-wbqsl
          readOnly: true
          mountPath: /var/run/secrets/kubernetes.io/serviceaccount ❻
      terminationMessagePolicy: File
      image: registry.redhat.io/openshift4/ose-logging-eventrouter:v4.3 ❼
  serviceAccount: default ❽
  volumes: ❾
    - name: default-token-wbqsl
      secret:
        secretName: default-token-wbqsl
        defaultMode: 420
  dnsPolicy: ClusterFirst
status:
  phase: Pending
  conditions:
    - type: Initialized
      status: 'True'
      lastProbeTime: null
      lastTransitionTime: '2019-02-13T20:31:37Z'

```

```

- type: Ready
  status: 'False'
  lastProbeTime: null
  lastTransitionTime: '2019-02-13T20:31:37Z'
  reason: ContainersNotReady
  message: 'containers with unready status: [hello-openshift]'
- type: ContainersReady
  status: 'False'
  lastProbeTime: null
  lastTransitionTime: '2019-02-13T20:31:37Z'
  reason: ContainersNotReady
  message: 'containers with unready status: [hello-openshift]'
- type: PodScheduled
  status: 'True'
  lastProbeTime: null
  lastTransitionTime: '2019-02-13T20:31:37Z'
hostIP: 10.0.140.16
startTime: '2019-02-13T20:31:37Z'
containerStatuses:
- name: hello-openshift
  state:
    waiting:
      reason: ContainerCreating
  lastState: {}
  ready: false
  restartCount: 0
  image: openshift/hello-openshift
  imageID: "
qosClass: BestEffort

```

- 1 Pod には1つまたは複数のラベルで "タグ付け" することができ、このラベルを使用すると、一度の操作で Pod グループの選択や管理が可能になります。これらのラベルは、キー/値形式で **metadata** ハッシュに保存されます。
- 2 Pod 再起動ポリシーと使用可能な値の **Always**、**OnFailure**、および **Never** です。デフォルト値は **Always** です。
- 3 OpenShift Container Platform は、コンテナが特権付きコンテナとして実行されるか、選択したユーザーとして実行されるかどうかを指定するセキュリティーコンテキストを定義します。デフォルトのコンテキストには多くの制限がありますが、管理者は必要に応じてこれを変更できます。
- 4 **containers** は、1つ以上のコンテナ定義の配列を指定します。
- 5 コンテナは外部ストレージボリュームがコンテナ内にマウントされるかどうかを指定します。この場合、OpenShift Container Platform API に対して要求を行うためにレジストリーが必要とする認証情報へのアクセスを保存するためにボリュームがあります。
- 6 Pod に提供するボリュームを指定します。ボリュームは指定されたパスにマウントされます。コンテナのルート (/) や、ホストとコンテナで同じパスにはマウントしないでください。これは、コンテナに十分な特権が付与されている場合に、ホストシステムを破壊する可能性があります (例: ホストの **/dev/pts** ファイル)。ホストをマウントするには、**/host** を使用するのが安全です。
- 7 Pod 内の各コンテナは、独自のコンテナイメージからインスタンス化されます。

- 8 OpenShift Container Platform API に対して要求する Pod は一般的なパターンです。この場合、**serviceAccount** フィールドがあり、これは要求を行う際に Pod が認証する必要のあるサービスアカウントトークンを含む **secret** ボリュームのエフェメラルボリュームを提供します。
- 9 Pod は、コンテナで使用するストレージボリュームを定義します。この場合、デフォルトのサービスアカウントトークンを含む **secret** ボリュームのエフェメラルボリュームを提供します。

ファイル数が多い永続ボリュームを Pod に割り当てる場合、それらの Pod は失敗するか、起動に時間がかかる場合があります。詳細は、[When using Persistent Volumes with high file counts in OpenShift, why do pods fail to start or take an excessive amount of time to achieve "Ready" state?](#) を参照してください。



注記

この Pod 定義には、Pod が作成され、ライフサイクルが開始された後に OpenShift Container Platform によって自動的に設定される属性が含まれません。[Kubernetes Pod ドキュメント](#) には、Pod の機能および目的の詳細が記載されています。

2.1.3. リソース要求および制限について

Pod の仕様 (「Pod 設定の例」を参照) または Pod の制御オブジェクトの仕様を使用すると、Pod の CPU およびメモリーの要求と制限を指定できます。

CPU およびメモリーの **要求** は、Pod の実行に必要なリソースの最小量を指定するものです。これは、OpenShift Container Platform が十分なリソースを持つノードに Pod をスケジューリングするのに役立ちます。

CPU とメモリーの **制限** は、Pod が消費できるリソースの最大量を定義するものです。これは、Pod がリソースを過剰に消費して同じノード上の他の Pod に影響を与える可能性を防ぎます。

CPU およびメモリーの要求と制限は、次の原則に従って処理されます。

- CPU 制限は、CPU スロットリングを使用して適用されます。コンテナが CPU 制限に近づくと、コンテナの制限として指定された CPU へのアクセスをカーネルが制限します。したがって、CPU 制限はカーネルによって適用されるハード制限です。OpenShift Container Platform では、コンテナが CPU 制限を長時間超過することが許される場合があります。ただし、コンテナランタイムは、CPU 使用率が高すぎる場合でも Pod またはコンテナを終了しません。

CPU の制限と要求は CPU 単位で測定されます。1つの CPU ユニットの、ノードが物理ホストであるか、物理マシン内で実行されている仮想マシンであるかに応じて、1つの物理 CPU コアまたは1つの仮想コアに相当します。小数の要求も許可されます。たとえば、CPU 要求を **0.5** にしてコンテナを定義すると、**1.0 CPU** を要求した場合の半分の CPU 時間を要求することになります。CPU ユニットの単位、**0.1** は **100m** に相当します。これは **100 millicpu** または **100 ミリコア** として読み取られます。CPU リソースは常に絶対的なリソース量であり、相対的な量ではありません。



注記

デフォルトでは、Pod に割り当てることができる CPU の最小量は 10 mCPU です。Pod の仕様では、10 mCPU 未満のリソース制限を要求できます。その場合も、Pod には 10 mCPU が割り当てられます。

- メモリー制限は、カーネルにより、Out of Memory (OOM) による強制終了を使用して適用されます。コンテナがメモリー制限を超えるメモリーを使用する場合、カーネルはそのコンテナを終了できます。ただし、終了はカーネルがメモリーの逼迫を検出した場合にのみ実行さ

れます。そのため、メモリーを過剰に割り当てるコンテナがすぐに強制終了されないことがあります。つまり、メモリー制限はリアクティブに適用されます。コンテナはメモリー制限を超えるメモリーを使用することがあります。その場合、コンテナが強制終了される可能性があります。

メモリーは、数量を表す **E**、**P**、**T**、**G**、**M**、または **k** のいずれかの接尾辞を使用して、単純な整数または固定小数点数として表すことができます。対応する 2 のべき乗の単位 (**Ei**、**Pi**、**Ti**、**Gi**、**Mi**、または **Ki**) を使用することもできます。

Pod が実行されているノードに十分なリソースがある場合、コンテナは要求よりも多くの CPU またはメモリーリソースを使用する可能性があります。ただし、コンテナは対応する制限を超えることはできません。たとえば、コンテナのメモリー要求を **256 MiB** に設定し、そのコンテナが **8GiB** のメモリーを持つノードにスケジュールされた Pod 内にあり、そのノードに他の Pod がない場合、コンテナは要求された **256 MiB** より多くのメモリーを使用しようとする可能性があります。

この動作は CPU およびメモリーの制限には適用されません。CPU およびメモリーの制限は、kubelet とコンテナランタイムによって適用され、カーネルによって強制されます。Linux ノードでは、カーネルが cgroups を使用して制限を適用します。

Linux ワークロードの場合、huge page リソースを指定できます。huge page は Linux 固有の機能です。この機能が有効な場合、ノードのカーネルが、デフォルトのページサイズよりもはるかに大きいメモリーブロックを割り当てます。たとえば、デフォルトのページサイズが 4 KiB のシステムで、より大きな制限を指定できます。huge page の詳細は、「huge page」を参照してください。

2.1.4. 関連情報

- Pod とストレージの詳細については、[Understanding persistent storage](#) と [Understanding ephemeral storage](#) を参照してください。
- [Pod 設定の例](#)
- [huge page](#)

2.2. POD の表示

管理者として、クラスターで Pod を表示し、それらの Pod および全体としてクラスターの正常性を判断することができます。

2.2.1. Pod について

OpenShift Container Platform は、**Pod** の Kubernetes の概念を活用しています。これはホスト上に共にデプロイされる 1 つ以上のコンテナであり、定義され、デプロイされ、管理される最小のコンピュート単位です。Pod はコンテナに対するマシンインスタンス (物理または仮想) とほぼ同等のものです。

特定のプロジェクトに関連付けられた Pod のリストを表示したり、Pod に関する使用状況の統計を表示したりすることができます。

2.2.2. プロジェクトでの Pod の表示

レプリカの数、Pod の現在のステータス、再起動の数および年数を含む、現在のプロジェクトに関連付けられた Pod のリストを表示できます。

手順

プロジェクトで Pod を表示するには、以下を実行します。

1. プロジェクトに切り替えます。

```
$ oc project <project-name>
```

2. 以下のコマンドを実行します。

```
$ oc get pods
```

以下に例を示します。

```
$ oc get pods
```

出力例

```
NAME                                READY STATUS RESTARTS AGE
console-698d866b78-bnshf 1/1   Running 2      165m
console-698d866b78-m87pm 1/1   Running 2      165m
```

-o wide フラグを追加して、Pod の IP アドレスと Pod があるノードを表示します。

```
$ oc get pods -o wide
```

出力例

```
NAME                                READY STATUS RESTARTS AGE IP      NODE
NOMINATED NODE
console-698d866b78-bnshf 1/1   Running 2      166m 10.128.0.24 ip-10-0-152-
71.ec2.internal <none>
console-698d866b78-m87pm 1/1   Running 2      166m 10.129.0.23 ip-10-0-173-
237.ec2.internal <none>
```

2.2.3. Pod の使用状況に関する統計の表示

コンテナのランタイム環境を提供する、Pod に関する使用状況の統計を表示できます。これらの使用状況の統計には CPU、メモリー、およびストレージの消費量が含まれます。

前提条件

- 使用状況の統計を表示するには、**cluster-reader** 権限が必要です。
- 使用状況の統計を表示するには、メトリクスをインストールしている必要があります。

手順

使用状況の統計を表示するには、以下を実行します。

1. 以下のコマンドを実行します。

```
$ oc adm top pods
```

以下に例を示します。

```
$ oc adm top pods -n openshift-console
```

出力例

NAME	CPU(cores)	MEMORY(bytes)
console-7f58c69899-q8c8k	0m	22Mi
console-7f58c69899-xhbgg	0m	25Mi
downloads-594fccf94-bcwk8	3m	18Mi
downloads-594fccf94-kv4p6	2m	15Mi

- ラベルを持つ Pod の使用状況の統計を表示するには、以下のコマンドを実行します。

```
$ oc adm top pod --selector=
```

フィルターに使用するセレクター (ラベルクエリー) を選択する必要があります。=、==、および != をサポートします。

以下に例を示します。

```
$ oc adm top pod --selector='name=my-pod'
```

2.2.4. リソースログの表示

OpenShift CLI (**oc**) および Web コンソールでさまざまなリソースのログを表示できます。ログの末尾から読み取られるログ。

前提条件

- OpenShift CLI (**oc**) へのアクセスがある。

手順 (UI)

- OpenShift Container Platform コンソールで **Workloads** → **Pods** に移動するか、調査するリソースから Pod に移動します。



注記

ビルドなどの一部のリソースには、直接クエリーする Pod がありません。このような場合は、リソースの **Details** ページで **Logs** リンクを特定できます。

- ドロップダウンメニューからプロジェクトを選択します。
- 調査する Pod の名前をクリックします。
- Logs** をクリックします。

手順 (CLI)

- 特定の Pod のログを表示します。

```
$ oc logs -f <pod_name> -c <container_name>
```

ここでは、以下ようになります。

-f

オプション: ログに書き込まれている内容に沿って出力することを指定します。

<pod_name>

Pod の名前を指定します。

<container_name>

オプション: コンテナの名前を指定します。Pod に複数のコンテナがある場合は、コンテナ名を指定する必要があります。

以下に例を示します。

```
$ oc logs ruby-58cd97df55-mww7r
```

```
$ oc logs -f ruby-57f7f4855b-znl92 -c ruby
```

ログファイルの内容が出力されます。

- 特定のリソースのログを表示します。

```
$ oc logs <object_type>/<resource_name> 1
```

1 リソースタイプおよび名前を指定します。

以下に例を示します。

```
$ oc logs deployment/ruby
```

ログファイルの内容が出力されます。

2.3. OPENSIFT CONTAINER PLATFORM クラスターでの POD の設定

管理者として、Pod に対して効率的なクラスターを作成し、維持することができます。

クラスターの効率性を維持することにより、1回のみ実行するように設計された Pod をいつ再起動するか、Pod が利用できる帯域幅をいつ制限するか、中断時に Pod をどのように実行させ続けるかなど、Pod が終了するときの動作をツールとして使用して必要な数の Pod が常に実行されるようにし、開発者により良い環境を提供することができます。

2.3.1. 再起動後の Pod の動作方法の設定

Pod 再起動ポリシーは、Pod のコンテナの終了時に OpenShift Container Platform が応答する方法を決定します。このポリシーは Pod のすべてのコンテナに適用されます。

以下の値を使用できます。

- **Always** - Pod で正常に終了したコンテナの再起動を継続的に試みます。指数関数的なバックオフ遅延 (10 秒、20 秒、40 秒) は 5 分に制限されています。デフォルトは **Always** です。
- **OnFailure**: Pod で失敗したコンテナの継続的な再起動を、5 分を上限として指数関数のバックオフ遅延 (10 秒、20 秒、40 秒) で試行します。

- **Never**: Pod で終了したコンテナまたは失敗したコンテナの再起動を試行しません。Pod はただちに失敗し、終了します。

いったんノードにバインドされた Pod は別のノードにはバインドされなくなります。これは、Pod がノードの失敗後も存続するにはコントローラーが必要であることを示しています。

条件	コントローラーのタイプ	再起動ポリシー
終了することが期待される Pod (バッチ計算など)	ジョブ	OnFailure または Never
終了しないことが期待される Pod (Web サーバーなど)	レプリケーションコントローラー	Always
マシンごとに1回実行される Pod	デーモンセット	すべて

Pod のコンテナが失敗し、再起動ポリシーが **OnFailure** に設定される場合、Pod はノード上に留まり、コンテナが再起動します。コンテナを再起動させない場合には、再起動ポリシーの **Never** を使用します。

Pod 全体が失敗すると、OpenShift Container Platform は新規 Pod を起動します。開発者は、アプリケーションが新規 Pod で再起動される可能性に対応しなくてはなりません。とくに、アプリケーションは、一時的なファイル、ロック、以前の実行で生じた未完成の出力などを処理する必要があります。

注記

Kubernetes アーキテクチャーでは、クラウドプロバイダーからの信頼性のあるエンドポイントが必要です。クラウドプロバイダーが停止している場合、kubelet は OpenShift Container Platform が再起動されないようにします。

基礎となるクラウドプロバイダーのエンドポイントに信頼性がない場合は、クラウドプロバイダー統合を使用してクラスターをインストールしないでください。クラスターを、非クラウド環境で実行する場合のようにインストールします。インストール済みのクラスターで、クラウドプロバイダー統合をオンまたはオフに切り替えることは推奨されていません。

OpenShift Container Platform が失敗したコンテナで再起動ポリシーを使用する方法の詳細は、Kubernetes ドキュメントの [Example States](#) を参照してください。

2.3.2. Pod で利用可能な帯域幅の制限

Quality-of-Service (QoS) トラフィックシェーピングを Pod に適用し、その利用可能な帯域幅を効果的に制限することができます。(Pod からの) Egress トラフィックは、設定したレートを超えるパケットを単純にドロップするポリシングによって処理されます。(Pod への) Ingress トラフィックは、データを効果的に処理できるようにシェーピングでパケットをキューに入れて処理されます。Pod に設定する制限は、他の Pod の帯域幅には影響を与えません。

手順

Pod の帯域幅を制限するには、以下を実行します。

1. オブジェクト定義 JSON ファイルを作成し、[kubernetes.io/ingress-bandwidth](https://kubernetes.io/docs/concepts/containers/ingress-bandwidth) および [kubernetes.io/egress-bandwidth](https://kubernetes.io/docs/concepts/containers/egress-bandwidth) アノテーションを使用してデータトラフィックの速度を指定

します。たとえば、Pod の egress および ingress の両方の帯域幅を 10M/s に制限するには、以下を実行します。

制限が設定された Pod オブジェクト定義

```
{
  "kind": "Pod",
  "spec": {
    "containers": [
      {
        "image": "openshift/hello-openshift",
        "name": "hello-openshift"
      }
    ]
  },
  "apiVersion": "v1",
  "metadata": {
    "name": "iperf-slow",
    "annotations": {
      "kubernetes.io/ingress-bandwidth": "10M",
      "kubernetes.io/egress-bandwidth": "10M"
    }
  }
}
```

2. オブジェクト定義を使用して Pod を作成します。

```
$ oc create -f <file_or_dir_path>
```

2.3.3. 起動している必要がある Pod の数を Pod Disruption Budget を使用して指定する方法について

Pod Disruption Budget を使用すると、メンテナンスのためにノードの drain (Pod の退避) を実行するなど、運用中の Pod に対して安全上の制約を指定できます。

PodDisruptionBudget は、同時に起動している必要のあるレプリカの最小数またはパーセンテージを指定する API オブジェクトです。これらをプロジェクトに設定することは、ノードのメンテナンス (クラスターのスケールダウンまたはクラスターのアップグレードなどの実行) 時に役立ち、この設定は (ノードの障害時ではなく) 自発的なエビクションの場合にのみ許可されます。

PodDisruptionBudget オブジェクトの設定は、次の主要な部分で構成されます。

- 一連の Pod に対するラベルのクエリー機能であるラベルセクター。
- 同時に利用可能にする必要のある Pod の最小数を指定する可用性レベル。
 - **minAvailable** は、中断時にも常に利用可能である必要のある Pod 数です。
 - **maxUnavailable** は、中断時に利用不可にできる Pod 数です。



注記

Available は、**Ready=True** の状態にある Pod 数を指します。**Ready=True** は、要求に対応でき、一致するすべてのサービスの負荷分散プールに追加する必要がある Pod を指します。

maxUnavailable の **0%** または **0** あるいは **minAvailable** の **100%**、ないしはレプリカ数に等しい値は許可されますが、これによりノードがドレイン (解放) されないようにブロックされる可能性があります。

以下を実行して、Pod の Disruption Budget をすべてのプロジェクトで確認することができます。

```
$ oc get poddisruptionbudget --all-namespaces
```

出力例

NAMESPACE	NAME	MIN AVAILABLE	MAX UNAVAILABLE
ALLOWED DISRUPTIONS AGE			
openshift-apiserver 121m	openshift-apiserver-pdb	N/A 1	1
openshift-cloud-controller-manager 125m	aws-cloud-controller-manager	1 N/A	1
openshift-cloud-credential-operator 117m	pod-identity-webhook	1 N/A	1
openshift-cluster-csi-drivers 121m	aws-ebs-csi-driver-controller-pdb	N/A 1	1
openshift-cluster-storage-operator 122m	csi-snapshot-controller-pdb	N/A 1	1
openshift-cluster-storage-operator 122m	csi-snapshot-webhook-pdb	N/A 1	1
openshift-console 116m	console	N/A 1	1
#...			

PodDisruptionBudget は、最低でも **minAvailable** Pod がシステムで実行されている場合は正常であるとみなされます。この制限を超えるすべての Pod はエビクションの対象となります。



注記

Pod の優先度とプリエンプシヨンの設定によっては、Pod Disruption Budget の要件にもかかわらず、優先度の低い Pod が削除される可能性があります。

2.3.3.1. 起動している必要がある Pod の数を Pod Disruption Budget を使用して指定する

同時に起動している必要のあるレプリカの最小数またはパーセンテージは、**PodDisruptionBudget** オブジェクトを使用して指定します。

手順

Pod Disruption Budget を設定するには、次の手順を実行します。

1. YAML ファイルを以下のようなオブジェクト定義で作成します。

```
apiVersion: policy/v1 1
```

```
kind: PodDisruptionBudget
metadata:
  name: my-pdb
spec:
  minAvailable: 2 ❷
  selector: ❸
    matchLabels:
      name: my-pod
```

- ❶ **PodDisruptionBudget** は **policy/v1** API グループの一部です。
- ❷ 同時に利用可能である必要のある Pod の最小数。これには、整数またはパーセンテージ (例: **20%**) を指定する文字列を使用できます。
- ❸ 一連のリソースに対するラベルのクエリー。**matchLabels** と **matchExpressions** の結果は論理的に結合されます。プロジェクト内のすべての Pod を選択するには、このパラメーターを空白のままにします (例: **selector {}**)。

または、以下を実行します。

```
apiVersion: policy/v1 ❶
kind: PodDisruptionBudget
metadata:
  name: my-pdb
spec:
  maxUnavailable: 25% ❷
  selector: ❸
    matchLabels:
      name: my-pod
```

- ❶ **PodDisruptionBudget** は **policy/v1** API グループの一部です。
- ❷ 同時に利用不可にできる Pod の最大数。これには、整数またはパーセンテージ (例: **20%**) を指定する文字列を使用できます。
- ❸ 一連のリソースに対するラベルのクエリー。**matchLabels** と **matchExpressions** の結果は論理的に結合されます。プロジェクト内のすべての Pod を選択するには、このパラメーターを空白のままにします (例: **selector {}**)。

2. 以下のコマンドを実行してオブジェクトをプロジェクトに追加します。

```
$ oc create -f </path/to/file> -n <project_name>
```

2.3.4. Critical Pod の使用による Pod の削除の防止

クラスターを十分に機能させるために不可欠であるのに、マスターノードではなく通常のクラスターノードで実行される重要なコンポーネントは多数あります。重要なアドオンを退避すると、クラスターが正常に動作しなくなる可能性があります。

Critical とマークされている Pod は退避できません。

手順

Pod を Critical にするには、以下を実行します。

1. **Pod** 仕様を作成するか、既存の Pod を編集して **system-cluster-critical** 優先順位クラスを含めます。

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pdb
spec:
  template:
    metadata:
      name: critical-pod
      priorityClassName: system-cluster-critical ❶
```

- ❶ ノードから退避すべきではない Pod のデフォルトの優先順位クラス。

または、クラスターにとって重要だが、必要に応じて削除できる Pod に **system-node-critical** を指定することもできます。

2. Pod を作成します。

```
$ oc create -f <file-name>.yaml
```

2.3.5. ファイル数の多い永続ボリュームを使用する場合の Pod タイムアウトの短縮

ストレージボリュームに多くのファイル (~1,000,000 以上) が含まれている場合、Pod のタイムアウトが発生する可能性があります。

これは、ボリュームがマウントされると、Pod の **securityContext** で指定された **fsGroup** と一致するように、OpenShift Container Platform が各ボリュームのコンテンツの所有権とパーミッションを再帰的に変更するために発生する可能性があります。ボリュームが大きい場合、所有権とアクセス許可の確認と変更にかかる時間が長くなり、Pod の起動が非常に遅くなる可能性があります。

次の回避策のいずれかを適用することで、この遅延を減らすことができます。

- セキュリティコンテキスト制約 (SCC) を使用して、ボリュームの SELinux の再ラベル付けをスキップします。
- SCC 内の **fsGroupChangePolicy** フィールドを使用して、OpenShift Container Platform がボリュームの所有権とパーミッションをチェックおよび管理する方法を制御します。
- ランタイムクラスを使用して、ボリュームの SELinux 再ラベル付けをスキップします。

詳細は、[When using Persistent Volumes with high file counts in OpenShift, why do pods fail to start or take an excessive amount of time to achieve "Ready" state?](#) を参照してください。

2.4. HORIZONTAL POD AUTOSCALER での POD の自動スケーリング

開発者として、Horizontal Pod Autoscaler (HPA) を使用して、レプリケーションコントローラーに属する Pod から収集されるメトリクスまたはデプロイメント設定に基づき、OpenShift Container Platform がレプリケーションコントローラーまたはデプロイメント設定のスケールを自動的に増減する方法を指定できます。HPA は、任意のデプロイメント、デプロイメント設定、レプリカセット、レプリケーションコントローラー、またはステートフルセットに対して作成できます。

カスタムメトリクスに基づいて Pod をスケーリングする方法の詳細は、[カスタムメトリクスに基づいて Pod を自動的にスケーリングする](#) を参照してください。



注記

他のオブジェクトが提供する特定の機能や動作が必要な場合を除き、**Deployment** オブジェクトまたは **ReplicaSet** オブジェクトを使用することを推奨します。これらのオブジェクトの詳細については、[Understanding Deployment and DeploymentConfig objects](#) を参照してください。

2.4.1. Horizontal Pod Autoscaler について

Horizontal Pod Autoscaler を作成して、実行する Pod の最小数と最大数、および Pod がターゲットとする CPU 使用量またはメモリー使用量を指定できます。

Horizontal Pod Autoscaler を作成すると、OpenShift Container Platform は Pod 上の CPU またはメモリー、あるいはその両方のリソースメトリクスのクエリーを開始します。これらのメトリクスが利用可能な場合、Horizontal Pod Autoscaler は、現在のメトリクス使用量と意図したメトリクス使用量の比率を計算し、必要に応じてスケールアップまたはスケールダウンします。クエリーとスケーリングは一定間隔で実行されますが、メトリックが利用可能になるのに 1 分から 2 分の時間がかかる場合があります。

レプリケーションコントローラーの場合、このスケーリングはレプリケーションコントローラーのレプリカに直接対応します。デプロイメントの場合、スケーリングはデプロイメントのレプリカ数に直接対応します。自動スケーリングは **Complete** フェーズの最新デプロイメントにのみ適用されることに注意してください。

OpenShift Container Platform はリソースに自動的に対応し、起動時などのリソースの使用が急増した場合など必要のない自動スケーリングを防ぎます。**unready** 状態の Pod には、スケールアップ時の使用率が **0 CPU** と指定され、Autoscaler はスケールダウン時にはこれらの Pod を無視します。既知のメトリックのない Pod にはスケールアップ時の使用率が **0% CPU**、スケールダウン時に **100% CPU** となります。これにより、HPA の決定時に安定性が増します。この機能を使用するには、readiness チェックを設定して新規 Pod が使用可能であるかどうかを判別します。

Horizontal Pod Autoscaler を使用するには、クラスターの管理者はクラスターメトリックを適切に設定している必要があります。

以下のメトリックは Horizontal Pod Autoscaler でサポートされています。

表2.1サポートされるメトリック

メトリクス	説明	API バージョン
CPU の使用率	使用されている CPU コアの数。これを使用して、Pod が要求した CPU の割合を計算できます。	autoscaling/v1、autoscaling/v2
メモリーの使用率	使用されているメモリーの量。これを使用して、Pod が要求したメモリーの割合を計算できます。	autoscaling/v2

重要

メモリーベースの自動スケーリングでは、メモリー使用量がレプリカ数と比例して増減する必要があります。平均的には以下ようになります。

- レプリカ数が増えると、Pod ごとのメモリー (作業セット) の使用量が全体的に減少します。
- レプリカ数が減ると、Pod ごとのメモリー使用量が全体的に増加します。

OpenShift Container Platform Web コンソールを使用して、アプリケーションのメモリー動作を確認し、メモリーベースの自動スケーリングを使用する前にアプリケーションがそれらの要件を満たしていることを確認します。

以下の例は、**hello-node Deployment** オブジェクトの自動スケーリングを示しています。最初のデプロイメントでは3つの Pod が必要です。HPA オブジェクトは、最小値を5に増やします。Pod の CPU 使用率が75%に達すると、Pod は7まで増加します。

```
$ oc autoscale deployment/hello-node --min=5 --max=7 --cpu-percent=75
```

出力例

```
horizontalpodautoscaler.autoscaling/hello-node autoscaled
```

minReplicas が3に設定された hello-node デプロイメントオブジェクトの HPA を作成するサンプル YAML

```
apiVersion: autoscaling/v1
kind: HorizontalPodAutoscaler
metadata:
  name: hello-node
  namespace: default
spec:
  maxReplicas: 7
  minReplicas: 3
  scaleTargetRef:
    apiVersion: apps/v1
    kind: Deployment
    name: hello-node
  targetCPUUtilizationPercentage: 75
status:
  currentReplicas: 5
  desiredReplicas: 0
```

HPA を作成したら、次のコマンドを実行して、デプロイメントの新しい状態を表示できます。

```
$ oc get deployment hello-node
```

デプロイメントには5つの Pod があります。

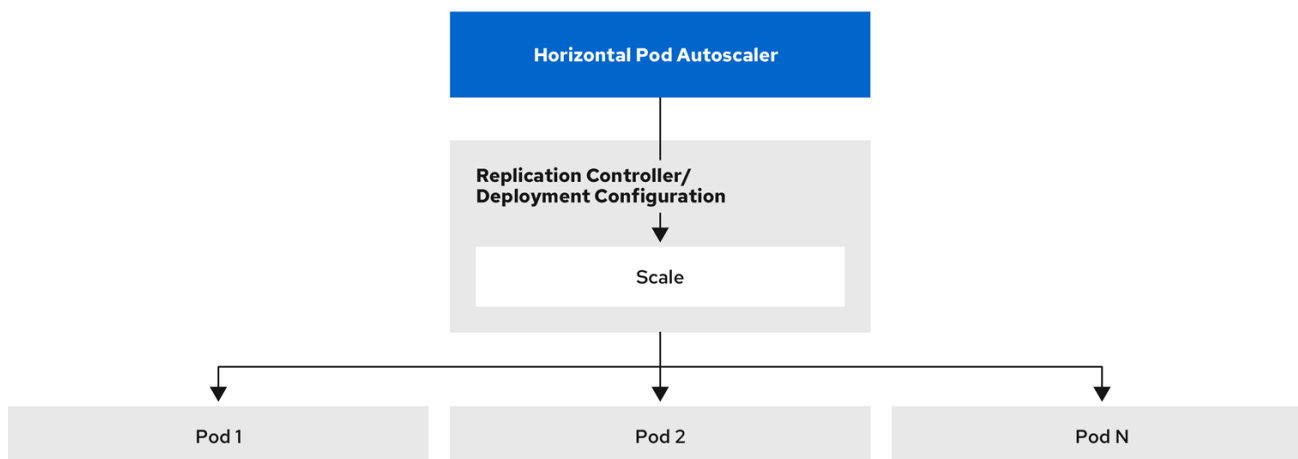
出力例

NAME	REVISION	DESIRED	CURRENT	TRIGGERED BY
hello-node	1	5	5	config

2.4.2. HPA はどのように機能するか

Horizontal Pod Autoscaler (HPA) は、Pod オートスケーリングの概念を拡張するものです。HPA を使用すると、負荷分散されたノードグループを作成および管理できます。HPA は、所定の CPU またはメモリーのしきい値を超えると、Pod 数を自動的に増減させます。

図2.1 HPA の高レベルのワークフロー



223_OpenShift_0222

HPA は、Kubernetes 自動スケーリング API グループの API リソースです。オートスケーラは制御ループとして動作し、同期期間のデフォルトは 15 秒です。この期間中、コントローラマネージャーは、HPA の YAML ファイルに定義されている CPU、メモリー使用率、またはその両方を照会します。コントローラマネージャーは、HPA の対象となる Pod ごとに、CPU やメモリーなどの Pod 単位のリソースメトリックをリソースメトリック API から取得します。

使用率の目標値が設定されている場合、コントローラーは、各 Pod のコンテナにおける同等のリソース要求のパーセンテージとして使用率の値を計算します。次に、コントローラーは、対象となるすべての Pod の使用率の平均を取り、必要なレプリカ数をスケーリングするために使用される比率を生成します。HPA は、メトリクスサーバーが提供する **metrics.k8s.io** からメトリクスを取得するように設定されています。メトリック評価は動的な性質を持っているため、レプリカのグループに対するスケーリング中にレプリカ数が変動する可能性があります。



注記

HPA を実装するには、対象となるすべての Pod のコンテナにリソース要求が設定されている必要があります。

2.4.3. 要求と制限について

スケジューラーは、Pod 内のコンテナに対して指定したリソース要求をもとに、どのノードに Pod を配置するかを決定します。kubelet は、コンテナに指定されたリソース制限を適用して、コンテナが指定された制限を超えて使用できないようにします。kubelet は、そのコンテナが使用するために、そのシステムリソースの要求量も予約します。

リソースメトリックの使用方法

Pod の仕様では、CPU やメモリーなどのリソース要求を指定する必要があります。HPA はこの仕様を使用してリソース使用率を決定し、ターゲットを増減させます。

たとえば、HPA オブジェクトは次のメトリックソースを使用します。

```
type: Resource
resource:
  name: cpu
target:
  type: Utilization
  averageUtilization: 60
```

この例では、HPA はスケーリングターゲットの Pod の平均使用率を 60% に維持しています。使用率とは、Pod の要求リソースに対する現在のリソース使用量の比率です。

2.4.4. ベストプラクティス

最適なパフォーマンスを得るには、すべての Pod のリソース要求を設定します。頻繁なレプリカの変動を防ぐには、クールダウン期間を設定します。

すべての Pod にリソース要求が設定されていること

HPA は、OpenShift Container Platform クラスター内の Pod の観測された CPU またはメモリー使用量の値に基づいてスケーリングの決定を行います。使用率の値は、各 Pod のリソース要求のパーセンテージとして計算されます。リソース要求値が欠落していると、HPA の最適性能に影響を与える可能性があります。

詳細は、「リソース要求および制限について」を参照してください。

クールダウン期間の設定

Horizontal Pod Autoscaling 中に、時間差なしでイベントが急速にスケーリングされる可能性があります。頻繁なレプリカの変動を防ぐために、クールダウン期間を設定します。**stabilizationWindowSeconds** フィールドを設定することで、クールダウン期間を指定できます。安定化ウィンドウは、スケーリングに使用するメトリックが変動し続ける場合に、レプリカ数の変動を制限するために使用されます。自動スケーリングアルゴリズムは、このウィンドウを使用して以前の必要な状態を推測し、ワークロードスケールの不要な変更を回避します。

たとえば、**scaleDown** フィールドに安定化ウィンドウが指定されています。

```
behavior:
  scaleDown:
    stabilizationWindowSeconds: 300
```

前の例では、過去 5 分間のすべての意図された状態が考慮されます。これにより、ローリング最大値が近似され、スケーリングアルゴリズムによって Pod が頻繁に削除され、その直後に同等の Pod が再作成されるという事態が回避されます。

詳細は、「スケーリングポリシー」を参照してください。

関連情報

- [リソース要求および制限について](#)
- [スケーリングポリシー](#)

2.4.4.1. スケーリングポリシー

autoscaling/v2 API を使用して、Horizontal Pod Autoscaler に **スケーリングポリシー** を追加します。スケーリングポリシーは、OpenShift Container Platform の Horizontal Pod Autoscaler (HPA) が Pod をスケーリングする方法を制御します。スケーリングポリシーを使用すると、特定の期間にスケーリングするように特定の数または特定のパーセンテージを設定して、HPA が Pod をスケールアップまたはスケールダウンするレートを制限できます。**安定化ウィンドウ** を定義することもできます。これはメトリクスが変動する場合に、先に計算される必要な状態を使用してスケーリングを制御します。同じスケーリング方向に対して複数のポリシーを作成し、変更の量に基づいて使用するポリシーを決定できます。タイミングが調整された反復によりスケーリングを制限することもできます。HPA は反復時に Pod をスケーリングし、その後の反復で必要に応じてスケーリングを実行します。

スケーリングポリシーを適用するサンプル HPA オブジェクト

```
apiVersion: autoscaling/v2
kind: HorizontalPodAutoscaler
metadata:
  name: hpa-resource-metrics-memory
  namespace: default
spec:
  behavior:
    scaleDown: ❶
    policies: ❷
    - type: Pods ❸
      value: 4 ❹
      periodSeconds: 60 ❺
    - type: Percent
      value: 10 ❻
      periodSeconds: 60
    selectPolicy: Min ❼
    stabilizationWindowSeconds: 300 ❽
    scaleUp: ❾
    policies:
    - type: Pods
      value: 5 ❿
      periodSeconds: 70
    - type: Percent
      value: 12 ⓫
      periodSeconds: 80
    selectPolicy: Max
    stabilizationWindowSeconds: 0
  ...
```

- ❶ **scaleDown** または **scaleUp** のいずれかのスケーリングポリシーの方向を指定します。この例では、スケールダウンのポリシーを作成します。
- ❷ スケーリングポリシーを定義します。
- ❸ ポリシーが反復時に特定の Pod の数または Pod のパーセンテージに基づいてスケーリングするかどうかを決定します。デフォルト値は **pods** です。
- ❹ 反復ごとに Pod の数または Pod のパーセンテージのいずれかでスケーリングの量を制限します。Pod 数でスケールダウンする際のデフォルト値はありません。

- 5 スケーリングの反復の長さを決定します。デフォルト値は **15** 秒です。
- 6 パーセンテージでのスケールダウンのデフォルト値は 100% です。
- 7 複数のポリシーが定義されている場合に、最初に使用するポリシーを決定します。最大限の変更を許可するポリシーを使用するように **Max** を指定するか、最小限の変更を許可するポリシーを使用するように **Min** を指定するか、HPA がポリシーの方向でスケーリングしないように **Disabled** を指定します。デフォルト値は **Max** です。
- 8 HPA が必要な状態を確認する期間を決定します。デフォルト値は **0** です。
- 9 この例では、スケールアップのポリシーを作成します。
- 10 Pod 数によるスケールアップの量を制限します。Pod 数をスケールアップするためのデフォルト値は 4% です。
- 11 Pod のパーセンテージによるスケールアップの量を制限します。パーセンテージでスケールアップするためのデフォルト値は 100% です。

スケールダウンポリシーの例

```

apiVersion: autoscaling/v2
kind: HorizontalPodAutoscaler
metadata:
  name: hpa-resource-metrics-memory
  namespace: default
spec:
  ...
  minReplicas: 20
  ...
  behavior:
    scaleDown:
      stabilizationWindowSeconds: 300
      policies:
        - type: Pods
          value: 4
          periodSeconds: 30
        - type: Percent
          value: 10
          periodSeconds: 60
      selectPolicy: Max
    scaleUp:
      selectPolicy: Disabled

```

この例では、Pod の数が 40 より大きい場合、パーセントベースのポリシーがスケールダウンに使用されます。このポリシーでは、**selectPolicy** による要求により、より大きな変更が生じるためです。

80 の Pod レプリカがある場合、初回の反復で HPA は Pod を 8 Pod 減らします。これは、1 分間 (**periodSeconds: 60**) の (**type: Percent** および **value: 10** パラメーターに基づく) 80 Pod の 10% に相当します。次の反復では、Pod 数は 72 になります。HPA は、残りの Pod の 10% が 7.2 であると計算し、これを 8 に丸め、8 Pod をスケールダウンします。後続の反復ごとに、スケーリングされる Pod 数は残りの Pod 数に基づいて再計算されます。Pod の数が 40 未満になると、Pod ベースの数がパーセントベースの数よりも大きいため、Pod ベースのポリシーが適用されます。HPA は、残りのレプリカ (**minReplicas**) が 20 になるまで、30 秒 (**periodSeconds: 30**) で一度に 4 Pod (**type: Pods** および **value: 4**) を減らします。

selectPolicy: Disabled パラメーターは HPA による Pod のスケールアップを防ぎます。必要な場合は、レプリカセットまたはデプロイメントセットでレプリカ数を調整して手動でスケールアップできます。

設定されている場合、**oc edit** コマンドを使用してスケーリングポリシーを表示できます。

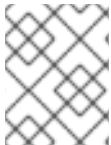
```
$ oc edit hpa hpa-resource-metrics-memory
```

出力例

```
apiVersion: autoscaling/v1
kind: HorizontalPodAutoscaler
metadata:
  annotations:
    autoscaling.alpha.kubernetes.io/behavior:\
'{"ScaleUp":{"StabilizationWindowSeconds":0,"SelectPolicy":"Max","Policies":\
[{"Type":"Pods","Value":4,"PeriodSeconds":15},{ "Type":"Percent","Value":100,"PeriodSeconds":15}]\
,"ScaleDown":{"StabilizationWindowSeconds":300,"SelectPolicy":"Min","Policies":\
[{"Type":"Pods","Value":4,"PeriodSeconds":60},{ "Type":"Percent","Value":10,"PeriodSeconds":60}]}}'
```

2.4.5. Web コンソールを使用した Horizontal Pod Autoscaler の作成

Web コンソールから、**Deployment** または **DeploymentConfig** オブジェクトで実行する Pod の最小および最大数を指定する Horizontal Pod Autoscaler (HPA) を作成できます。Pod がターゲットに設定する CPU またはメモリー使用量を定義することもできます。



注記

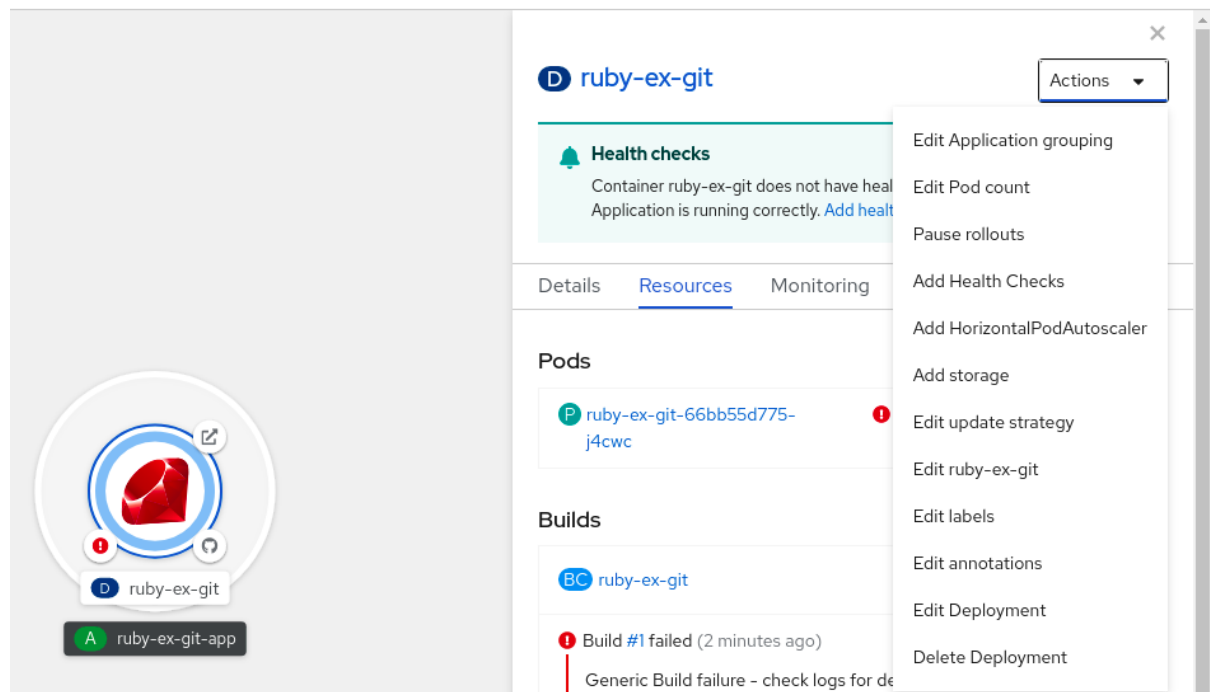
HPA は、Operator がサポートするサービス、Knative サービス、または Helm チャートの一部であるデプロイメントに追加することはできません。

手順

Web コンソールで HPA を作成するには、以下を実行します。

1. **Topology** ビューで、ノードをクリックしてサイドペインを表示します。
2. **Actions** ドロップダウンリストから、**Add HorizontalPodAutoscaler** を選択して **Add HorizontalPodAutoscaler** フォームを開きます。

図2.2 HorizontalPodAutoscaler の追加



3. **Add HorizontalPodAutoscaler** フォームから、名前、最小および最大の Pod 制限、CPU およびメモリーの使用状況を定義し、**Save** をクリックします。

**注記**

CPU およびメモリー使用量の値のいずれかが見つからない場合は、警告が表示されます。

2.4.5.1. Web コンソールを使用して Horizontal Pod Autoscaler を編集する

Web コンソールから、**Deployment** または **DeploymentConfig** オブジェクトで実行する Pod の最小および最大数を指定する Horizontal Pod Autoscaler (HPA) を変更できます。Pod がターゲットに設定する CPU またはメモリー使用量を定義することもできます。

手順

1. **Topology** ビューで、ノードをクリックしてサイドペインを表示します。
2. **Actions** ドロップダウンリストから、**Edit HorizontalPodAutoscaler** を選択し、**Horizontal Pod Autoscaler** フォームを開きます。
3. **Edit Horizontal Pod Autoscaler** フォームから、最小および最大の Pod 制限および CPU およびメモリー使用量を編集し、**Save** をクリックします。

**注記**

Web コンソールで Horizontal Pod Autoscaler を作成または編集する際に、**Form view** から **YAML view** に切り替えることができます。

2.4.5.2. Web コンソールを使用して Horizontal Pod Autoscaler を削除する

Web コンソールで Horizontal Pod Autoscaler (HPA) を削除できます。

手順

1. **Topology** ビューで、ノードをクリックし、サイドパネルを表示します。
2. **Actions** ドロップダウンリストから、**Remove HorizontalPodAutoscaler** を選択します。
3. 確認ウィンドウで、**Remove** をクリックして HPA を削除します。

2.4.6. CLI を使用して Horizontal Pod Autoscaler を作成する

OpenShift Container Platform CLI を使用して Horizontal Pod Autoscaler (HPA) を作成すると、既存の **Deployment**、**DeploymentConfig**、**ReplicaSet**、**ReplicationController**、または **StatefulSet** オブジェクトを自動的にスケーリングできます。HPA は、指定した CPU またはメモリーリソースを維持するために、そのオブジェクトに関連付けられた Pod をスケーリングします。

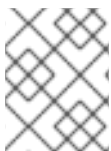
次のセクションで説明するように、リソース使用量のパーセンテージまたは特定の値を指定することにより、CPU またはメモリーの使用量に基づいて自動スケーリングできます。

HPA は、すべての Pod にわたって指定されたリソースの使用を維持するために、レプリカ数を最小数と最大数の間で増減します。

2.4.6.1. CPU 使用率のパーセンテージに応じて Horizontal Pod Autoscaler を作成する

OpenShift Container Platform CLI を使用すると、CPU 使用率に基づいて既存のオブジェクトを自動的にスケーリングする Horizontal Pod Autoscaler (HPA) を作成できます。HPA は、指定した CPU 使用率を維持するために、そのオブジェクトに関連付けられた Pod をスケーリングします。

CPU 使用率のパーセンテージを自動スケーリングする場合、**oc autoscale** コマンドを使用して、特定の時点で実行する Pod の最小数と最大数、および Pod がターゲットとする平均 CPU 使用率を指定できます。最小値を指定しない場合、Pod には OpenShift Container Platform サーバーからのデフォルト値が付与されます。



注記

他のオブジェクトによって提供される特定の機能または動作が必要でない限り、**Deployment** オブジェクトまたは **ReplicaSet** オブジェクトを使用します。

前提条件

Horizontal Pod Autoscaler を使用するには、クラスターの管理者はクラスターメトリックを適切に設定する必要があります。メトリクスが設定されているかどうかは、**oc describe PodMetrics <pod-name>** コマンドを使用して判断できます。メトリックが設定されている場合、出力は以下の **Usage** の下にある **Cpu** と **Memory** のように表示されます。

```
$ oc describe PodMetrics openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
```

出力例

```
Name:      openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
Namespace: openshift-kube-scheduler
Labels:    <none>
Annotations: <none>
API Version: metrics.k8s.io/v1beta1
Containers:
```

```

Name: wait-for-host-port
Usage:
  Memory: 0
Name: scheduler
Usage:
  Cpu: 8m
  Memory: 45440Ki
Kind: PodMetrics
Metadata:
  Creation Timestamp: 2019-05-23T18:47:56Z
  Self Link: /apis/metrics.k8s.io/v1beta1/namespaces/openshift-kube-scheduler/pods/openshift-
kube-scheduler-ip-10-0-135-131.ec2.internal
  Timestamp: 2019-05-23T18:47:56Z
  Window: 1m0s
  Events: <none>

```

手順

1. 既存のオブジェクトに対して **HorizontalPodAutoscaler** オブジェクトを作成します。

```

$ oc autoscale <object_type>/<name> \
  --min <number> \
  --max <number> \
  --cpu-percent=<percent>

```

- 1 自動スケーリングするオブジェクトのタイプと名前を指定します。オブジェクトが存在し、**Deployment**、**DeploymentConfig/dc**、**ReplicaSet/rs**、**ReplicationController/rc**、または **StatefulSet** である必要があります。
- 2 オプション: スケールダウン時のレプリカの最小数を指定します。
- 3 スケールアップ時のレプリカの最大数を指定します。
- 4 すべての Pod における CPU 使用率の目標平均値を、要求された CPU に対するパーセンテージとして指定します。指定しない場合または負の値の場合、デフォルトの自動スケーリングポリシーが使用されます。

たとえば、次のコマンドは **hello-node** デプロイメントオブジェクトの自動スケーリングを示しています。最初のデプロイメントでは 3 つの Pod が必要です。HPA オブジェクトは、最小値を 5 に増やします。Pod の CPU 使用率が 75% に達すると、Pod は 7 まで増加します。

```
$ oc autoscale deployment/hello-node --min=5 --max=7 --cpu-percent=75
```

2. Horizontal Pod Autoscaler を作成します。

```
$ oc create -f <file-name>.yaml
```

検証

- Horizontal Pod Autoscaler が作成されていることを確認します。

```
$ oc get hpa cpu-autoscale
```

出力例

NAME	REFERENCE	TARGETS	MINPODS	MAXPODS	REPLICAS
AGE					
cpu-autoscale	Deployment/example	173m/500m	1	10	1
					20m

2.4.6.2. 特定の CPU 値に対する Horizontal Pod Autoscaler の作成

OpenShift Container Platform CLI を使用すると、ターゲット CPU と Pod 制限を持つ

HorizontalPodAutoscaler オブジェクトを作成することで、特定の CPU 値に基づいて既存のオブジェクトを自動的にスケーリングする Horizontal Pod Autoscaler (HPA) を作成できます。HPA は、指定した CPU 使用率を維持するために、そのオブジェクトに関連付けられた Pod をスケーリングします。



注記

他のオブジェクトによって提供される特定の機能または動作が必要でない限り、**Deployment** オブジェクトまたは **ReplicaSet** オブジェクトを使用します。

前提条件

Horizontal Pod Autoscaler を使用するには、クラスターの管理者はクラスターメトリックを適切に設定する必要があります。メトリクスが設定されているかどうかは、**oc describe PodMetrics <pod-name>** コマンドを使用して判断できます。メトリックが設定されている場合、出力は以下の **Usage** の下にある **Cpu** と **Memory** のように表示されます。

```
$ oc describe PodMetrics openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
```

出力例

```
Name:      openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
Namespace: openshift-kube-scheduler
Labels:    <none>
Annotations: <none>
API Version: metrics.k8s.io/v1beta1
Containers:
  Name: wait-for-host-port
  Usage:
    Memory: 0
  Name: scheduler
  Usage:
    Cpu: 8m
    Memory: 45440Ki
Kind:      PodMetrics
Metadata:
  Creation Timestamp: 2019-05-23T18:47:56Z
  Self Link: /apis/metrics.k8s.io/v1beta1/namespaces/openshift-kube-scheduler/pods/openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
  Timestamp: 2019-05-23T18:47:56Z
  Window: 1m0s
  Events: <none>
```

手順

1. 既存のオブジェクトに対して次のような YAML ファイルを作成します。

```
apiVersion: autoscaling/v2 ❶
kind: HorizontalPodAutoscaler
metadata:
  name: cpu-autoscale ❷
  namespace: default
spec:
  scaleTargetRef:
    apiVersion: apps/v1 ❸
    kind: Deployment ❹
    name: example ❺
  minReplicas: 1 ❻
  maxReplicas: 10 ❼
  metrics: ❽
  - type: Resource
    resource:
      name: cpu ❾
      target:
        type: AverageValue ❿
        averageValue: 500m ⓫
```

- ❶ **autoscaling/v2** API を使用します。
- ❷ この Horizontal Pod Autoscaler オブジェクトの名前を指定します。
- ❸ スケーリングするオブジェクトの API バージョンを指定します。
 - **Deployment**、**ReplicaSet**、**StatefulSet** オブジェクトの場合は、**apps/v1** を使用します。
 - **ReplicationController** の場合は、**v1** を使用します。
 - **DeploymentConfig** の場合は、**apps.openshift.io/v1** を使用します。
- ❹ オブジェクトのタイプを指定します。オブジェクトは、**Deployment**、**DeploymentConfig/dc**、**ReplicaSet/rs**、**ReplicationController/rc**、または **StatefulSet** である必要があります。
- ❺ スケーリングするオブジェクトの名前を指定します。オブジェクトが存在する必要があります。
- ❻ スケールダウン時のレプリカの最小数を指定します。
- ❼ スケールアップ時のレプリカの最大数を指定します。
- ❽ メモリ使用量には、**metrics** パラメーターを使用します。
- ❾ CPU 使用率には **cpu** を指定します。
- ❿ **AverageValue** に設定します。
- ⓫ ターゲットに設定された CPU 値で **averageValue** に設定します。

2. Horizontal Pod Autoscaler を作成します。

```
$ oc create -f <file-name>.yaml
```

検証

- Horizontal Pod Autoscaler が作成されたことを確認します。

```
$ oc get hpa cpu-autoscale
```

出力例

NAME	REFERENCE	TARGETS	MINPODS	MAXPODS	REPLICAS
AGE					
cpu-autoscale	Deployment/example	173m/500m	1	10	1 20m

2.4.6.3. メモリー使用量のパーセンテージに対する Horizontal Pod Autoscaler オブジェクトの作成

OpenShift Container Platform CLI を使用すると、メモリー使用量のパーセンテージに基づいて既存のオブジェクトを自動的にスケーリングする Horizontal Pod Autoscaler (HPA) を作成できます。HPA は、指定したメモリー使用量を維持するために、そのオブジェクトに関連付けられた Pod をスケーリングします。



注記

他のオブジェクトによって提供される特定の機能または動作が必要でない限り、**Deployment** オブジェクトまたは **ReplicaSet** オブジェクトを使用します。

Pod の最小数と最大数、および Pod がターゲットとする平均メモリー使用量を指定できます。最小値を指定しない場合、Pod には OpenShift Container Platform サーバーからのデフォルト値が付与されます。

前提条件

Horizontal Pod Autoscaler を使用するには、クラスターの管理者はクラスターメトリックを適切に設定する必要があります。メトリクスが設定されているかどうかは、**oc describe PodMetrics <pod-name>** コマンドを使用して判断できます。メトリックが設定されている場合、出力は以下の **Usage** の下にある **Cpu** と **Memory** のように表示されます。

```
$ oc describe PodMetrics openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
```

出力例

```
Name:      openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
Namespace: openshift-kube-scheduler
Labels:    <none>
Annotations: <none>
API Version: metrics.k8s.io/v1beta1
Containers:
  Name: wait-for-host-port
  Usage:
```

```

Memory: 0
Name: scheduler
Usage:
  Cpu: 8m
  Memory: 45440Ki
Kind: PodMetrics
Metadata:
  Creation Timestamp: 2019-05-23T18:47:56Z
  Self Link: /apis/metrics.k8s.io/v1beta1/namespaces/openshift-kube-scheduler/pods/openshift-
kube-scheduler-ip-10-0-135-131.ec2.internal
  Timestamp: 2019-05-23T18:47:56Z
  Window: 1m0s
  Events: <none>

```

手順

1. 既存のオブジェクトに対して、次のような **HorizontalPodAutoscaler** オブジェクトを作成します。

```

apiVersion: autoscaling/v2 ❶
kind: HorizontalPodAutoscaler
metadata:
  name: memory-autoscale ❷
  namespace: default
spec:
  scaleTargetRef:
    apiVersion: apps/v1 ❸
    kind: Deployment ❹
    name: example ❺
  minReplicas: 1 ❻
  maxReplicas: 10 ❼
  metrics: ❽
  - type: Resource
    resource:
      name: memory ❾
      target:
        type: Utilization ❿
        averageUtilization: 50 ⓫
  behavior: ⓬
    scaleUp:
      stabilizationWindowSeconds: 180
      policies:
        - type: Pods
          value: 6
          periodSeconds: 120
        - type: Percent
          value: 10
          periodSeconds: 120
      selectPolicy: Max

```

❶ **autoscaling/v2** API を使用します。

❷ この Horizontal Pod Autoscaler オブジェクトの名前を指定します。

- 3 スケーリングするオブジェクトの API バージョンを指定します。
 - ReplicationController の場合は、**v1** を使用します。
 - DeploymentConfig については、**apps.openshift.io/v1** を使用します。
 - Deployment、ReplicaSet、Statefulset オブジェクトの場合は、**apps/v1** を使用します。
- 4 オブジェクトのタイプを指定します。オブジェクトは、**Deployment**、**DeploymentConfig**、**ReplicaSet**、**ReplicationController**、または **StatefulSet** である必要があります。
- 5 スケーリングするオブジェクトの名前を指定します。オブジェクトが存在する必要があります。
- 6 スケールダウン時のレプリカの最小数を指定します。
- 7 スケールアップ時のレプリカの最大数を指定します。
- 8 メモリ使用量には、**metrics** パラメーターを使用します。
- 9 メモリ使用量には、**memory** を指定します。
- 10 **Utilization** に設定します。
- 11 **averageUtilization** およびターゲットに設定する平均メモリ使用率をすべての Pod に対して指定します (要求されるメモリのパーセンテージで表す)。ターゲット Pod にはメモリ要求が設定されている必要があります。
- 12 オプション: スケールアップまたはスケールダウンのレートを制御するスケーリングポリシーを指定します。

2. 次のようなコマンドを使用して、Horizontal Pod Autoscaler を作成します。

```
$ oc create -f <file-name>.yaml
```

以下に例を示します。

```
$ oc create -f hpa.yaml
```

出力例

```
horizontalpodautoscaler.autoscaling/hpa-resource-metrics-memory created
```

検証

- 次のようなコマンドを使用して、Horizontal Pod Autoscaler が作成されたことを確認します。

```
$ oc get hpa hpa-resource-metrics-memory
```

出力例

NAME	REFERENCE	TARGETS	MINPODS	MAXPODS
REPLICAS AGE				
hpa-resource-metrics-memory	Deployment/example	2441216/500Mi	1	10
20m				1

- 次のようなコマンドを使用して、Horizontal Pod Autoscaler の詳細を確認します。

```
$ oc describe hpa hpa-resource-metrics-memory
```

出力例

```
Name: hpa-resource-metrics-memory
Namespace: default
Labels: <none>
Annotations: <none>
CreationTimestamp: Wed, 04 Mar 2020 16:31:37 +0530
Reference: Deployment/example
Metrics: ( current / target )
  resource memory on pods: 2441216 / 500Mi
Min replicas: 1
Max replicas: 10
ReplicationController pods: 1 current / 1 desired
Conditions:
  Type          Status Reason          Message
  ----          -
  AbleToScale   True   ReadyForNewScale   recommended size matches current size
  ScalingActive True   ValidMetricFound   the HPA was able to successfully calculate a
replica count from memory resource
  ScalingLimited False  DesiredWithinRange the desired count is within the acceptable
range
Events:
  Type    Reason           Age          From          Message
  ----    -
  Normal  SuccessfulRescale 6m34s        horizontal-pod-autoscaler New size: 1;
reason: All metrics below target
```

2.4.6.4. 特定のメモリー使用のための Horizontal Pod Autoscaler オブジェクトの作成

OpenShift Container Platform CLI を使用すると、既存のオブジェクトを自動的にスケーリングする Horizontal Pod Autoscaler (HPA) を作成できます。HPA は、指定した平均メモリー使用量を維持するために、そのオブジェクトに関連付けられた Pod をスケーリングします。



注記

他のオブジェクトによって提供される特定の機能または動作が必要でない限り、**Deployment** オブジェクトまたは **ReplicaSet** オブジェクトを使用します。

Pod の最小数と最大数、および Pod がターゲットとする平均メモリー使用量を指定できます。最小値を指定しない場合、Pod には OpenShift Container Platform サーバーからのデフォルト値が付与されます。

前提条件

Horizontal Pod Autoscaler を使用するには、クラスターの管理者はクラスターメトリックを適切に設定

している必要があります。メトリクスが設定されているかどうかは、**oc describe PodMetrics <pod-name>** コマンドを使用して判断できます。メトリックが設定されている場合、出力は以下の **Usage** の下にある **Cpu** と **Memory** のように表示されます。

```
$ oc describe PodMetrics openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
```

出力例

```
Name:      openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
Namespace: openshift-kube-scheduler
Labels:    <none>
Annotations: <none>
API Version: metrics.k8s.io/v1beta1
Containers:
  Name: wait-for-host-port
  Usage:
    Memory: 0
  Name: scheduler
  Usage:
    Cpu: 8m
    Memory: 45440Ki
Kind: PodMetrics
Metadata:
  Creation Timestamp: 2019-05-23T18:47:56Z
  Self Link: /apis/metrics.k8s.io/v1beta1/namespaces/openshift-kube-scheduler/pods/openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
  Timestamp: 2019-05-23T18:47:56Z
  Window: 1m0s
  Events: <none>
```

手順

1. 既存のオブジェクトに対して、次のような **HorizontalPodAutoscaler** オブジェクトを作成します。

```
apiVersion: autoscaling/v2 ❶
kind: HorizontalPodAutoscaler
metadata:
  name: hpa-resource-metrics-memory ❷
  namespace: default
spec:
  scaleTargetRef:
    apiVersion: apps/v1 ❸
    kind: Deployment ❹
    name: example ❺
  minReplicas: 1 ❻
  maxReplicas: 10 ❼
  metrics: ❽
  - type: Resource
    resource:
      name: memory ❾
      target:
        type: AverageValue ❿
```

```

    averageValue: 500Mi 11
  behavior: 12
    scaleDown:
      stabilizationWindowSeconds: 300
    policies:
      - type: Pods
        value: 4
        periodSeconds: 60
      - type: Percent
        value: 10
        periodSeconds: 60
    selectPolicy: Max

```

- 1 **autoscaling/v2** API を使用します。
- 2 この Horizontal Pod Autoscaler オブジェクトの名前を指定します。
- 3 スケーリングするオブジェクトの API バージョンを指定します。
 - **Deployment**、**ReplicaSet**、または **StatefulSet** オブジェクトの場合は、**apps/v1** を使用します。
 - **ReplicationController** の場合は、**v1** を使用します。
 - **DeploymentConfig** の場合は、**apps.openshift.io/v1** を使用します。
- 4 オブジェクトのタイプを指定します。オブジェクトは、**Deployment**、**DeploymentConfig**、**ReplicaSet**、**ReplicationController**、または **StatefulSet** である必要があります。
- 5 スケーリングするオブジェクトの名前を指定します。オブジェクトが存在する必要があります。
- 6 スケールダウン時のレプリカの最小数を指定します。
- 7 スケールアップ時のレプリカの最大数を指定します。
- 8 メモリ使用量には、**metrics** パラメーターを使用します。
- 9 メモリ使用量には、**memory** を指定します。
- 10 タイプを **AverageValue** に設定します。
- 11 **averageValue** および特定のメモリ値を指定します。
- 12 オプション: スケールアップまたはスケールダウンのレートを制御するスケーリングポリシーを指定します。

2. 次のようなコマンドを使用して、Horizontal Pod Autoscaler を作成します。

```
$ oc create -f <file-name>.yaml
```

以下に例を示します。

```
$ oc create -f hpa.yaml
```

■

出力例

```
horizontalpodautoscaler.autoscaling/hpa-resource-metrics-memory created
```

検証

- 次のようなコマンドを使用して、Horizontal Pod Autoscaler が作成されたことを確認します。

```
$ oc get hpa hpa-resource-metrics-memory
```

出力例

NAME	REFERENCE	TARGETS	MINPODS	MAXPODS
REPLICAS AGE				
hpa-resource-metrics-memory	Deployment/example	2441216/500Mi	1	10
20m				1

- 次のようなコマンドを使用して、Horizontal Pod Autoscaler の詳細を確認します。

```
$ oc describe hpa hpa-resource-metrics-memory
```

出力例

```

Name:          hpa-resource-metrics-memory
Namespace:     default
Labels:        <none>
Annotations:   <none>
CreationTimestamp:  Wed, 04 Mar 2020 16:31:37 +0530
Reference:     Deployment/example
Metrics:       ( current / target )
  resource memory on pods: 2441216 / 500Mi
Min replicas:   1
Max replicas:   10
ReplicationController pods: 1 current / 1 desired
Conditions:
  Type          Status Reason          Message
  ----          -
  AbleToScale   True   ReadyForNewScale   recommended size matches current size
  ScalingActive True   ValidMetricFound   the HPA was able to successfully calculate a
replica count from memory resource
  ScalingLimited False  DesiredWithinRange the desired count is within the acceptable
range
Events:
  Type    Reason           Age          From          Message
  ----    -
  Normal  SuccessfulRescale 6m34s        horizontal-pod-autoscaler New size: 1;
reason: All metrics below target

```

2.4.7. CLI を使用した Horizontal Pod Autoscaler の状態条件について

状態条件セットを使用して、Horizontal Pod Autoscaler (HPA) がスケーリングできるかどうかや、現時点でこれがいずれかの方法で制限されているかどうかを判別できます。

HPA の状態条件は、自動スケーリング API の **v2** バージョンで利用できます。

HPA は、以下の状態条件で応答します。

- **AbleToScale** 条件では、HPA がメトリックを取得して更新できるか、またバックオフ関連の条件によりスケーリングが回避されるかどうかを指定します。
 - **True** 条件はスケーリングが許可されることを示します。
 - **False** 条件は指定される理由によりスケーリングが許可されないことを示します。
- **ScalingActive** 条件は、HPA が有効にされており (ターゲットのレプリカ数がゼロでない)、必要なメトリックを計算できるかどうかを示します。
 - **True** 条件はメトリックが適切に機能していることを示します。
 - **False** 条件は通常フェッチするメトリックに関する問題を示します。
- **ScalingLimited** 条件は、必要とするスケールが Horizontal Pod Autoscaler の最大値または最小値によって制限されていたことを示します。
 - **True** 条件は、スケーリングするためにレプリカの最小または最大数を引き上げるか、引き下げる必要があることを示します。
 - **False** 条件は、要求されたスケーリングが許可されることを示します。

```
$ oc describe hpa cm-test
```

出力例

```
Name:                cm-test
Namespace:           prom
Labels:              <none>
Annotations:         <none>
CreationTimestamp:   Fri, 16 Jun 2017 18:09:22 +0000
Reference:           ReplicationController/cm-test
Metrics:             ( current / target )
  "http_requests" on pods:  66m / 500m
Min replicas:        1
Max replicas:        4
ReplicationController pods:  1 current / 1 desired
Conditions: 1
  Type        Status  Reason                Message
  ----        -
  AbleToScale  True    ReadyForNewScale      the last scale time was sufficiently old
as to warrant a new scale
  ScalingActive True    ValidMetricFound      the HPA was able to successfully
calculate a replica count from pods metric http_request
  ScalingLimited False   DesiredWithinRange    the desired replica count is within the
acceptable range
Events:
```

1 Horizontal Pod Autoscaler の状況メッセージです。

以下は、スケーリングできない Pod の例です。

出力例

```
Conditions:
  Type          Status Reason          Message
  ----          -
  AbleToScale   False  FailedGetScale   the HPA controller was unable to get the target's current
scale: no matches for kind "ReplicationController" in group "apps"
Events:
  Type    Reason          Age          From          Message
  ----    -
  Warning FailedGetScale  6s (x3 over 36s) horizontal-pod-autoscaler no matches for kind
"ReplicationController" in group "apps"
```

以下は、スケーリングに必要なメトリックを取得できなかった Pod の例です。

出力例

```
Conditions:
  Type          Status Reason          Message
  ----          -
  AbleToScale    True   SucceededGetScale the HPA controller was able to get the target's
current scale
  ScalingActive  False FailedGetResourceMetric the HPA was unable to compute the replica
count: failed to get cpu utilization: unable to get metrics for resource cpu: no metrics returned from
resource metrics API
```

以下は、要求される自動スケーリングが要求される最小数よりも小さい場合の Pod の例です。

出力例

```
Conditions:
  Type          Status Reason          Message
  ----          -
  AbleToScale    True   ReadyForNewScale   the last scale time was sufficiently old as to warrant
a new scale
  ScalingActive  True   ValidMetricFound   the HPA was able to successfully calculate a replica
count from pods metric http_request
  ScalingLimited False  DesiredWithinRange the desired replica count is within the acceptable
range
```

2.4.7.1. CLI を使用した Horizontal Pod Autoscaler の状態条件の表示

Pod に設定された状態条件は、Horizontal Pod Autoscaler (HPA) で表示することができます。



注記

Horizontal Pod Autoscaler の状態条件は、自動スケーリング API の **v2** バージョンで利用できます。

前提条件

Horizontal Pod Autoscaler を使用するには、クラスターの管理者はクラスターメトリックを適切に設定している必要があります。メトリクスが設定されているかどうかは、**oc describe PodMetrics <pod-name>** コマンドを使用して判断できます。メトリックが設定されている場合、出力は以下の **Usage** の下にある **Cpu** と **Memory** のように表示されます。

```
$ oc describe PodMetrics openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
```

出力例

```
Name:      openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
Namespace: openshift-kube-scheduler
Labels:    <none>
Annotations: <none>
API Version: metrics.k8s.io/v1beta1
Containers:
  Name: wait-for-host-port
  Usage:
    Memory: 0
  Name: scheduler
  Usage:
    Cpu: 8m
    Memory: 45440Ki
Kind: PodMetrics
Metadata:
  Creation Timestamp: 2019-05-23T18:47:56Z
  Self Link: /apis/metrics.k8s.io/v1beta1/namespaces/openshift-kube-scheduler/pods/openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
  Timestamp: 2019-05-23T18:47:56Z
  Window: 1m0s
  Events: <none>
```

手順

Pod の状態条件を表示するには、Pod の名前と共に以下のコマンドを使用します。

```
$ oc describe hpa <pod-name>
```

以下に例を示します。

```
$ oc describe hpa cm-test
```

条件は、出力の **Conditions** フィールドに表示されます。

出力例

```
Name:      cm-test
Namespace: prom
Labels:    <none>
Annotations: <none>
CreationTimestamp: Fri, 16 Jun 2017 18:09:22 +0000
Reference: ReplicationController/cm-test
Metrics:   ( current / target )
  "http_requests" on pods: 66m / 500m
Min replicas: 1
```

```

Max replicas:          4
ReplicationController pods: 1 current / 1 desired
Conditions: 1
  Type           Status Reason           Message
  ----           -
  AbleToScale    True   ReadyForNewScale the last scale time was sufficiently old as to warrant
a new scale
  ScalingActive  True   ValidMetricFound the HPA was able to successfully calculate a replica
count from pods metric http_request
  ScalingLimited False  DesiredWithinRange the desired replica count is within the acceptable
range

```

2.4.8. 関連情報

- レプリケーションコントローラーとデプロイメントコントローラーの詳細は、[デプロイメントとデプロイメント設定](#) を参照してください。
- HPA の使用例は、[Horizontal Pod Autoscaling of Quarkus Application Based on Memory Utilization](#) を参照してください。

2.5. VERTICAL POD AUTOSCALER を使用した POD リソースレベルの自動調整

OpenShift Container Platform の Vertical Pod Autoscaler Operator (VPA) は、Pod 内のコンテナの履歴および現在の CPU とメモリーリソースを自動的に確認し、把握する使用値に基づいてリソース制限および要求を更新できます。VPA は個別のカスタムリソース (CR) を使用して、プロジェクトの **Deployment**、**DeploymentConfig**、**StatefulSet**、**Job**、**DaemonSet**、**ReplicaSet**、または **ReplicationController** などのワークロードオブジェクトに関連付けられたすべての Pod を更新します。

VPA は、Pod に最適な CPU およびメモリーの使用状況を理解するのに役立ち、Pod のライフサイクルを通じて Pod のリソースを自動的に維持します。

2.5.1. Vertical Pod Autoscaler Operator について

Vertical Pod Autoscaler Operator (VPA) は、API リソースおよびカスタムリソース (CR) として実装されます。CR は、プロジェクト内のデーモンセット、レプリケーションコントローラーなどの特定のワークロードオブジェクトに関連付けられた Pod に対して VPA が実行するアクションを決定します。

VPA は 3 つのコンポーネントで構成され、各コンポーネントは VPA namespace に独自の Pod を持ちます。

レコメンダー

VPA レコメンダーは、現在のリソース消費量と過去のリソース消費量を監視します。このデータに基づいて、VPA レコメンダーは、関連付けられたワークロードオブジェクト内の Pod に最適な CPU およびメモリーリソースを決定します。

アップデーター

VPA アップデーターは、関連付けられたワークロードオブジェクト内の Pod に正しいリソースがあるか確認します。リソースが正しい場合、アップデーターは何も行いません。リソースが正しくない場合、アップデーターは Pod を強制終了し、Pod のコントローラーが更新されたリクエストでリソースを再作成できるようにします。

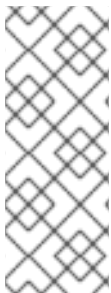
アドミッションコントローラー

VPA アドミッションコントローラーは、関連付けられたワークロードオブジェクト内の各新しい Pod に正しいリソース要求を設定します。これは、Pod が新規であるか、または VPA アップデーターアクションによりコントローラーが Pod を再作成したかに関係なく適用されます。

デフォルトのレコメンダーを使用することも、独自の代替レコメンダーを使用して独自のアルゴリズムに基づいて自動スケーリングを実行することもできます。

デフォルトのレコメンダーは、これらの Pod 内のコンテナの CPU とメモリーの過去および現在の使用状況を自動的に計算します。デフォルトのレコメンダーは、これらの Pod が常に効率的に動作するように、このデータを使用して最適なリソース制限および要求を決定します。たとえば、デフォルトレコメンダーは使用している量よりも多くのリソースを要求する Pod のリソースを減らし、十分なりソースを要求していない Pod のリソースを増やします。

VPA は、一度に1つずつ、これらの推奨値で調整されていない Pod を自動的に削除するため、アプリケーションはダウンタイムなしに継続して要求を提供できます。その後、ワークロードオブジェクトが、元のリソース制限および要求を使用して Pod を再デプロイします。VPA は変更用のアドミッション Webhook を使用して、Pod がノードに許可される前に最適化されたリソース制限および要求で Pod を更新します。VPA が Pod を削除する必要がある場合は、VPA リソース制限および要求を表示し、必要に応じて Pod を手動で更新できます。



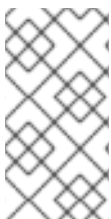
注記

デフォルトで、ワークロードオブジェクトは、VPA が Pod を自動的に削除できるようにするためにレプリカを 2 つ以上指定する必要があります。この最小値よりも少ないレプリカを指定するワークロードオブジェクトは削除されません。これらの Pod を手動で削除すると、ワークロードオブジェクトが Pod を再デプロイするときに、VPA は推奨内容に基づいて新規 Pod を更新します。この最小値は、**VPA の最小値の変更** に記載されているとおり、**VerticalPodAutoscalerController** オブジェクトを変更して変更できます。

たとえば、CPU の 50% を使用する Pod が 10% しか要求しない場合、VPA は Pod が要求よりも多くの CPU を消費すると判別してその Pod を削除します。レプリカセットなどのワークロードオブジェクトは Pod を再起動し、VPA は推奨リソースで新しい Pod を更新します。

開発者は VPA を使用して、各 Pod に適切なリソースを持つノードに Pod をスケジューリングすることにより、需要が高い期間に Pod がアクティブであることを確認できます。

管理者は VPA を使用して、クラスターリソースをより適切に活用できます。たとえば、必要以上の CPU リソースを Pod が予約できないようにします。VPA は、ワークロードが実際に使用しているリソースをモニターし、他のワークロードで容量を使用できるようにリソース要件を調整します。VPA は、初期のコンテナ設定で指定された制限と要求の比率も維持します。



注記

VPA の実行を停止するか、クラスターの特定の VPA CR を削除する場合、VPA によってすでに変更された Pod のリソース要求は変更されません。ただし、新しい Pod は、VPA による以前の推奨内容ではなく、ワークロードオブジェクトで定義されたリソースを取得します。

2.5.2. Vertical Pod Autoscaler Operator のインストール

OpenShift Container Platform Web コンソールを使用して Vertical Pod Autoscaler Operator (VPA) をインストールすることができます。

手順

1. OpenShift Container Platform Web コンソールで、**Operators** → **OperatorHub** をクリックします。
2. 利用可能な Operator のリストから **VerticalPodAutoscaler** を選択し、**Install** をクリックします。
3. **Install Operator** ページで、**Operator recommended namespace** オプションが選択されていることを確認します。これにより、Operator が必須の **openshift-vertical-pod-autoscaler** namespace にインストールされます。この namespace は存在しない場合は、自動的に作成されます。
4. **Install** をクリックします。

検証

1. VPA コンポーネントをリスト表示してインストールを確認します。
 - a. **Workloads** → **Pods** に移動します。
 - b. ドロップダウンメニューから **openshift-vertical-pod-autoscaler** プロジェクトを選択し、4 つの Pod が実行されていることを確認します。
 - c. **Workloads** → **Deployments** に移動し、4 つのデプロイメントが実行されていることを確認します。
2. オプション: 以下のコマンドを使用して、OpenShift Container Platform CLI でインストールを確認します。

```
$ oc get all -n openshift-vertical-pod-autoscaler
```

出力には、4 つの Pod と 4 つのデプロイメントが表示されます。

出力例

NAME	READY	STATUS	RESTARTS	AGE
pod/vertical-pod-autoscaler-operator-85b4569c47-2gmhc	1/1	Running	0	3m13s
pod/vpa-admission-plugin-default-67644fc87f-xq7k9	1/1	Running	0	2m56s
pod/vpa-recommender-default-7c54764b59-8gckt	1/1	Running	0	2m56s
pod/vpa-updater-default-7f6cc87858-47vw9	1/1	Running	0	2m56s

NAME	TYPE	CLUSTER-IP	EXTERNAL-IP	PORT(S)	AGE
service/vpa-webhook	ClusterIP	172.30.53.206	<none>	443/TCP	2m56s

NAME	READY	UP-TO-DATE	AVAILABLE	AGE
deployment.apps/vertical-pod-autoscaler-operator	1/1	1	1	3m13s
deployment.apps/vpa-admission-plugin-default	1/1	1	1	2m56s
deployment.apps/vpa-recommender-default	1/1	1	1	2m56s
deployment.apps/vpa-updater-default	1/1	1	1	2m56s

NAME	DESIRED	CURRENT	READY	AGE
replicaset.apps/vertical-pod-autoscaler-operator-85b4569c47	1	1	1	3m13s
replicaset.apps/vpa-admission-plugin-default-67644fc87f	1	1	1	2m56s
replicaset.apps/vpa-recommender-default-7c54764b59	1	1	1	2m56s
replicaset.apps/vpa-updater-default-7f6cc87858	1	1	1	2m56s

2.5.3. Vertical Pod Autoscaler Operator の使用について

Vertical Pod Autoscaler Operator (VPA) を使用するには、クラスター内にワークロードオブジェクトの VPA カスタムリソース (CR) を作成します。VPA は、そのワークロードオブジェクトに関連付けられた Pod に最適な CPU およびメモリーリソースを確認し、適用します。VPA は、デプロイメント、ステートフルセット、ジョブ、デーモンセット、レプリカセット、またはレプリケーションコントローラーのワークロードオブジェクトと共に使用できます。VPA CR は、チェックする Pod と同じプロジェクト内にある必要があります。

VPA CR を使用してワークロードオブジェクトを関連付け、VPA が動作するモードを指定します。

- **Auto** および **Recreate** モードは、Pod の有効期間中は VPA CPU およびメモリーの推奨事項を自動的に適用します。VPA は、推奨値で調整されていないプロジェクトの Pod を削除します。ワークロードオブジェクトによって再デプロイされる場合、VPA はその推奨値で新規 Pod を更新します。
- **Initial** モードは、Pod の作成時にのみ VPA の推奨値を自動的に適用します。
- **Off** モードでは、推奨されるリソース制限と要求のみが提供されます。その後、推奨値を手動で適用できます。**Off** モードは Pod を更新しません。

CR を使用して、VPA 評価および更新から特定のコンテナをオプトアウトすることもできます。

たとえば、Pod には以下の制限および要求があります。

```
resources:
  limits:
    cpu: 1
    memory: 500Mi
  requests:
    cpu: 500m
    memory: 100Mi
```

Auto に設定された VPA を作成すると、VPA はリソースの使用状況を確認して Pod を削除します。再デプロイ時に、Pod は新規のリソース制限および要求を使用します。

```
resources:
  limits:
    cpu: 50m
    memory: 1250Mi
  requests:
    cpu: 25m
    memory: 262144k
```

次のコマンドを使用して、VPA の推奨値を表示できます。

```
$ oc get vpa <vpa-name> --output yaml
```

数分後に、出力には、以下のような CPU およびメモリー要求の推奨値が表示されます。

出力例

```
...
status:
...
```

```

recommendation:
  containerRecommendations:
  - containerName: frontend
    lowerBound:
      cpu: 25m
      memory: 262144k
    target:
      cpu: 25m
      memory: 262144k
    uncappedTarget:
      cpu: 25m
      memory: 262144k
    upperBound:
      cpu: 262m
      memory: "274357142"
  - containerName: backend
    lowerBound:
      cpu: 12m
      memory: 131072k
    target:
      cpu: 12m
      memory: 131072k
    uncappedTarget:
      cpu: 12m
      memory: 131072k
    upperBound:
      cpu: 476m
      memory: "498558823"
  ...

```

出力には、**target** (推奨リソース)、**lowerBound** (最小推奨リソース)、**upperBound** (最大推奨リソース)、および **uncappedTarget** (最新の推奨リソース) が表示されます。

VPA は **lowerBound** および **upperBound** の値を使用して、Pod の更新が必要か判断します。Pod のリソース要求が **lowerBound** 値より少ないか **upperBound** 値より大きい場合、VPA は Pod を終了し、**target** 値で Pod を再作成します。

2.5.3.1. VPA の最小値の変更

デフォルトで、ワークロードオブジェクトは、VPA が Pod を自動的に削除し、更新できるようにするためにレプリカを 2 つ以上指定する必要があります。そのため、2 つ未満を指定するワークロードオブジェクトの場合 VPA は自動的に機能しません。VPA 外部のプロセスによって Pod が再起動された場合、VPA はこれらのワークロードオブジェクトから新しい Pod を更新します。このクラスター全体の最小値の変更は、**VerticalPodAutoscalerController** カスタムリソース (CR) の **minReplicas** パラメータを変更して実行できます。

たとえば、**minReplicas** を **3** に設定する場合、VPA は 2 レプリカ以下のレプリカを指定するワークロードオブジェクトの Pod を削除せず、更新しません。



注記

minReplicas を **1** に設定する場合、VPA は1つのレプリカのみを指定するワークロードオブジェクトの Pod のみを削除できます。VPA が Pod を削除してリソースを調整するたびに、ワークロードがダウンタイムを許容できる場合にのみ、1つのレプリカオブジェクトでこの設定を使用します。1つのレプリカオブジェクトで不要なダウンタイムを回避するには、**podUpdatePolicy** を **Initial** に設定して VPA CR を設定します。これにより、VPA 外部のプロセスが再起動した場合にのみ Pod が自動的に更新されます。または、**Off** に設定すると、アプリケーションの適切なタイミングで Pod を手動で更新できます。

VerticalPodAutoscalerController オブジェクトの例

```
apiVersion: autoscaling.openshift.io/v1
kind: VerticalPodAutoscalerController
metadata:
  creationTimestamp: "2021-04-21T19:29:49Z"
  generation: 2
  name: default
  namespace: openshift-vertical-pod-autoscaler
  resourceVersion: "142172"
  uid: 180e17e9-03cc-427f-9955-3b4d7aeb2d59
spec:
  minReplicas: 3 ❶
  podMinCPUMillicores: 25
  podMinMemoryMb: 250
  recommendationOnly: false
  safetyMarginFraction: 0.15
```

❶❶ 動作させる VPA のワークロードオブジェクトのレプリカの最小数を指定します。最低数に満たない数のレプリカを持つオブジェクトは、VPA によって自動的に削除されません。

2.5.3.2. VPA の推奨事項の自動適用

VPA を使用して Pod を自動的に更新するには、**updateMode** が **Auto** または **Recreate** に設定された特定のワークロードオブジェクトの VPA CR を作成します。

Pod がワークロードオブジェクト用に作成されると、VPA はコンテナを継続的にモニターして、CPU およびメモリーのニーズを分析します。VPA は、CPU およびメモリーに関する VPA の推奨値を満たさない Pod を削除します。再デプロイ時に、Pod は VPA の推奨値に基づいて新規のリソース制限および要求を使用し、アプリケーションに設定された Pod の Disruption Budget (停止状態の予算) を反映します。この推奨事項は、参照用に VPA CR の **status** フィールドに追加されます。



注記

デフォルトで、ワークロードオブジェクトは、VPA が Pod を自動的に削除できるようにするためにレプリカを 2 つ以上指定する必要があります。この最小値よりも少ないレプリカを指定するワークロードオブジェクトは削除されません。これらの Pod を手動で削除すると、ワークロードオブジェクトが Pod を再デプロイします。VPA は推奨内容に基づいて新規 Pod を更新します。この最小値は、**Changing the VPA minimum value** に示されるように **VerticalPodAutoscalerController** オブジェクトを変更して変更できます。

Auto モードの VPA CR の例

```
apiVersion: autoscaling.k8s.io/v1
kind: VerticalPodAutoscaler
metadata:
  name: vpa-recommender
spec:
  targetRef:
    apiVersion: "apps/v1"
    kind: Deployment ❶
    name: frontend ❷
  updatePolicy:
    updateMode: "Auto" ❸
```

❶ この VPA CR が管理するワークロードオブジェクトのタイプ。

❷ この VPA CR が管理するワークロードオブジェクトの名前。

❸ モードを **Auto** または **Recreate** に設定します。

- **Auto**:VPA は、Pod の作成時にリソース要求を割り当て、要求されるリソースが新規の推奨事項と大きく異なる場合に、それらを終了して既存の Pod を更新します。
- **Recreate**:VPA は、Pod の作成時にリソース要求を割り当て、要求されるリソースが新規の推奨事項と大きく異なる場合に、それらを終了して既存の Pod を更新します。このモードが使用されることはほとんどありません。リソース要求の変更に応じて Pod を必ず再起動させたい場合に限定して使用します。



注記

VPA によってリソースの推奨事項を決定し、推奨リソースを新しい Pod に適用するには、動作中の Pod がプロジェクト内に存在し、実行されている必要があります。

CPU やメモリーなどのワークロードのリソース使用量が安定している場合、VPA はリソースの推奨事項を数分で決定できます。ワークロードのリソース使用量が安定していない場合、VPA は正確な推奨を行うために、さまざまなリソース使用量の間隔でメトリクスを収集する必要があります。

2.5.3.3. Pod 作成時における VPA 推奨の自動適用

VPA を使用して、Pod が最初にデプロイされる場合にのみ推奨リソースを適用するには、**updateMode** が **Initial** に設定された特定のワークロードオブジェクトの VPA CR を作成します。

次に、VPA の推奨値を使用する必要のあるワークロードオブジェクトに関連付けられた Pod を手動で削除します。**Initial** モードで、VPA は新しいリソースの推奨内容を確認する際に Pod を削除したり、更新したりしません。

Initial モードの VPA CR の例

```
apiVersion: autoscaling.k8s.io/v1
kind: VerticalPodAutoscaler
metadata:
  name: vpa-recommender
```

```
spec:
  targetRef:
    apiVersion: "apps/v1"
    kind: Deployment ❶
    name: frontend ❷
  updatePolicy:
    updateMode: "Initial" ❸
```

- ❶ この VPA CR が管理するワークロードオブジェクトのタイプ。
- ❷ この VPA CR が管理するワークロードオブジェクトの名前。
- ❸ モードを **Initial** に設定します。VPA は、Pod の作成時にリソースを割り当て、Pod の有効期間中はリソースを変更しません。



注記

VPA によって推奨リソースを決定し、推奨事項を新しい Pod に適用するには、動作中の Pod がプロジェクト内に存在し、実行されている必要があります。

VPA から最も正確な推奨事項を取得するには、Pod が実行され、VPA が安定するまで少なくとも 8 日間待機してください。

2.5.3.4. VPA の推奨事項の手動適用

CPU およびメモリの推奨値を判別するためだけに VPA を使用するには、**updateMode** を **Off** に設定した特定のワークロードオブジェクトの VPA CR を作成します。

Pod がワークロードオブジェクト用に作成されると、VPA はコンテナの CPU およびメモリのニーズを分析し、VPA CR の **status** フィールドにそれらの推奨事項を記録します。VPA は、新しい推奨リソースを判別する際に Pod を更新しません。

Off モードの VPA CR の例

```
apiVersion: autoscaling.k8s.io/v1
kind: VerticalPodAutoscaler
metadata:
  name: vpa-recommender
spec:
  targetRef:
    apiVersion: "apps/v1"
    kind: Deployment ❶
    name: frontend ❷
  updatePolicy:
    updateMode: "Off" ❸
```

- ❶ この VPA CR が管理するワークロードオブジェクトのタイプ。
- ❷ この VPA CR が管理するワークロードオブジェクトの名前。
- ❸ モードを **Off** に設定します。

以下のコマンドを使用して、推奨事項を表示できます。

```
$ oc get vpa <vpa-name> --output yaml
```

この推奨事項により、ワークロードオブジェクトを編集して CPU およびメモリー要求を追加し、推奨リソースを使用して Pod を削除および再デプロイできます。



注記

VPA によって推奨リソースを決定し、推奨事項を新しい Pod に適用するには、動作中の Pod がプロジェクト内に存在し、実行されている必要があります。

VPA から最も正確な推奨事項を取得するには、Pod が実行され、VPA が安定するまで少なくとも 8 日間待機してください。

2.5.3.5. VPA の推奨事項をすべてのコンテナに適用しないようにする

ワークロードオブジェクトに複数のコンテナがあり、VPA がすべてのコンテナを評価および実行対象としないようにするには、特定のワークロードオブジェクトの VPA CR を作成し、**resourcePolicy** を追加して特定のコンテナをオプトアウトします。

VPA が推奨リソースで Pod を更新すると、**resourcePolicy** が設定されたコンテナは更新されず、VPA は Pod 内のそれらのコンテナの推奨事項を提示しません。

```
apiVersion: autoscaling.k8s.io/v1
kind: VerticalPodAutoscaler
metadata:
  name: vpa-recommender
spec:
  targetRef:
    apiVersion: "apps/v1"
    kind: Deployment ❶
    name: frontend ❷
  updatePolicy:
    updateMode: "Auto" ❸
  resourcePolicy: ❹
    containerPolicies:
      - containerName: my-opt-sidecar
        mode: "Off"
```

- ❶ この VPA CR が管理するワークロードオブジェクトのタイプ。
- ❷ この VPA CR が管理するワークロードオブジェクトの名前。
- ❸ モードを **Auto**、**Recreate**、**Initial**、または **Off** に設定します。**Recreate** モードが使用されることはほとんどありません。リソース要求の変更に応じて Pod を必ず再起動させたい場合に限定して使用します。
- ❹ VPA によって更新しないコンテナを指定し、**mode** を **Off** に設定します。

たとえば、Pod には同じリソース要求および制限の 2 つのコンテナがあります。

```
# ...
```

```
spec:
  containers:
  - name: frontend
    resources:
      limits:
        cpu: 1
        memory: 500Mi
      requests:
        cpu: 500m
        memory: 100Mi
  - name: backend
    resources:
      limits:
        cpu: "1"
        memory: 500Mi
      requests:
        cpu: 500m
        memory: 100Mi
# ...
```

backend コンテナがオプトアウトに設定された VPA CR を起動した後、VPA は Pod を終了し、**frontend** コンテナのみに適用される推奨リソースで Pod を再作成します。

```
...
spec:
  containers:
  name: frontend
  resources:
    limits:
      cpu: 50m
      memory: 1250Mi
    requests:
      cpu: 25m
      memory: 262144k
...
  name: backend
  resources:
    limits:
      cpu: "1"
      memory: 500Mi
    requests:
      cpu: 500m
      memory: 100Mi
...
```

2.5.3.6. OOM イベント後のカスタムのメモリー増加量

クラスターで OOM (メモリー不足) イベントが発生した場合、Vertical Pod Autoscaler Operator (VPA) はメモリーの推奨値を増やします。この推奨値は、OOM イベントの発生時に観測されたメモリー消費量と、将来的なメモリー不足によるクラッシュを防ぐために指定された乗数に基づいています。

推奨値は、OOM イベント発生時に Pod によって使用されていたメモリー使用量に指定バイト数または指定パーセンテージを掛けて算出される値のうち、どちらか大きい方です。計算は次の式で表されます。

```
recommendation = max(memory-usage-in-oom-event + oom-min-bump-up-bytes, memory-usage-in-oom-event * oom-bump-up-ratio)
```

メモリーの増加量は、レコメンダー Pod で次の値を指定して設定できます。

- **oom-min-bump-up-bytes**。この値 (バイト単位) は、OOM イベントが発生した後のメモリーの具体的な増加量です。デフォルトは **100MiB** です。
- **oom-bump-up-ratio**。この値は、OOM イベント発生時のメモリーの増加率です。デフォルト値は **1.2** です。

たとえば、OOM イベント中の Pod メモリー使用量が 100 MB で、**oom-min-bump-up-bytes** が 150 MB に設定され、**oom-min-bump-ratio** が 1.2 に設定されている場合。OOM イベントの後、VPA では、その Pod のメモリー要求を 120 MB (100 MB * 1.2) よりも高い 150 MB に増やすことを推奨します。

レコメンダーの Deployment オブジェクトの例

```
apiVersion: apps/v1
kind: Deployment
metadata:
  name: vpa-recommender-default
  namespace: openshift-vertical-pod-autoscaler
# ...
spec:
# ...
  template:
# ...
    spec
      containers:
      - name: recommender
        args:
        - --oom-bump-up-ratio=2.0
        - --oom-min-bump-up-bytes=524288000
# ...
```

関連情報

- [OOM の強制終了ポリシーについて](#)

2.5.3.7. 代替のレコメンダーを使用する

独自のレコメンダーを使用して、独自のアルゴリズムに基づいて自動スケーリングできます。代替レコメンダーを指定しない場合、OpenShift Container Platform はデフォルトのレコメンダーを使用します。これは、過去の使用状況に基づいて CPU およびメモリー要求を提案します。すべてのタイプのワークロードに適用されるユニバーサルレコメンデーションポリシーはないため、特定のワークロードに対して異なるレコメンダーを作成してデプロイメントすることを推奨します。

たとえば、コンテナが特定のリソース動作を示している場合、デフォルトのレコメンダーは将来のリソース使用量を正確に予測できない可能性があります。例としては、監視アプリケーションで使用される使用量の急増とアイドル状態が交互に繰り返される周期的なパターンや、ディープラーニングアプリケーションで使用される繰り返しパターンなどがあります。これらの使用動作でデフォルトのレコメンダーを使用すると、アプリケーションのプロビジョニングが大幅に過剰になり、Out of Memory (OOM) が強制終了される可能性があります。



注記

レコメンダーを作成する方法については、このドキュメントの範囲外です。

手順

Pod に代替のレコメンダーを使用するには:

1. 代替レコメンダーのサービスアカウントを作成し、そのサービスアカウントを必要なクラスターロールにバインドします。

```

apiVersion: v1 1
kind: ServiceAccount
metadata:
  name: alt-vpa-recommender-sa
  namespace: <namespace_name>
---
apiVersion: rbac.authorization.k8s.io/v1 2
kind: ClusterRoleBinding
metadata:
  name: system:example-metrics-reader
roleRef:
  apiGroup: rbac.authorization.k8s.io
  kind: ClusterRole
  name: system:metrics-reader
subjects:
- kind: ServiceAccount
  name: alt-vpa-recommender-sa
  namespace: <namespace_name>
---
apiVersion: rbac.authorization.k8s.io/v1 3
kind: ClusterRoleBinding
metadata:
  name: system:example-vpa-actor
roleRef:
  apiGroup: rbac.authorization.k8s.io
  kind: ClusterRole
  name: system:vpa-actor
subjects:
- kind: ServiceAccount
  name: alt-vpa-recommender-sa
  namespace: <namespace_name>
---
apiVersion: rbac.authorization.k8s.io/v1 4
kind: ClusterRoleBinding
metadata:
  name: system:example-vpa-target-reader-binding
roleRef:
  apiGroup: rbac.authorization.k8s.io
  kind: ClusterRole
  name: system:vpa-target-reader
subjects:
- kind: ServiceAccount
  name: alt-vpa-recommender-sa
  namespace: <namespace_name>

```

- 1 レコメンダーを表示する namespace にレコメンダーのサービスアカウントを作成します。
 - 2 レコメンダーサービスアカウントを **metrics-reader** ロールにバインドします。レコメンダーをデプロイする場所の namespace を指定します。
 - 3 レコメンダーサービスアカウントを **vpa-actor** ロールにバインドします。レコメンダーをデプロイする場所の namespace を指定します。
 - 4 レコメンダーサービスアカウントを **vpa-target-reader** ロールにバインドします。レコメンダーを表示する namespace を指定します。
2. 代替レコメンダーをクラスターに追加するには、次のような **Deployment** オブジェクトを作成します。

```

apiVersion: apps/v1
kind: Deployment
metadata:
  name: alt-vpa-recommender
  namespace: <namespace_name>
spec:
  replicas: 1
  selector:
    matchLabels:
      app: alt-vpa-recommender
  template:
    metadata:
      labels:
        app: alt-vpa-recommender
    spec:
      containers: 1
      - name: recommender
        image: quay.io/example/alt-recommender:latest 2
        imagePullPolicy: Always
        resources:
          limits:
            cpu: 200m
            memory: 1000Mi
          requests:
            cpu: 50m
            memory: 500Mi
        ports:
          - name: prometheus
            containerPort: 8942
        securityContext:
          allowPrivilegeEscalation: false
          capabilities:
            drop:
              - ALL
          seccompProfile:
            type: RuntimeDefault
        serviceAccountName: alt-vpa-recommender-sa 3
        securityContext:
          runAsNonRoot: true

```

- ❶ 代替レコメンダーのコンテナを作成します。
- ❷ 推奨イメージを指定します。
- ❸ レコメンダー用に作成したサービスアカウントを関連付けます。

同じ namespace 内の代替レコメンダー用に新しい Pod が作成されます。

```
$ oc get pods
```

出力例

```
NAME                                READY STATUS RESTARTS AGE
frontend-845d5478d-558zf            1/1   Running 0      4m25s
frontend-845d5478d-7z9gx            1/1   Running 0      4m25s
frontend-845d5478d-b7l4j            1/1   Running 0      4m25s
vpa-alt-recommender-55878867f9-6tp5v 1/1   Running 0      9s
```

3. 代替レコメンダー **Deployment** オブジェクトの名前を含む Vertical Pod Autoscaler Operator (VPA) カスタムリソース (CR) を設定します。

代替レコメンダーを含めるための VPA CR の例

```
apiVersion: autoscaling.k8s.io/v1
kind: VerticalPodAutoscaler
metadata:
  name: vpa-recommender
  namespace: <namespace_name>
spec:
  recommenders:
    - name: alt-vpa-recommender ❶
  targetRef:
    apiVersion: "apps/v1"
    kind: Deployment ❷
    name: frontend
```

- ❶ 代替レコメンダーデプロイメントの名前を指定します。
- ❷ この VPA で管理する既存のワークロードオブジェクトの名前を指定します。

2.5.4. Vertical Pod Autoscaler Operator の使用

VPA カスタムリソース (CR) を作成して、Vertical Pod Autoscaler Operator (VPA) を使用できます。CR は分析する Pod を示し、それらの Pod に対して VPA が実行するアクションを決定します。

前提条件

- 自動スケーリングするワークロードオブジェクトが存在することを確認します。
- 代替レコメンダーを使用する場合は、そのレコメンダーを含むデプロイメントが存在することを確認してください。

手順

特定のワークロードオブジェクトの VPA CR を作成するには、以下を実行します。

1. スケーリングするワークロードオブジェクトのプロジェクトの場所に切り替えます。
 - a. VPA CR YAML ファイルを作成します。

```
apiVersion: autoscaling.k8s.io/v1
kind: VerticalPodAutoscaler
metadata:
  name: vpa-recommender
spec:
  targetRef:
    apiVersion: "apps/v1"
    kind: Deployment ❶
    name: frontend ❷
  updatePolicy:
    updateMode: "Auto" ❸
  resourcePolicy: ❹
    containerPolicies:
      - containerName: my-opt-sidecar
        mode: "Off"
  recommenders: ❺
    - name: my-recommender
```

- ❶ この VPA が管理するワークロードオブジェクトのタイプ (**Deployment**、**StatefulSet**、**Job**、**DaemonSet**、**ReplicaSet**、または **ReplicationController**) を指定します。
- ❷ この VPA が管理する既存のワークロードオブジェクトの名前を指定します。
- ❸ VPA モードを指定します。
 - **Auto** は、コントローラーに関連付けられた Pod に推奨リソースを自動的に適用します。VPA は既存の Pod を終了し、推奨されるリソース制限および要求で新規 Pod を作成します。
 - **Recreate** は、ワークロードオブジェクトに関連付けられた Pod に推奨リソースを自動的に適用します。VPA は既存の Pod を終了し、推奨されるリソース制限および要求で新規 Pod を作成します。**Recreate** モードが使用されることはほとんどありません。リソース要求の変更に応じて Pod を必ず再起動させたい場合に限定して使用します。
 - **Initial** は、ワークロードオブジェクトに関連付けられた新しく作成された Pod に推奨リソースを自動的に適用します。VPA は、新しい推奨リソースを確認する際に Pod を更新しません。
 - **Off** は、ワークロードオブジェクトに関連付けられた Pod の推奨リソースのみを生成します。VPA は、新しい推奨リソースを確認する際に Pod を更新しません。また、新規 Pod に推奨事項を適用しません。
- ❹ オプション: オプトアウトするコンテナを指定し、モードを **Off** に設定します。
- ❺ オプション: レコメンダーの推奨者を指定します。

b. VPA CR を作成します。

```
$ oc create -f <file-name>.yaml
```

しばらくすると、VPA はワークロードオブジェクトに関連付けられた Pod 内のコンテナのリソース使用状況を確認します。

次のコマンドを使用して、VPA の推奨値を表示できます。

```
$ oc get vpa <vpa-name> --output yaml
```

出力には、以下のような CPU およびメモリー要求の推奨事項が表示されます。

出力例

```
...
status:
...

recommendation:
  containerRecommendations:
    - containerName: frontend
      lowerBound: ①
        cpu: 25m
        memory: 262144k
      target: ②
        cpu: 25m
        memory: 262144k
      uncappedTarget: ③
        cpu: 25m
        memory: 262144k
      upperBound: ④
        cpu: 262m
        memory: "274357142"
    - containerName: backend
      lowerBound:
        cpu: 12m
        memory: 131072k
      target:
        cpu: 12m
        memory: 131072k
      uncappedTarget:
        cpu: 12m
        memory: 131072k
      upperBound:
        cpu: 476m
        memory: "498558823"
  ...
```

① **lowerBound** は、推奨リソースの最小レベルです。

② **target** は、推奨リソースのレベルです。

- 3 **upperBound** は、推奨リソースの最大レベルです。
- 4 **uncappedTarget** は最新の推奨リソースです。

2.5.5. Vertical Pod Autoscaler Operator のアンインストール

Vertical Pod Autoscaler Operator (VPA) を OpenShift Container Platform クラスターから削除できます。アンインストール後、既存の VPA カスタムリソース (CR) によってすでに変更されている Pod のリソース要求は変更されません。VPA によって行われた以前の推奨事項ではなく、ワークロードオブジェクトで定義されたリソースが、新しい Pod に割り当てられます。



注記


oc delete vpa <vpa-name> コマンドを使用して、特定の VPA CR を削除できます。Vertical Pod Autoscaler のアンインストール時と同じアクションがリソース要求に対して適用されます。

VPA を削除した後、潜在的な問題を回避するために、Operator に関連する他のコンポーネントを削除することを推奨します。

前提条件

- VPA をインストールしている。

手順

1. OpenShift Container Platform Web コンソールで、**Operators → Installed Operators** をクリックします。
2. **openshift-vertical-pod-autoscaler** プロジェクトに切り替えます。
3. **VerticalPodAutoscaler** Operator の場合は、Options メニュー  をクリックし、**Uninstall Operator** を選択します。
4. オプション: Operator に関連付けられているすべてのオペランドを削除するには、ダイアログボックスで **Delete all operand instances for this operator** チェックボックスをオンにします。
5. **Uninstall** をクリックします。
6. オプション: OpenShift CLI を使用して VPA コンポーネントを削除します。
 - a. VPA namespace を削除します。

```
$ oc delete namespace openshift-vertical-pod-autoscaler
```

- b. VPA カスタムリソース定義 (CRD) オブジェクトを削除します。

```
$ oc delete crd verticalpodautoscalercheckpoints.autoscaling.k8s.io
```

```
$ oc delete crd verticalpodautoscalercontrollers.autoscaling.openshift.io
```

```
$ oc delete crd verticalpodautoscalers.autoscaling.k8s.io
```

CRD を削除すると、関連付けられたロール、クラスターロール、およびロールバインディングが削除されます。



注記

この操作により、ユーザーが作成したすべての VPA CR がクラスターから削除されます。VPA を再インストールする場合は、これらのオブジェクトを再度作成する必要があります。

- c. 次のコマンドを実行して **MutatingWebhookConfiguration** オブジェクトを削除します。

```
$ oc delete MutatingWebhookConfiguration vpa-webhook-config
```

- d. VPA Operator を削除します。

```
$ oc delete operator/vertical-pod-autoscaler.openshift-vertical-pod-autoscaler
```

2.6. POD への機密性の高いデータの提供

アプリケーションによっては、パスワードやユーザー名など開発者に使用させない秘密情報が必要になります。

管理者は、**Secret** オブジェクトを使用して、機密情報をクリアテキストで公開せずに提供できます。

2.6.1. シークレットについて

Secret オブジェクトタイプはパスワード、OpenShift Container Platform クライアント設定ファイル、プライベートソースリポジトリの認証情報などの機密情報を保持するメカニズムを提供します。シークレットは機密内容を Pod から切り離します。シークレットはボリュームプラグインを使用してコンテナにマウントすることも、システムが Pod の代わりにシークレットを使用して各種アクションを実行することもできます。

キーのプロパティには以下が含まれます。

- シークレットデータはその定義とは別に参照できます。
- シークレットデータのボリュームは一時ファイルストレージ機能 (tmpfs) でサポートされ、ノードで保存されることはありません。
- シークレットデータは namespace 内で共有できます。

YAML Secret オブジェクト定義

```
apiVersion: v1
kind: Secret
metadata:
  name: test-secret
  namespace: my-namespace
type: Opaque ❶
data: ❷
```

```
username: <username> ③
password: <password>
stringData: ④
hostname: myapp.mydomain.com ⑤
```

- ① シークレットにキー名および値の構造を示しています。
- ② **data** フィールドのキーに使用可能な形式は、[Kubernetes identifiers glossary](#) の **DNS_SUBDOMAIN** 値のガイドラインに従う必要があります。
- ③ **data** マップのキーに関連付けられる値は base64 でエンコーディングされている必要があります。
- ④ **stringData** マップのエントリーが base64 に変換され、このエントリーは自動的に **data** マップに移動します。このフィールドは書き込み専用です。この値は **data** フィールドでのみ返されます。
- ⑤ **stringData** マップのキーに関連付けられた値は単純なテキスト文字列で構成されます。

シークレットに依存する Pod を作成する前に、シークレットを作成する必要があります。

シークレットの作成時に以下を実行します。

- シークレットデータでシークレットオブジェクトを作成します。
- Pod のサービスアカウントをシークレットの参照を許可するように更新します。
- シークレットを環境変数またはファイルとして使用する Pod を作成します (**secret** ボリュームを使用)。

2.6.1.1. シークレットの種類

type フィールドの値で、シークレットのキー名と値の構造を指定します。このタイプを使用して、シークレットオブジェクトにユーザー名とキーの配置を実行できます。検証の必要がない場合には、デフォルト設定の **opaque** タイプを使用してください。

以下のタイプから1つ指定して、サーバー側で最小限の検証をトリガーし、シークレットデータに固有のキー名が存在することを確認します。

- **kubernetes.io/basic-auth**: Basic 認証で使用します。
- **kubernetes.io/dockercfg**: イメージプルシークレットとして使用します。
- **kubernetes.io/dockerconfigjson**: イメージプルシークレットとして使用します。
- **kubernetes.io/service-account-token**: レガシーサービスアカウント API トークンの取得に使用します。
- **kubernetes.io/ssh-auth**: SSH キー認証で使用します。
- **kubernetes.io/tls**: TLS 認証局で使用します。

検証が必要ない場合には **type: Opaque** と指定します。これは、シークレットがキー名または値の規則に準拠しないという意味です。**opaque** シークレットでは、任意の値を含む、体系化されていない **key:value** ペアも利用できます。



注記

example.com/my-secret-type などの他の任意のタイプを指定できます。これらのタイプはサーバー側では実行されませんが、シークレットの作成者がその種類のキー/値の要件に従う意図があることを示します。

さまざまな種類のシークレットを作成する例は、**シークレットの作成方法** を参照してください。

2.6.1.2. シークレットデータキー

シークレットキーは DNS サブドメインになければなりません。

2.6.1.3. 自動生成されるサービスアカウントトークンシークレット

サービスアカウントが作成されると、そのサービスアカウント用のトークンシークレットが自動的に生成されます。このサービスアカウントトークンシークレットは、自動的に生成された Docker 設定シークレットとともに、内部 OpenShift Container Platform レジストリーに対する認証に使用されます。これらの自動生成されたシークレットは、自分での使用に依存することがないようにしてください。これらは将来の OpenShift Container Platform リリースで削除される可能性があります。



注記

OpenShift Container Platform 4.11 より前では、サービスアカウントの作成時に 2 番目のサービスアカウントトークンシークレットが生成されました。このサービスアカウントトークンシークレットは、Kubernetes API へのアクセスに使用されていました。

OpenShift Container Platform 4.11 以降、この 2 番目のサービスアカウントトークンシークレットは作成されなくなりました。これは、**LegacyServiceAccountTokenNoAutoGeneration** アップストリーム Kubernetes フィーチャゲートが有効になっており、Kubernetes API にアクセスするためのシークレットベースのサービスアカウントトークンの自動生成が停止されているためです。

4.12 にアップグレードした後も、既存のサービスアカウントトークンシークレットは削除されず、引き続き機能します。

バインドされたサービスアカウントトークンを取得するために、ワークロードに Projected ボリュームが自動的に注入されます。ワークロードに追加のサービスアカウントトークンが必要な場合は、ワークロードマニフェストに追加の予測ボリュームを追加します。バインドされたサービスアカウントトークンは、次の理由により、サービスアカウントトークンのシークレットよりも安全です。

- バインドされたサービスアカウントトークンには有効期間が制限されています。
- バインドされたサービスアカウントトークンには対象ユーザーが含まれます。
- バインドされたサービスアカウントトークンは Pod またはシークレットにバインドでき、バインドされたオブジェクトが削除されるとバインドされたトークンは無効になります。

詳細は、**ボリュームプロジェクションを使用したバインドされたサービスアカウントトークンの設定** を参照してください。

読み取り可能な API オブジェクト内の有効期限のないトークンのセキュリティ露出が許容される場合は、サービスアカウントトークンシークレットを手動で作成してトークンを取得することもできます。詳細は、**サービスアカウントトークンシークレットの作成** を参照してください。

関連情報

- バインドされたサービスアカウントトークンの要求については、[バインドされたサービスアカウントトークンの使用](#) を参照してください。
- サービスアカウントトークンシークレットの作成については、[サービスアカウントトークンシークレットの作成](#) を参照してください。

2.6.2. シークレットの作成方法

管理者は、開発者がシークレットに依存する Pod を作成できるよう事前にシークレットを作成しておく必要があります。

シークレットの作成時に以下を実行します。

1. 秘密にしておきたいデータを含む秘密オブジェクトを作成します。各シークレットタイプに必要な特定のデータは、以下のセクションで非表示になります。

不透明なシークレットを作成する YAML オブジェクトの例

```
apiVersion: v1
kind: Secret
metadata:
  name: test-secret
type: Opaque ❶
data: ❷
  username: <username>
  password: <password>
stringData: ❸
  hostname: myapp.mydomain.com
secret.properties: |
  property1=valueA
  property2=valueB
```

- ❶ シークレットのタイプを指定します。
- ❷ エンコードされた文字列およびデータを指定します。
- ❸ デコードされた文字列およびデータを指定します。

data フィールドまたは **stringdata** フィールドの両方ではなく、いずれかを使用してください。

2. Pod のサービスアカウントをシークレットを参照するように更新します。

シークレットを使用するサービスアカウントの YAML

```
apiVersion: v1
kind: ServiceAccount
...
secrets:
- name: test-secret
```

3. シークレットを環境変数またはファイルとして使用する Pod を作成します (**secret** ボリュームを使用)。

シークレットデータと共にボリュームのファイルが設定された Pod の YAML

```

apiVersion: v1
kind: Pod
metadata:
  name: secret-example-pod
spec:
  containers:
    - name: secret-test-container
      image: busybox
      command: [ "/bin/sh", "-c", "cat /etc/secret-volume/*" ]
      volumeMounts: ❶
        - name: secret-volume
          mountPath: /etc/secret-volume ❷
          readOnly: true ❸
  volumes:
    - name: secret-volume
      secret:
        secretName: test-secret ❹
  restartPolicy: Never

```

- ❶ シークレットが必要な各コンテナに **volumeMounts** フィールドを追加します。
- ❷ シークレットが表示される未使用のディレクトリー名を指定します。シークレットデータマップの各キーは **mountPath** の下にあるファイル名になります。
- ❸ **true** に設定します。true の場合、ドライバーに読み取り専用ボリュームを提供するように指示します。
- ❹ シークレットの名前を指定します。

シークレットデータと共に環境変数が設定された Pod の YAML

```

apiVersion: v1
kind: Pod
metadata:
  name: secret-example-pod
spec:
  containers:
    - name: secret-test-container
      image: busybox
      command: [ "/bin/sh", "-c", "export" ]
      env:
        - name: TEST_SECRET_USERNAME_ENV_VAR
          valueFrom:
            secretKeyRef: ❶
              name: test-secret
              key: username
  restartPolicy: Never

```

- 1 シークレットキーを使用する環境変数を指定します。

シークレットデータと環境変数が設定されたビルド設定の YAML

```
apiVersion: build.openshift.io/v1
kind: BuildConfig
metadata:
  name: secret-example-bc
spec:
  strategy:
    sourceStrategy:
      env:
        - name: TEST_SECRET_USERNAME_ENV_VAR
          valueFrom:
            secretKeyRef: 1
            name: test-secret
            key: username
      from:
        kind: ImageStreamTag
        namespace: openshift
        name: 'cli:latest'
```

- 1 シークレットキーを使用する環境変数を指定します。

2.6.2.1. シークレットの作成に関する制限

シークレットを使用するには、Pod がシークレットを参照できる必要があります。シークレットは、以下の 3 つの方法で Pod で使用されます。

- コンテナの環境変数を事前に設定するために使用される。
- 1 つ以上のコンテナにマウントされるボリュームのファイルとして使用される。
- Pod のイメージをプルする際に kubelet によって使用される。

ボリュームタイプのシークレットは、ボリュームメカニズムを使用してデータをファイルとしてコンテナに書き込みます。イメージプルシークレットは、シークレットを namespace のすべての Pod に自動的に挿入するためにサービスアカウントを使用します。

テンプレートにシークレット定義が含まれる場合、テンプレートで指定のシークレットを使用できるようにするには、シークレットのボリュームソースを検証し、指定されるオブジェクト参照が **Secret** オブジェクトを実際に参照していることを確認する必要があります。そのため、シークレットはこれに依存する Pod の作成前に作成されている必要があります。最も効果的な方法として、サービスアカウントを使用してシークレットを自動的に注入することができます。

シークレット API オブジェクトは namespace にあります。それらは同じ namespace の Pod によってのみ参照されます。

個々のシークレットは 1MB のサイズに制限されます。これにより、apiserver および kubelet メモリーを使い切るような大規模なシークレットの作成を防ぐことができます。ただし、小規模なシークレットであってもそれらを数多く作成するとメモリーの消費につながります。

2.6.2.2. 不透明なシークレットの作成

管理者は、不透明なシークレットを作成できます。これにより、任意の値を含むことができる非構造化 **key:value** のペアを格納できます。

手順

1. コントロールプレーンノードの YAML ファイルに **Secret** オブジェクトを作成します。
以下に例を示します。

```
apiVersion: v1
kind: Secret
metadata:
  name: mysecret
type: Opaque ❶
data:
  username: <username>
  password: <password>
```

- ❶ 不透明なシークレットを指定します。

2. 以下のコマンドを使用して **Secret** オブジェクトを作成します。

```
$ oc create -f <filename>.yaml
```

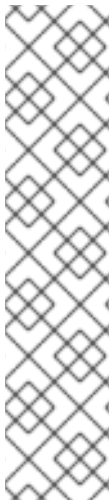
3. Pod でシークレットを使用するには、以下を実行します。
 - a. 「シークレットの作成方法について」セクションで説明されているとおり、Pod のサービスアカウントを更新してシークレットを参照します。
 - b. 「シークレットの作成方法について」で説明されているとおり、シークレットを環境変数またはファイル (**secret** ボリュームを使用) として使用する Pod を作成します。

関連情報

- Pod でのシークレットの使用の詳細については、[シークレットの作成方法について](#) を参照してください。

2.6.2.3. サービスアカウントトークンシークレットの作成

管理者は、サービスアカウントトークンシークレットを作成できます。これにより、API に対して認証する必要のあるアプリケーションにサービスアカウントトークンを配布できます。



注記

サービスアカウントトークンシークレットを使用する代わりに、TokenRequest API を使用してバインドされたサービスアカウントトークンを取得することを推奨します。TokenRequest API から取得したトークンは、有効期間が制限されており、他の API クライアントが読み取れないため、シークレットに保存されているトークンよりも安全です。

TokenRequest API を使用できず、読み取り可能な API オブジェクトで有効期限が切れていないトークンのセキュリティーエクスポージャーが許容できる場合にのみ、サービスアカウントトークンシークレットを作成する必要があります。

バインドされたサービスアカウントトークンの作成に関する詳細は、以下の追加リソースセクションを参照してください。

手順

1. コントロールプレーンノードの YAML ファイルに **Secret** オブジェクトを作成します。

secret オブジェクトの例:

```
apiVersion: v1
kind: Secret
metadata:
  name: secret-sa-sample
  annotations:
    kubernetes.io/service-account.name: "sa-name" ❶
type: kubernetes.io/service-account-token ❷
```

- ❶ 既存のサービスアカウント名を指定します。**ServiceAccount** と **Secret** オブジェクトの両方を作成する場合は、**ServiceAccount** オブジェクトを最初に作成します。

- ❷ サービスアカウントトークンシークレットを指定します。

2. 以下のコマンドを使用して **Secret** オブジェクトを作成します。

```
$ oc create -f <filename>.yaml
```

3. Pod でシークレットを使用するには、以下を実行します。
 - a. 「シークレットの作成方法について」セクションで説明されているとおり、Pod のサービスアカウントを更新してシークレットを参照します。
 - b. 「シークレットの作成方法について」で説明されているとおり、シークレットを環境変数またはファイル (**secret** ボリュームを使用) として使用する Pod を作成します。

関連情報

- Pod でのシークレットの使用の詳細については、[シークレットの作成方法について](#) を参照してください。
- バインドされたサービスアカウントトークンの要求については、[バインドされたサービスアカウントトークンの使用](#) を参照してください。

- サービスアカウントの作成については、[サービスアカウントの概要と作成](#) を参照してください。

2.6.2.4. Basic 認証シークレットの作成

管理者は Basic 認証シークレットを作成できます。これにより、Basic 認証に必要な認証情報を保存できます。このシークレットタイプを使用する場合は、**Secret** オブジェクトの **data** パラメーターには、base64 形式でエンコードされた以下のキーが含まれている必要があります。

- **username**: 認証用のユーザー名
- **password**: 認証のパスワードまたはトークン



注記

stringData パラメーターを使用して、クリアテキストコンテンツを使用できます。

手順

1. コントロールプレーンノードの YAML ファイルに **Secret** オブジェクトを作成します。

secret オブジェクトの例

```
apiVersion: v1
kind: Secret
metadata:
  name: secret-basic-auth
type: kubernetes.io/basic-auth 1
data:
stringData: 2
  username: admin
  password: <password>
```

- 1** Basic 認証のシークレットを指定します。
- 2** 使用する Basic 認証値を指定します。

2. 以下のコマンドを使用して **Secret** オブジェクトを作成します。

```
$ oc create -f <filename>.yaml
```

3. Pod でシークレットを使用するには、以下を実行します。
 - a. 「シークレットの作成方法について」セクションで説明されているとおり、Pod のサービスアカウントを更新してシークレットを参照します。
 - b. 「シークレットの作成方法について」で説明されているとおり、シークレットを環境変数またはファイル (**secret** ボリュームを使用) として使用する Pod を作成します。

関連情報

- Pod でのシークレットの使用の詳細については、[シークレットの作成方法について](#) を参照してください。

2.6.2.5. SSH 認証シークレットの作成

管理者は、SSH 認証シークレットを作成できます。これにより、SSH 認証に使用されるデータを保存できます。このシークレットタイプを使用する場合、**Secret** オブジェクトの **data** パラメーターには、使用する SSH 認証情報が含まれている必要があります。

手順

1. コントロールプレーンノードの YAML ファイルに **Secret** オブジェクトを作成します。

secret オブジェクトの例:

```
apiVersion: v1
kind: Secret
metadata:
  name: secret-ssh-auth
type: kubernetes.io/ssh-auth ❶
data:
  ssh-privatekey: | ❷
    MIIEpQIBAAKCAQEAulqb/Y ...
```

- ❶ SSH 認証シークレットを指定します。
- ❷ SSH のキー/値のペアを、使用する SSH 認証情報として指定します。

2. 以下のコマンドを使用して **Secret** オブジェクトを作成します。

```
$ oc create -f <filename>.yaml
```

3. Pod でシークレットを使用するには、以下を実行します。
 - a. 「シークレットの作成方法について」セクションで説明されているとおり、Pod のサービスアカウントを更新してシークレットを参照します。
 - b. 「シークレットの作成方法について」で説明されているとおり、シークレットを環境変数またはファイル (**secret** ボリュームを使用) として使用する Pod を作成します。

関連情報

- [シークレットの作成方法を理解する。](#)

2.6.2.6. Docker 設定シークレットの作成

管理者は Docker 設定シークレットを作成できます。これにより、コンテナイメージレジストリーにアクセスするための認証情報を保存できます。

- **kubernetes.io/dockercfg**: このシークレットタイプを使用してローカルの Docker 設定ファイルを保存します。**secret** オブジェクトの **data** パラメーターには、base64 形式でエンコードされた **.dockercfg** ファイルの内容が含まれている必要があります。
- **kubernetes.io/dockerconfigjson**: このシークレットタイプを使用して、ローカルの Docker 設定 JSON ファイルを保存します。**secret** オブジェクトの **data** パラメーターには、base64 形式でエンコードされた **.docker/config.json** ファイルの内容が含まれている必要があります。

手順

1. コントロールプレーンノードの YAML ファイルに **Secret** オブジェクトを作成します。

Docker 設定の secret オブジェクトの例

```
apiVersion: v1
kind: Secret
metadata:
  name: secret-docker-cfg
  namespace: my-project
type: kubernetes.io/dockerconfig 1
data:

.dockerconfig:bm5ubm5ubm5ubm5ubm5ubm5ubmdnZ2dnZ2dnZ2dnZ2dnZ2cgYXV0aCBrZXlzcG== 2
```

- 1** シークレットが Docker 設定ファイルを使用することを指定します。
- 2** base64 でエンコードされた Docker 設定ファイルの出力

Docker 設定の JSON secret オブジェクトの例

```
apiVersion: v1
kind: Secret
metadata:
  name: secret-docker-json
  namespace: my-project
type: kubernetes.io/dockerconfig 1
data:

.dockerconfigjson:bm5ubm5ubm5ubm5ubm5ubm5ubmdnZ2dnZ2dnZ2dnZ2dnZ2cgYXV0aCBrZXlzcG== 2
```

- 1** シークレットが Docker 設定の JSON ファイルを使用することを指定します。
- 2** base64 でエンコードされた Docker 設定 JSON ファイルの出力

2. 以下のコマンドを使用して **Secret** オブジェクトを作成します。

```
$ oc create -f <filename>.yaml
```

3. Pod でシークレットを使用するには、以下を実行します。
 - a. 「シークレットの作成方法について」セクションで説明されているとおり、Pod のサービスアカウントを更新してシークレットを参照します。
 - b. 「シークレットの作成方法について」で説明されているとおり、シークレットを環境変数またはファイル (**secret** ボリュームを使用) として使用する Pod を作成します。

関連情報

- Pod でのシークレットの使用の詳細については、[シークレットの作成方法について](#) を参照してください。

2.6.2.7. Web コンソールを使用したシークレットの作成

Web コンソールを使用してシークレットを作成できます。

手順

1. **Workloads** → **Secrets** に移動します。
2. **Create** → **From YAML** をクリックします。
 - a. 仕様に合わせて YAML を手動で編集するか、ファイルを YAML エディターにドラッグアンドドロップします。以下に例を示します。

```
apiVersion: v1
kind: Secret
metadata:
  name: example
  namespace: <namespace>
type: Opaque 1
data:
  username: <base64 encoded username>
  password: <base64 encoded password>
stringData: 2
  hostname: myapp.mydomain.com
```

- 1** この例では、不透明なシークレットを指定します。ただし、サービスアカウントトークンシークレット、基本認証シークレット、SSH 認証シークレット、Docker 設定を使用するシークレットなど、他のシークレットタイプが表示される場合があります。
- 2** **stringData** マップのエントリーが base64 に変換され、このエントリーは自動的に **data** マップに移動します。このフィールドは書き込み専用です。この値は **data** フィールドでのみ返されます。

3. **Create** をクリックします。
4. **Add Secret to workload** をクリックします。
 - a. ドロップダウンメニューから、追加するワークロードを選択します。
 - b. **Save** をクリックします。

2.6.3. シークレットの更新方法

シークレットの値を変更する場合、値 (すでに実行されている Pod で使用される値) は動的に変更されません。シークレットを変更するには、元の Pod を削除してから新規の Pod を作成する必要があります (同じ PodSpec を使用する場合があります)。

シークレットの更新は、新規コンテナイメージのデプロイメントと同じワークフローで実行されます。**kubectl rolling-update** コマンドを使用できます。

シークレットの **resourceVersion** 値は参照時に指定されません。したがって、シークレットが Pod の起動と同じタイミングで更新される場合、Pod に使用されるシークレットのバージョンは定義されません。



注記

現時点で、Pod の作成時に使用されるシークレットオブジェクトのリソースバージョンを確認することはできません。コントローラーが古い **resourceVersion** を使用して Pod を再起動できるように、Pod がこの情報を報告できるようにすることが予定されています。それまでは既存シークレットのデータを更新せずに別の名前で新規のシークレットを作成します。

2.6.4. シークレットの作成および使用

管理者は、サービスアカウントトークンシークレットを作成できます。これにより、サービスアカウントトークンを API に対して認証する必要のあるアプリケーションに配布できます。

手順

1. 以下のコマンドを実行して namespace にサービスアカウントを作成します。

```
$ oc create sa <service_account_name> -n <your_namespace>
```

2. 以下の YAML の例は **service-account-token-secret.yaml** という名前のファイルに保存します。この例には、サービスアカウントトークンの生成に使用可能な **Secret** オブジェクト設定が含まれています。

```
apiVersion: v1
kind: Secret
metadata:
  name: <secret_name> ❶
  annotations:
    kubernetes.io/service-account.name: "sa-name" ❷
type: kubernetes.io/service-account-token ❸
```

- ❶ **<secret_name>** は、サービストークンシークレットの名前に置き換えます。
- ❷ 既存のサービスアカウント名を指定します。**ServiceAccount** と **Secret** オブジェクトの両方を作成する場合は、**ServiceAccount** オブジェクトを最初に作成します。
- ❸ サービスアカウントトークンシークレットタイプを指定します。

3. ファイルを適用してサービスアカウントトークンを生成します。

```
$ oc apply -f service-account-token-secret.yaml
```

4. 以下のコマンドを実行して、シークレットからサービスアカウントトークンを取得します。

```
$ oc get secret <sa_token_secret> -o jsonpath='{.data.token}' | base64 --decode ❶
```

出力例

ayJhbGciOiJSUzI1NiIsImtpZCI6IklOb2d2ctk1qZ3hCSWp0Nnh5YnZhSE9QMkk3YnRZMVZocFlF
QTZfRFp1YlUifQ.eyJpc3MiOiJrdWJlcm5ldGVzL3NlcnZpY2VhY2NvdW50liwia3ViZXJuZXRlcy5
pby9zZXJ2aWNIYWNIb3VudC9uYW1lc3BhY2UiOiJkZWZhdWx0liwia3ViZXJuZXRlcy5pby9zZX
J2aWNIYWNIb3VudC9zZWNIYXQubmFtZSI6ImJ1aWxkZXItZG9rZW4tdHJrbnliLjCjrdWJlcm5l
dGVzLmVlL3NlcnZpY2VhY2NvdW50L3NlcnZpY2UyYWNjb3VudC5uYW1lIjoieYnVpbGRlcilmt1
YmVybWV0ZXMuZW50V2VydmljZWZjY291bnQvc2VydmljZS1hY2NvdW50LnVpZCI6IjNmZGU
2MGZmLTAtNGYtNDkyZi04YzhjLTNjZjE0NDk3MmFmNyIsInN1Yil6InN5c3RlbTpozXJ2aWNI
YWNjb3VudDpkZWZhdWx0O0J1aWxkZXIifQ.OmqFTDuMHC_IYvvEURjr1x453hlEEHYcxS9VK
SzmRkP1SiVZWPNPkTWIfNRp6bIUZD3U6aN3N7dMSN0el5hu36xPgpKTdvuckKLTCnelMx6c
xOdAbrcw1mCmOCInscwjS1KO1kzMtYnnq8rXHiMJELsNIhnRyyIXRTtNBsy4t64T3283s3SLsa
ncyx0gy0ujx-Ch3uKAKdZi5iT-I8jnnQ-ds5THDs2h65RJhggIQEmSxpHrLGZFmyHAQI-
_SjvmHZPXEc482x3SkaQHNLqpmrpJorNqh1M8ZHKzlujhZgVooMvJmWPXTb2vnvi3DGn2XI-
hZxl1yD2yGH1RBpYUHA

- 1 <sa_token_secret> は、サービストークンシークレットの名前に置き換えます。

5. サービスアカウントトークンを使用して、クラスターの API で認証します。

```
$ curl -X GET <openshift_cluster_api> --header "Authorization: Bearer <token>" 1 2
```

- 1 **<openshift_cluster_api>** は OpenShift クラスター API に置き換えます。
- 2 **<token>** は、直前のコマンドで出力されるサービスアカウントトークンに置き換えます。

2.6.5. シークレットで署名証明書を使用する方法

サービスの通信を保護するため、プロジェクト内のシークレットに追加可能な、署名されたサービス証明書/キーペアを生成するように OpenShift Container Platform を設定することができます。

サービス提供証明書のシークレット は、追加設定なしの証明書を必要とする複雑なミドルウェアアプリケーションをサポートするように設計されています。これにはノードおよびマスターの管理者ツールで生成されるサーバー証明書と同じ設定が含まれます。

サービス提供証明書のシークレット用に設定されるサービス Pod 仕様

```
apiVersion: v1
kind: Service
metadata:
  name: registry
  annotations:
    service.beta.openshift.io/serving-cert-secret-name: registry-cert-1
# ...
```

- 1 証明書の名前を指定します。

他の Pod は Pod に自動的にマウントされる

/var/run/secrets/kubernetes.io/serviceaccount/service-ca.crt ファイルの CA バンドルを使用し、クラスターで作成される証明書 (内部 DNS 名の場合にのみ署名される) を信頼できます。

この機能の署名アルゴリズムは **x509.SHA256WithRSA** です。ローテーションを手動で実行するには、生成されたシークレットを削除します。新規の証明書が作成されます。

2.6.5.1. シークレットで使用する署名証明書の生成

署名されたサービス証明書/キーペアを Pod で使用するには、サービスを作成または編集して **service.beta.openshift.io/serving-cert-secret-name** アノテーションを追加した後に、シークレットを Pod に追加します。

手順

サービス提供証明書のシークレットを作成するには、以下を実行します。

1. サービスの **Pod** 仕様を編集します。
2. シークレットに使用する名前に **service.beta.openshift.io/serving-cert-secret-name** アノテーションを追加します。

```
kind: Service
apiVersion: v1
metadata:
  name: my-service
  annotations:
    service.beta.openshift.io/serving-cert-secret-name: my-cert 1
spec:
  selector:
    app: MyApp
  ports:
    - protocol: TCP
      port: 80
      targetPort: 9376
```

証明書およびキーは PEM 形式であり、それぞれ **tls.crt** および **tls.key** に保存されます。

3. サービスを作成します。

```
$ oc create -f <file-name>.yaml
```

4. シークレットを表示して、作成されていることを確認します。

- a. すべてのシークレットのリストを表示します。

```
$ oc get secrets
```

出力例

NAME	TYPE	DATA	AGE
my-cert	kubernetes.io/tls	2	9m

- b. シークレットの詳細を表示します。

```
$ oc describe secret my-cert
```

出力例

```
Name:      my-cert
Namespace: openshift-console
```

```

Labels:      <none>
Annotations: service.beta.openshift.io/expiry: 2023-03-08T23:22:40Z
             service.beta.openshift.io/originating-service-name: my-service
             service.beta.openshift.io/originating-service-uid: 640f0ec3-afc2-4380-bf31-
a8c784846a11
             service.beta.openshift.io/expiry: 2023-03-08T23:22:40Z

Type: kubernetes.io/tls

Data
====
tls.key: 1679 bytes
tls.crt: 2595 bytes

```

5. このシークレットを使用して **Pod** 仕様を編集します。

```

apiVersion: v1
kind: Pod
metadata:
  name: my-service-pod
spec:
  containers:
  - name: mypod
    image: redis
    volumeMounts:
    - name: my-container
      mountPath: "/etc/my-path"
  volumes:
  - name: my-volume
    secret:
      secretName: my-cert
      items:
      - key: username
        path: my-group/my-username
        mode: 511

```

これが利用可能な場合、Pod が実行されます。この証明書は内部サービス DNS 名、**<service.name>.<service.namespace>.svc** に適しています。

証明書/キーのペアは有効期限に近づくとき自動的に置換されます。シークレットの **service.beta.openshift.io/expiry** アノテーションで RFC3339 形式の有効期限の日付を確認します。



注記

ほとんどの場合、サービス DNS 名 **<service.name>.<service.namespace>.svc** は外部にルーティング可能ではありません。**<service.name>.<service.namespace>.svc** の主な使用方法として、クラスターまたはサービス間の通信用として、re-encrypt ルートで使用されます。

2.6.6. シークレットのトラブルシューティング

サービス証明書の生成は以下を出して失敗します (サービスの **service.beta.openshift.io/serving-cert-generation-error** アノテーションには以下が含まれます)。

-

```
secret/ssl-key references serviceUID 62ad25ca-d703-11e6-9d6f-0e9c0057b608, which does not
match 77b6dd80-d716-11e6-9d6f-0e9c0057b60
```

証明書を生成したサービスがすでに存在しないか、サービスに異なる **serviceUID** があります。古いシークレットを削除し、サービスのアノテーション (**service.beta.openshift.io/serving-cert-generation-error**、**service.beta.openshift.io/serving-cert-generation-error-num**) をクリアして証明書の再生成を強制的に実行する必要があります。

1. シークレットを削除します。

```
$ oc delete secret <secret_name>
```

2. アノテーションをクリアします。

```
$ oc annotate service <service_name> service.beta.openshift.io/serving-cert-generation-
error-
```

```
$ oc annotate service <service_name> service.beta.openshift.io/serving-cert-generation-
error-num-
```



注記

アノテーションを削除するコマンドでは、削除するアノテーション名の後に - を付けます。

2.7. 設定マップの作成および使用

以下のセクションでは、設定マップおよびそれらを作成し、使用方法を定義します。

2.7.1. 設定マップについて

多くのアプリケーションには、設定ファイル、コマンドライン引数、および環境変数の組み合わせを使用した設定が必要です。OpenShift Container Platform では、これらの設定アーティファクトは、コンテナ化されたアプリケーションを移植可能な状態に保つためにイメージコンテンツから切り離されます。

ConfigMap オブジェクトは、コンテナを OpenShift Container Platform に依存させないようにする一方で、コンテナに設定データを挿入するメカニズムを提供します。設定マップは、個々のプロパティなどの粒度の細かい情報や、設定ファイル全体または JSON Blob などの粒度の荒い情報を保存するために使用できます。

ConfigMap オブジェクトは、Pod で使用したり、コントローラーなどのシステムコンポーネントの設定データを保存するために使用できる設定データのキーと値のペアを保持します。以下に例を示します。

ConfigMap オブジェクト定義

```
kind: ConfigMap
apiVersion: v1
metadata:
  creationTimestamp: 2016-02-18T19:14:38Z
  name: example-config
  namespace: my-namespace
```

```
data: ①
  example.property.1: hello
  example.property.2: world
  example.property.file: |-
    property.1=value-1
    property.2=value-2
    property.3=value-3
binaryData:
  bar: L3Jvb3QvMTAw ②
```

- ① ① 設定データが含まれます。
- ② バイナリー Java キーストアファイルなどの UTF8 以外のデータを含むファイルを参照します。Base 64 のファイルデータを入力します。



注記

イメージなどのバイナリーファイルから設定マップを作成する場合に、**binaryData** フィールドを使用できます。

設定データはさまざまな方法で Pod 内で使用できます。設定マップは以下を実行するために使用できます。

- コンテナへの環境変数値の設定
- コンテナのコマンドライン引数の設定
- ボリュームの設定ファイルの設定

ユーザーとシステムコンポーネントの両方が設定データを設定マップに保存できます。

設定マップはシークレットに似ていますが、機密情報を含まない文字列の使用をより効果的にサポートするように設計されています。

設定マップの制限

設定マップは、コンテンツを Pod で使用される前に作成する必要があります。

コントローラーは、設定データが不足していても、その状況を許容して作成できます。ケースごとに設定マップを使用して設定される個々のコンポーネントを参照してください。

ConfigMap オブジェクトはプロジェクト内にあります。

それらは同じプロジェクトの Pod によってのみ参照されます。

Kubelet は、API サーバーから取得する Pod の設定マップの使用のみをサポートします。

これには、CLI を使用して作成された Pod、またはレプリケーションコントローラーから間接的に作成された Pod が含まれます。これには、OpenShift Container Platform ノードの **--manifest-url** フラグ、その **--config** フラグ、またはその REST API を使用して作成された Pod は含まれません (これらは Pod を作成する一般的な方法ではありません)。

2.7.2. OpenShift Container Platform Web コンソールでの設定マップの作成

OpenShift Container Platform Web コンソールで設定マップを作成できます。

手順

- クラスター管理者として設定マップを作成するには、以下を実行します。
 1. Administrator パースペクティブで **Workloads** → **Config Maps** を選択します。
 2. ページの右上にある **Create Config Map** を選択します。
 3. 設定マップの内容を入力します。
 4. **Create** を選択します。
- 開発者として設定マップを作成するには、以下を実行します。
 1. 開発者パースペクティブで、**Config Maps** を選択します。
 2. ページの右上にある **Create Config Map** を選択します。
 3. 設定マップの内容を入力します。
 4. **Create** を選択します。

2.7.3. CLI を使用して設定マップを作成する

以下のコマンドを使用して、ディレクトリー、特定のファイルまたはリテラル値から設定マップを作成できます。

手順

- 設定マップの作成

```
$ oc create configmap <configmap_name> [options]
```

2.7.3.1. ディレクトリーからの設定マップの作成

--from-file フラグを使用すると、ディレクトリーから config map を作成できます。この方法では、ディレクトリー内の複数のファイルを使用して設定マップを作成できます。

ディレクトリー内の各ファイルは、config map にキーを設定するために使用されます。キーの名前はファイル名で、キーの値はファイルの内容です。

たとえば、次のコマンドは、**example-files** ディレクトリーの内容を使用して config map を作成します。

```
$ oc create configmap game-config --from-file=example-files/
```

config map 内のキーを表示します。

```
$ oc describe configmaps game-config
```

出力例

```
Name:      game-config
Namespace: default
Labels:    <none>
```

```
Annotations:  <none>
```

```
Data
```

```
game.properties:    158 bytes
ui.properties:      83 bytes
```

マップにある 2 つのキーが、コマンドで指定されたディレクトリーのファイル名に基づいて作成されていることに気づかれることでしょう。これらのキーの内容は大きい可能性があるため、**oc describe** の出力にはキーの名前とそのサイズのみが表示されます。

前提条件

- config map に追加するデータを含むファイルを含むディレクトリーが必要です。
次の手順では、サンプルファイル **game.properties** および **ui.properties** を使用します。

```
$ cat example-files/game.properties
```

出力例

```
enemies=aliens
lives=3
enemies.cheat=true
enemies.cheat.level=noGoodRotten
secret.code.passphrase=UUDDLRLRBABAS
secret.code.allowed=true
secret.code.lives=30
```

```
$ cat example-files/ui.properties
```

出力例

```
color.good=purple
color.bad=yellow
allow.textmode=true
how.nice.to.look=fairlyNice
```

手順

- 次のコマンドを入力して、このディレクトリー内の各ファイルの内容を保持する設定マップを作成します。

```
$ oc create configmap game-config \
  --from-file=example-files/
```

検証

- o** オプションを使用してオブジェクトの **oc get** コマンドを入力し、キーの値を表示します。

```
$ oc get configmaps game-config -o yaml
```

出力例

```

apiVersion: v1
data:
  game.properties: |-
    enemies=aliens
    lives=3
    enemies.cheat=true
    enemies.cheat.level=noGoodRotten
    secret.code.passphrase=UUDDLRLRBABAS
    secret.code.allowed=true
    secret.code.lives=30
  ui.properties: |
    color.good=purple
    color.bad=yellow
    allow.textmode=true
    how.nice.to.look=fairlyNice
kind: ConfigMap
metadata:
  creationTimestamp: 2016-02-18T18:34:05Z
  name: game-config
  namespace: default
  resourceVersion: "407"
  selflink: /api/v1/namespaces/default/configmaps/game-config
  uid: 30944725-d66e-11e5-8cd0-68f728db1985

```

2.7.3.2. ファイルから設定マップを作成する

--from-file フラグを使用すると、ファイルから config map を作成できます。**--from-file** オプションを CLI に複数回渡すことができます。

key=value 式を **--from-file** オプションに渡すことで、ファイルからインポートされたコンテンツの config map に設定するキーを指定することもできます。以下に例を示します。

```
$ oc create configmap game-config-3 --from-file=game-special-key=example-files/game.properties
```



注記

ファイルから設定マップを作成する場合、UTF8 以外のデータを破損することなく、UTF8 以外のデータを含むファイルをこの新規フィールドに配置できます。OpenShift Container Platform はバイナリーファイルを検出し、ファイルを **MIME** として透過的にエンコーディングします。サーバーでは、データを破損することなく **MIME** ペイロードがデコーディングされ、保存されます。

前提条件

- config map に追加するデータを含むファイルを含むディレクトリが必要です。次の手順では、サンプルファイル **game.properties** および **ui.properties** を使用します。

```
$ cat example-files/game.properties
```

出力例

```

enemies=aliens
lives=3
enemies.cheat=true
enemies.cheat.level=noGoodRotten
secret.code.passphrase=UDDLRRLRBABAS
secret.code.allowed=true
secret.code.lives=30

```

```
$ cat example-files/ui.properties
```

出力例

```

color.good=purple
color.bad=yellow
allow.textmode=true
how.nice.to.look=fairlyNice

```

手順

- 特定のファイルを指定して設定マップを作成します。

```

$ oc create configmap game-config-2 \
  --from-file=example-files/game.properties \
  --from-file=example-files/ui.properties

```

- キーと値のペアを指定して、設定マップを作成します。

```

$ oc create configmap game-config-3 \
  --from-file=game-special-key=example-files/game.properties

```

検証

- o** オプションを使用してオブジェクトの **oc get** コマンドを入力し、ファイルからキーの値を表示します。

```
$ oc get configmaps game-config-2 -o yaml
```

出力例

```

apiVersion: v1
data:
  game.properties: |-
    enemies=aliens
    lives=3
    enemies.cheat=true
    enemies.cheat.level=noGoodRotten
    secret.code.passphrase=UDDLRRLRBABAS
    secret.code.allowed=true
    secret.code.lives=30
  ui.properties: |
    color.good=purple
    color.bad=yellow

```

```

    allow.textmode=true
    how.nice.to.look=fairlyNice
kind: ConfigMap
metadata:
  creationTimestamp: 2016-02-18T18:52:05Z
  name: game-config-2
  namespace: default
  resourceVersion: "516"
  selflink: /api/v1/namespaces/default/configmaps/game-config-2
  uid: b4952dc3-d670-11e5-8cd0-68f728db1985

```

- **-o** オプションを使用してオブジェクトの **oc get** コマンドを入力し、key-value (キー/値) ペアからキーの値を表示します。

```
$ oc get configmaps game-config-3 -o yaml
```

出力例

```

apiVersion: v1
data:
  game-special-key: |- ❶
    enemies=aliens
    lives=3
    enemies.cheat=true
    enemies.cheat.level=noGoodRotten
    secret.code.passphrase=UUDDLRLRBABAS
    secret.code.allowed=true
    secret.code.lives=30
kind: ConfigMap
metadata:
  creationTimestamp: 2016-02-18T18:54:22Z
  name: game-config-3
  namespace: default
  resourceVersion: "530"
  selflink: /api/v1/namespaces/default/configmaps/game-config-3
  uid: 05f8da22-d671-11e5-8cd0-68f728db1985

```

- ❶ これは、先の手順で設定したキーです。

2.7.3.3. リテラル値からの設定マップの作成

設定マップにリテラル値を指定することができます。

--from-literal オプションは、リテラル値をコマンドラインに直接指定できる **key=value** 構文を取りま

手順

- リテラル値を指定して設定マップを作成します。

```

$ oc create configmap special-config \
  --from-literal=special.how=very \
  --from-literal=special.type=charm

```

検証

- **-o** オプションを使用してオブジェクトの **oc get** コマンドを入力し、キーの値を表示します。

```
$ oc get configmaps special-config -o yaml
```

出力例

```
apiVersion: v1
data:
  special.how: very
  special.type: charm
kind: ConfigMap
metadata:
  creationTimestamp: 2016-02-18T19:14:38Z
  name: special-config
  namespace: default
  resourceVersion: "651"
  selflink: /api/v1/namespaces/default/configmaps/special-config
  uid: dadce046-d673-11e5-8cd0-68f728db1985
```

2.7.4. ユースケース: Pod で設定マップを使用する

以下のセクションでは、Pod で **ConfigMap** オブジェクトを使用する際のいくつかのユースケースを説明します。

2.7.4.1. 設定マップの使用によるコンテナでの環境変数の設定

config map を使用して、コンテナで個別の環境変数を設定するために使用したり、有効な環境変数名を生成するすべてのキーを使用してコンテナで環境変数を設定するために使用したりすることができます。

例として、以下の設定マップを見てみましょう。

2つの環境変数を含む ConfigMap

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: special-config ❶
  namespace: default ❷
data:
  special.how: very ❸
  special.type: charm ❹
```

- ❶ 設定マップの名前。
- ❷ 設定マップが存在するプロジェクト。設定マップは同じプロジェクトの Pod によってのみ参照されます。
- ❸ ❹ 挿入する環境変数。

1つの環境変数を含む ConfigMap

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: env-config ❶
  namespace: default
data:
  log_level: INFO ❷
```

- ❶ 設定マップの名前。
- ❷ 挿入する環境変数。

手順

- **configMapKeyRef** セクションを使用して、Pod のこの **ConfigMap** のキーを使用できます。

特定の環境変数を挿入するように設定されている Pod 仕様のサンプル

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-test-pod
spec:
  containers:
    - name: test-container
      image: gcr.io/google_containers/busybox
      command: [ "/bin/sh", "-c", "env" ]
      env: ❶
        - name: SPECIAL_LEVEL_KEY ❷
          valueFrom:
            configMapKeyRef:
              name: special-config ❸
              key: special.how ❹
        - name: SPECIAL_TYPE_KEY
          valueFrom:
            configMapKeyRef:
              name: special-config ❺
              key: special.type ❻
              optional: true ❼
      envFrom: ❽
        - configMapRef:
            name: env-config ❾
      restartPolicy: Never
```

- ❶ **ConfigMap** から指定された環境変数をプルするためのスタンザです。
- ❷ キーの値を挿入する Pod 環境変数の名前です。
- ❸ ❺ 特定の環境変数のプルに使用する **ConfigMap** の名前です。

4 6 **ConfigMap** からプルする環境変数です。

7 環境変数をオプションにします。オプションとして、Pod は指定された **ConfigMap** およびキーが存在しない場合でも起動します。

8 **ConfigMap** からすべての環境変数をプルするためのスタンザです。

9 すべての環境変数のプルに使用する **ConfigMap** の名前です。

この Pod が実行されると、Pod のログには以下の出力が含まれます。

```
SPECIAL_LEVEL_KEY=very
log_level=INFO
```



注記

SPECIAL_TYPE_KEY=charm は出力例にリスト表示されません。**optional: true** が設定されているためです。

2.7.4.2. 設定マップを使用したコンテナコマンドのコマンドライン引数の設定

config map を使用すると、Kubernetes 置換構文 **\$(VAR_NAME)** を使用してコンテナ内のコマンドまたは引数の値を設定できます。

例として、以下の設定マップを見てみましょう。

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: special-config
  namespace: default
data:
  special.how: very
  special.type: charm
```

手順

- コンテナ内のコマンドに値を挿入するには、環境変数として使用するキーを使用する必要があります。次に、**\$(VAR_NAME)** 構文を使用してコンテナのコマンドでそれらを参照することができます。

特定の環境変数を挿入するように設定されている Pod 仕様のサンプル

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-test-pod
spec:
  containers:
    - name: test-container
      image: gcr.io/google_containers/busybox
      command: [ "/bin/sh", "-c", "echo $(SPECIAL_LEVEL_KEY) $(SPECIAL_TYPE_KEY)" ]
```

1

```
env:
  - name: SPECIAL_LEVEL_KEY
    valueFrom:
      configMapKeyRef:
        name: special-config
        key: special.how
  - name: SPECIAL_TYPE_KEY
    valueFrom:
      configMapKeyRef:
        name: special-config
        key: special.type
restartPolicy: Never
```

- 1 環境変数として使用するキーを使用して、コンテナのコマンドに値を挿入します。

この Pod が実行されると、test-container コンテナで実行される echo コマンドの出力は以下ようになります。

```
very charm
```

2.7.4.3. 設定マップの使用によるボリュームへのコンテンツの挿入

設定マップを使用して、コンテンツをボリュームに挿入することができます。

ConfigMap カスタムリソース (CR) の例

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: special-config
  namespace: default
data:
  special.how: very
  special.type: charm
```

手順

設定マップを使用してコンテンツをボリュームに挿入するには、2つの異なるオプションを使用できます。

- 設定マップを使用してコンテンツをボリュームに挿入するための最も基本的な方法は、キーがファイル名であり、ファイルの内容がキーの値になっているファイルでボリュームを設定する方法です。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-test-pod
spec:
  containers:
    - name: test-container
      image: gcr.io/google_containers/busybox
      command: [ "/bin/sh", "-c", "cat", "/etc/config/special.how" ]
      volumeMounts:
```

```

- name: config-volume
  mountPath: /etc/config
volumes:
- name: config-volume
  configMap:
    name: special-config ❶
restartPolicy: Never

```

- ❶ キーを含むファイル。

この Pod が実行されると、cat コマンドの出力は以下のようになります。

```
very
```

- 設定マップキーが投影されるボリューム内のパスを制御することもできます。

```

apiVersion: v1
kind: Pod
metadata:
  name: dapi-test-pod
spec:
  containers:
  - name: test-container
    image: gcr.io/google_containers/busybox
    command: [ "/bin/sh", "-c", "cat", "/etc/config/path/to/special-key" ]
    volumeMounts:
    - name: config-volume
      mountPath: /etc/config
  volumes:
  - name: config-volume
    configMap:
      name: special-config
      items:
      - key: special.how
        path: path/to/special-key ❶
    restartPolicy: Never

```

- ❶ 設定マップキーへのパス。

この Pod が実行されると、cat コマンドの出力は以下のようになります。

```
very
```

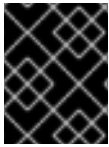
2.8. POD で外部リソースにアクセスするためのデバイスプラグインの使用

デバイスプラグインを使用すると、カスタムコードを作成せずに特定のデバイスタイプ (GPU、InfiniBand、またはベンダー固有の初期化およびセットアップを必要とする他の同様のコンピューティングリソース) を OpenShift Container Platform Pod で使用できます。

2.8.1. デバイスプラグインについて

デバイスプラグインは、クラスター間でハードウェアデバイスを使用する際の一貫した移植可能なソ

リューションを提供します。デバイスプラグインは、拡張メカニズムを通じてこれらのデバイスをサポートし (これにより、コンテナがこれらのデバイスを利用できるようになります)、デバイスのヘルスチェックを実施し、それらを安全に共有します。



重要

OpenShift Container Platform はデバイスのプラグイン API をサポートしますが、デバイスプラグインコンテナは個別のベンダーによりサポートされます。

デバイスプラグインは、特定のハードウェアリソースの管理を行う、ノード上で実行される gRPC サービスです (**kubelet** の外部にあります)。デバイスプラグインは以下のリモートプロシージャコール (RPC) をサポートしている必要があります。

```
service DevicePlugin {
    // GetDevicePluginOptions returns options to be communicated with Device
    // Manager
    rpc GetDevicePluginOptions(Empty) returns (DevicePluginOptions) {}

    // ListAndWatch returns a stream of List of Devices
    // Whenever a Device state change or a Device disappears, ListAndWatch
    // returns the new list
    rpc ListAndWatch(Empty) returns (stream ListAndWatchResponse) {}

    // Allocate is called during container creation so that the Device
    // Plug-in can run device specific operations and instruct Kubelet
    // of the steps to make the Device available in the container
    rpc Allocate(AllocateRequest) returns (AllocateResponse) {}

    // PreStartcontainer is called, if indicated by Device Plug-in during
    // registration phase, before each container start. Device plug-in
    // can run device specific operations such as resetting the device
    // before making devices available to the container
    rpc PreStartcontainer(PreStartcontainerRequest) returns (PreStartcontainerResponse) {}
}
```

2.8.1.1. デバイスプラグインの例

- [Nvidia GPU device plugin for COS-based operating system](#)
- [Nvidia official GPU device plugin](#)
- [Solarflare device plugin](#)
- [KubeVirt device plugins: vfio and kvm](#)
- [Kubernetes device plugin for IBM Crypto Express \(CEX\) cards](#)



注記

デバイスプラグイン参照の実装を容易にするために、[vendor/k8s.io/kubernetes/pkg/kubelet/cm/deviceplugin/device_plugin_stub.go](https://github.com/kubernetes/pkg/kubelet/cm/deviceplugin/device_plugin_stub.go) という Device Manager コードのスタブデバイスプラグインを使用できます。

2.8.1.2. デバイスプラグインのデプロイ方法

- デモンセットは、デバイスプラグインのデプロイメントに推奨される方法です。
- 起動時にデバイスプラグインは、Device Manager から RPC を送信するためにノードの `/var/lib/kubelet/device-plugin/` での UNIX ドメインソケットの作成を試行します。
- デバイスプラグインは、ソケットの作成のほかにもハードウェアリソース、ホストファイルシステムへのアクセスを管理する必要があるため、特権付きセキュリティーコンテキストで実行される必要があります。
- デプロイメント手順の詳細は、それぞれのデバイスプラグインの実装で確認できます。

2.8.2. Device Manager について

Device Manager は、特殊なノードのハードウェアリソースを、デバイスプラグインとして知られるプラグインを使用して公開するメカニズムを提供します。

特殊なハードウェアは、アップストリームのコード変更なしに公開できます。



重要

OpenShift Container Platform はデバイスのプラグイン API をサポートしますが、デバイスプラグインコンテナは個別のベンダーによりサポートされます。

Device Manager はデバイスを **拡張リソース** として公開します。ユーザー Pod は、他の **拡張リソース** を要求するために使用されるのと同じ **制限/要求** メカニズムを使用して Device Manager で公開されるデバイスを消費できます。

使用開始時に、デバイスプラグインは `/var/lib/kubelet/device-plugins/kubelet.sock` の **Register** を起動して Device Manager に自己登録し、Device Manager の要求を提供するために `/var/lib/kubelet/device-plugins/<plugin>.sock` で gRPC サービスを起動します。

Device Manager は、新規登録要求の処理時にデバイスプラグインサービスで **ListAndWatch** リモートプロシージャコール (RPC) を起動します。応答として Device Manager は gRPC ストリームでプラグインから **デバイス** オブジェクトの一覧を取得します。Device Manager はプラグインからの新規の更新の有無についてストリームを監視します。プラグイン側では、プラグインはストリームを開いた状態にし、デバイスの状態に変更があった場合には常に新規デバイスの一覧が同じストリーム接続で Device Manager に送信されます。

新しい Pod の受付リクエストの処理中に、Kubelet が要求された **Extended Resources** をデバイス割り当てのためにデバيسマネージャーに渡します。Device Manager はそのデータベースにチェックインして対応するプラグインが存在するかどうかを確認します。プラグインが存在し、ローカルキャッシュと共に割り当て可能な空きデバイスがある場合、**Allocate** RPC がその特定デバイスのプラグインで起動します。

さらにデバイスプラグインは、ドライバーのインストール、デバイスの初期化、およびデバイスのリセットなどの他のいくつかのデバイス固有の操作も実行できます。これらの機能は実装ごとに異なります。

2.8.3. Device Manager の有効化

Device Manager を有効にし、デバイスプラグインを実装してアップストリームのコード変更なしに特殊なハードウェアを公開できるようにします。

Device Manager は、特殊なノードのハードウェアリソースを、デバイスプラグインとして知られるプラグインを使用して公開するメカニズムを提供します。

1. 次のコマンドを入力して、設定するノードタイプの静的な **MachineConfigPool** CRD に関連付けられたラベルを取得します。以下のいずれかの手順を実行します。

- a. マシン設定を表示します。

```
# oc describe machineconfig <name>
```

以下に例を示します。

```
# oc describe machineconfig 00-worker
```

出力例

```
Name:      00-worker
Namespace:
Labels:    machineconfiguration.openshift.io/role=worker ❶
```

- ❶ Device Manager に必要なラベル。

手順

1. 設定変更のためのカスタムリソース (CR) を作成します。

Device Manager CR の設定例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: devicemgr ❶
spec:
  machineConfigPoolSelector:
    matchLabels:
      machineconfiguration.openshift.io: devicemgr ❷
  kubeletConfig:
    feature-gates:
      - DevicePlugins=true ❸
```

- ❶ CR に名前を割り当てます。
- ❷ Machine Config Pool からラベルを入力します。
- ❸ **DevicePlugins** を 'true' に設定します。

2. Device Manager を作成します。

```
$ oc create -f devicemgr.yaml
```

出力例

```
kubeletconfig.machineconfiguration.openshift.io/devicemgr created
```

3. Device Manager が実際に有効にされるように、`/var/lib/kubelet/device-plugins/kubelet.sock` がノードで作成されていることを確認します。これは、Device Manager の gRPC サーバーが新規プラグインの登録がないかどうかリッスンする UNIX ドメインソケットです。このソケットファイルは、Device Manager が有効にされている場合にのみ Kubelet の起動時に作成されます。

2.9. POD スケジューリングの決定に POD の優先順位を含める

クラスターで Pod の優先順位およびプリエンプションを有効にできます。Pod の優先度は、他の Pod との比較した Pod の重要度を示し、その優先度に基づいて Pod をキューに入れます。Pod のプリエンプションは、クラスターが優先順位の低い Pod の退避またはプリエンプションを実行することを可能にするため、適切なノードに利用可能な領域がない場合に優先順位のより高い Pod をスケジューリングできます。Pod の優先順位は Pod のスケジューリングの順序にも影響を与え、リソース不足の場合のノード上でのエビクションの順序に影響を与えます。

優先順位およびプリエンプションを使用するには、Pod の相対的な重みを定義する優先順位クラスを作成します。次に Pod 仕様で優先順位クラスを参照し、スケジューリングの重みを適用します。

2.9.1. Pod の優先順位について

Pod の優先順位およびプリエンプション機能を使用する場合、スケジューラーは優先順位に基づいて保留中の Pod を順序付け、保留中の Pod はスケジューリングのキューで優先順位のより低い他の保留中の Pod よりも前に置かれます。その結果、より優先順位の高い Pod は、スケジューリングの要件を満たす場合に優先順位の低い Pod よりも早くスケジューリングされる可能性があります。Pod をスケジューリングできない場合、スケジューラーは引き続き他の優先順位の低い Pod をスケジューリングします。

2.9.1.1. Pod の優先順位クラス

Pod には優先順位クラスを割り当てることができます。これは、名前から優先順位の整数値へのマッピングを定義する namespace を使用していないオブジェクトです。値が高いと優先順位が高くなります。

優先順位およびプリエンプションは、1000000000 (10 億) 以下の 32 ビットの整数値を取ることができます。プリエンプションやエビクションを実行すべきでない Critical Pod 用に 10 億以上の数値を予約する必要があります。デフォルトで、OpenShift Container Platform には 2 つの予約された優先順位クラスがあり、これらは重要なシステム Pod で保証されたスケジューリングが適用されるために使用されます。

```
$ oc get priorityclasses
```

出力例

NAME	VALUE	GLOBAL-DEFAULT	AGE
system-node-critical	2000001000	false	72m
system-cluster-critical	2000000000	false	72m
openshift-user-critical	1000000000	false	3d13h
cluster-logging	1000000	false	29s

- **system-node-critical**: この優先順位クラスには 2000001000 の値があり、ノードからエビクトすべきでないすべての Pod に使用されます。この優先順位クラスを持つ Pod の例として、**sdn-ovs**、**sdn** などがあります。数多くの重要なコンポーネントには、デフォルトで **system-node-critical** の優先順位クラスが含まれます。以下は例になります。
 - master-api

- master-controller
- master-etcd
- sdn
- sdn-ovs
- sync
- **system-cluster-critical**: この優先順位クラスには 2000000000 (20 億) の値があり、クラスターに重要な Pod に使用されます。この優先順位クラスの Pod は特定の状況でノードから退避される可能性があります。たとえば、**system-node-critical** 優先順位クラスで設定される Pod が優先される可能性があります。この場合でも、この優先順位クラスではスケジューリングが保証されます。この優先順位クラスを持つ可能性のある Pod の例として、fluentd、descheduler などのアドオンコンポーネントなどがあります。数多くの重要なコンポーネントには、デフォルトで **system-cluster-critical** 優先順位クラスが含まれます。以下はその一例です。
 - fluentd
 - metrics-server
 - descheduler
- **openshift-user-critical**: **priorityClassName** フィールドを、リソース消費をバインドできず、予測可能なリソース消費動作がない重要な Pod で使用できます。**openshift-monitoring** および **openshift-user-workload-monitoring** namespace 下にある Prometheus Pod は、**openshift-user-critical priorityClassName** を使用します。モニタリングのワークロードは **system-critical** を最初の **priorityClass** として使用しますが、これにより、モニタリング時にメモリーが過剰に使用され、ノードが退避できない問題が発生します。その結果、モニタリングの優先順位が下がり、スケジューラーに柔軟性が与えられ、重要なノードの動作を維持するために重いワークロード発生します。
- **cluster-logging**: この優先順位は、Fluentd Pod が他のアプリケーションより優先してノードにスケジュールされるようにするために Fluentd で使用されます。

2.9.1.2. Pod の優先順位名

1つ以上の優先順位クラスを準備した後に、**Pod** 仕様に優先順位クラス名を指定する Pod を作成できます。優先順位のアドミッションコントローラーは、優先順位クラス名フィールドを使用して優先順位の整数値を設定します。名前付きの優先順位クラスが見つからない場合、Pod は拒否されます。

2.9.2. Pod のプリエンプションについて

開発者が Pod を作成する場合、Pod はキューに入れられます。開発者が Pod の優先順位またはプリエンプションを設定している場合、スケジューラーはキューから Pod を選択し、Pod をノードにスケジュールしようとしています。スケジューラーが Pod に指定されたすべての要件を満たす適切なノードに領域を見つけられない場合、プリエンプションロジックが保留中の Pod にトリガーされます。

スケジューラーがノードで1つ以上の Pod のプリエンプションを実行する場合、優先順位の高い **Pod** 仕様の **nominatedNodeName** フィールドは、**nodename** フィールドと共にノードの名前に設定されます。スケジューラーは **nominatedNodeName** フィールドを使用して Pod の予約されたリソースを追跡し、またクラスターのプリエンプションに関する情報をユーザーに提供します。

スケジューラーが優先順位の低い Pod のプリエンプションを実行した後に、スケジューラーは Pod の

正常な終了期間を許可します。スケジューラーが優先順位の低い Pod の終了を待機する間に別のノードが利用可能になると、スケジューラーはそのノードに優先順位の高い Pod をスケジュールできます。その結果、**Pod** 仕様の **nominatedNodeName** フィールドおよび **nodeName** フィールドが異なる可能性があります。

さらに、スケジューラーがノード上で Pod のプリエンプションを実行し、終了を待機している場合で、保留中の Pod よりも優先順位の高い Pod をスケジュールする必要がある場合、スケジューラーは代わりに優先順位の高い Pod をスケジュールできます。その場合、スケジューラーは保留中の Pod の **nominatedNodeName** をクリアし、その Pod を他のノードの対象とすることができます。

プリエンプションは、ノードから優先順位の低いすべての Pod を削除する訳ではありません。スケジューラーは、優先順位の低い Pod の一部を削除して保留中の Pod をスケジュールできます。

スケジューラーは、保留中の Pod をノードにスケジュールできる場合にのみ、Pod のプリエンプションを実行するノードを考慮します。

2.9.2.1. プリエンプションを実行しない優先順位クラス

プリエンプションポリシーが **Never** に設定された Pod は優先順位の低い Pod よりも前のスケジューリングキューに置かれますが、他の Pod のプリエンプションを実行することはできません。スケジューリングを待機しているプリエンプションを実行しない Pod は、十分なリソースが解放され、これがスケジュールされるまでスケジューリングキュー内に留まります。他の Pod などのプリエンプションを実行しない Pod はスケジューラーのバックオフの対象になります。つまり、スケジューラーがこれらの Pod のスケジューリングの試行に成功しない場合、低頻度で再試行されるため、優先順位の低い他の Pod をそれらの Pod よりも前にスケジュールできます。

プリエンプションを実行しない Pod には、他の優先順位の高い Pod が依然としてプリエンプションを実行できます。

2.9.2.2. Pod プリエンプションおよび他のスケジューラーの設定

Pod の優先順位およびプリエンプションを有効にする場合、他のスケジューラー設定を考慮します。

Pod の優先順位および Pod の Disruption Budget (停止状態の予算)

Pod の Disruption Budget (停止状態の予算) は一度に稼働している必要のあるレプリカの最小数またはパーセンテージを指定します。Pod の Disruption Budget (停止状態の予算) を指定する場合、OpenShift Container Platform は、Best Effort レベルで Pod のプリエンプションを実行する際にそれらを適用します。スケジューラーは、Pod の Disruption Budget (停止状態の予算) に違反しない範囲で Pod のプリエンプションを試行します。該当する Pod が見つからない場合には、Pod の Disruption Budget (停止状態の予算) の要件を無視して優先順位の低い Pod のプリエンプションが実行される可能性があります。

Pod の優先順位およびアフィニティー

Pod のアフィニティーは、新規 Pod が同じラベルを持つ他の Pod と同じノードにスケジュールされることを要求します。

保留中の Pod にノード上の1つ以上の優先順位の低い Pod との Pod 間のアフィニティーがある場合、スケジューラーはアフィニティーの要件を違反せずに優先順位の低い Pod のプリエンプションを実行することはできません。この場合、スケジューラーは保留中の Pod をスケジュールするための別のノードを探します。ただし、スケジューラーが適切なノードを見つけることは保証できず、保留中の Pod がスケジュールされない可能性があります。

この状態を防ぐには、優先順位が等しい Pod との Pod のアフィニティーの設定を慎重に行ってください。

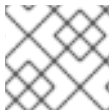
2.9.2.3. プリエンプションが実行された Pod の正常な終了

Pod のプリエンプションの実行中、スケジューラーは Pod の正常な終了期間が期限切れになるのを待ちます。その後、Pod は機能を完了し、終了します。Pod がこの期間後も終了しない場合、スケジューラーは Pod を強制終了します。この正常な終了期間により、スケジューラーによる Pod のプリエンプションの実行時と保留中の Pod のノードへのスケジュール時に時間差が出ます。

この時間差を最小限にするには、優先順位の低い Pod の正常な終了期間を短く設定します。

2.9.3. 優先順位およびプリエンプションの設定

Pod 仕様で **priorityClassName** を使用して優先順位クラスオブジェクトを作成し、Pod を優先順位に関連付けることで、Pod の優先度およびプリエンプションを適用できます。



注記

優先クラスを既存のスケジュール済み Pod に直接追加することはできません。

手順

優先順位およびプリエンプションを使用するようにクラスターを設定するには、以下を実行します。

1. 1つ以上の優先順位クラスを作成します。
 - a. 以下のような YAML ファイルを作成します。

```
apiVersion: scheduling.k8s.io/v1
kind: PriorityClass
metadata:
  name: high-priority ❶
value: 1000000 ❷
preemptionPolicy: PreemptLowerPriority ❸
globalDefault: false ❹
description: "This priority class should be used for XYZ service pods only." ❺
```

- ❶ 優先順位クラスオブジェクトの名前です。
- ❷ オブジェクトの優先順位の値です。
- ❸ オプション: この優先クラスがプリエンプティングであるか非プリエンプティングであるかを指定します。プリエンプションポリシーは、デフォルトで **PreemptLowerPriority** に設定されます。これにより、その優先順位クラスの Pod はそれよりも優先順位の低い Pod のプリエンプションを実行できます。プリエンプションポリシーが **Never** に設定される場合、その優先順位クラスの Pod はプリエンプションを実行しません。
- ❹ オプション: 優先クラス名が指定されていない Pod にこの優先クラスを使用するかどうかを指定します。このフィールドはデフォルトで **false** です。 **globalDefault** が **true** に設定される1つの優先順位クラスのみがクラスター内に存在できます。 **globalDefault:true** が設定された優先順位クラスがない場合、優先順位クラス名が設定されていない Pod の優先順位はゼロになります。 **globalDefault:true** が設定された優先順位クラスを追加すると、優先順位クラスが追加された後に作成された Pod のみがその影響を受け、これによって既存 Pod の優先順位は変更されません。

- 5 オプション: 開発者がこの優先クラスで使用する必要がある Pod を説明します。任意の文字列を入力します。

- b. 優先クラスを作成します。

```
$ oc create -f <file-name>.yaml
```

2. 優先クラスの名前を含む Pod 仕様を作成します。

- a. 以下のような YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: nginx
  labels:
    env: test
spec:
  containers:
  - name: nginx
    image: nginx
    imagePullPolicy: IfNotPresent
    priorityClassName: high-priority 1
```

- 1 この Pod で使用する優先順位クラスを指定します。

- b. Pod を作成します。

```
$ oc create -f <file-name>.yaml
```

優先順位の名前は Pod 設定または Pod テンプレートに直接追加できます。

2.10. ノードセクターの使用による特定ノードへの POD の配置

ノードセクター は、キーと値のペアのマップを指定します。ルールは、ノード上のカスタムラベルと Pod で指定されたセクターを使用して定義されます。

Pod がノードで実行する要件を満たすには、Pod はノードのラベルとして示されるキーと値のペアを持っている必要があります。

同じ Pod 設定でノードのアフィニティーとノードセクターを使用している場合、以下の重要な考慮事項を参照してください。

2.10.1. ノードセクターの使用による Pod 配置の制御

Pod でノードセクターを使用し、ノードでラベルを使用して、Pod がスケジュールされる場所を制御できます。ノードセクターにより、OpenShift Container Platform は一致するラベルが含まれるノード上に Pod をスケジュールします。

ラベルをノード、コンピューティングマシンセット、またはマシン設定に追加します。コンピューティングマシンセットにラベルを追加すると、ノードまたはマシンが停止した場合に、新規ノードにそのラベルが追加されます。ノードまたはマシン設定に追加されるラベルは、ノードまたはマシンが停止すると維持されません。

ノードセクターを既存 Pod に追加するには、ノードセクターを **ReplicaSet** オブジェクト、**DaemonSet** オブジェクト、**StatefulSet** オブジェクト、**Deployment** オブジェクト、または **DeploymentConfig** オブジェクトなどの Pod の制御オブジェクトに追加します。制御オブジェクト下の既存 Pod は、一致するラベルを持つノードで再作成されます。新規 Pod を作成する場合、ノードセクターを Pod 仕様に直接追加できます。Pod に制御オブジェクトがない場合は、Pod を削除し、Pod 仕様を編集して、Pod を再作成する必要があります。



注記

ノードセクターを既存のスケジュールされている Pod に直接追加することはできません。

前提条件

ノードセクターを既存 Pod に追加するには、Pod の制御オブジェクトを判別します。たとえば、**router-default-66d5cf9464-m2g75** Pod は **router-default-66d5cf9464** レプリカセットによって制御されます。

```
$ oc describe pod router-default-66d5cf9464-7pwkc
```

出力例

```
kind: Pod
apiVersion: v1
metadata:
#...
Name:      router-default-66d5cf9464-7pwkc
Namespace: openshift-ingress
# ...
Controlled By:  ReplicaSet/router-default-66d5cf9464
# ...
```

Web コンソールでは、Pod YAML の **ownerReferences** に制御オブジェクトをリスト表示します。

```
apiVersion: v1
kind: Pod
metadata:
  name: router-default-66d5cf9464-7pwkc
# ...
ownerReferences:
- apiVersion: apps/v1
  kind: ReplicaSet
  name: router-default-66d5cf9464
  uid: d81dd094-da26-11e9-a48a-128e7edf0312
  controller: true
  blockOwnerDeletion: true
# ...
```

手順

1. コンピュートマシンセットを使用するか、ノードを直接編集してラベルをノードに追加します。
 - **MachineSet** オブジェクトを使用して、ノードの作成時にコンピュートマシンセットによっ

て管理されるノードにラベルを追加します。

- a. 以下のコマンドを実行してラベルを **MachineSet** オブジェクトに追加します。

```
$ oc patch MachineSet <name> --type='json' -
p=[{"op":"add","path":"/spec/template/spec/metadata/labels", "value":{"<key>="
<value>","<key>="<value>"}]}] -n openshift-machine-api
```

以下に例を示します。

```
$ oc patch MachineSet abc612-msrtw-worker-us-east-1c --type='json' -
p=[{"op":"add","path":"/spec/template/spec/metadata/labels", "value":{"type":"user-
node","region":"east"}}] -n openshift-machine-api
```

ヒント

あるいは、以下の YAML を適用してコンピュータマシンセットにラベルを追加することもできます。

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
  name: xf2bd-infra-us-east-2a
  namespace: openshift-machine-api
spec:
  template:
    spec:
      metadata:
        labels:
          region: "east"
          type: "user-node"
#...
```

- b. **oc edit** コマンドを使用して、ラベルが **MachineSet** オブジェクトに追加されていることを確認します。
以下に例を示します。

```
$ oc edit MachineSet abc612-msrtw-worker-us-east-1c -n openshift-machine-api
```

MachineSet オブジェクトの例

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet

# ...

spec:
# ...
  template:
    metadata:
# ...
    spec:
      metadata:
```

```
labels:
  region: east
  type: user-node
# ...
```

- ラベルをノードに直接追加します。
 - a. ノードの **Node** オブジェクトを編集します。

```
$ oc label nodes <name> <key>=<value>
```

たとえば、ノードにラベルを付けるには、以下を実行します。

```
$ oc label nodes ip-10-0-142-25.ec2.internal type=user-node region=east
```

ヒント

あるいは、以下の YAML を適用してノードにラベルを追加することもできます。

```
kind: Node
apiVersion: v1
metadata:
  name: hello-node-6fbccf8d9
  labels:
    type: "user-node"
    region: "east"
#...
```

- b. ラベルがノードに追加されていることを確認します。

```
$ oc get nodes -l type=user-node,region=east
```

出力例

```
NAME                                STATUS ROLES  AGE  VERSION
ip-10-0-142-25.ec2.internal  Ready  worker  17m  v1.25.0
```

2. 一致するノードセクターを Pod に追加します。

- ノードセクターを既存 Pod および新規 Pod に追加するには、ノードセクターを Pod の制御オブジェクトに追加します。

ラベルを含む ReplicaSet オブジェクトのサンプル

```
kind: ReplicaSet
apiVersion: apps/v1
metadata:
  name: hello-node-6fbccf8d9
# ...
spec:
# ...
template:
  metadata:
```

```

creationTimestamp: null
labels:
  ingresscontroller.operator.openshift.io/deployment-ingresscontroller: default
  pod-template-hash: 66d5cf9464
spec:
  nodeSelector:
    kubernetes.io/os: linux
    node-role.kubernetes.io/worker: "
    type: user-node ❶
#...
```

❶ ノードセクターを追加します。

- ノードセクターを特定の新規 Pod に追加するには、セクターを **Pod** オブジェクトに直接追加します。

ノードセクターを持つ Pod オブジェクトの例

```

apiVersion: v1
kind: Pod
metadata:
  name: hello-node-6fbccf8d9
#...
spec:
  nodeSelector:
    region: east
    type: user-node
#...
```



注記

ノードセクターを既存のスケジュールされている Pod に直接追加することはできません。

第3章 CUSTOM METRICS AUTOSCALER OPERATOR を使用した POD の自動スケーリング

3.1. リリースノート

3.1.1. Custom Metrics Autoscaler Operator リリースノート

Red Hat OpenShift の Custom Metrics Autoscaler Operator のリリースノートでは、新機能および拡張機能、非推奨となった機能、および既知の問題を説明しています。

Custom Metrics Autoscaler Operator は、Kubernetes ベースの Event Driven Autoscaler (KEDA) を使用し、OpenShift Container Platform の Horizontal Pod Autoscaler (HPA) の上に構築されます。



注記

Red Hat OpenShift の Custom Metrics Autoscaler Operator のロギングサブシステムは、インストール可能なコンポーネントとして提供され、コアの OpenShift Container Platform とは異なるリリースサイクルを備えています。[Red Hat OpenShift Container Platform ライフサイクルポリシー](#) はリリースの互換性を概説しています。

3.1.1.1. サポート対象バージョン

以下の表は、各 OpenShift Container Platform バージョンの Custom Metrics Autoscaler Operator バージョンを定義しています。

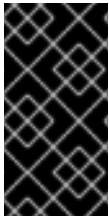
バージョン	OpenShift Container Platform バージョン	一般提供
2.17.2-2	4.20	一般提供
2.17.2-2	4.19	一般提供
2.17.2-2	4.18	一般提供
2.17.2-2	4.17	一般提供
2.17.2-2	4.16	一般提供
2.17.2-2	4.15	一般提供
2.17.2-2	4.14	一般提供
2.17.2-2	4.13	一般提供
2.17.2-2	4.12	一般提供

3.1.1.2. Custom Metrics Autoscaler Operator 2.17.2-2 リリースノート

発行日: 2025 年 10 月 21 日

Custom Metrics Autoscaler Operator 2.17.2-2 のこのリリースは、新しいベースイメージと Go コンパイラーを使用した Custom Metrics Autoscaler Operator の 2.17.2 バージョンの再構築です。Custom Metrics Autoscaler Operator にコードの変更はありません。Custom Metrics Autoscaler Operator には、次のアドバイザリーが利用可能です。

- [RHBA-2025:18914](#)



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの Kubernetes ベースの Event Driven Autoscaler (KEDA) を削除します。

3.1.2. Custom Metrics Autoscaler Operator の過去リリースに関するリリースノート

次のリリースノートは、以前の Custom Metrics Autoscaler Operator バージョンを対象としています。

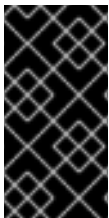
現在のバージョンは、[Custom Metrics Autoscaler Operator リリースノート](#) を参照してください。

3.1.2.1. Custom Metrics Autoscaler Operator 2.17.2 リリースノート

発行日: 2025 年 9 月 25 日

Custom Metrics Autoscaler Operator 2.17.2 のこのリリースでは、Common Vulnerabilities and Exposures (CVE) に対処しています。Custom Metrics Autoscaler Operator には、次のアドバイザリーが利用可能です。

- [RHSA-2025:16124](#)



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの Kubernetes ベースの Event Driven Autoscaler (KEDA) を削除します。

3.1.2.1.1. 新機能および機能拡張

3.1.2.1.1.1. KEDA コントローラーはインストール中に自動的に作成される

Custom Metrics Autoscaler Operator をインストールすると、KEDA コントローラーが自動的に作成されるようになりました。以前は、KEDA コントローラーを手動で作成する必要がありました。必要に応じて、自動作成された KEDA コントローラーを編集できます。

3.1.2.1.1.2. Kubernetes ワークロードトリガーのサポート

Cluster Metrics Autoscaler Operator は、Kubernetes ワークロードトリガーを使用して、特定のラベルセクターに一致する Pod の数に基づいて Pod をスケーリングできるようになりました。

3.1.2.1.1.3. バインドされたサービスアカウントトークンのサポート

Cluster Metrics Autoscaler Operator は、バインドされたサービスアカウントトークンをサポートするようになりました。これまで、Operator はレガシーサービスアカウントトークンのみをサポートして

いましたが、セキュリティ上の理由から、バインドされたサービスアカウントトークンに段階的に移行しています。

3.1.2.1.2. バグ修正

- 以前は、KEDA コントローラーはボリュームマウントをサポートしていませんでした。その結果、Kafka スケーラーで Kerberos を使用できませんでした。この修正により、KEDA コントローラーはボリュームマウントをサポートするようになりました。(OCPBUGS-42559)
- 以前は、**keda-operator** デプロイメントオブジェクトログの KEDA バージョンで、Custom Metrics Autoscaler Operator が誤った KEDA バージョンに基づいていることが報告されていました。この修正により、正しい KEDA バージョンがログに報告されるようになりました。(OCPBUGS-58129)

関連情報

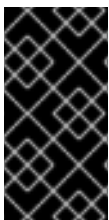
- [Keda Controller CR の編集](#)
- [Kubernetes ワークロードトリガーを理解する](#)
- [カスタムメトリクスオートスケーラトリガー認証について](#)

3.1.2.2. Custom Metrics Autoscaler Operator 2.15.1-4 リリースノート

発行日: 2025 年 3 月 31 日

Custom Metrics Autoscaler Operator 2.15.1-4 のこのリリースでは、Common Vulnerabilities and Exposures (CVE) に対処しています。Custom Metrics Autoscaler Operator には、次のアドバイザリーが利用可能です。

- [RHSA-2025:3501](#)



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの Kubernetes ベースの Event Driven Autoscaler (KEDA) を削除します。

3.1.2.2.1. 新機能および機能拡張

3.1.2.2.1.1. CMA マルチアーキテクチャビルド

このバージョンの Custom Metrics Autoscaler Operator では、ARM64 OpenShift Container Platform クラスタに Operator をインストールして実行できるようになりました。

3.1.2.3. Custom Metrics Autoscaler Operator 2.14.1-467 リリースノート

Custom Metrics Autoscaler Operator 2.14.1-467 のこのリリースでは、OpenShift Container Platform クラスタで Operator を実行するための CVE とバグ修正が提供されています。[RHSA-2024:7348](#) に関する次のアドバイザリーが利用可能です。



重要

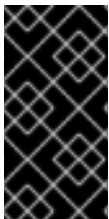
このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの Kubernetes ベースの Event Driven Autoscaler (KEDA) を削除します。

3.1.2.3.1. バグ修正

- 以前は、Custom Metrics Autoscaler Operator Pod のルートファイルシステムが書き込み可能でした。これは不要であり、セキュリティ上の問題を引き起こす可能性があります。この更新により、Pod のルートファイルシステムが読み取り専用になり、潜在的なセキュリティ問題が解決されました。(OCPBUGS-37989)

3.1.2.4. Custom Metrics Autoscaler Operator 2.14.1-454 リリースノート

この Custom Metrics Autoscaler Operator 2.14.1-454 リリースでは、OpenShift Container Platform クラスタで Operator を実行するための CVE、新機能、およびバグ修正を使用できます。[RHBA-2024:5865](#) に関する次のアドバイザリーが利用可能です。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの Kubernetes ベースの Event Driven Autoscaler (KEDA) を削除します。

3.1.2.4.1. 新機能および機能拡張

3.1.2.4.1.1. Custom Metrics Autoscaler Operator による Cron トリガーのサポート

Custom Metrics Autoscaler Operator が、Cron トリガーを使用して、時間単位のスケジュールに基づいて Pod をスケーリングできるようになりました。指定した時間枠が開始すると、Custom Metrics Autoscaler Operator が Pod を必要な数にスケーリングします。時間枠が終了すると、Operator は以前のレベルまでスケールダウンします。

詳細は、[Cron トリガーについて](#) を参照してください。

3.1.2.4.2. バグ修正

- 以前は、**KedaController** カスタムリソースの監査設定パラメーターに変更を加えても、**keda-metrics-server-audit-policy** config map が更新されませんでした。その結果、Custom Metrics Autoscaler の初期デプロイ後に監査設定パラメーターを変更することができませんでした。この修正により、監査設定への変更が config map に適切に反映されるようになり、インストール後いつでも監査設定を変更できるようになりました。(OCPBUGS-32521)

3.1.2.5. Custom Metrics Autoscaler Operator 2.13.1 リリースノート

Custom Metrics Autoscaler Operator 2.13.1-421 のこのリリースでは、OpenShift Container Platform クラスタで Operator を実行するための新機能およびバグ修正が提供されています。[RHBA-2024:4837](#) に関する次のアドバイザリーが利用可能です。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの Kubernetes ベースの Event Driven Autoscaler (KEDA) を削除します。

3.1.2.5.1. 新機能および機能拡張

3.1.2.5.1.1. Custom Metrics Autoscaler Operator によるカスタム証明書のサポート

Custom Metrics Autoscaler Operator は、カスタムサービス CA 証明書を使用して、外部 Kafka クラスターや外部 Prometheus サービスなどの TLS 対応メトリクスソースに安全に接続できるようになりました。デフォルトでは、Operator は自動生成されたサービス証明書を使用して、クラスター上のサービスにのみ接続します。**KedaController** オブジェクトには、config map を使用して外部サービスに接続するためのカスタムサーバー CA 証明書を読み込むことができる新しいフィールドがあります。

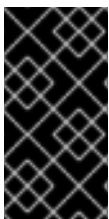
詳細は、[Custom Metrics Autoscaler のカスタム CA 証明書](#) を参照してください。

3.1.2.5.2. バグ修正

- 以前は、**custom-metrics-autoscaler** および **custom-metrics-autoscaler-adapter** イメージにタイムゾーン情報がありませんでした。その結果、コントローラーがタイムゾーン情報を見つけれなかったため、**cron** トリガーを使用した scaled object は機能しなくなりました。この修正により、イメージビルドが更新され、タイムゾーン情報が含まれるようになりました。その結果、**cron** トリガーを含む scaled object が正常に機能するようになりました。**cron** トリガーを含む scaled object は、現在、カスタムメトリクスオートスケーラーではサポートされていません。(OCBUGS-34018)

3.1.2.6. Custom Metrics Autoscaler Operator 2.12.1-394 リリースノート

Custom Metrics Autoscaler Operator 2.12.1-394 のこのリリースでは、OpenShift Container Platform クラスターで Operator を実行するためのバグ修正が提供されています。[RHSA-2024:2901](#) には、次のアドバイザリーを利用できます。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの Kubernetes ベースの Event Driven Autoscaler (KEDA) を削除します。

3.1.2.6.1. バグ修正

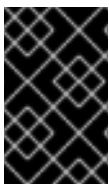
- 以前は、**protojson.Unmarshal** 関数は、特定の形式の無効な JSON をアンマーシャリングするときに無限ループに入りました。この状態は、**google.protobuf.Any** 値を含むメッセージにアンマーシャリングするとき、または **UnmarshalOptions.DiscardUnknown** オプションが設定されているときに発生する可能性があります。このリリースではこの問題が修正されています。(OCBUGS-30305)
- 以前は、**Request.ParseMultipartForm** メソッドを使用して明示的に、または **Request.FormValue**、**Request.PostFormValue**、**Request.FormFile** メソッドを使用して暗黙的にマルチパートフォームを解析する場合、解析されたフォームの合計サイズの制限は、消費

されるメモリーには適用されませんでした。これによりメモリー不足が発生する可能性があります。この修正により、解析プロセスでは、単一のフォーム行を読み取る際に、フォーム行の最大サイズが正しく制限されるようになりました。(OCBUGS-30360)

- 以前は、一致するサブドメイン上または最初のドメインと完全に一致しないドメインへの HTTP リダイレクトに従う場合、HTTP クライアントは **Authorization** や **Cookie** などの機密ヘッダーを転送しませんでした。たとえば、**example.com** から **www.example.com** へのリダイレクトでは **Authorization** ヘッダーが転送されますが、**www.example.org** へのリダイレクトではヘッダーは転送されません。このリリースではこの問題が修正されています。(OCBUGS-30365)
- 以前は、不明な公開鍵アルゴリズムを持つ証明書を含む証明書チェーンを検証すると、証明書検証プロセスがパニックに陥っていました。この状況は、**Config.ClientAuth** パラメーターを **VerifyClientCertIfGiven** または **RequireAndVerifyClientCert** 値に設定するすべての暗号化および Transport Layer Security (TLS) クライアントとサーバーに影響しました。デフォルトの動作では、TLS サーバーはクライアント証明書を検証しません。このリリースではこの問題が修正されています。(OCBUGS-30370)
- 以前は、**MarshalJSON** メソッドから返されるエラーにユーザーが制御するデータが含まれている場合、攻撃者はそのデータを使用して HTML テンプレートパッケージのコンテキスト自動エスケープ動作を破ることができた可能性があります。この条件により、後続のアクションによってテンプレートに予期しないコンテンツが挿入される可能性があります。このリリースではこの問題が修正されています。(OCBUGS-30397)
- 以前は、Go パッケージ **net/http** および **golang.org/x/net/http2** では、HTTP/2 リクエストの **CONTINUATION** フレームの数に制限がありませんでした。この状態により、CPU が過剰に消費される可能性があります。このリリースではこの問題が修正されています。(OCBUGS-30894)

3.1.2.7. Custom Metrics Autoscaler Operator 2.12.1-384 リリースノート

Custom Metrics Autoscaler Operator 2.12.1-384 のこのリリースでは、OpenShift Container Platform クラスタで Operator を実行するためのバグ修正が提供されています。[RHBA-2024:2043](#) に関する次のアドバイザリーが利用可能です。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの KEDA を削除します。

3.1.2.7.1. バグ修正

- 以前は、**custom-metrics-autoscaler** および **custom-metrics-autoscaler-adapter** イメージにタイムゾーン情報がありませんでした。その結果、コントローラーがタイムゾーン情報を見つけれなかったため、**cron** トリガーを使用した scaled object は機能しなくなりました。この修正により、イメージビルドが更新され、タイムゾーン情報が含まれるようになりました。その結果、**cron** トリガーを含む scaled object が正常に機能するようになりました。(OCBUGS-32395)

3.1.2.8. Custom Metrics Autoscaler Operator 2.12.1-376 リリースノート

Custom Metrics Autoscaler Operator 2.12.1-376 のこのリリースでは、OpenShift Container Platform クラスタで Operator を実行するためのセキュリティ更新とバグ修正が提供されます。[RHSA-2024:1812](#) には、次のアドバイザリーを利用できます。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの KEDA を削除します。

3.1.2.8.1. バグ修正

- 以前は、存在しない namespace などの無効な値が scaled object メタデータに指定されている場合、基盤となるスケーラクライアントはクライアント記述子を解放または終了できず、低速のメモリーリークが発生していました。この修正により、エラーが発生した場合に基礎となるクライアント記述子が適切に終了され、メモリーのリークが防止されます。[\(OCPBUGS-30145\)](#)
- 以前は、**keda-metrics-apiserver** Pod の **ServiceMonitor** カスタムリソース (CR) が機能していませんでした。これは、CR が **http** という誤ったメトリクスポート名を参照していたためです。この修正により、**ServiceMonitor** CR が修正され、**metrics** の適切なポート名が参照されるようになります。その結果、Service Monitor が正常に機能します。[\(OCPBUGS-25806\)](#)

3.1.2.9. Custom Metrics Autoscaler Operator 2.11.2-322 リリースノート

Custom Metrics Autoscaler Operator 2.11.2-322 のこのリリースでは、OpenShift Container Platform クラスタで Operator を実行するためのセキュリティ更新とバグ修正が提供されます。[RHSA-2023:6144](#) には、次のアドバイザリーを利用できます。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの KEDA を削除します。

3.1.2.9.1. バグ修正

- Custom Metrics Autoscaler Operator バージョン 3.11.2-311 は、Operator デプロイメントに必要なボリュームマウントなしにリリースされたため、Custom Metrics Autoscaler Operator Pod は 15 分ごとに再起動しました。この修正により、必要なボリュームマウントが Operator デプロイメントに追加されました。その結果、Operator は 15 分ごとに再起動しなくなりました。[\(OCPBUGS-22361\)](#)

3.1.2.10. Custom Metrics Autoscaler Operator 2.11.2-311 リリースノート

この Custom Metrics Autoscaler Operator 2.11.2-311 リリースでは、OpenShift Container Platform クラスタで Operator を実行するための新機能とバグ修正を使用できます。Custom Metrics Autoscaler Operator 2.11.2-311 のコンポーネントは [RHBA-2023:5981](#) でリリースされました。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの KEDA を削除します。

3.1.2.10.1. 新機能および機能拡張

3.1.2.10.1.1. Red Hat OpenShift Service on AWS と OpenShift Dedicated がサポートされるようになる

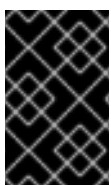
Custom Metrics Autoscaler Operator 2.11.2-311 は、Red Hat OpenShift Service on AWS および OpenShift Dedicated マネージドクラスターにインストールできます。Custom Metrics Autoscaler Operator の以前のバージョンは、**openshift-keda** namespace にのみインストールできました。これにより、Operator を Red Hat OpenShift Service on AWS および OpenShift Dedicated クラスターにインストールできませんでした。このバージョンの Custom Metrics Autoscaler では、**openshift-operators** または **keda** などの他の namespace へのインストールが可能になり、Red Hat OpenShift Service on AWS および OpenShift Dedicated クラスターへのインストールが可能になります。

3.1.2.10.2. バグ修正

- 以前は、Custom Metrics Autoscaler Operator がインストールおよび設定されているが使用されていない場合、OpenShift CLI では、**oc** コマンドを入力すると、**couldn't get resource list for external.metrics.k8s.io/v1beta1: Got empty response for: external.metrics.k8s.io/v1beta1** エラーが報告されていました。このメッセージは無害ではありますが、混乱を引き起こす可能性がありました。この修正により、**Got empty response for: external.metrics...** エラーが不適切に表示されなくなりました。(OCPBUGS-15779)
- 以前は、設定変更後など、Keda Controller が変更されるたびに、Custom Metrics Autoscaler Operator によって管理されるオブジェクトに対するアノテーションやラベルの変更は、Custom Metrics Autoscaler Operator によって元に戻されました。これにより、オブジェクト内のラベルが継続的に変更されてしまいました。Custom Metrics Autoscaler は、独自のアノテーションを使用してラベルとアノテーションを管理するようになり、アノテーションやラベルが不適切に元に戻されることがなくなりました。(OCPBUGS-15590)

3.1.2.11. Custom Metrics Autoscaler Operator 2.10.1-267 リリースノート

この Custom Metrics Autoscaler Operator 2.10.1-267 リリースでは、OpenShift Container Platform クラスターで Operator を実行するための新機能とバグ修正を使用できます。Custom Metrics Autoscaler Operator 2.10.1-267 のコンポーネントは [RHBA-2023:4089](#) でリリースされました。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの KEDA を削除します。

3.1.2.11.1. バグ修正

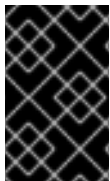
- 以前は、**custom-metrics-autoscaler** イメージと **custom-metrics-autoscaler-adapter** イメージにはタイムゾーン情報が含まれていませんでした。そのため、コントローラーがタイムゾーン情報を検出できないことが原因で、cron トリガーを使用した scaled object が機能していませんでした。今回の修正により、イメージビルドにタイムゾーン情報が含まれるようになりました。その結果、cron トリガーを含む scaled object が正常に機能するようになりました。(OCPBUGS-15264)
- 以前のバージョンでは、Custom Metrics Autoscaler Operator は、他の namespace 内のオブジェクトやクラスタースコープのオブジェクトを含む、すべてのマネージドオブジェクトの所有権を取得しようとしていました。このため、Custom Metrics Autoscaler Operator は API サーバーに必要な認証情報を読み取るためのロールバインディングを作成できませんでした。これにより、**kube-system** namespace でエラーが発生しました。今回の修正により、Custom

Metrics Autoscaler Operator は、別の namespace 内のオブジェクトまたはクラスタースコープのオブジェクトへの **ownerReference** フィールドの追加をスキップします。その結果、ロールバインディングがエラーなしで作成されるようになりました。(OCPBUGS-15038)

- 以前は、Custom Metrics Autoscaler Operator によって、**ownerReferences** フィールドが **openshift-keda** namespace に追加されていました。これによって機能上の問題が発生することはありませんでしたが、このフィールドの存在によりクラスター管理者が混乱する可能性があります。今回の修正により、Custom Metrics Autoscaler Operator は **ownerReference** フィールドを **openshift-keda** namespace に追加しなくなりました。その結果、**openshift-keda** namespace には余分な **ownerReference** フィールドが含まれなくなりました。(OCPBUGS-15293)
- 以前のバージョンでは、Pod ID 以外の認証方法で設定された Prometheus トリガーを使用し、**podIdentity** パラメーターが **none** に設定されている場合、トリガーはスケーリングに失敗しました。今回の修正により、OpenShift の Custom Metrics Autoscaler は、Pod ID プロバイダータイプ **none** を適切に処理できるようになりました。その結果、Pod ID 以外の認証方法で設定され、**podIdentity** パラメーターが **none** に設定された Prometheus トリガーが適切にスケーリングされるようになりました。(OCPBUGS-15274)

3.1.2.12. Custom Metrics Autoscaler Operator 2.10.1 リリースノート

この Custom Metrics Autoscaler Operator 2.10.1 リリースでは、OpenShift Container Platform クラスターで Operator を実行するための新機能とバグ修正を使用できます。Custom Metrics Autoscaler Operator 2.10.1 のコンポーネントは [RHEA-2023:3199](#) でリリースされました。



重要

このバージョンの Custom Metrics Autoscaler Operator をインストールする前に、以前にインストールされたテクノロジープレビューバージョンまたはコミュニティがサポートするバージョンの KEDA を削除します。

3.1.2.12.1. 新機能および機能拡張

3.1.2.12.1.1. Custom Metrics Autoscaler Operator の一般提供

Custom Metrics Autoscaler Operator バージョン 2.10.1 以降で、Custom Metrics Autoscaler Operator の一般提供が開始されました。



重要

スケーリングされたジョブを使用したスケーリングはテクノロジープレビュー機能です。テクノロジープレビュー機能は、Red Hat 製品のサービスレベルアグリーメント (SLA) の対象外であり、機能的に完全ではないことがあります。Red Hat は、実稼働環境でこれらを使用することを推奨していません。テクノロジープレビュー機能は、最新の製品機能をいち早く提供して、開発段階で機能のテストを行い、フィードバックを提供していただくことを目的としています。

Red Hat のテクノロジープレビュー機能のサポート範囲に関する詳細は、[テクノロジープレビュー機能のサポート範囲](#) を参照してください。

3.1.2.12.1.2. パフォーマンスメトリクス

Prometheus Query Language (PromQL) を使用して、Custom Metrics Autoscaler Operator でメトリクスのクエリーを行えるようになりました。

3.1.2.12.1.3. スケーリングされたオブジェクトのカスタムメトリクス自動スケーリングの一時停止

必要に応じてスケーリングされたオブジェクトの自動スケーリングを一時停止し、準備ができたら再開できるようになりました。

3.1.2.12.1.4. スケーリングされたオブジェクトのレプリカフォールバック

スケーリングされたオブジェクトがソースからメトリクスを取得できなかった場合に、フォールバックするレプリカ数を指定できるようになりました。

3.1.2.12.1.5. スケーリングされたオブジェクトのカスタマイズ可能な HPA 命名

スケーリングされたオブジェクトで、Horizontal Pod Autoscaler のカスタム名を指定できるようになりました。

3.1.2.12.1.6. アクティブ化およびスケーリングのしきい値

Horizontal Pod Autoscaler (HPA) は 0 レプリカへの、または 0 レプリカからのスケーリングができないため、Custom Metrics Autoscaler Operator がそのスケーリングを実行し、その後 HPA がスケーリングを実行します。レプリカ数に基づき HPA が自動スケーリングを引き継ぐタイミングを指定できるようになりました。これにより、スケーリングポリシーの柔軟性が向上します。

3.1.2.13. Custom Metrics Autoscaler Operator 2.8.2-174 リリースノート

この Custom Metrics Autoscaler Operator 2.8.2-174 リリースでは、OpenShift Container Platform クラスタで Operator を実行するための新機能とバグ修正を使用できます。Custom Metrics Autoscaler Operator 2.8.2-174 のコンポーネントは [RHEA-2023:1683](#) でリリースされました。



重要

Custom Metrics Autoscaler Operator バージョン 2.8.2-174 は、[テクノロジープレビュー](#)機能です。

3.1.2.13.1. 新機能および機能拡張

3.1.2.13.1.1. Operator のアップグレードサポート

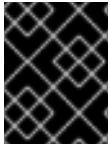
以前の Custom Metrics Autoscaler Operator バージョンからアップグレードできるようになりました。Operator のアップグレードの詳細は、「関連情報」の「Operator の更新チャンネルの変更」を参照してください。

3.1.2.13.1.2. must-gather サポート

OpenShift Container Platform **must-gather** ツールを使用して、Custom Metrics Autoscaler Operator およびそのコンポーネントに関するデータを収集できるようになりました。現時点で、Custom Metrics Autoscaler で **must-gather** ツールを使用するプロセスは、他の Operator とは異なります。詳細は、関連情報の「デバッグデータの収集」を参照してください。

3.1.2.14. Custom Metrics Autoscaler Operator 2.8.2 リリースノート

Custom Metrics Autoscaler Operator 2.8.2 のこのリリースは、OpenShift Container Platform クラスタで Operator を実行するための新機能とバグ修正を提供します。Custom Metrics Autoscaler Operator 2.8.2 のコンポーネントは [RHSA-2023:1042](#) でリリースされました。



重要

Custom Metrics Autoscaler Operator バージョン 2.8.2 は [テクノロジーレビュー](#) 機能です。

3.1.2.14.1. 新機能および機能拡張

3.1.2.14.1.1. 監査ロギング

Custom Metrics Autoscaler Operator とその関連コンポーネントの監査ログを収集して表示できるようになりました。監査ログは、システムに影響を与えた一連のアクティビティを個別のユーザー、管理者その他システムのコンポーネント別に記述したセキュリティ関連の時系列のレコードです。

3.1.2.14.1.2. Apache Kafka メトリクスに基づくアプリケーションのスケーリング

KEDA Apache kafka トリガー/スケーラーを使用して、Apache Kafka トピックに基づいてデプロイメントをスケーリングできるようになりました。

3.1.2.14.1.3. CPU メトリクスに基づくアプリケーションのスケーリング

KEDA CPU トリガー/スケーラーを使用して、CPU メトリクスに基づいてデプロイメントをスケーリングできるようになりました。

3.1.2.14.1.4. メモリーメトリクスに基づくアプリケーションのスケーリング

KEDA メモリートリガー/スケーラーを使用して、メモリーメトリクスに基づいてデプロイメントをスケーリングできるようになりました。

3.2. CUSTOM METRICS AUTOSCALER OPERATOR の概要

開発者は、Red Hat OpenShift の Custom Metrics Autoscaler Operator を使用して、OpenShift Container Platform が CPU またはメモリーのみに基づくものではないカスタムメトリクスに基づきデプロイメント、ステートフルセット、カスタムリソース、またはジョブの Pod 数を自動的に増減する方法を指定できます。

Custom Metrics Autoscaler Operator は、Kubernetes Event Driven Autoscaler (KEDA) に基づくオプションの Operator であり、Pod メトリクス以外の追加のメトリクスソースを使用してワークロードをスケーリングできます。

カスタムメトリクスオートスケーラーは現在、Prometheus、CPU、メモリー、および Apache Kafka メトリクスのみをサポートしています。

Custom Metrics Autoscaler Operator は、特定のアプリケーションからのカスタムの外部メトリクスに基づいて、Pod をスケールアップおよびスケールダウンします。他のアプリケーションは引き続き他のスケーリング方法を使用します。スケーラーとも呼ばれる **トリガー** を設定します。これは、カスタムメトリックオートスケーラーがスケーリング方法を決定するために使用するイベントとメトリックのソースです。カスタムメトリックオートスケーラーはメトリック API を使用して、外部メトリックを OpenShift Container Platform が使用できる形式に変換します。カスタムメトリクスオートスケーラーは、実際のスケーリングを実行する Horizontal Pod Autoscaler (HPA) を作成します。

カスタムメトリクスオートスケーラーを使用するには、ワークロード用の **ScaledObject** または **ScaledJob** オブジェクトを作成します。これらは、スケーリングメタデータを定義するカスタムリソース (CR) です。スケーリングするデプロイメントまたはジョブ、スケーリングするメトリクスのソース (トリガー)、許可される最小および最大レプリカ数などのその他のパラメーターを指定します。



注記

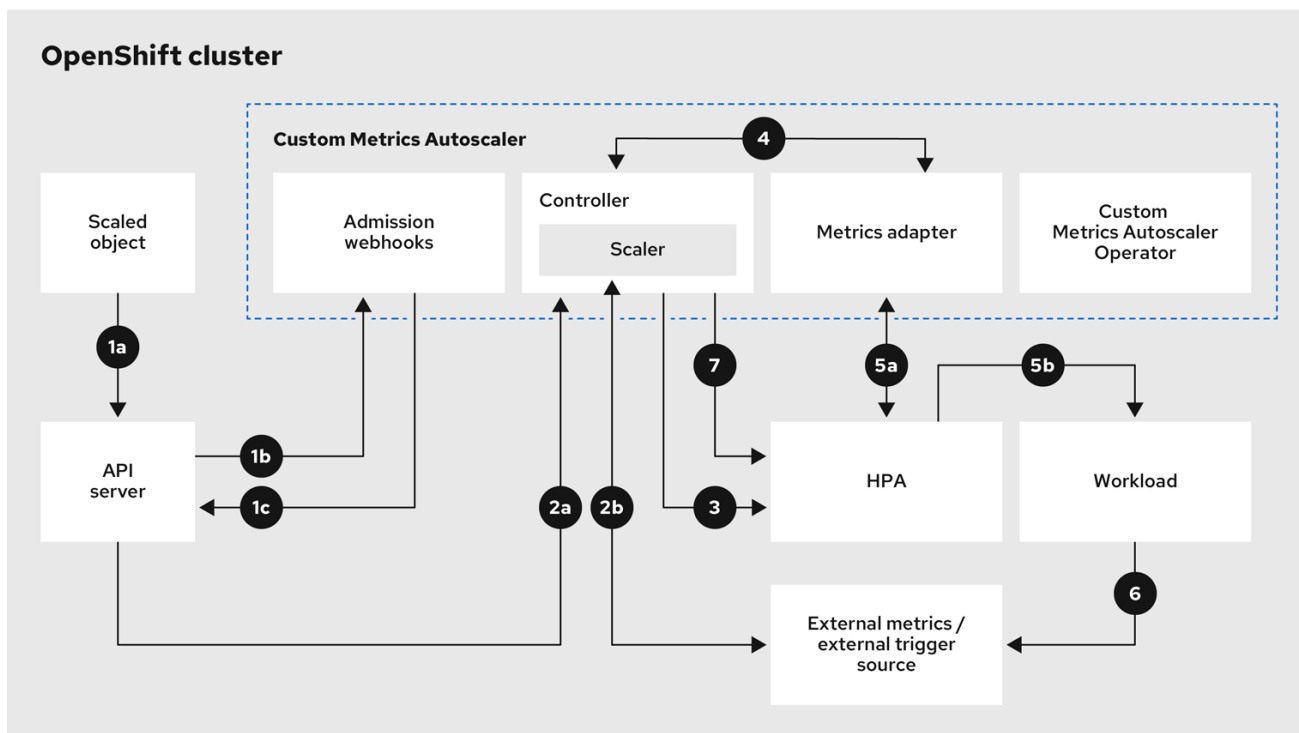
スケーリングするワークロードごとに、スケーリングされたオブジェクトまたはスケーリングされたジョブを1つだけ作成できます。また、スケーリングされたオブジェクトまたはスケーリングされたジョブと Horizontal Pod Autoscaler (HPA) を同じワークロードで使用することはできません。

カスタムメトリクスオートスケーラーは、HPA とは異なり、ゼロにスケーリングできます。カスタムメトリクスオートスケーラー CR の **minReplicaCount** 値を **0** に設定すると、カスタムメトリクスオートスケーラーはワークロードを1レプリカから0レプリカにスケールダウンするか、0レプリカから1にスケールアップします。これは、**アクティベーションフェーズ** として知られています。1つのレプリカにスケールアップした後、HPA はスケーリングを制御します。これは **スケーリングフェーズ** として知られています。

一部のトリガーにより、クラスターメトリクスオートスケーラーによってスケーリングされるレプリカの数を変更できます。いずれの場合も、アクティベーションフェーズを設定するパラメーターは、**activation** で始まる同じフレーズを常に使用します。たとえば、**threshold** パラメーターがスケーリングを設定する場合、**activationThreshold** はアクティベーションを設定します。アクティベーションフェーズとスケーリングフェーズを設定すると、スケーリングポリシーの柔軟性が向上します。たとえば、アクティベーションフェーズをより高く設定することで、メトリクスが特に低い場合にスケールアップまたはスケールダウンを防ぐことができます。

それぞれ異なる決定を行う場合は、スケーリングの値よりもアクティベーションの値が優先されます。たとえば、**threshold** が **10** に設定されていて、**activationThreshold** が **50** である場合にメトリクスが **40** を報告した場合、スケーラーはアクティブにならず、HPA が4つのインスタンスを必要とする場合でも Pod はゼロにスケーリングされます。

図3.1 カスタムメトリクスオートスケーラーのワークフロー



565_OpenShift_0224

1. クラスター上のワークロード用のスケーリングされたオブジェクトのカスタムリソースを作成または変更します。オブジェクトには、そのワークロードのスケーリング設定を含めます。OpenShift API サーバーは、新しいオブジェクトを受け入れる前に、そのオブジェクトをカス

タムメトリクスオートスケーラーのアドミSSION Webhook プロセスに送信して、オブジェクトが有効であることを確認します。検証が成功すると、API サーバーはオブジェクトを永続化します。

2. カスタムメトリクスオートスケーラーコントローラーが、スケーリングされたオブジェクトの更新または変更を監視します。OpenShift API サーバーがコントローラーに変更を通知すると、コントローラーは、オブジェクト内で指定されている外部トリガースource (データソースとも呼ばれる) を監視して、メトリクスデータの変更を確認します。1つ以上のスケーラーが外部トリガースourceからのスケーリングデータを要求します。たとえば、Kafka トリガータイプの場合、コントローラーは Kafka スケーラーを使用して Kafka インスタンスと通信し、トリガーによって要求されたデータを取得します。
3. コントローラーが、スケーリングされたオブジェクトの Horizontal Pod Autoscaler オブジェクトを作成します。その結果、Horizontal Pod Autoscaler (HPA) Operator が、トリガーに関連付けられたスケーリングデータの監視を開始します。HPA は、クラスターの OpenShift API サーバーエンドポイントからスケーリングデータを要求します。
4. OpenShift API サーバーエンドポイントが、カスタムメトリクスオートスケーラーのメトリクスアダプターによって提供されます。メトリクスアダプターは、カスタムメトリクスの要求を受信すると、コントローラーへの GRPC 接続を使用して、スケーラーから受信した最新のトリガーデータを要求します。
5. HPA がメトリクスアダプターから受信したデータに基づいてスケーリングを決定し、レプリカを増減することでワークロードをスケールアップまたはスケールダウンします。
6. 運用中に、ワークロードがスケーリングメトリクスに影響を与えることがあります。たとえば、Kafka キュー内の作業を処理するためにワークロードがスケールアップされた場合、ワークロードがすべての作業を処理した後、キューのサイズが減少します。その結果、ワークロードがスケールダウンされます。
7. メトリクスが **minReplicaCount** 値で指定された範囲内にある場合、カスタムメトリクスオートスケーラーコントローラーがすべてのスケーリングを無効にして、レプリカ数を一定に維持します。メトリクスがその範囲を超える場合、カスタムメトリクスオートスケーラーコントローラーはスケーリングを有効にして、HPA がワークロードをスケーリングできるようにします。スケーリングが無効になっている間、HPA は何もアクションを実行しません。

3.2.1. Custom Metrics Autoscaler 用のカスタム CA 証明書

デフォルトでは、Custom Metrics Autoscaler Operator は、自動的に生成されたサービス CA 証明書を使用して、クラスター上のサービスに接続します。

カスタム CA 証明書を必要とするクラスター外のサービスを使用する場合は、必要な証明書を config map に追加できます。次に、[カスタムメトリクスオートスケーラーのインストール](#)の説明に従って、**KedaController** カスタムリソースに config map を追加します。Operator は起動時にこれらの証明書を読み込み、Operator によって信頼されたものとして登録します。

config map には、1つ以上の PEM エンコードされた CA 証明書を含む1つ以上の証明書ファイルを含めることができます。または、証明書ファイルごとに個別の config map を使用することもできます。



注記

後で config map を更新して追加の証明書を追加する場合は、変更を有効にするために **keda-operator-*** Pod を再起動する必要があります。

3.3. カスタムメトリクスオートスケーラーのインストール

OpenShift Container Platform Web コンソールを使用して Custom Metrics Autoscaler Operator をインストールすることができます。

インストールにより、以下の 5 つの CRD が作成されます。

- **ClusterTriggerAuthentication**
- **KedaController**
- **ScaledJob**
- **ScaledObject**
- **TriggerAuthentication**

インストールプロセスでは、**KedaController** カスタムリソース (CR) も作成されます。必要に応じて、デフォルトの **KedaController** CR を変更できます。詳細は、「Keda Controller CR の編集」を参照してください。



注記

2.17.2 より前のバージョンの Custom Metrics Autoscaler Operator をインストールする場合は、Keda Controller CR を手動で作成する必要があります。CR を作成するには、「Keda Controller CR の編集」で説明されている手順を使用できます。

3.3.1. カスタムメトリクスオートスケーラーのインストール

次の手順を使用して、Custom Metrics Autoscaler Operator をインストールできます。

前提条件

- これまでにインストールしたテクノロジープレビューバージョンの Cluster Metrics Autoscaler Operator を削除する。
- コミュニティーベースの KEDA バージョンをすべて削除する。
次のコマンドを実行して、KEDA 1.x カスタムリソース定義を削除する。

```
$ oc delete crd scaledobjects.keda.k8s.io
```

```
$ oc delete crd triggerauthentications.keda.k8s.io
```

- オプション: Custom Metrics Autoscaler Operator を外部 Kafka クラスターや外部 Prometheus サービスなどのクラスター外のサービスに接続する必要がある場合は、必要なサービス CA 証明書を config map に配置します。config map は、Operator がインストールされているのと同じ namespace に存在する必要があります。以下に例を示します。

```
$ oc create configmap -n openshift-keda thanos-cert --from-file=ca-cert.pem
```

手順

1. OpenShift Container Platform Web コンソールで、**Operators → OperatorHub** をクリックします。

2. 使用可能な Operator のリストから **Custom Metrics Autoscaler** を選択し、**Install** をクリックします。
3. **Install Operator** ページで、**Installation Mode** に **All namespaces on the cluster (default)** オプションが選択されていることを確認します。これにより、Operator がすべての namespace にインストールされます。
4. **Installed Namespace** に **openshift-keda** namespace が選択されていることを確認します。クラスターに存在しない場合、OpenShift Container Platform は namespace を作成します。
5. **Install** をクリックします。
6. Custom Metrics Autoscaler Operator コンポーネントをリスト表示して、インストールを確認します。
 - a. **Workloads** → **Pods** に移動します。
 - b. ドロップダウンメニューから **openshift-keda** プロジェクトを選択し、**custom-metrics-autoscaler-operator-*** Pod が実行されていることを確認します。
 - c. **Workloads** → **Deployments** に移動して、**custom-metrics-autoscaler-operator** デプロイメントが実行されていることを確認します。
7. オプション: 次のコマンドを使用して、OpenShift CLI でインストールを確認します。

```
$ oc get all -n openshift-keda
```

以下のような出力が表示されます。

出力例

```
NAME                                READY STATUS  RESTARTS  AGE
pod/custom-metrics-autoscaler-operator-5fd8d9ffd8-xt4xp  1/1   Running    0        18m

NAME                                READY UP-TO-DATE AVAILABLE AGE
deployment.apps/custom-metrics-autoscaler-operator  1/1   1          1        18m

NAME                                DESIRED CURRENT READY AGE
replicaset.apps/custom-metrics-autoscaler-operator-5fd8d9ffd8  1      1      1        18m
```

3.3.2. Keda Controller CR の編集

Custom Metrics Autoscaler Operator のインストール中に自動的にインストールされる **KedaController** カスタムリソース (CR) を変更するには、次の手順に従います。

手順

1. OpenShift Container Platform Web コンソールで、**Operators** → **Installed Operators** をクリックします。
2. **Custom Metrics Autoscaler** をクリックします。
3. **Operator Details** ページで、**KedaController** タブをクリックします。
4. **KedaController** タブで、**Create KedaController** をクリックしてファイルを編集します。

—

```

kind: KedaController
apiVersion: keda.sh/v1alpha1
metadata:
  name: keda
  namespace: openshift-keda
spec:
  watchNamespace: " ❶
  operator:
    logLevel: info ❷
    logEncoder: console ❸
    caConfigMaps: ❹
    - thanos-cert
    - kafka-cert
    volumeMounts: ❺
    - mountPath: /<path_to_directory>
      name: <name>
    volumes: ❻
    - name: <volume_name>
      emptyDir:
        medium: Memory
  metricsServer:
    logLevel: '0' ❷
    auditConfig: ❸
    logFormat: "json"
    logOutputVolumeClaim: "persistentVolumeClaimName"
    policy:
      rules:
        - level: Metadata
      omitStages: ["RequestReceived"]
      omitManagedFields: false
    lifetime:
      maxAge: "2"
      maxBackup: "1"
      maxSize: "50"
  serviceAccount: {}

```

- ❶ Custom Metrics Autoscaler Operator がアプリケーションをスケーリングする単一の namespace を指定します。空白のままにするか、または空にして、すべての namespace でアプリケーションをスケーリングします。このフィールドは、namespace があるか、空である必要があります。デフォルト値は空です。
- ❷ Custom Metrics Autoscaler Operator ログメッセージの詳細レベルを指定します。許可される値は **debug**、**info**、**error** です。デフォルトは **info** です。
- ❸ Custom Metrics Autoscaler Operator ログメッセージのログ形式を指定します。許可される値は **console** または **json** です。デフォルトは **console** です。
- ❹ オプション: CA 証明書を持つ 1 つ以上の config map を指定します。Custom Metrics Autoscaler Operator はこれを使用して、TLS 対応のメトリクスソースに安全に接続できます。
- ❺ オプション: コンテナのマウントパスを追加します。
- ❻ オプション: **volumes** ブロックを追加し、各 Projected ボリュームのソースをリストします。

- 7 Custom Metrics Autoscaler Metrics Server のログレベルを指定します。使用可能な値は、**info** の場合は **0**、**debug** の場合は **4** です。デフォルトは **0** です。
- 8 Custom Metrics Autoscaler Operator の監査ログをアクティブにして、使用する監査ポリシーを指定します（「監査ログの設定」セクションを参照）。

5. **Save** をクリックして、変更を保存します。

3.4. カスタムメトリクスオートスケーラートリガーについて

スケーラーとも呼ばれるトリガーは、Custom Metrics Autoscaler Operator が Pod をスケーリングするために使用するメトリクスを提供します。

カスタムメトリクスオートスケーラーは現在、Prometheus、CPU、メモリー、Apache Kafka、cron トリガーをサポートしています。

以下のセクションで説明するように、**ScaledObject** または **ScaledJob** カスタムリソースを使用して、特定のオブジェクトのトリガーを設定します。

[scaled object で使用](#) する認証局、または [クラスター内のすべてのスケーラー用](#) の認証局を設定できます。

3.4.1. Prometheus トリガーについて

Prometheus メトリクスに基づいて Pod をスケーリングできます。このメトリクスは、インストール済みの OpenShift Container Platform モニタリングまたは外部 Prometheus サーバーをメトリクスソースとして使用できます。OpenShift Container Platform モニタリングをメトリクスのソースとして使用するために必要な設定は、「OpenShift Container Platform モニタリングを使用するためのカスタムメトリクスオートスケーラーの設定」を参照してください。



注記

カスタムメトリクスオートスケーラーがスケーリングしているアプリケーションから Prometheus がメトリクスを収集している場合は、カスタムリソースで最小レプリカ数を **0** に設定しないでください。アプリケーション Pod がないと、カスタムメトリクスオートスケーラーにスケーリングの基準となるメトリクスが提供されません。

Prometheus ターゲットを使用した scaled object の例

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: prom-scaledobject
  namespace: my-namespace
spec:
  # ...
  triggers:
  - type: prometheus 1
    metadata:
      serverAddress: https://thanos-querier.openshift-monitoring.svc.cluster.local:9092 2
      namespace: kedatest 3
      metricName: http_requests_total 4
      threshold: '5' 5
```

```

query: sum(rate(http_requests_total{job="test-app"}[1m])) 6
authModes: basic 7
cortexOrgID: my-org 8
ignoreNullValues: false 9
unsafeSsl: false 10
timeout: 1000 11

```

- 1 Prometheus をトリガータイプとして指定します。
- 2 Prometheus サーバーのアドレスを指定します。この例では、OpenShift Container Platform モニタリングを使用します。
- 3 オプション: スケーリングするオブジェクトの namespace を指定します。メトリクスのソースとして OpenShift Container Platform モニタリングを使用する場合、このパラメーターは必須です。
- 4 **external.metrics.k8s.io** API でメトリクスを識別する名前を指定します。複数のトリガーを使用している場合、すべてのメトリクス名が一意である必要があります。
- 5 スケーリングをトリガーする値を指定します。引用符で囲まれた文字列値として指定する必要があります。
- 6 使用する Prometheus クエリーを指定します。
- 7 使用する認証方法を指定します。Prometheus スケーラーは、ベアラー認証 (**bearer**)、Basic 認証 (**basic**)、または TLS 認証 (**tls**) をサポートしています。以下のセクションで説明するように、トリガー認証で特定の認証パラメーターを設定します。必要に応じて、シークレットを使用することもできます。
- 8 オプション: **X-Scope-OrgID** ヘッダーを Prometheus のマルチテナント **Cortex** または **Mimir** ストレージに渡します。このパラメーターは、Prometheus が返す必要のあるデータを示すために、マルチテナント Prometheus ストレージでのみ必要です。
- 9 オプション: Prometheus ターゲットが失われた場合のトリガーの処理方法を指定します。
 - **true** の場合、Prometheus ターゲットが失われても、トリガーは動作し続けます。これがデフォルトの動作です。
 - **false** の場合、Prometheus ターゲットが失われると、トリガーはエラーを返します。
- 10 オプション: 証明書チェックをスキップするかどうかを指定します。たとえば、テスト環境で実行しており、Prometheus エンドポイントで自己署名証明書を使用している場合は、チェックをスキップできます。
 - **false** の場合、証明書のチェックが実行されます。これがデフォルトの動作です。
 - **true** の場合、証明書のチェックは実行されません。



重要

チェックのスキップは推奨されません。

- 11 オプション: この Prometheus トリガーで使用される HTTP クライアントの HTTP 要求タイムアウトをミリ秒単位で指定します。この値は、グローバルタイムアウト設定をオーバーライドします。

3.4.1.1. Prometheus および DCGM メトリクスを使用した GPU ベースの自動スケーリングの設定

カスタムメトリクスオートスケーラーを NVIDIA データセンター GPU マネージャー (DCGM) メトリクスとともに使用すると、GPU 使用率に基づいてワークロードをスケーリングできます。これは、GPU リソースを必要とする AI および機械学習のワークロードに特に役立ちます。

GPU ベースの自動スケーリングのために Prometheus ターゲットを使用する scaled object の例

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: gpu-scaledobject
  namespace: my-namespace
spec:
  scaleTargetRef:
    kind: Deployment
    name: gpu-deployment
  minReplicaCount: 1 ❶
  maxReplicaCount: 5 ❷
  triggers:
  - type: prometheus
    metadata:
      serverAddress: https://thanos-querier.openshift-monitoring.svc.cluster.local:9092
      namespace: my-namespace
      metricName: gpu_utilization
      threshold: '90' ❸
      query: SUM(DCGM_FI_DEV_GPU_UTIL{instance=~".+", gpu=~".+"}) ❹
      authModes: bearer
      authenticationRef:
        name: keda-trigger-auth-prometheus
```

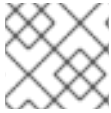
- ❶ 維持するレプリカの最小数を指定します。GPU ワークロードの場合は、メトリクスが継続的に収集されるように、これを **0** に設定しないでください。
- ❷ スケールアップ操作中に許可するレプリカの最大数を指定します。
- ❸ スケーリングをトリガーする GPU 使用率のしきい値をパーセンテージで指定します。GPU の平均使用率が 90% を超えると、オートスケーラーがデプロイメントをスケールアップします。
- ❹ すべての GPU デバイスの GPU 使用率を監視するために、NVIDIA DCGM メトリクスを使用して Prometheus クエリーを指定します。**DCGM_FI_DEV_GPU_UTIL** メトリクスは、GPU 使用率を提供します。

3.4.1.2. OpenShift Container Platform モニタリングを使用するためのカスタムメトリクスオートスケーラーの設定

カスタムメトリクスオートスケーラーが使用するメトリクスのソースとして、インストール済みの OpenShift Container Platform Prometheus モニタリングを使用できます。ただし、実行する必要がある追加の設定がいくつかあります。

scaled object が OpenShift Container Platform Prometheus メトリクスを読み取れるように、トリガー認証またはクラスタトリガー認証を使用して、必要な認証情報を提供する必要があります。以下の手

順は、使用するトリガー認証方式によって異なります。トリガー認証の詳細は、「カスタムメトリクスオートスケーラーのトリガー認証について」を参照してください。



注記

これらの手順は、外部 Prometheus ソースには必要ありません。

このセクションで説明するように、次のタスクを実行する必要があります。

- サービスアカウントを作成します。
- トリガー認証を作成します。
- ロールを作成します。
- そのロールをサービスアカウントに追加します。
- Prometheus が使用するトリガー認証オブジェクトでトークンを参照します。

前提条件

- OpenShift Container Platform モニタリングをインストールしている必要がある。
- ユーザー定義のワークロードのモニタリングを、OpenShift Container Platform モニタリングで有効にする必要がある ([ユーザー定義のワークロードモニタリング設定マップの作成](#) セクションで説明)。
- Custom Metrics Autoscaler Operator をインストールしている。

手順

1. 適切なプロジェクトに切り替えます。

```
$ oc project <project_name> ❶
```

- ❶ 次のプロジェクトのいずれかを指定します。

- トリガー認証を使用している場合は、スケーリングするオブジェクトを含むプロジェクトを指定します。
- クラスタトリガー認証を使用している場合は、**openshift-keda** プロジェクトを指定します。

2. クラスタにサービスアカウントがない場合は作成します。

- a. 次のコマンドを使用して、**service account** オブジェクトを作成します。

```
$ oc create serviceaccount thanos ❶
```

- ❶ サービスアカウントの名前を指定します。

3. サービスアカウントトークンを使用してトリガー認証を作成します。

- a. 以下のような YAML ファイルを作成します。

```
apiVersion: keda.sh/v1alpha1
kind: <authentication_method> ❶
metadata:
  name: keda-trigger-auth-prometheus
spec:
  boundServiceAccountToken: ❷
    - parameter: bearerToken ❸
      serviceAccountName: thanos ❹
```

- ❶ 次のいずれかのトリガー認証方法を指定します。
 - トリガー認証を使用している場合は、**TriggerAuthentication** を指定します。この例では、トリガー認証を設定します。
 - クラスタトリガー認証を使用している場合は、**ClusterTriggerAuthentication** を指定します。
- ❷ このトリガー認証では、メトリクスエンドポイントに接続するときに、バインドされたサービスアカウントトークンを使用して認可を行うことを指定します。
- ❸ トークンを使用して提供する認証パラメーターを指定します。この例では、ベアラー認証を使用します。
- ❹ 使用するサービスアカウントの名前を指定します。

- b. CR オブジェクトを作成します。

```
$ oc create -f <file-name>.yaml
```

4. Thanos メトリクスを読み取るためのロールを作成します。

- a. 次のパラメーターを使用して YAML ファイルを作成します。

```
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  name: thanos-metrics-reader
rules:
- apiGroups:
  - ""
  resources:
  - pods
  verbs:
  - get
- apiGroups:
  - metrics.k8s.io
  resources:
  - pods
  - nodes
  verbs:
```

```
- get
- list
- watch
```

b. CR オブジェクトを作成します。

```
$ oc create -f <file-name>.yaml
```

5. Thanos メトリクスを読み取るためのロールバインディングを作成します。

a. 以下のような YAML ファイルを作成します。

```
apiVersion: rbac.authorization.k8s.io/v1
kind: <binding_type> ❶
metadata:
  name: thanos-metrics-reader ❷
  namespace: my-project ❸
roleRef:
  apiGroup: rbac.authorization.k8s.io
  kind: Role
  name: thanos-metrics-reader
subjects:
- kind: ServiceAccount
  name: thanos ❹
  namespace: <namespace_name> ❺
```

❶ 次のオブジェクト型のいずれかを指定します。

- トリガー認証を使用している場合は、**RoleBinding** を指定します。
- クラスタートリガー認証を使用している場合は、**ClusterRoleBinding** を指定します。

❷ 作成したロールの名前を指定します。

❸ 次のプロジェクトのいずれかを指定します。

- トリガー認証を使用している場合は、スケーリングするオブジェクトを含むプロジェクトを指定します。
- クラスタートリガー認証を使用している場合は、**openshift-keda** プロジェクトを指定します。

❹ ロールにバインドするサービスアカウントの名前を指定します。

❺ サービスアカウントを先に作成したプロジェクトを指定します。

b. CR オブジェクトを作成します。

```
$ oc create -f <file-name>.yaml
```

「カスタムメトリクスオートスケーラーの追加方法について」で説明されているとおり、スケーリングされたオブジェクトまたはスケーリングされたジョブをデプロイして、アプリケーションの自動スケーリングを有効化できます。OpenShift Container Platform モニタリングをソースとして使用するには、

トリガーまたはスケーラーに以下のパラメーターを含める必要があります。

- **triggers.type** は **prometheus** にしてください。
- **triggers.metadata.serverAddress** は **https://thanos-querier.openshift-monitoring.svc.cluster.local:9092** にしてください。
- **triggers.metadata.authModes** は **bearer** にしてください。
- **triggers.metadata.namespace** は、スケーリングするオブジェクトの namespace に設定してください。
- **triggers.authenticationRef** は、直前の手順で指定されたトリガー認証リソースを指す必要があります。

3.4.2. CPU トリガーについて

CPU メトリクスに基づいて Pod をスケーリングできます。このトリガーは、クラスターメトリクスをメトリクスのソースとして使用します。

カスタムメトリクスオートスケーラーは、オブジェクトに関連付けられた Pod をスケーリングして、指定された CPU 使用率を維持します。オートスケーラーは、すべての Pod で指定された CPU 使用率を維持するために、最小数と最大数の間でレプリカ数を増減します。メモリートリガーは、Pod 全体のメモリー使用率を考慮します。Pod に複数のコンテナがある場合、メモリートリガーは Pod 内にあるすべてのコンテナの合計メモリー使用率を考慮します。



注記

- このトリガーは、**ScaledJob** カスタムリソースでは使用できません。
- メモリートリガーを使用してオブジェクトをスケーリングすると、複数のトリガーを使用している場合でも、オブジェクトは **0** にスケーリングされません。

CPU ターゲットを使用した scaled object の例

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: cpu-scaledobject
  namespace: my-namespace
spec:
  # ...
  triggers:
  - type: cpu ❶
    metricType: Utilization ❷
    metadata:
      value: '60' ❸
  minReplicaCount: 1 ❹
```

- ❶ トリガータイプとして CPU を指定します。
- ❷ 使用するメトリクスのタイプ (**Utilization** または **AverageValue** のいずれか) を指定します。
- ❸ スケーリングをトリガーする値を指定します。引用符で囲まれた文字列値として指定する必要があります。

ります。

- **Utilization** を使用する場合、ターゲット値は、関連する全 Pod のリソースメトリクスの平均値であり、Pod のリソースの要求値に占めるパーセンテージとして表されます。
- **AverageValue** を使用する場合、ターゲット値は、関連する全 Pod のメトリクスの平均値です。

- 4 スケールダウン時のレプリカの最小数を指定します。CPU トリガーの場合は、**1** 以上の値を入力します。CPU メトリクスのみを使用している場合、HPA はゼロにスケールできないためです。

3.4.3. メモリトリガーについて

メモリーメトリクスに基づいて Pod をスケーリングできます。このトリガーは、クラスターメトリクスをメトリクスのソースとして使用します。

カスタムメトリクスオートスケーラーは、オブジェクトに関連付けられた Pod をスケーリングして、指定されたメモリー使用率を維持します。オートスケーラーは、すべての Pod で指定のメモリー使用率を維持するために、最小数と最大数の間でレプリカ数を増減します。メモリートリガーは、Pod 全体のメモリー使用率を考慮します。Pod に複数のコンテナがある場合、メモリー使用率はすべてのコンテナの合計になります。



注記

- このトリガーは、**ScaledJob** カスタムリソースでは使用できません。
- メモリートリガーを使用してオブジェクトをスケーリングすると、複数のトリガーを使用している場合でも、オブジェクトは **0** にスケーリングされません。

メモリーターゲットを使用した scaled object の例

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: memory-scaledobject
  namespace: my-namespace
spec:
  # ...
  triggers:
  - type: memory 1
    metricType: Utilization 2
    metadata:
      value: '60' 3
      containerName: api 4
```

- 1 トリガータイプとしてメモリーを指定します。
- 2 使用するメトリクスのタイプ (**Utilization** または **AverageValue** のいずれか) を指定します。
- 3 スケーリングをトリガーする値を指定します。引用符で囲まれた文字列値として指定する必要があります。

- **Utilization** を使用する場合、ターゲット値は、関連する全 Pod のリソースメトリクスの平均値であり、Pod のリソースの要求値に占めるパーセンテージとして表されます。
- **AverageValue** を使用する場合、ターゲット値は、関連する全 Pod のメトリクスの平均値です。

- 4 オプション: Pod 全体ではなく、そのコンテナのみのメモリー使用率に基づいて、スケーリングする個々のコンテナを指定します。この例では、**api** という名前のコンテナのみがスケーリングされます。

3.4.4. Kafka トリガーについて

Apache Kafka トピックまたは Kafka プロトコルをサポートするその他のサービスに基づいて Pod をスケーリングできます。カスタムメトリクスオートスケーラーは、スケーリングされるオブジェクトまたはスケーリングされるジョブで **allowIdleConsumers** パラメーターを **true** に設定しない限り、Kafka パーティションの数を超過してスケーリングしません。

注記

コンシューマーグループの数がトピック内のパーティションの数を超過すると、余分なコンシューマーグループはそのままアイドル状態になります。これを回避するために、デフォルトではレプリカの数を超えてスケーリングしません。

- トピックのパーティションの数 (トピックが指定されている場合)。
- コンシューマーグループ内の全トピックのパーティション数 (トピックが指定されていない場合)。
- スケーリングされるオブジェクトまたはスケーリングされるジョブの CR で指定された **maxReplicaCount**。

これらのデフォルトの動作は、**allowIdleConsumers** パラメーターを使用して無効にすることができます。

Kafka ターゲットを使用した scaled object の例

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: kafka-scaledobject
  namespace: my-namespace
spec:
  # ...
  triggers:
    - type: kafka ①
      metadata:
        topic: my-topic ②
        bootstrapServers: my-cluster-kafka-bootstrap.openshift-operators.svc:9092 ③
        consumerGroup: my-group ④
        lagThreshold: '10' ⑤
        activationLagThreshold: '5' ⑥
        offsetResetPolicy: latest ⑦
        allowIdleConsumers: true ⑧
```

```
scaleToZeroOnInvalidOffset: false 9
excludePersistentLag: false 10
version: '1.0.0' 11
partitionLimitation: '1,2,10-20,31' 12
tls: enable 13
```

- 1 トリガータ입として Kafka を指定します。
- 2 Kafka がオフセットラグを処理している Kafka トピックの名前を指定します。
- 3 接続する Kafka ブローカーのコンマ区切りリストを指定します。
- 4 トピックのオフセットの確認と、関連するラグの処理に使用される Kafka コンシューマーグループの名前を指定します。
- 5 オプション: スケーリングをトリガーする平均ターゲット値を指定します。引用符で囲まれた文字列値として指定する必要があります。デフォルトは **5** です。
- 6 オプション: アクティベーションフェーズのターゲット値を指定します。引用符で囲まれた文字列値として指定する必要があります。
- 7 オプション: Kafka コンシューマーの Kafka オフセットリセットポリシーを指定します。使用可能な値は **latest** および **earliest** です。デフォルトは **latest** です。
- 8 オプション: Kafka レプリカの数が入入りのパーティションの数を超えることを許可するかどうかを指定します。
 - **true** の場合、Kafka レプリカ数は入入りのパーティションの数を超えることができます。これにより、Kafka コンシューマーがアイドル状態になることが許容されます。
 - **false** の場合、Kafka レプリカ数は入入りのパーティションの数を超えることはできません。これがデフォルトです。
- 9 Kafka パーティションに有効なオフセットがない場合のトリガーの動作を指定します。
 - **true** の場合、そのパーティションのコンシューマーはゼロにスケールされます。
 - **false** の場合、スケールはそのパーティションのために1つのコンシューマーを保持します。これがデフォルトです。
- 10 オプション: 現在のオフセットが前のポーリングサイクルの現在のオフセットと同じであるパーティションのパーティションラグをトリガーに含めるか除外するかを指定します。
 - **true** の場合、スケールはこれらのパーティションのパーティションラグを除外します。
 - **false** の場合、すべてのパーティションのコンシューマーラグがすべてトリガーに含まれます。これがデフォルトです。
- 11 オプション: Kafka ブローカーのバージョンを指定します。引用符で囲まれた文字列値として指定する必要があります。デフォルトは **1.0.0** です。
- 12 オプション: スケーリングの範囲を適用するパーティション ID のコンマ区切りリストを指定します。指定されている場合、ラグの計算時にリスト内の ID のみが考慮されます。引用符で囲まれた文字列値として指定する必要があります。デフォルトでは、すべてのパーティションが考慮されます。

- 13 オプション: Kafka に TLS クライアント認証を使用するかどうかを指定します。デフォルトは **disable** です。TLS の設定の詳細は、「カスタムメトリクスオートスケーラートリガー認証について」

3.4.5. Cron トリガーについて

Pod は時間範囲に基づいてスケーリングできます。

時間範囲の開始時に、カスタムメトリクスオートスケーラーが、オブジェクトに関連する Pod を、設定された最小 Pod 数から指定された必要な Pod 数にスケーリングします。時間範囲の終了時に、Pod は設定された最小値にスケールダウンされます。期間は **cron 形式** で設定する必要があります。

次の例では、この scaled object に関連する Pod を、インド標準時の午前 6 時から午後 6 時 30 分まで **0** から **100** にスケーリングします。

Cron トリガーを使用した scaled object の例

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: cron-scaledobject
  namespace: default
spec:
  scaleTargetRef:
    name: my-deployment
  minReplicaCount: 0 1
  maxReplicaCount: 100 2
  cooldownPeriod: 300
  triggers:
  - type: cron 3
    metadata:
      timezone: Asia/Kolkata 4
      start: "0 6 * * *" 5
      end: "30 18 * * *" 6
      desiredReplicas: "100" 7
```

- 1 時間枠の終了時にスケールダウンする Pod の最小数を指定します。
- 2 スケールアップ時のレプリカの最大数を指定します。この値は **desiredReplicas** と同じである必要があります。デフォルトは **100** です。
- 3 Cron トリガーを指定します。
- 4 時間枠のタイムゾーンを指定します。この値は、[IANA Time Zone Database](#) から取得する必要があります。
- 5 時間枠の始点を指定します。
- 6 時間枠の終点を指定します。
- 7 時間枠の始点から終点までの間にスケーリングする Pod の数を指定します。この値は **maxReplicaCount** と同じである必要があります。

3.4.6. Kubernetes ワークロードトリガーを理解する

特定のラベルセクターに一致する Pod の数に基づいて Pod をスケーリングできます。

Custom Metrics Autoscaler Operator は、同じ namespace にある特定のラベルが付いた Pod の数を追跡し、ラベル付き Pod の数に基づいて scaled object の Pod との **関係** を計算します。この関係を使用して、Custom Metrics Autoscaler Operator は、**ScaledObject** または **ScaledJob** 仕様のスケーリングポリシーに従ってオブジェクトをスケーリングします。

Pod 数には、**Succeeded** フェーズまたは **Failed** フェーズの Pod が含まれます。

たとえば、**frontend** デプロイメントと **backend** デプロイメントがあるとします。**kubernetes-workload** トリガーを使用すると、**frontend** Pod の数に基づいて **backend** デプロイメントをスケーリングできます。**frontend** Pod の数が増えると、Operator は指定された比率を維持するために **backend** Pod をスケーリングします。この例では、**app=frontend** Pod セクターを持つ Pod が 10 個ある場合、Operator は、scaled object で設定された **0.5** の比率を維持するために、バックエンド Pod を 5 にスケーリングします。

Kubernetes ワークロードトリガーを使用した scaled object の例

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: workload-scaledobject
  namespace: my-namespace
spec:
  triggers:
    - type: kubernetes-workload ❶
      metadata:
        podSelector: 'app=frontend' ❷
        value: '0.5' ❸
        activationValue: '3.1' ❹
```

- ❶ Kubernetes ワークロードトリガーを指定します。
- ❷ Pod 数を取得するために使用する 1 つ以上の Pod セクターやセットベースセクターをコンマで区切って指定します。
- ❸ スケーリングされたワークロードとセクターに一致する Pod の数との間のターゲット関係を指定します。この関係は次の式に従って計算されます。

$$\text{relation} = (\text{pods that match the selector}) / (\text{scaled workload pods})$$

- ❹ オプション: スケーラーアクティベーションフェーズのターゲット値を指定します。デフォルトは **0** です。

3.5. カスタムメトリクスオートスケーラートリガー認証について

トリガー認証を使用すると、関連付けられたコンテナで利用できるスケーリングされたオブジェクトまたはスケーリングされたジョブに認証情報を含めることができます。トリガー認証を使用して、OpenShift Container Platform シークレット、プラットフォームネイティブの Pod 認証メカニズム、環境変数などを渡すことができます。

スケーリングするオブジェクトと同じ namespace に **TriggerAuthentication** オブジェクトを定義します。そのトリガー認証は、その namespace 内のオブジェクトによってのみ使用できます。

または、複数の namespace のオブジェクト間で認証情報を共有するには、すべての namespace で使用できる **ClusterTriggerAuthentication** オブジェクトを作成できます。

トリガー認証とクラスタートリガー認証は同じ設定を使用します。ただし、クラスタートリガー認証では、スケーリングされたオブジェクトの認証参照に追加の **kind** パラメーターが必要です。

バインドされたサービスアカウントトークンを使用するトリガー認証の例

```
kind: TriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: secret-triggerauthentication
  namespace: my-namespace ❶
spec:
  boundServiceAccountToken: ❷
  - parameter: bearerToken
    serviceAccountName: thanos ❸
```

- ❶ スケーリングするオブジェクトの namespace を指定します。
- ❷ このトリガー認証では、メトリクスエンドポイントに接続するときに、バインドされたサービスアカウントトークンを使用して認可を行うことを指定します。
- ❸ 使用するサービスアカウントの名前を指定します。

バインドされたサービスアカウントトークンを使用するクラスタートリガー認証の例

```
kind: ClusterTriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: bound-service-account-token-triggerauthentication ❶
spec:
  boundServiceAccountToken: ❷
  - parameter: bearerToken
    serviceAccountName: thanos ❸
```

- ❶ スケーリングするオブジェクトの namespace を指定します。
- ❷ このクラスタートリガー認証では、メトリクスエンドポイントに接続するときに、認可のバインドされたサービスアカウントトークンを使用することを指定します。
- ❸ 使用するサービスアカウントの名前を指定します。

Basic 認証にシークレットを使用するトリガー認証の例

```
kind: TriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: secret-triggerauthentication
```

```

namespace: my-namespace ❶
spec:
  secretTargetRef: ❷
  - parameter: username ❸
    name: my-basic-secret ❹
    key: username ❺
  - parameter: password
    name: my-basic-secret
    key: password

```

- ❶ スケーリングするオブジェクトの namespace を指定します。
- ❷ このトリガー認証では、メトリクスエンドポイントに接続するときに、認可にシークレットを使用することを指定します。
- ❸ シークレットを使用して提供する認証パラメーターを指定します。
- ❹ 使用するシークレットの名前を指定します。以下の Basic 認証のシークレットの例を参照してください。
- ❺ 指定されたパラメーターで使用するシークレットのキーを指定します。

Basic 認証のシークレットの例

```

apiVersion: v1
kind: Secret
metadata:
  name: my-basic-secret
  namespace: default
data:
  username: "dXNlcm5hbWU=" ❶
  password: "cGFzc3dvcmQ="

```

- ❶ トリガー認証に提供するユーザー名とパスワード。**data** スタンザ内の値は、Base64 でエンコードされている必要があります。

CA の詳細にシークレットを使用するトリガー認証の例

```

kind: TriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: secret-triggerauthentication
  namespace: my-namespace ❶
spec:
  secretTargetRef: ❷
  - parameter: key ❸
    name: my-secret ❹
    key: client-key.pem ❺
  - parameter: ca ❻
    name: my-secret ❼
    key: ca-cert.pem ❽

```

- 1 スケーリングするオブジェクトの namespace を指定します。
- 2 このトリガー認証では、メトリクスエンドポイントに接続するときに、認可にシークレットを使用することを指定します。
- 3 使用する認証の種類を指定します。
- 4 使用するシークレットの名前を指定します。
- 5 指定されたパラメーターで使用するシークレットのキーを指定します。
- 6 メトリクスエンドポイントに接続するときに、カスタム CA の認証パラメーターを指定します。
- 7 使用するシークレットの名前を指定します。認証局 (CA) の詳細を含む次のシークレットの例を参照してください。
- 8 指定されたパラメーターで使用するシークレットのキーを指定します。

認証局 (CA) の詳細を含むシークレットの例

```
apiVersion: v1
kind: Secret
metadata:
  name: my-secret
  namespace: my-namespace
data:
  ca-cert.pem: LS0tLS1CRUdJTiBDRVJUSUZJQ0FURS0tLS0... 1
  client-cert.pem: LS0tLS1CRUdJTiBDRVJUSUZJQ0FURS0... 2
  client-key.pem: LS0tLS1CRUdJTiBQUkVRFIEtFWS0t...
```

- 1 メトリクスエンドポイントの認証用の TLS CA 証明書を指定します。値は Base64 でエンコードされている必要があります。
- 2 TLS クライアント認証用の TLS 証明書と鍵を指定します。値は Base64 でエンコードされている必要があります。

ベアラートークンを使用するトリガー認証の例

```
kind: TriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: token-triggerauthentication
  namespace: my-namespace 1
spec:
  secretTargetRef: 2
  - parameter: bearerToken 3
    name: my-secret 4
    key: bearerToken 5
```

- 1 スケーリングするオブジェクトの namespace を指定します。
- 2 このトリガー認証では、メトリクスエンドポイントに接続するときに、認可にシークレットを使用することを指定します。

- 3 使用する認証の種類を指定します。
- 4 使用するシークレットの名前を指定します。以下のベアラートークンのシークレットの例を参照してください。
- 5 指定されたパラメーターで使用するトークン内のキーを指定します。

ベアラートークンのシークレットの例

```
apiVersion: v1
kind: Secret
metadata:
  name: my-secret
  namespace: my-namespace
data:
  bearerToken: "<bearer_token>" 1
```

- 1 ベアラ認証で使用するベアラートークンを指定します。値は Base64 でエンコードされている必要があります。

環境変数を使用するトリガー認証の例

```
kind: TriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: env-var-triggerauthentication
  namespace: my-namespace 1
spec:
  env: 2
  - parameter: access_key 3
    name: ACCESS_KEY 4
  containerName: my-container 5
```

- 1 スケーリングするオブジェクトの namespace を指定します。
- 2 このトリガー認証では、メトリクスエンドポイントに接続するときに、認可に環境変数を使用することを指定します。
- 3 この変数で設定するパラメーターを指定します。
- 4 環境変数の名前を指定します。
- 5 オプション: 認証が必要なコンテナを指定します。コンテナは、スケーリングされたオブジェクトの **scaleTargetRef** によって参照されるものと同じリソースにある必要があります。

Pod 認証プロバイダーを使用するトリガー認証の例

```
kind: TriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: pod-id-triggerauthentication
```

```
namespace: my-namespace ❶
spec:
  podIdentity: ❷
    provider: aws-eks ❸
```

- ❶ スケーリングするオブジェクトの namespace を指定します。
- ❷ このトリガー認証では、メトリクスエンドポイントに接続するときに、プラットフォームネイティブの Pod 認証を使用することを指定します。
- ❸ Pod ID を指定します。サポートされている値は、**none**、**azure**、**gcp**、**aws-eks**、または **aws-kiam** です。デフォルト値は **none** です。

関連情報

- [サービスアカウントの概要および作成](#)
- [Pod への機密性の高いデータの提供](#)

3.5.1. トリガー認証の使用

トリガー認証とクラスタトリガー認証は、カスタムリソースを使用して認証を作成し、スケーリングされたオブジェクトまたはスケーリングされたジョブへの参照を追加することで使用します。

前提条件

- Custom Metrics Autoscaler Operator をインストールしている。
- バインドされたサービスアカウントトークンを使用している場合は、サービスアカウントが存在している必要があります。
- バインドされたサービスアカウントトークンを使用している場合は、Custom Metrics Autoscaler Operator がサービスアカウントからサービスアカウントトークンを要求できるようにするロールベースのアクセス制御 (RBAC) オブジェクトが存在する必要があります。

```
apiVersion: rbac.authorization.k8s.io/v1
kind: Role
metadata:
  name: keda-operator-token-creator
  namespace: <namespace_name> ❶
rules:
- apiGroups:
  - ""
  resources:
  - serviceaccounts/token
  verbs:
  - create
  resourceNames:
  - thanos ❷
---
apiVersion: rbac.authorization.k8s.io/v1
kind: RoleBinding
metadata:
  name: keda-operator-token-creator-binding
```

```

namespace: <namespace_name> ❸
roleRef:
  apiGroup: rbac.authorization.k8s.io
  kind: Role
  name: keda-operator-token-creator
subjects:
- kind: ServiceAccount
  name: keda-operator
  namespace: openshift-keda

```

- ❶ サービスアカウントの namespace を指定します。
 - ❷ サービスアカウントの名前を指定します。
 - ❸ サービスアカウントの namespace を指定します。
- シークレットを使用している場合は、**Secret** オブジェクトが存在している必要があります。

手順

1. **TriggerAuthentication** または **ClusterTriggerAuthentication** オブジェクトを作成します。
 - a. オブジェクトを定義する YAML ファイルを作成します。

バインドされたサービスアカウントトークンを使用したトリガー認証の例

```

kind: TriggerAuthentication
apiVersion: keda.sh/v1alpha1
metadata:
  name: prom-triggerauthentication
  namespace: my-namespace ❶
spec:
  boundServiceAccountToken: ❷
  - parameter: token
    serviceName: thanos ❸

```

- ❶ スケーリングするオブジェクトの namespace を指定します。
- ❷ このトリガー認証では、メトリクスエンドポイントに接続するときに、バインドされたサービスアカウントトークンを使用して認可を行うことを指定します。
- ❸ 使用するサービスアカウントの名前を指定します。

- b. **TriggerAuthentication** オブジェクトを作成します。

```
$ oc create -f <filename>.yaml
```

2. トリガー認証を使用する **ScaledObject** YAML ファイルを作成または編集します。
 - a. 次のコマンドを実行して、オブジェクトを定義する YAML ファイルを作成します。

トリガー認証を使用したスケーリングされたオブジェクトの例

```

apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: scaledobject
  namespace: my-namespace
spec:
  scaleTargetRef:
    name: example-deployment
  maxReplicaCount: 100
  minReplicaCount: 0
  pollingInterval: 30
  triggers:
  - type: prometheus
    metadata:
      serverAddress: https://thanos-querier.openshift-monitoring.svc.cluster.local:9092
      namespace: kedatest # replace <NAMESPACE>
      metricName: http_requests_total
      threshold: '5'
      query: sum(rate(http_requests_total{job="test-app"}[1m]))
      authModes: "basic"
    authenticationRef:
      name: prom-triggerauthentication ❶
      kind: TriggerAuthentication ❷

```

❶ トリガー認証オブジェクトの名前を指定します。

❷ **TriggerAuthentication** を指定します。**TriggerAuthentication** がデフォルトです。

クラスタトリガー認証を使用したスケーリングされたオブジェクトの例

```

apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  name: scaledobject
  namespace: my-namespace
spec:
  scaleTargetRef:
    name: example-deployment
  maxReplicaCount: 100
  minReplicaCount: 0
  pollingInterval: 30
  triggers:
  - type: prometheus
    metadata:
      serverAddress: https://thanos-querier.openshift-monitoring.svc.cluster.local:9092
      namespace: kedatest # replace <NAMESPACE>
      metricName: http_requests_total
      threshold: '5'
      query: sum(rate(http_requests_total{job="test-app"}[1m]))
      authModes: "basic"
    authenticationRef:
      name: prom-cluster-triggerauthentication ❶
      kind: ClusterTriggerAuthentication ❷

```

- 1 トリガー認証オブジェクトの名前を指定します。
- 2 **ClusterTriggerAuthentication** を指定します。

b. 次のコマンドを実行して、スケーリングされたオブジェクトを作成します。

```
$ oc apply -f <filename>
```

3.6. カスタムメトリクスオートスケーラーの追加方法について

カスタムメトリクスオートスケーラーを追加するには、デプロイメント、ステートフルセット、またはカスタムリソース用の **ScaledObject** カスタムリソースを作成します。ジョブの **ScaledJob** カスタムリソースを作成します。

スケーリングするワークロードごとに、スケーリングされたオブジェクトを1つだけ作成できます。スケーリングされたオブジェクトと Horizontal Pod Autoscaler (HPA) は、同じワークロードで使用できません。

3.6.1. ワークロードへのカスタムメトリクスオートスケーラーの追加

Deployment、**StatefulSet**、または **custom resource** オブジェクトによって作成されるワークロード用のカスタムメトリクスオートスケーラーを作成できます。

前提条件

- Custom Metrics Autoscaler Operator をインストールしている。
- CPU またはメモリーに基づくスケーリングにカスタムメトリクスオートスケーラーを使用する場合:
 - クラスター管理者は、クラスターメトリクスを適切に設定する必要があります。メトリクスが設定されているかどうかは、**oc describe PodMetrics <pod-name>** コマンドを使用して判断できます。メトリクスが設定されている場合、出力は以下の Usage の下にある CPU と Memory のように表示されます。

```
$ oc describe PodMetrics openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
```

出力例

```
Name:      openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
Namespace: openshift-kube-scheduler
Labels:    <none>
Annotations: <none>
API Version: metrics.k8s.io/v1beta1
Containers:
  Name: wait-for-host-port
  Usage:
    Memory: 0
  Name: scheduler
  Usage:
    Cpu: 8m
    Memory: 45440Ki
Kind:      PodMetrics
```

```

Metadata:
  Creation Timestamp: 2019-05-23T18:47:56Z
  Self Link:         /apis/metrics.k8s.io/v1beta1/namespaces/openshift-kube-
scheduler/pods/openshift-kube-scheduler-ip-10-0-135-131.ec2.internal
  Timestamp:         2019-05-23T18:47:56Z
  Window:            1m0s
  Events:            <none>

```

- スケーリングするオブジェクトに関連付けられた Pod には、指定されたメモリーと CPU の制限が含まれている必要があります。以下に例を示します。

Pod 仕様の例

```

apiVersion: v1
kind: Pod
# ...
spec:
  containers:
  - name: app
    image: images.my-company.example/app:v4
    resources:
      limits:
        memory: "128Mi"
        cpu: "500m"
# ...

```

手順

1. 以下のような YAML ファイルを作成します。名前 <2>、オブジェクト名 <4>、およびオブジェクトの種類 <5> のみが必要です。

スケーリングされたオブジェクトの例

```

apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  annotations:
    autoscaling.keda.sh/paused-replicas: "0" ❶
  name: scaledobject ❷
  namespace: my-namespace
spec:
  scaleTargetRef:
    apiVersion: apps/v1 ❸
    name: example-deployment ❹
    kind: Deployment ❺
    envSourceContainerName: .spec.template.spec.containers[0] ❻
  cooldownPeriod: 200 ❼
  maxReplicaCount: 100 ❽
  minReplicaCount: 0 ❾
  metricsServer: ❿
  auditConfig:
    logFormat: "json"
    logOutputVolumeClaim: "persistentVolumeClaimName"

```

```

policy:
  rules:
    - level: Metadata
      omitStages: "RequestReceived"
      omitManagedFields: false
  lifetime:
    maxAge: "2"
    maxBackup: "1"
    maxSize: "50"
fallback: 11
failureThreshold: 3
replicas: 6
behavior: static 12
pollingInterval: 30 13
advanced:
  restoreToOriginalReplicaCount: false 14
  horizontalPodAutoscalerConfig:
    name: keda-hpa-scale-down 15
    behavior: 16
    scaleDown:
      stabilizationWindowSeconds: 300
    policies:
      - type: Percent
        value: 100
        periodSeconds: 15
triggers:
  - type: prometheus 17
    metadata:
      serverAddress: https://thanos-querier.openshift-monitoring.svc.cluster.local:9092
      namespace: kedatest
      metricName: http_requests_total
      threshold: '5'
      query: sum(rate(http_requests_total{job="test-app"}[1m]))
      authModes: basic
    authenticationRef: 18
      name: prom-triggerauthentication
      kind: TriggerAuthentication

```

- 1 オプション: 「ワークロードのカスタムメトリクスオートスケーラーの一時停止」セクションで説明されているように、Custom Metrics Autoscaler Operator がレプリカを指定された値にスケールし、自動スケールを停止するよう指定します。
- 2 このカスタムメトリクスオートスケーラーの名前を指定します。
- 3 オプション: ターゲットリソースの API バージョンを指定します。デフォルトは **apps/v1** です。
- 4 スケールするオブジェクトの名前を指定します。
- 5 **kind** を **Deployment**、**StatefulSet** または **CustomResource** として指定します。
- 6 オプション: カスタムメトリクスオートスケーラーがシークレットなどを保持する環境変数を取得する、ターゲットリソース内のコンテナの名前を指定します。デフォルトは **.spec.template.spec.containers[0]** です。

- 7 オプション: **minReplicaCount** が **0** に設定されている場合、最後のトリガーが報告されてからデプロイメントを **0** にスケールバックするまでの待機時間を秒単位で指定します。デ
- 8 オプション: スケールアップ時のレプリカの最大数を指定します。デフォルトは **100** です。
- 9 オプション: スケールダウン時のレプリカの最小数を指定します。
- 10 オプション: 「監査ログの設定」セクションで説明されているように、監査ログのパラメーターを指定します。
- 11 オプション: **failureThreshold** パラメーターで定義された回数だけスケーラーがソースからメトリクスを取得できなかった場合に、フォールバックするレプリカ数を指定します。フォールバック動作の詳細は、[KEDA のドキュメント](#) を参照してください。
- 12 オプション: フォールバックが発生した場合に使用するレプリカ数を指定します。次のいずれかのオプションを入力するか、パラメーターを省略します。
 - **fallback.replicas** パラメーターで指定されたレプリカ数を使用するには、**static** と入力します。これがデフォルトです。
 - 現在のレプリカ数を維持するには、**currentReplicas** と入力します。
 - 現在のレプリカ数が **fallback.replicas** パラメーターより大きい場合は、**currentReplicasIfHigher** と入力して、現在のレプリカ数を維持します。現在のレプリカ数が **fallback.replicas** パラメーターより少ない場合は、**fallback.replicas** 値を使用します。
 - 現在のレプリカ数が **fallback.replicas** パラメーターより少ない場合は、**currentReplicasIfLower** と入力して、現在のレプリカ数を維持します。現在のレプリカ数が **fallback.replicas** パラメーターより大きい場合は、**fallback.replicas** 値を使用します。
- 13 オプション: 各トリガーをチェックする間隔を秒単位で指定します。デフォルトは **30** です。
- 14 オプション: スケーリングされたオブジェクトが削除された後に、ターゲットリソースを元のレプリカ数にスケールバックするかどうかを指定します。デフォルトは **false** で、スケーリングされたオブジェクトが削除されたときのレプリカ数をそのまま保持します。
- 15 オプション: Horizontal Pod Autoscaler の名前を指定します。デフォルトは **keda-hpa-{scaled-object-name}** です。
- 16 オプション: 「スケーリングポリシー」セクションで説明されているように、Pod をスケールアップまたはスケールダウンするレートを制御するために使用するスケーリングポリシーを指定します。
- 17 「カスタムメトリクスオートスケーラートリガーについて」セクションで説明されているように、スケーリングの基準として使用するトリガーを指定します。この例では、OpenShift Container Platform モニタリングを使用します。
- 18 オプション: トリガー認証またはクラスタートリガー認証を指定します。詳細は、[関連情報](#) セクションの [カスタムメトリクスオートスケーラー認証について](#) を参照してください。

- トリガー認証を使用するには、**TriggerAuthentication** と入力します。これがデフォルトです。
- クラスタトリガー認証を使用するには、**ClusterTriggerAuthentication** と入力します。

2. 次のコマンドを実行して、カスタムメトリクスオートスケーラーを作成します。

```
$ oc create -f <filename>.yaml
```

検証

- コマンド出力を表示して、カスタムメトリクスオートスケーラーが作成されたことを確認します。

```
$ oc get scaledobject <scaled_object_name>
```

出力例

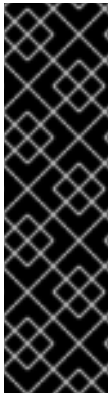
```
NAME          SCALETARGETKIND  SCALETARGETNAME  MIN  MAX  TRIGGERS
AUTHENTICATION  READY  ACTIVE  FALLBACK  AGE
scaledobject  apps/v1.Deployment  example-deployment  0   50  prometheus  prom-
triggerauthentication  True  True  True  17s
```

出力の次のフィールドに注意してください。

- **TRIGGERS:** 使用されているトリガーまたはスケーラーを示します。
- **AUTHENTICATION:** 使用されているトリガー認証の名前を示します。
- **READY:** スケーリングされたオブジェクトがスケーリングを開始する準備ができているかどうかを示します。
 - **True** の場合、スケーリングされたオブジェクトの準備は完了しています。
 - **False** の場合、作成したオブジェクトの1つ以上に問題があるため、スケーリングされたオブジェクトの準備は完了していません。
- **ACTIVE:** スケーリングが行われているかどうかを示します。
 - **True** の場合、スケーリングが行われています。
 - **False** の場合、メトリクスがないか、作成したオブジェクトの1つ以上に問題があるため、スケーリングは行われていません。
- **FALLBACK:** カスタムメトリクスオートスケーラーがソースからメトリクスを取得できるかどうかを示します。
 - **False** の場合、カスタムメトリクスオートスケーラーはメトリクスを取得しています。
 - **True** の場合、メトリクスがないか、作成したオブジェクトの1つ以上に問題があるため、カスタムメトリクスオートスケーラーはメトリクスを取得しています。

3.6.2. ジョブへのカスタムメトリックオートスケーラーの追加

任意の **Job** オブジェクトに対してカスタムメトリックオートスケーラーを作成できます。



重要

スケーリングされたジョブを使用したスケーリングはテクノロジープレビュー機能です。テクノロジープレビュー機能は、Red Hat 製品のサービスレベルアグリーメント (SLA) の対象外であり、機能的に完全ではないことがあります。Red Hat は、実稼働環境でこれらを使用することを推奨していません。テクノロジープレビュー機能は、最新の製品機能をいち早く提供して、開発段階で機能のテストを行い、フィードバックを提供していただくことを目的としています。

Red Hat のテクノロジープレビュー機能のサポート範囲に関する詳細は、[テクノロジープレビュー機能のサポート範囲](#) を参照してください。

前提条件

- Custom Metrics Autoscaler Operator をインストールしている。

手順

1. 以下のような YAML ファイルを作成します。

```
kind: ScaledJob
apiVersion: keda.sh/v1alpha1
metadata:
  name: scaledjob
  namespace: my-namespace
spec:
  failedJobsHistoryLimit: 5
  jobTargetRef:
    activeDeadlineSeconds: 600 ❶
    backoffLimit: 6 ❷
    parallelism: 1 ❸
    completions: 1 ❹
    template: ❺
      metadata:
        name: pi
      spec:
        containers:
        - name: pi
          image: perl
          command: ["perl", "-Mbignum=bpi", "-wle", "print bpi(2000)"]
  maxReplicaCount: 100 ❻
  pollingInterval: 30 ❼
  successfulJobsHistoryLimit: 5 ❽
  failedJobsHistoryLimit: 5 ❾
  envSourceContainerName: ❿
  rolloutStrategy: gradual ❶❶
  scalingStrategy: ❶❷
    strategy: "custom"
    customScalingQueueLengthDeduction: 1
    customScalingRunningJobPercentage: "0.5"
```

```

pendingPodConditions:
  - "Ready"
  - "PodScheduled"
  - "AnyOtherCustomPodCondition"
multipleScalersCalculation : "max"
triggers:
- type: prometheus 13
  metadata:
    serverAddress: https://thanos-querier.openshift-monitoring.svc.cluster.local:9092
    namespace: kedatest
    metricName: http_requests_total
    threshold: '5'
    query: sum(rate(http_requests_total{job="test-app"}[1m]))
    authModes: "bearer"
  authenticationRef: 14
    name: prom-cluster-triggerauthentication

```

- 1** ジョブを実行できる最大期間を指定します。
- 2** ジョブの再試行回数を指定します。デフォルト値は **6** です。
- 3** オプション: ジョブを並行して実行する Pod レプリカの数指定します。デフォルトは **1** です。
 - 非並列ジョブの場合は、未設定のままにします。設定されていない場合、デフォルトは **1** になります。
- 4** オプション: ジョブを完了したとマークするために必要な、正常に完了した Pod 数を指定します。
 - 非並列ジョブの場合は、未設定のままにします。設定されていない場合、デフォルトは **1** になります。
 - 固定の完了数を持つ並列ジョブの場合、完了の数を指定します。
 - ワークキューのある並列ジョブでは、未設定のままにします。設定されていない場合、デフォルトは **parallelism** パラメーターの値になります。
- 5** コントローラーが作成する Pod のテンプレートを指定します。
- 6** オプション: スケールアップ時のレプリカの最大数を指定します。デフォルトは **100** です。
- 7** オプション: 各トリガーをチェックする間隔を秒単位で指定します。デフォルトは **30** です。
- 8** オプション: 保持する必要がある正常に終了したジョブの数を指定します。デフォルトは **100** です。
- 9** オプション: 保持する必要がある失敗したジョブの数を指定します。デフォルトは **100** です。
- 10** オプション: カスタムオートスケーラーがシークレットなどを保持する環境変数を取得するターゲットリソース内のコンテナの名前を指定します。デフォルトは **.spec.template.spec.containers[0]** です。

- 11 オプション: スケーリングされたジョブが更新されるたびに、既存のジョブを終了するかどうかを指定します。
- **default**: 関連する scaled job が更新された場合、オートスケーラーは既存のジョブを終了します。オートスケーラーは、最新の仕様でジョブを再作成します。
 - **gradual**: 関連する scaled job が更新された場合、オートスケーラーは既存のジョブを終了しません。オートスケーラーは、最新の仕様で新しいジョブを作成します。
- 12 オプション: スケーリングストラテジーを指定します: **default**、**custom**、または **accurate**。デフォルトは **default** です。詳細は、以下の「関連情報」セクションのリンクを参照してください。
- 13 「カスタムメトリクスオートスケーラートリガーについて」セクションで説明されているように、スケーリングの基準として使用するトリガーを指定します。
- 14 オプション: トリガー認証またはクラスタートリガー認証を指定します。詳細は、**関連情報** セクションの **カスタムメトリクスオートスケーラー認証について** を参照してください。
- トリガー認証を使用するには、**TriggerAuthentication** と入力します。これがデフォルトです。
 - クラスタートリガー認証を使用するには、**ClusterTriggerAuthentication** と入力します。

2. 次のコマンドを実行して、カスタムメトリクスオートスケーラーを作成します。

```
$ oc create -f <filename>.yaml
```

検証

- コマンド出力を表示して、カスタムメトリクスオートスケーラーが作成されたことを確認します。

```
$ oc get scaledjob <scaled_job_name>
```

出力例

```
NAME      MAX TRIGGERS  AUTHENTICATION  READY  ACTIVE  AGE
scaledjob 100 prometheus  prom-triggerauthentication  True   True    8s
```

出力の次のフィールドに注意してください。

- **TRIGGERS**: 使用されているトリガーまたはスケーラーを示します。
- **AUTHENTICATION**: 使用されているトリガー認証の名前を示します。
- **READY**: スケーリングされたオブジェクトがスケーリングを開始する準備ができているかどうかを示します。
 - **True** の場合、スケーリングされたオブジェクトの準備は完了しています。

- **False** の場合、作成したオブジェクトの1つ以上に問題があるため、スケーリングされたオブジェクトの準備は完了していません。
- **ACTIVE**: スケーリングが行われているかどうかを示します。
- **True** の場合、スケーリングが行われています。
- **False** の場合、メトリクスがないか、作成したオブジェクトの1つ以上に問題があるため、スケーリングは行われていません。

3.6.3. 関連情報

- [カスタムメトリクスオートスケーラトリガー認証について](#)

3.7. スケーリングされたオブジェクトのカスタムメトリクスオートスケーラーの一時停止

必要に応じて、ワークロードの自動スケーリングを一時停止および再開できます。

たとえば、クラスターのメンテナンスを実行する前に自動スケーリングを一時停止したり、ミッションクリティカルではないワークロードを削除してリソース不足を回避したりできます。

3.7.1. カスタムメトリクスオートスケーラーの一時停止

スケーリングされたオブジェクトの自動スケーリングを一時停止するには、そのスケーリングされたオブジェクトのカスタムメトリクスオートスケーラーに **autoscaling.keda.sh/paused-replicas** アノテーションを追加します。カスタムメトリクスオートスケーラーは、そのワークロードのレプリカを指定された値にスケーリングし、アノテーションが削除されるまで自動スケーリングを一時停止します。

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  annotations:
    autoscaling.keda.sh/paused-replicas: "4"
# ...
```

手順

1. 次のコマンドを使用して、ワークロードの **ScaledObject** CR を編集します。

```
$ oc edit ScaledObject scaledobject
```

2. **autoscaling.keda.sh/paused-replicas** アノテーションに任意の値を追加します。

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  annotations:
    autoscaling.keda.sh/paused-replicas: "4" ❶
  creationTimestamp: "2023-02-08T14:41:01Z"
  generation: 1
  name: scaledobject
```

```
namespace: my-project
resourceVersion: '65729'
uid: f5aec682-acdf-4232-a783-58b5b82f5dd0
```

- 1 Custom Metrics Autoscaler Operator がレプリカを指定された値にスケーリングし、自動スケーリングを停止するよう指定します。

3.7.2. スケーリングされたオブジェクトのカスタムメトリクスオートスケーラーの再開

一時停止されたカスタムメトリクスオートスケーラーを再開するには、その **ScaledObject** の **autoscaling.keda.sh/paused-replicas** アノテーションを削除します。

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  annotations:
    autoscaling.keda.sh/paused-replicas: "4"
# ...
```

手順

1. 次のコマンドを使用して、ワークロードの **ScaledObject** CR を編集します。

```
$ oc edit ScaledObject scaledobject
```

2. **autoscaling.keda.sh/paused-replicas** アノテーションを削除します。

```
apiVersion: keda.sh/v1alpha1
kind: ScaledObject
metadata:
  annotations:
    autoscaling.keda.sh/paused-replicas: "4" 1
  creationTimestamp: "2023-02-08T14:41:01Z"
  generation: 1
  name: scaledobject
  namespace: my-project
  resourceVersion: '65729'
  uid: f5aec682-acdf-4232-a783-58b5b82f5dd0
```

- 1 このアノテーションを削除して、一時停止されたカスタムメトリクスオートスケーラーを再開します。

3.8. 監査ログの収集

システムに影響を与えた一連のアクティビティを個別のユーザー、管理者その他システムのコンポーネント別に記述したセキュリティ関連の時系列のレコードを提供する、監査ログを収集できます。

たとえば、監査ログは、自動スケーリングリクエストの送信元を理解するのに役立ちます。これは、ユーザーアプリケーションによる自動スケーリングリクエストによってバックエンドが過負荷になり、問題のあるアプリケーションを特定する必要がある場合に重要な情報です。

3.8.1. 監査ログの設定

KedaController カスタムリソースを編集することで、Custom Metrics Autoscaler Operator の監査を設定できます。ログは、**KedaController** CR の永続ボリューム要求を使用して保護されたボリューム上の監査ログファイルに送信されます。

前提条件

- Custom Metrics Autoscaler Operator をインストールしている。

手順

1. **KedaController** カスタムリソースを編集して、**auditConfig** スタンザを追加します。

```
kind: KedaController
apiVersion: keda.sh/v1alpha1
metadata:
  name: keda
  namespace: openshift-keda
spec:
  # ...
  metricsServer:
  # ...
  auditConfig:
    logFormat: "json" ❶
    logOutputVolumeClaim: "pvc-audit-log" ❷
    policy:
      rules: ❸
      - level: Metadata
      omitStages: "RequestReceived" ❹
      omitManagedFields: false ❺
    lifetime: ❻
      maxAge: "2"
      maxBackup: "1"
      maxSize: "50"
```

- ❶ 監査ログの出力形式を **legacy** または **json** のいずれかで指定します。
- ❷ ログデータを格納するための既存の永続ボリューム要求を指定します。API サーバーに送信されるすべてのリクエストは、この永続ボリューム要求に記録されます。このフィールドを空のままにすると、ログデータは stdout に送信されます。
- ❸ どのイベントを記録し、どのデータを含めるかを指定します。
 - **None:** イベントをログに記録しません。
 - **Metadata:** ユーザー、タイムスタンプなど、リクエストのメタデータのみをログに記録します。リクエストテキストとレスポンステキストはログに記録しません。これがデフォルトです。
 - **Request:** メタデータと要求テキストのみをログに記録しますが、応答テキストはログに記録しません。このオプションは、リソース以外の要求には適用されません。

- **RequestResponse**: イベントのメタデータ、要求テキスト、および応答テキストをログに記録します。このオプションは、リソース以外の要求には適用されません。

- 4 イベントを作成しないステージを指定します。
- 5 リクエストボディーとレスポンスボディーのマネージドフィールドを API 監査ログに書き込まれないようにするかどうかを指定します。フィールドを省略する場合は **true**、フィールドを含める場合は **false** を指定します。
- 6 監査ログのサイズと有効期間を指定します。
 - **maxAge**: ファイル名にエンコードされたタイムスタンプに基づく、監査ログファイルを保持する最大日数。
 - **maxBackup**: 保持する監査ログファイルの最大数。すべての監査ログファイルを保持するには、**0** に設定します。
 - **maxSize**: ローテーションされる前の監査ログファイルの最大サイズ (メガバイト単位)。

検証

1. 監査ログファイルを直接表示します。

- a. **keda-metrics-apiserver-*** Pod の名前を取得します。

```
oc get pod -n openshift-keda
```

出力例

```
NAME                                READY STATUS  RESTARTS  AGE
custom-metrics-autoscaler-operator-5cb44cd75d-9v4lv  1/1   Running    0         8m20s
keda-metrics-apiserver-65c7cc44fd-rrl4r             1/1   Running    0         2m55s
keda-operator-776cbb6768-zpj5b                     1/1   Running    0         2m55s
```

- b. 次のようなコマンドを使用して、ログデータを表示します。

```
$ oc logs keda-metrics-apiserver-<hash>|grep -i metadata 1
```

- 1 オプション: **grep** コマンドを使用して、表示するログレベル (**Metadata**、**Request**、**RequestResponse**) を指定できます。

以下に例を示します。

```
$ oc logs keda-metrics-apiserver-65c7cc44fd-rrl4r|grep -i metadata
```

出力例

```
...
{"kind":"Event","apiVersion":"audit.k8s.io/v1","level":"Metadata","auditID":"4c81d41b-3dab-4675-90ce-20b87ce24013","stage":"ResponseComplete","requestURI":"/healthz","verb":"get","user":
```

```
{
  "username": "system:anonymous",
  "groups": ["system:unauthenticated"],
  "sourceIPs": ["10.131.0.1"],
  "userAgent": "kube-probe/1.26",
  "responseStatus": {
    "metadata": {},
    "code": 200
  },
  "requestReceivedTimestamp": "2023-02-16T13:00:03.554567Z",
  "stageTimestamp": "2023-02-16T13:00:03.555032Z",
  "annotations": {
    "authorization.k8s.io/decision": "allow",
    "authorization.k8s.io/reason": ""
  }
}
```

2. または、特定のログを表示できます。

a. 次のようなコマンドを使用して、**keda-metrics-apiserver-*** Pod にログインします。

```
$ oc rsh pod/keda-metrics-apiserver-<hash> -n openshift-keda
```

以下に例を示します。

```
$ oc rsh pod/keda-metrics-apiserver-65c7cc44fd-rrl4r -n openshift-keda
```

b. **/var/audit-policy/** ディレクトリーに移動します。

```
sh-4.4$ cd /var/audit-policy/
```

c. 利用可能なログを一覧表示します。

```
sh-4.4$ ls
```

出力例

```
log-2023.02.17-14:50 policy.yaml
```

d. 必要に応じてログを表示します。

```
sh-4.4$ cat <log_name>/<pvc_name>|grep -i <log_level> ❶
```

❶ オプション: **grep** コマンドを使用して、表示するログレベル (**Metadata**、**Request**、**RequestResponse**) を指定できます。

以下に例を示します。

```
sh-4.4$ cat log-2023.02.17-14:50/pvc-audit-log|grep -i Request
```

出力例

```
...
{"kind": "Event", "apiVersion": "audit.k8s.io/v1", "level": "Request", "auditID": "63e7f68c-04ec-4f4d-8749-bf1656572a41", "stage": "ResponseComplete", "requestURI": "/openapi/v2", "verb": "get", "user": {
  "username": "system:aggregator",
  "groups": ["system:authenticated"],
  "sourceIPs": ["10.128.0.1"],
  "responseStatus": {
    "metadata": {},
    "code": 304
  },
  "requestReceivedTimestamp": "2023-02-17T13:12:55.035478Z",
  "stageTimestamp": "2023-02-17T13:12:55.038346Z",
  "annotations": {
```

```
{
  "authorization.k8s.io/decision": "allow",
  "authorization.k8s.io/reason": "RBAC: allowed by ClusterRoleBinding \\\"system:discovery\\\" of ClusterRole \\\"system:discovery\\\" to Group \\\"system:authenticated\\\""}
...

```

3.9. デバッグデータの収集

サポートケースを作成する際、ご使用のクラスターのデバッグ情報を Red Hat サポートに提供していただくと Red Hat のサポートに役立ちます。

問題のトラブルシューティングに使用するため、以下の情報を提供してください。

- **must-gather** ツールを使用して収集されるデータ。
- 一意のクラスター ID。

must-gather ツールを使用して、以下を含む Custom Metrics Autoscaler Operator とそのコンポーネントに関するデータを収集できます。

- **openshift-keda** namespace とその子オブジェクト。
- Custom Metric Autoscaler Operator のインストールオブジェクト。
- Custom Metric Autoscaler Operator の CRD オブジェクト。

3.9.1. デバッグデータの収集

以下のコマンドは、Custom Metrics Autoscaler Operator の **must-gather** ツールを実行します。

```
$ oc adm must-gather --image="$(oc get packagemanifests openshift-custom-metrics-autoscaler-operator \
-n openshift-marketplace \
-o jsonpath='{.status.channels[?(@.name=="stable")].currentCSVDesc.annotations.containerImage}')"

```



注記

標準の OpenShift Container Platform **must-gather** コマンドである **oc adm must-gather** は、Custom Metrics Autoscaler Operator データを収集しません。

前提条件

- **cluster-admin** ロールを持つユーザーとしてクラスターにアクセスできる。
- OpenShift Container Platform CLI (**oc**) がインストールされている。

手順

1. **must-gather** データを保存するディレクトリーに移動します。



注記

クラスターがネットワークが制限された環境を使用している場合、追加の手順を実行する必要があります。ミラーレジストリーに信頼される CA がある場合、まず信頼される CA をクラスターに追加する必要があります。制限されたネットワーク上のすべてのクラスターでは、次のコマンドを実行して、デフォルトの **must-gather** イメージをイメージストリームとしてインポートする必要があります。

```
$ oc import-image is/must-gather -n openshift
```

2. 以下のいずれかを実行します。

- Custom Metrics Autoscaler Operator の **must-gather** データのみを取得するには、以下のコマンドを使用します。

```
$ oc adm must-gather --image="$(oc get packagemanifests openshift-custom-metrics-autoscaler-operator \
-n openshift-marketplace \
-o jsonpath='{.status.channels[?(@.name=="stable")].currentCSVDesc.annotations.containerImage}')
```

must-gather コマンドのカスタムイメージは、Operator パッケージマニフェストから直接プルされます。そうすることで、Custom Metric Autoscaler Operator が利用可能なクラスター上で機能します。

- Custom Metric Autoscaler Operator 情報に加えてデフォルトの **must-gather** データを収集するには、以下を実行します。
 - 以下のコマンドを使用して Custom Metrics Autoscaler Operator イメージを取得し、これを環境変数として設定します。

```
$ IMAGE="$(oc get packagemanifests openshift-custom-metrics-autoscaler-operator \
-n openshift-marketplace \
-o jsonpath='{.status.channels[?(@.name=="stable")].currentCSVDesc.annotations.containerImage}')
```

- Custom Metrics Autoscaler Operator イメージで **oc adm must-gather** を使用するには、以下を実行します。

```
$ oc adm must-gather --image-stream=openshift/must-gather --image=${IMAGE}
```

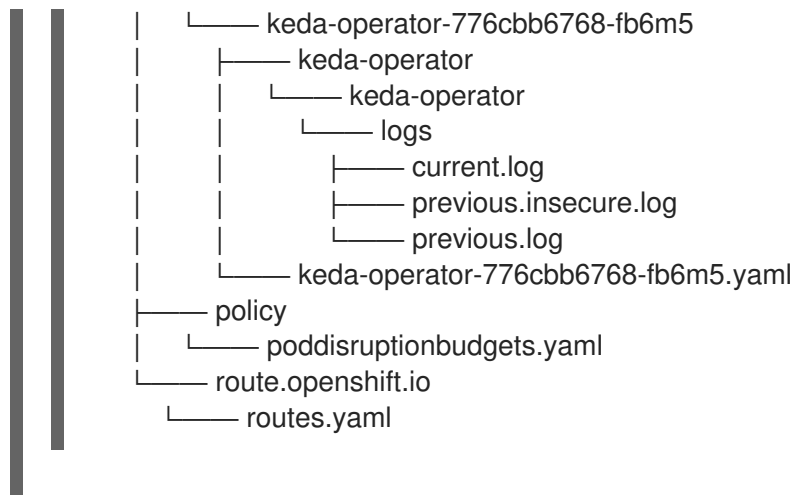
例3.1 Custom Metric Autoscaler の must-gather 出力例:

```
├── openshift-keda
│   ├── apps
│   │   ├── daemonsets.yaml
│   │   ├── deployments.yaml
│   │   ├── replicasetsets.yaml
│   │   └── statefulsets.yaml
│   ├── apps.openshift.io
│   │   └── deploymentconfigs.yaml
│   └── autoscaling
```

```

├── horizontalpodautoscalers.yaml
├── batch
│   ├── cronjobs.yaml
│   └── jobs.yaml
├── build.openshift.io
│   ├── buildconfigs.yaml
│   └── builds.yaml
├── core
│   ├── configmaps.yaml
│   ├── endpoints.yaml
│   ├── events.yaml
│   ├── persistentvolumeclaims.yaml
│   ├── pods.yaml
│   ├── replicationcontrollers.yaml
│   ├── secrets.yaml
│   └── services.yaml
├── discovery.k8s.io
│   └── endpointslices.yaml
├── image.openshift.io
│   └── imagestreams.yaml
├── k8s.ovn.org
│   ├── egressfirewalls.yaml
│   └── egressqoses.yaml
├── keda.sh
│   ├── kedacontrollers
│   │   └── keda.yaml
│   ├── scaledobjects
│   │   └── example-scaledobject.yaml
│   └── triggerauthentications
│       └── example-triggerauthentication.yaml
├── monitoring.coreos.com
│   └── servicemonitors.yaml
├── networking.k8s.io
│   └── networkpolicies.yaml
├── openshift-keda.yaml
├── pods
│   ├── custom-metrics-autoscaler-operator-58bd9f458-ptgwx
│   │   ├── custom-metrics-autoscaler-operator
│   │   │   └── custom-metrics-autoscaler-operator
│   │   │       └── logs
│   │   │           ├── current.log
│   │   │           ├── previous.insecure.log
│   │   │           └── previous.log
│   │   └── custom-metrics-autoscaler-operator-58bd9f458-ptgwx.yaml
│   ├── custom-metrics-autoscaler-operator-58bd9f458-thbsh
│   │   ├── custom-metrics-autoscaler-operator
│   │   │   └── custom-metrics-autoscaler-operator
│   │   │       └── logs
│   ├── keda-metrics-apiserver-65c7cc44fd-6wq4g
│   │   ├── keda-metrics-apiserver
│   │   │   └── keda-metrics-apiserver
│   │   │       └── logs
│   │   │           ├── current.log
│   │   │           ├── previous.insecure.log
│   │   │           └── previous.log
│   └── keda-metrics-apiserver-65c7cc44fd-6wq4g.yaml

```



- 作業ディレクトリーに作成された **must-gather** ディレクトリーから圧縮ファイルを作成します。たとえば、Linux オペレーティングシステムを使用するコンピューターで以下のコマンドを実行します。

```
$ tar cvaf must-gather.tar.gz must-gather-local.5421342344627712289/ ❶
```

- ❶ **must-gather-local.5421342344627712289/** を実際のディレクトリー名に置き換えます。

- 圧縮ファイルを [Red Hat カスタマーポータル](#) で作成したサポートケースに添付します。

3.10. OPERATOR メトリクスの表示

Custom Metrics Autoscaler Operator は、クラスター上のモニタリングコンポーネントからプルした、すぐに使用可能なメトリクスを公開します。Prometheus Query Language (PromQL) を使用してメトリクスをクエリーし、問題を分析および診断できます。コントローラー Pod の再起動時にすべてのメトリクスがリセットされます。

3.10.1. パフォーマンスメトリックへのアクセス

OpenShift Container Platform Web コンソールを使用し、メトリクスにアクセスしてクエリーを実行できます。

手順

- OpenShift Container Platform Web コンソールの **Administrator** パースペクティブを選択します。
- Observe** → **Metrics** の順に選択します。
- カスタムクエリーを作成するには、PromQL クエリーを **Expression** フィールドに追加します。
- 複数のクエリーを追加するには、**Add Query** を選択します。

3.10.1.1. 提供される Operator メトリクス

Custom Metrics Autoscaler Operator は、以下のメトリクスを公開します。メトリクスは、OpenShift Container Platform Web コンソールを使用して表示できます。

表3.1 Custom Metric Autoscaler Operator メトリクス

メトリクス名	説明
keda_scaler_activity	特定のスケーラーがアクティブか非アクティブかを示します。値が 1 の場合はスケーラーがアクティブであることを示し、値が 0 の場合はスケーラーが非アクティブであることを示します。
keda_scaler_metrics_value	各スケーラーのメトリクスの現在の値。ターゲットの平均を計算する際に Horizontal Pod Autoscaler (HPA) によって使用されます。
keda_scaler_metrics_latency	各スケーラーから現在のメトリクスを取得する際のレイテンシー。
keda_scaler_errors	各スケーラーで発生したエラーの数。
keda_scaler_errors_total	すべてのスケーラーで発生したエラーの合計数。
keda_scaled_object_errors	スケーリングされた各オブジェクトで発生したエラーの数。
keda_resource_totals	各カスタムリソースタイプの各 namespace における Custom Metrics Autoscaler カスタムリソースの合計数。
keda_trigger_totals	トリガータイプごとのトリガー合計数。

Custom Metrics Autoscaler Admission Webhook メトリクス

Custom Metrics Autoscaler Admission Webhook は、以下の Prometheus メトリクスも公開します。

メトリクス名	説明
keda_scaled_object_validation_total	スケーリングされたオブジェクトの検証数。
keda_scaled_object_validation_errors	検証エラーの数。

3.11. CUSTOM METRICS AUTOSCALER OPERATOR の削除

OpenShift Container Platform クラスタからカスタムメトリックオートスケーラーを削除できます。Custom Metrics Autoscaler Operator を削除した後、潜在的な問題を回避するために、Operator に関連付けられている他のコンポーネントを削除します。



注記

最初に **KedaController** カスタムリソース (CR) を削除します。 **KedaController** CR を削除しない場合、**openshift-keda** プロジェクトを削除すると OpenShift Container Platform がハングする可能性があります。CR を削除する前に Custom Metrics Autoscaler Operator を削除すると、CR を削除することはできません。


3.11.1. Custom Metrics Autoscaler Operator のアンインストール

以下の手順を使用して、OpenShift Container Platform クラスターからカスタムメトリクスオートスケーラーを削除します。

前提条件

- Custom Metrics Autoscaler Operator をインストールしている。

手順

1. OpenShift Container Platform Web コンソールで、**Operators → Installed Operators** をクリックします。
2. **openshift-keda** プロジェクトに切り替えます。
3. **KedaController** カスタムリソースを削除します。
 - a. **CustomMetricsAutoscaler** Operator を見つけて、**KedaController** タブをクリックします。
 - b. カスタムリソースを見つけてから、**Delete KedaController** をクリックします。
 - c. **Uninstall** をクリックします。
4. Custom Metrics Autoscaler Operator を削除します。
 - a. **Operators → Installed Operators** をクリックします。
 - b. **CustomMetricsAutoscaler** Operator を見つけて **Options** メニュー  をクリックし、**Uninstall Operator** を選択します。
 - c. **Uninstall** をクリックします。
5. オプション: OpenShift CLI を使用して、カスタムメトリクスオートスケーラーのコンポーネントを削除します。
 - a. カスタムメトリクスオートスケーラーの CRD を削除します。
 - **clustertriggerauthentications.keda.sh**
 - **kedacontrollers.keda.sh**
 - **scaledjobs.keda.sh**
 - **scaledobjects.keda.sh**
 - **triggerauthentications.keda.sh**

```
$ oc delete crd clustertriggerauthentications.keda.sh kedacontrollers.keda.sh  
scaledjobs.keda.sh scaledobjects.keda.sh triggerauthentications.keda.sh
```

CRD を削除すると、関連付けられたロール、クラスターロール、およびロールバインディングが削除されます。ただし、手動で削除する必要のあるクラスターロールがいくつかあります。

- b. カスタムメトリクスオートスケーラークラスターのロールをリスト表示します。

```
$ oc get clusterrole | grep keda.sh
```

- c. リスト表示されているカスタムメトリクスオートスケーラークラスターのロールを削除します。以下に例を示します。

```
$ oc delete clusterrole.keda.sh-v1alpha1-admin
```

- d. カスタムメトリクスオートスケーラークラスターのロールバインディングをリスト表示します。

```
$ oc get clusterrolebinding | grep keda.sh
```

- e. リスト表示されているカスタムメトリクスオートスケーラークラスターのロールバインディングを削除します。以下に例を示します。

```
$ oc delete clusterrolebinding.keda.sh-v1alpha1-admin
```

6. カスタムメトリクスオートスケーラーのプロジェクトを削除します。

```
$ oc delete project openshift-keda
```

7. Cluster Metric Autoscaler Operator を削除します。

```
$ oc delete operator/openshift-custom-metrics-autoscaler-operator.openshift-keda
```

第4章 POD のノードへの配置の制御 (スケジューリング)

4.1. スケジューラーによる POD 配置の制御

Pod のスケジューリングは、クラスター内のノードへの新規 Pod の配置を決定する内部プロセスです。

スケジューラーコードは、新規 Pod の作成時にそれらを確認し、それらをホストするのに最も適したノードを識別します。次に、マスター API を使用して Pod のバインディング (Pod とノードのバインディング) を作成します。

デフォルトの Pod スケジューリング

OpenShift Container Platform には、ほとんどのユーザーのニーズに対応するデフォルトスケジューラーが同梱されます。デフォルトスケジューラーは、Pod に最適なノードを判別するために固有のツールとカスタマイズ可能なツールの両方を使用します。

詳細な Pod スケジューリング

新規 Pod の配置場所に対する制御を強化する必要がある場合、OpenShift Container Platform の詳細スケジューリング機能を使用すると、Pod が特定ノード上か、特定の Pod と共に実行されることを要求する (または実行されることが優先される) よう Pod を設定することができます。

以下のスケジューリング機能を使用して、Pod の配置を制御できます。

- [スケジューラーのプロファイル](#)
- [Pod のアフィニティーおよびアンチアフィニティールール](#)
- [ノードのアフィニティー](#)
- [ノードセレクター](#)
- [taint および toleration](#)
- [ノードのオーバーコミット](#)

4.1.1. デフォルトスケジューラーについて

OpenShift Container Platform のデフォルトの Pod スケジューラーは、クラスター内のノードにおける新規 Pod の配置場所を判別します。スケジューラーは Pod からデータを読み取り、設定されるプロファイルに基づいて適切なノードを見つけます。これは完全に独立した機能であり、スタンドアロンソリューションです。Pod を変更することではなく、Pod を特定ノードに関連付ける Pod のバインディングを作成します。

4.1.1.1. デフォルトスケジューリングについて

既存の汎用スケジューラーはプラットフォームで提供されるデフォルトのスケジューラー エンジン であり、Pod をホストするノードを 3 つの手順で選択します。

ノードのフィルタリング

使用可能なノードを、指定された制約または要件に基づいてフィルタリングします。これは、各ノードを **predicates** または **filters** と呼ばれるフィルター関数のリストに順番に適用することによって行われます。

フィルタリングされたノードのリストの優先順位付け

優先順位付けは、各ノードに一連の **優先度** または **スコアリング** 関数を実行することによって行わ

れます。この関数は 0-10 までのスコアをノードに割り当て、0 は不適切であることを示し、10 は Pod のホストに適していることを示します。スケジューラー設定では、各スコアリング関数について、単純な **重み** (正の数値) も取り込むことができます。各スコアリング関数で指定されるノードのスコアは重み (ほとんどのスコアのデフォルトの重みは 1) で乗算され、すべてのスコアで指定されるそれぞれのノードのスコアを追加して組み合わせられます。この重み属性は、一部のスコアにより重きを置くようにするなどの目的で管理者によって使用されます。

最適ノードの選択

ノードの並び替えはそれらのスコアに基づいて行われ、最高のスコアを持つノードが Pod をホストするように選択されます。複数のノードに同じ高スコアが付けられている場合、それらのいずれかがランダムに選択されます。

4.1.2. スケジューラーの使用例

OpenShift Container Platform 内でのスケジューリングの重要な使用例として、柔軟なアフィニティーとアンチアフィニティーポリシーのサポートを挙げることができます。

4.1.2.1. インフラストラクチャーのトポロジレベル

管理者は、ノードにラベルを指定することで、インフラストラクチャー (ノード) の複数のトポロジレベルを定義することができます。たとえば、**region=r1**、**zone=z1**、**rack=s1** などではそれらの例になります。

これらのラベル名には特別な意味はなく、管理者はそれらのインフラストラクチャーラベルに任意の名前 (例: 都市/建物/部屋) を付けることができます。さらに、管理者はインフラストラクチャートポロジに任意の数のレベルを定義できます。通常は、(**regions** → **zones** → **racks**) などの 3 つのレベルが適切なサイズです。管理者はこれらのレベルのそれぞれにアフィニティーとアンチアフィニティールールを任意の組み合わせで指定することができます。

4.1.2.2. アフィニティー

管理者は、任意のトポロジレベルまたは複数のレベルでもアフィニティーを指定できるようにスケジューラーを設定することができます。特定レベルのアフィニティーは、同じサービスに属するすべての Pod が同じレベルに属するノードにスケジュールされることを示します。これは、管理者がピア Pod が地理的に離れ過ぎないようにすることでアプリケーションの待機時間の要件に対応します。同じアフィニティーグループ内で Pod をホストするために利用できるノードがない場合、Pod はスケジュールされません。

Pod がスケジュールされる場所をより詳細に制御する必要がある場合は、[ノードのアフィニティールールを使用してノードへの Pod の配置を制御する](#) および [アフィニティールールとアンチアフィニティールールを使用して、他の Pod を基準にして Pod を配置する](#) を参照してください。

これらの高度なスケジュール機能を使うと、管理者は Pod をスケジュールするノードを指定でき、他の Pod との比較でスケジューリングを実行したり、拒否したりすることができます。

4.1.2.3. アンチアフィニティー

管理者は、任意のトポロジレベルまたは複数のレベルでもアンチアフィニティーを設定できるようにスケジューラーを設定することができます。特定レベルのアンチアフィニティー (または '分散') は、同じサービスに属するすべての Pod が該当レベルに属するノード全体に分散されることを示します。これにより、アプリケーションが高可用性の目的で適正に分散されます。スケジューラーは、可能な限り均等になるようにすべての適用可能なノード全体にサービス Pod を配置しようとします。

Pod がスケジュールされる場所をより詳細に制御する必要がある場合は、[ノードのアフィニティールール](#)を使用してノードへの Pod の配置を制御する および [アフィニティールールとアンチアフィニティールール](#)を使用して、他の Pod を基準にして Pod を配置する を参照してください。

これらの高度なスケジュール機能を使うと、管理者は Pod をスケジュールするノードを指定でき、他の Pod との比較でスケジューリングを実行したり、拒否したりすることができます。

4.2. スケジューラープロファイルを使用した POD のスケジューリング

OpenShift Container Platform は、スケジューリングプロファイルを使用して Pod をクラスター内のノードにスケジュールするように設定できます。

4.2.1. スケジューラープロファイルについて

スケジューラープロファイルを指定して、Pod をノードにスケジュールする方法を制御できます。

以下のスケジューラープロファイルを利用できます。

LowNodeUtilization

このプロファイルは、ノードごとのリソースの使用量を減らすためにノード間で Pod を均等に分散しようとします。このプロファイルは、デフォルトのスケジューラー動作を提供します。

HighNodeUtilization

このプロファイルは、できるだけ少ないノードにできるだけ多くの Pod を配置することを試行します。これによりノード数が最小限に抑えられ、ノードごとのリソースの使用率が高くなります。



注記

HighNodeUtilization スケジューラープロファイルに切り替えると、**ReplicaSet** オブジェクトのすべての Pod が同じノードにスケジュールされるようになります。これにより、ノードに障害が発生した場合に Pod 障害が発生するリスクが高まります。

NoScoring

これは、すべての score プラグインを無効にして最速のスケジューリングサイクルを目指す低レイテンシープロファイルです。これにより、スケジューリングの高速化がスケジューリングにおける意思決定の質に対して優先されます。

4.2.2. スケジューラープロファイルの設定

スケジューラーがスケジューラープロファイルを使用するように設定できます。

前提条件

- **cluster-admin** ロールを持つユーザーとしてクラスターにアクセスできる。

手順

1. **Scheduler** オブジェクトを編集します。

```
$ oc edit scheduler cluster
```

2. **spec.profile** フィールドで使用するプロファイルを指定します。

■

```

apiVersion: config.openshift.io/v1
kind: Scheduler
metadata:
  name: cluster
#...
spec:
  mastersSchedulable: false
  profile: HighNodeUtilization ❶
#...

```

❶ **LowNodeUtilization**、**HighNodeUtilization**、または **NoScoring** に設定されます。

3. 変更を適用するためにファイルを保存します。

4.3. アフィニティールールとアンチアフィニティールールを使用して、他の POD を基準にして POD を配置する

アフィニティとは、スケジュールするノードを制御する Pod の特性です。アンチアフィニティは、ノード上で Pod がスケジュールされるのを防ぐ Pod のプロパティです。

OpenShift Container Platform では、**Pod のアフィニティ** と **Pod のアンチアフィニティ** によって、他の Pod のキー/値ラベルに基づいて、Pod のスケジュールに適したノードを制限できます。

4.3.1. Pod のアフィニティについて

Pod のアフィニティ と **Pod のアンチアフィニティ** によって、他の Pod のキー/値ラベルに基づいて、Pod をスケジュールすることに適したノードを制限することができます。

- Pod のアフィニティはスケジューラーに対し、新規 Pod のラベルセクターが現在の Pod のラベルに一致する場合に他の Pod と同じノードで新規 Pod を見つけるように指示します。
- Pod のアンチアフィニティにより、新しい Pod のラベルセクターが現在の Pod のラベルと一致する場合、スケジューラーが同じラベルを持つ Pod と同じノード上に新しい Pod を配置するのを防ぐことができます。

たとえば、アフィニティールールを使用することで、サービス内で、または他のサービスの Pod との関連で Pod を分散したり、パックしたりすることができます。アンチアフィニティールールを使用すると、特定のサービスの Pod が、そのサービスの Pod のパフォーマンスに干渉することが判明している別のサービスの Pod と同じノードにスケジュールされるのを防止できます。または、関連する障害を減らすために複数のノード、アベイラビリティゾーン、またはアベイラビリティセットの間でサービスの Pod を分散することもできます。



注記

ラベルセクターは、複数の Pod デプロイメントを持つ Pod に一致する可能性があります。アンチアフィニティールールを設定して Pod が一致しないようにする場合は、一意のラベル組み合わせを使用します。

Pod のアフィニティには、**required (必須)** および **preferred (優先)** の2つのタイプがあります。

Pod をノードにスケジュールする前に、**required (必須)** ルールを **満たしている必要があります**。
preferred (優先) ルールは、ルールを満たす場合に、スケジューラーはルールの実施を試行しますが、その実施が必ずしも保証される訳ではありません。



注記

Pod の優先順位およびプリエンプレションの設定により、スケジューラーはアフィニティーの要件に違反しなければ Pod の適切なノードを見つけられない可能性があります。その場合、Pod はスケジュールされない可能性があります。

この状態を防ぐには、優先順位が等しい Pod との Pod のアフィニティーの設定を慎重に行ってください。

Pod のアフィニティー/アンチアフィニティーは **Pod** 仕様ファイルで設定します。required (必須) ルール、preferred (優先) ルールのいずれか、その両方を指定することができます。両方を指定する場合、ノードは最初に required (必須) ルールを満たす必要があり、その後に preferred (優先) ルールを満たそうとします。

以下の例は、Pod のアフィニティーおよびアンチアフィニティーに設定される **Pod** 仕様を示しています。

この例では、Pod のアフィニティールールは、ノードにキー **security** と値 **S1** を持つラベルの付いた 1 つ以上の Pod がすでに実行されている場合にのみ Pod をノードにスケジュールできることを示しています。Pod のアンチアフィニティールールは、ノードがキー **security** と値 **S2** を持つラベルが付いた Pod がすでに実行されている場合は Pod をノードにスケジュールしないように設定することを示しています。

Pod のアフィニティーが設定された Pod 設定ファイルのサンプル

```
apiVersion: v1
kind: Pod
metadata:
  name: with-pod-affinity
spec:
  affinity:
    podAffinity: ❶
      requiredDuringSchedulingIgnoredDuringExecution: ❷
        - labelSelector:
            matchExpressions:
              - key: security ❸
                operator: In ❹
                values:
                  - S1 ❺
          topologyKey: failure-domain.beta.kubernetes.io/zone
  containers:
    - name: with-pod-affinity
      image: docker.io/ocpqe/hello-pod
```

❶ Pod のアフィニティーを設定するためのスタンザです。

❷ required (必須) ルールを定義します。

❸ ❺ ルールを適用するために一致している必要のあるキーと値 (ラベル) です。

❹ 演算子は、既存 Pod のラベルと新規 Pod の仕様の **matchExpression** パラメーターの値のセットの間の関係を表します。これには **In**、**NotIn**、**Exists**、または **DoesNotExist** のいずれかを使用できます。

Pod のアンチアフィニティーが設定された Pod 設定ファイルのサンプル

```

apiVersion: v1
kind: Pod
metadata:
  name: with-pod-antiaffinity
spec:
  affinity:
    podAntiAffinity: ❶
    preferredDuringSchedulingIgnoredDuringExecution: ❷
    - weight: 100 ❸
      podAffinityTerm:
        labelSelector:
          matchExpressions:
            - key: security ❹
              operator: In ❺
              values:
                - S2
        topologyKey: kubernetes.io/hostname
  containers:
    - name: with-pod-affinity
      image: docker.io/ocpqe/hello-pod

```

- ❶ Pod のアンチアフィニティーを設定するためのスタンザです。
- ❷ preferred (優先) ルールを定義します。
- ❸ preferred (優先) ルールの重みを指定します。最も高い重みを持つノードが優先されます。
- ❹ アンチアフィニティールールが適用される時を決定する Pod ラベルの説明です。ラベルのキーおよび値を指定します。
- ❺ 演算子は、既存 Pod のラベルと新規 Pod の仕様の **matchExpression** パラメーターの値のセットの間の関係を表します。これには **In**、**NotIn**、**Exists**、または **DoesNotExist** のいずれかを使用できます。



注記

ノードのラベルに、Pod のノードのアフィニティールールを満たさなくなるような結果になる変更がランタイム時に生じる場合も、Pod はノードで引き続き実行されます。

4.3.2. Pod アフィニティー規則の設定

以下の手順は、ラベルの付いた Pod と Pod のスケジュールを可能にするアフィニティーを使用する Pod を作成する 2 つの Pod の単純な設定を示しています。



注記

アフィニティーをスケジュールされた Pod に直接追加することはできません。

手順

1. Pod 仕様の特定のラベルの付いた Pod を作成します。

- a. 以下の内容を含む YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: security-s1
  labels:
    security: S1
spec:
  containers:
  - name: security-s1
    image: docker.io/ocpqe/hello-pod
```

- b. Pod を作成します。

```
$ oc create -f <pod-spec>.yaml
```

2. 他の Pod の作成時に、以下のパラメーターを設定してアフィニティーを追加します。

- a. 以下の内容を含む YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: security-s1-east
#...
spec
  affinity 1
    podAffinity:
      requiredDuringSchedulingIgnoredDuringExecution: 2
      - labelSelector:
          matchExpressions:
            - key: security 3
              values:
                - S1
              operator: In 4
            topologyKey: topology.kubernetes.io/zone 5
#...
```

- 1** Pod のアフィニティーを追加します。
- 2** **requiredDuringSchedulingIgnoredDuringExecution** パラメーターまたは **preferredDuringSchedulingIgnoredDuringExecution** パラメーターを設定します。
- 3** 満たす必要のある **key** および **values** を指定します。新規 Pod を他の Pod と共にスケジュールする必要がある場合、最初の Pod のラベルと同じ **key** および **values** パラメーターを使用します。
- 4** **operator** を指定します。演算子は **In**、**NotIn**、**Exists**、または **DoesNotExist** にすることができます。たとえば、演算子 **In** を使用してラベルをノードで必要になるようにします。
- 5** **topologyKey** を指定します。これは、システムがトポロジードメインを表すために使用する事前にデータが設定された [Kubernetes ラベル](#) です。

- b. Pod を作成します。

```
$ oc create -f <pod-spec>.yaml
```

4.3.3. Pod アンチアフィニティールールの設定

以下の手順は、ラベルの付いた Pod と Pod のスケジューリングの禁止を試行するアンチアフィニティの preferred (優先) ルールを使用する Pod を作成する 2 つの Pod の単純な設定を示しています。



注記

アフィニティをスケジューリングされた Pod に直接追加することはできません。

手順

1. Pod 仕様の特定のラベルの付いた Pod を作成します。

- a. 以下の内容を含む YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: security-s1
  labels:
    security: S1
spec:
  containers:
  - name: security-s1
    image: docker.io/ocpqe/hello-pod
```

- b. Pod を作成します。

```
$ oc create -f <pod-spec>.yaml
```

2. 他の Pod の作成時に、以下のパラメーターを設定します。

- a. 以下の内容を含む YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: security-s2-east
  #...
spec
  affinity 1
  podAntiAffinity:
    preferredDuringSchedulingIgnoredDuringExecution: 2
  - weight: 100 3
    podAffinityTerm:
      labelSelector:
        matchExpressions:
        - key: security 4
          values:
          - S1
```

```
operator: In 5
topologyKey: kubernetes.io/hostname 6
#...
```

- 1 Pod のアンチアフィニティを追加します。
- 2 **requiredDuringSchedulingIgnoredDuringExecution** パラメーターまたは **preferredDuringSchedulingIgnoredDuringExecution** パラメーターを設定します。
- 3 preferred (優先) ルールの場合、ノードの重みを 1-100 で指定します。最も高い重みを持つノードが優先されます。
- 4 満たす必要のある **key** および **values** を指定します。新規 Pod を他の Pod と共にスケジュールされないようにする必要がある場合、最初の Pod のラベルと同じ **key** および **values** パラメーターを使用します。
- 5 **operator** を指定します。演算子は **In**、**NotIn**、**Exists**、または **DoesNotExist** にすることができます。たとえば、演算子 **In** を使用してラベルをノードで必要になるようにします。
- 6 **topologyKey** を指定します。これは、システムがトポロジドメインを表すために使用する事前にデータが設定された [Kubernetes ラベル](#) です。

b. Pod を作成します。

```
$ oc create -f <pod-spec>.yaml
```

4.3.4. Pod のアフィニティールールとアンチアフィニティールールの例

以下の例は、Pod のアフィニティおよびアンチアフィニティを示しています。

4.3.4.1. Pod のアフィニティ

以下の例は、一致するラベルとラベルセクターを持つ Pod に関する Pod のアフィニティを示しています。

- Pod **team4** にはラベル **team:4** が付けられています。

```
apiVersion: v1
kind: Pod
metadata:
  name: team4
  labels:
    team: "4"
#...
spec:
  containers:
  - name: ocp
    image: docker.io/ocpqe/hello-pod
#...
```

- Pod **team4a** には、**podAffinity** の下にラベルセクター **team:4** が付けられています。

```

apiVersion: v1
kind: Pod
metadata:
  name: team4a
#...
spec:
  affinity:
    podAffinity:
      requiredDuringSchedulingIgnoredDuringExecution:
        - labelSelector:
            matchExpressions:
              - key: team
                operator: In
                values:
                  - "4"
            topologyKey: kubernetes.io/hostname
  containers:
    - name: pod-affinity
      image: docker.io/ocpqe/hello-pod
#...

```

- **team4a** Pod は **team4** Pod と同じノードにスケジュールされます。

4.3.4.2. Pod のアンチアフィニティー

以下の例は、一致するラベルとラベルセレクターを持つ Pod に関する Pod のアンチアフィニティーを示しています。

- Pod **pod-s1** にはラベル **security:s1** が付けられています。

```

apiVersion: v1
kind: Pod
metadata:
  name: pod-s1
  labels:
    security: s1
#...
spec:
  containers:
    - name: ocp
      image: docker.io/ocpqe/hello-pod
#...

```

- Pod **pod-s2** には、**podAntiAffinity** の下にラベルセレクター **security:s1** が付けられています。

```

apiVersion: v1
kind: Pod
metadata:
  name: pod-s2
#...
spec:
  affinity:
    podAntiAffinity:
      requiredDuringSchedulingIgnoredDuringExecution:

```

```

- labelSelector:
  matchExpressions:
  - key: security
    operator: In
    values:
    - s1
  topologyKey: kubernetes.io/hostname
containers:
- name: pod-antiaffinity
  image: docker.io/ocpqe/hello-pod
#...

```

- Pod **pod-s2** は **pod-s1** と同じノードにスケジュールできません。

4.3.4.3. 一致するラベルのない Pod のアフィニティー

以下の例は、一致するラベルとラベルセクターのない Pod に関する Pod のアフィニティーを示しています。

- Pod **pod-s1** にはラベル **security:s1** が付けられています。

```

apiVersion: v1
kind: Pod
metadata:
  name: pod-s1
  labels:
    security: s1
#...
spec:
  containers:
  - name: ocp
    image: docker.io/ocpqe/hello-pod
#...

```

- Pod **pod-s2** にはラベルセクター **security:s2** があります。

```

apiVersion: v1
kind: Pod
metadata:
  name: pod-s2
#...
spec:
  affinity:
    podAffinity:
      requiredDuringSchedulingIgnoredDuringExecution:
      - labelSelector:
        matchExpressions:
        - key: security
          operator: In
          values:
          - s2
        topologyKey: kubernetes.io/hostname
  containers:

```

```
- name: pod-affinity
  image: docker.io/ocpqe/hello-pod
#...
```

- Pod **pod-s2** は、**security:s2** ラベルの付いた Pod を持つノードがない場合はスケジュールされません。そのラベルの付いた他の Pod がない場合、新規 Pod は保留状態のままになります。

出力例

```
NAME    READY   STATUS    RESTARTS   AGE    IP      NODE
pod-s2  0/1     Pending  0          32s     <none>
```

4.3.5. Pod のアフィニティーとアンチアフィニティーを使用して、Operator がインストールされている場所を制御する

デフォルトでは、Operator をインストールすると、OpenShift Container Platform は Operator Pod をワーカーノードの1つにランダムにインストールします。ただし、特定のノードまたはノードのセットでその Pod をスケジュールする必要がある場合があります。

以下の例では、Operator Pod を特定のノードまたはノードのセットにスケジュールする状況を説明します。

- Operator が **amd64** や **arm64** などの特定のプラットフォームを必要とする場合
- オペレータが Linux や Windows などの特定のオペレーティングシステムを必要とする場合
- 同じホストまたは同じラックに配置されたホストでスケジュールされた一緒に動作する Operator が必要な場合
- ネットワークまたはハードウェアの問題によるダウンタイムを回避するために、Operator をインフラストラクチャー全体に分散させたい場合

Operator の **Subscription** オブジェクトに Pod アフィニティーまたはアンチアフィニティーを追加することで、Operator Pod がインストールされる場所を制御できます。

次の例は、Pod のアンチアフィニティーを使用して、特定のラベルを持つ Pod を持つノードから Custom Metrics Autoscaler Operator がインストールされないようにする方法を示しています。

Operator Pod を1つ以上の特定のノードに配置する Pod アフィニティーの例

```
apiVersion: operators.coreos.com/v1alpha1
kind: Subscription
metadata:
  name: openshift-custom-metrics-autoscaler-operator
  namespace: openshift-keda
spec:
  name: my-package
  source: my-operators
  sourceNamespace: operator-registries
config:
  affinity:
    podAffinity: ❶
    requiredDuringSchedulingIgnoredDuringExecution:
      - labelSelector:
          matchExpressions:
```

```

- key: app
  operator: In
  values:
  - test
topologyKey: kubernetes.io/hostname
#...
```

- ① **app=test** ラベルを持つ Pod を持つノードに Operator の Pod を配置する Pod アフィニティー。

Operator Pod が1つ以上の特定のノードからアクセスできないようにする Pod アンチアフィニティーの例

```

apiVersion: operators.coreos.com/v1alpha1
kind: Subscription
metadata:
  name: openshift-custom-metrics-autoscaler-operator
  namespace: openshift-keda
spec:
  name: my-package
  source: my-operators
  sourceNamespace: operator-registries
  config:
    affinity:
      podAntiAffinity: ①
      requiredDuringSchedulingIgnoredDuringExecution:
      - labelSelector:
          matchExpressions:
          - key: cpu
            operator: In
            values:
            - high
        topologyKey: kubernetes.io/hostname
#...
```

- ① Operator の Pod が **cpu=high** ラベルの Pod を持つノードでスケジュールされないようにする Pod アンチアフィニティー。

手順

Operator Pod の配置を制御するには、次の手順を実行します。

1. 通常どおり Operator をインストールします。
2. 必要に応じて、ノードがアフィニティーに適切に応答するようにラベル付けされていることを確認してください。
3. Operator **Subscription** オブジェクトを編集してアフィニティーを追加します。

```

apiVersion: operators.coreos.com/v1alpha1
kind: Subscription
metadata:
  name: openshift-custom-metrics-autoscaler-operator
  namespace: openshift-keda
spec:
```

```

name: my-package
source: my-operators
sourceNamespace: operator-registries
config:
  affinity:
    podAntiAffinity: ❶
    requiredDuringSchedulingIgnoredDuringExecution:
      podAffinityTerm:
        labelSelector:
          matchExpressions:
            - key: kubernetes.io/hostname
              operator: In
              values:
                - ip-10-0-185-229.ec2.internal
        topologyKey: topology.kubernetes.io/zone
#...
```

❶ **podAffinity** または **podAntiAffinity** を追加します。

検証

- Pod が特定のノードにデプロイされていることを確認するには、次のコマンドを実行します。

```
$ oc get pods -o wide
```

出力例

NAME	READY	STATUS	RESTARTS	AGE	IP
NODE	NOMINATED NODE	READINESS GATES			
custom-metrics-autoscaler-operator-5dcc45d656-bhshg	1/1	Running	0	50s	
10.131.0.20	ip-10-0-185-229.ec2.internal	<none>	<none>		

4.4. ノードのアフィニティールールを使用してノードへの POD の配置を制御する

アフィニティとは、スケジュールするノードを制御する Pod の特性です。

OpenShift Container Platform では、アフィニティとはスケジューラーが Pod を配置する場所を決定するために使用する一連のルールのことです。このルールは、ノードのカスタムラベルと Pod で指定されたラベルセクターを使用して定義されます。

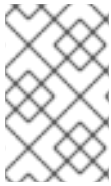
4.4.1. ノードのアフィニティについて

ノードのアフィニティにより、Pod がその配置に使用できるノードのグループに対してアフィニティを指定できます。ノード自体は配置に対して制御を行いません。

たとえば、Pod を特定の CPU を搭載したノードまたは特定のアベイラビリティゾーンにあるノードでのみ実行されるよう設定することができます。

ノードのアフィニティールールには、**required (必須)** および **preferred (優先)** の2つのタイプがあります。

Pod をノードにスケジュールする前に、required (必須) ルールを **満たしている必要があります**。
preferred (優先) ルールは、ルールを満たす場合に、スケジューラーはルールの実施を試行しますが、その実施が必ずしも保証される訳ではありません。



注記

ランタイム時にノードのラベルに変更が生じ、その変更により Pod でのノードのアフィニティルールを満たさなくなる状態が生じるでも、Pod はノードで引き続き実行されます。

ノードのアフィニティは **Pod** 仕様ファイルで設定します。required (必須) ルール、preferred (優先) ルールのいずれか、その両方を指定することができます。両方を指定する場合、ノードは最初に required (必須) ルールを満たす必要があり、その後に preferred (優先) ルールを満たそうとします。

以下の例は、Pod をキーが **e2e-az-NorthSouth** で、その値が **e2e-az-North** または **e2e-az-South** のいずれかであるラベルの付いたノードに Pod を配置することを求めるルールが設定された **Pod** 仕様です。

ノードのアフィニティの required (必須) ルールが設定された Pod 設定ファイルのサンプル

```
apiVersion: v1
kind: Pod
metadata:
  name: with-node-affinity
spec:
  affinity:
    nodeAffinity: ❶
      requiredDuringSchedulingIgnoredDuringExecution: ❷
        nodeSelectorTerms:
          - matchExpressions:
              - key: e2e-az-NorthSouth ❸
                operator: In ❹
                values:
                  - e2e-az-North ❺
                  - e2e-az-South ❻
        containers:
          - name: with-node-affinity
            image: docker.io/ocpqe/hello-pod
#...
```

❶ ノードのアフィニティを設定するためのスタンザです。

❷ required (必須) ルールを定義します。

❸ ❺ ❻ ルールを適用するために一致している必要のあるキー/値のペア (ラベル) です。

❹ 演算子は、ノードのラベルと **Pod** 仕様の **matchExpression** パラメーターの値のセットの間の関係を表します。この値は、**In**、**NotIn**、**Exists**、または **DoesNotExist**、**Lt**、または **Gt** にすることができます。

以下の例は、キーが **e2e-az-EastWest** で、その値が **e2e-az-East** または **e2e-az-West** のラベルが付いたノードに Pod を配置すること優先する preferred (優先) ルールが設定されたノード仕様です。

ノードのアフィニティーの preferred (優先) ルールが設定された Pod 設定ファイルのサンプル

```

apiVersion: v1
kind: Pod
metadata:
  name: with-node-affinity
spec:
  affinity:
    nodeAffinity: ❶
      preferredDuringSchedulingIgnoredDuringExecution: ❷
        - weight: 1 ❸
          preference:
            matchExpressions:
              - key: e2e-az-EastWest ❹
                operator: In ❺
                values:
                  - e2e-az-East ❻
                  - e2e-az-West ❼
            containers:
              - name: with-node-affinity
                image: docker.io/ocpqe/hello-pod
#...
```

- ❶ ノードのアフィニティーを設定するためのスタンザです。
- ❷ preferred (優先) ルールを定義します。
- ❸ preferred (優先) ルールの重みを指定します。最も高い重みを持つノードが優先されます。
- ❹❻❼ ルールを適用するために一致している必要のあるキー/値のペア (ラベル) です。
- ❺ 演算子は、ノードのラベルと **Pod** 仕様の **matchExpression** パラメーターの値のセットの間の関係を表します。この値は、**In**、**NotIn**、**Exists**、または **DoesNotExist**、**Lt**、または **Gt** にすることができます。

ノードのアンチアフィニティーに関する明示的な概念はありませんが、**NotIn** または **DoesNotExist** 演算子を使用すると、動作が複製されます。



注記

同じ Pod 設定でノードのアフィニティーとノードのセクターを使用している場合は、以下に注意してください。

- **nodeSelector** と **nodeAffinity** の両方を設定する場合、Pod が候補ノードでスケジュールされるにはどちらの条件も満たしている必要があります。
- **nodeAffinity** タイプに関連付けられた複数の **nodeSelectorTerms** を指定する場合、**nodeSelectorTerms** のいずれかが満たされている場合に Pod をノードにスケジュールすることができます。
- **nodeSelectorTerms** に関連付けられた複数の **matchExpressions** を指定する場合、すべての **matchExpressions** が満たされている場合にのみ Pod をノードにスケジュールすることができます。

4.4.2. ノードアフィニティーの **required** (必須) ルールの設定

Pod をノードにスケジュールする前に、**required** (必須) ルールを **満たしている必要があります**。

手順

以下の手順は、ノードとスケジューラーがノードに配置する必要のある Pod を作成する単純な設定を示しています。

1. **oc label node** コマンドを使用してラベルをノードに追加します。

```
$ oc label node node1 e2e-az-name=e2e-az1
```

ヒント

あるいは、以下の YAML を適用してラベルを追加できます。

```
kind: Node
apiVersion: v1
metadata:
  name: <node_name>
  labels:
    e2e-az-name: e2e-az1
#...
```

2. Pod 仕様の特定のラベルの付いた Pod を作成します。
 - a. 以下の内容を含む YAML ファイルを作成します。



注記

アフィニティーをスケジュールされた Pod に直接追加することはできません。

出力例

```
apiVersion: v1
kind: Pod
metadata:
  name: s1
spec:
  affinity: ❶
    nodeAffinity:
      requiredDuringSchedulingIgnoredDuringExecution: ❷
        nodeSelectorTerms:
          - matchExpressions:
              - key: e2e-az-name ❸
                values:
                  - e2e-az1
                  - e2e-az2
            operator: In ❹
#...
```

- 1 Pod のアフィニティーを追加します。
- 2 **requiredDuringSchedulingIgnoredDuringExecution** パラメーターを設定します。
- 3 満たす必要のある **key** および **values** を指定します。新規 Pod を編集したノードにスケジューリングする必要がある場合、ノードのラベルと同じ **key** および **values** パラメーターを使用します。
- 4 **operator** を指定します。演算子は **In**、**NotIn**、**Exists**、または **DoesNotExist** にすることができます。たとえば、演算子 **In** を使用してラベルをノードで必要になるようにします。

b. Pod を作成します。

```
$ oc create -f <file-name>.yaml
```

4.4.3. ノードアフィニティーの preferred (優先) ルールの設定

preferred (優先) ルールは、ルールを満たす場合に、スケジューラーはルールの実施を試行しますが、その実施が必ずしも保証される訳ではありません。

手順

以下の手順は、ノードとスケジューラーがノードに配置しようとする Pod を作成する単純な設定を示しています。

1. **oc label node** コマンドを使用してラベルをノードに追加します。

```
$ oc label node node1 e2e-az-name=e2e-az3
```

2. 特定のラベルの付いた Pod を作成します。

- a. 以下の内容を含む YAML ファイルを作成します。



注記

アフィニティーをスケジューリングされた Pod に直接追加することはできません。

```
apiVersion: v1
kind: Pod
metadata:
  name: s1
spec:
  affinity: ①
    nodeAffinity:
      preferredDuringSchedulingIgnoredDuringExecution: ②
      - weight: ③
        preference:
          matchExpressions:
            - key: e2e-az-name ④
              values:
```

```
- e2e-az3
  operator: In 5
#...
```

- 1 Pod のアフィニティーを追加します。
- 2 **preferredDuringSchedulingIgnoredDuringExecution** パラメーターを設定します。
- 3 ノードの重みを数字の 1-100 で指定します。最も高い重みを持つノードが優先されます。
- 4 満たす必要のある **key** および **values** を指定します。新規 Pod を編集したノードにスケジュールする必要がある場合、ノードのラベルと同じ **key** および **values** パラメーターを使用します。
- 5 **operator** を指定します。演算子は **In**、**NotIn**、**Exists**、または **DoesNotExist** にすることができます。たとえば、演算子 **In** を使用してラベルをノードで必要になるようにします。

b. Pod を作成します。

```
$ oc create -f <file-name>.yaml
```

4.4.4. ノードのアフィニティールールの例

以下の例は、ノードのアフィニティーを示しています。

4.4.4.1. 一致するラベルを持つノードのアフィニティー

以下の例は、一致するラベルを持つノードと Pod のノードのアフィニティーを示しています。

- Node1 ノードにはラベル **zone:us** があります。

```
$ oc label node node1 zone=us
```

ヒント

あるいは、以下の YAML を適用してラベルを追加できます。

```
kind: Node
apiVersion: v1
metadata:
  name: <node_name>
  labels:
    zone: us
#...
```

- pod-s1 pod にはノードアフィニティーの required (必須) ルールの下に **zone** と **us** のキー/値のペアがあります。

```
$ cat pod-s1.yaml
```

出力例

```
apiVersion: v1
kind: Pod
metadata:
  name: pod-s1
spec:
  containers:
    - image: "docker.io/ocpqe/hello-pod"
      name: hello-pod
  affinity:
    nodeAffinity:
      requiredDuringSchedulingIgnoredDuringExecution:
        nodeSelectorTerms:
          - matchExpressions:
              - key: "zone"
                operator: In
                values:
                  - us
#...
```

- pod-s1 pod は Node1 でスケジュールできます。

```
$ oc get pod -o wide
```

出力例

```
NAME    READY   STATUS    RESTARTS   AGE   IP      NODE
pod-s1  1/1     Running   0           4m    IP1     node1
```

4.4.4.2. 一致するラベルのないノードのアフィニティー

以下の例は、一致するラベルを持たないノードと Pod のノードのアフィニティーを示しています。

- Node1 ノードにはラベル **zone:emea** があります。

```
$ oc label node node1 zone=emea
```

ヒント

あるいは、以下の YAML を適用してラベルを追加できます。

```
kind: Node
apiVersion: v1
metadata:
  name: <node_name>
labels:
  zone: emea
#...
```

- pod-s1 pod にはノードアフィニティーの required (必須) ルールの下に **zone** と **us** のキー/値のペアがあります。

```
$ cat pod-s1.yaml
```

出力例

```
apiVersion: v1
kind: Pod
metadata:
  name: pod-s1
spec:
  containers:
    - image: "docker.io/ocpqe/hello-pod"
      name: hello-pod
  affinity:
    nodeAffinity:
      requiredDuringSchedulingIgnoredDuringExecution:
        nodeSelectorTerms:
          - matchExpressions:
              - key: "zone"
                operator: In
                values:
                  - us
#...
```

- pod-s1 pod は Node1 でスケジュールすることができません。

```
$ oc describe pod pod-s1
```

出力例

```
...

Events:
  FirstSeen LastSeen Count From              SubObjectPath  Type            Reason
  -----
  1m         33s         8    default-scheduler Warning        FailedScheduling  No nodes are
available that match all of the following predicates:: MatchNodeSelector (1).
```

4.4.5. ノードアフィニティーを使用して **Operator** がインストールされる場所を制御する

デフォルトでは、Operator をインストールすると、OpenShift Container Platform は Operator Pod をワーカーノードの1つにランダムにインストールします。ただし、特定のノードまたはノードのセットでその Pod をスケジュールする必要がある場合があります。

以下の例では、Operator Pod を特定のノードまたはノードのセットにスケジュールする状況を説明します。

- Operator が **amd64** や **arm64** などの特定のプラットフォームを必要とする場合
- オペレータが Linux や Windows などの特定のオペレーティングシステムを必要とする場合
- 同じホストまたは同じラックに配置されたホストでスケジュールされた一緒に動作する Operator が必要な場合

- ネットワークまたはハードウェアの問題によるダウンタイムを回避するために、Operator をインフラストラクチャー全体に分散させたい場合

Operator の **Subscription** オブジェクトにノードアフィニティーの制約を追加することで、Operator Pod がインストールされる場所を制御できます。

次の例は、ノードアフィニティーを使用して、Custom Metrics Autoscaler Operator のインスタンスをクラスター内の特定のノードにインストールする方法を示しています。

Operator Pod を特定のノードに配置するノードアフィニティーの例

```
apiVersion: operators.coreos.com/v1alpha1
kind: Subscription
metadata:
  name: openshift-custom-metrics-autoscaler-operator
  namespace: openshift-keda
spec:
  name: my-package
  source: my-operators
  sourceNamespace: operator-registries
  config:
    affinity:
      nodeAffinity: ❶
      requiredDuringSchedulingIgnoredDuringExecution:
        nodeSelectorTerms:
          - matchExpressions:
              - key: kubernetes.io/hostname
                operator: In
            values:
              - ip-10-0-163-94.us-west-2.compute.internal
#...
```

- ❶ Operator の Pod を **ip-10-0-163-94.us-west-2.compute.internal** という名前のノードでスケジュールする必要があるノードアフィニティー。

Operator Pod を特定のプラットフォームのノードに配置するノードアフィニティーの例

```
apiVersion: operators.coreos.com/v1alpha1
kind: Subscription
metadata:
  name: openshift-custom-metrics-autoscaler-operator
  namespace: openshift-keda
spec:
  name: my-package
  source: my-operators
  sourceNamespace: operator-registries
  config:
    affinity:
      nodeAffinity: ❶
      requiredDuringSchedulingIgnoredDuringExecution:
        nodeSelectorTerms:
          - matchExpressions:
              - key: kubernetes.io/arch
                operator: In
```

```

values:
- arm64
- key: kubernetes.io/os
operator: In
values:
- linux
#...
```

- 1 Operator の Pod を **kubernetes.io/arch=arm64** および **kubernetes.io/os=linux** ラベルを持つノードでスケジュールする必要があるノードアフィニティー。

手順

Operator Pod の配置を制御するには、次の手順を実行します。

1. 通常どおり Operator をインストールします。
2. 必要に応じて、ノードがアフィニティーに適切に応答するようにラベル付けされていることを確認してください。
3. Operator **Subscription** オブジェクトを編集してアフィニティーを追加します。

```

apiVersion: operators.coreos.com/v1alpha1
kind: Subscription
metadata:
  name: openshift-custom-metrics-autoscaler-operator
  namespace: openshift-keda
spec:
  name: my-package
  source: my-operators
  sourceNamespace: operator-registries
config:
  affinity: 1
  nodeAffinity:
    requiredDuringSchedulingIgnoredDuringExecution:
      nodeSelectorTerms:
      - matchExpressions:
        - key: kubernetes.io/hostname
          operator: In
          values:
          - ip-10-0-185-229.ec2.internal
#...
```

- 1 **nodeAffinity** を追加します。

検証

- Pod が特定のノードにデプロイされていることを確認するには、次のコマンドを実行します。

```
$ oc get pods -o wide
```

出力例

NAME	READY	STATUS	RESTARTS	AGE	IP
NODE	NOMINATED NODE	READINESS GATES			
custom-metrics-autoscaler-operator-5dcc45d656-bhshg	1/1	Running	0	50s	
10.131.0.20 ip-10-0-185-229.ec2.internal	<none>	<none>			

4.4.6. 関連情報

- [ノードでラベルを更新する方法について](#)

4.5. POD のオーバーコミットノードへの配置

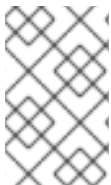
オーバーコミットとは、コンテナの計算リソース要求と制限の合計が、そのシステムで利用できるリソースを超えた状態のことです。オーバーコミットは、容量に対して保証されたパフォーマンスのトレードオフが許容可能である開発環境において、望ましいことがあります。

要求および制限により、管理者はノードでのリソースのオーバーコミットを許可し、管理できます。スケジューラーは、要求を使用してコンテナをスケジュールし、最小限のサービス保証を提供します。制限は、ノード上で消費されるコンピュートリソースの量を制限します。

4.5.1. オーバーコミットについて

要求および制限により、管理者はノードでのリソースのオーバーコミットを許可し、管理できます。スケジューラーは、要求を使用してコンテナをスケジュールし、最小限のサービス保証を提供します。制限は、ノード上で消費されるコンピュートリソースの量を制限します。

OpenShift Container Platform の管理者は、開発者用のコンテナに設定された要求と制限の比率をオーバーライドするようにマスターを設定することで、オーバーコミットのレベルを制御し、ノード上のコンテナ密度を管理できます。この設定を、制限とデフォルトを指定するプロジェクトごとの **LimitRange** と共に使用することで、オーバーコミットを必要なレベルに設定できるようコンテナの制限と要求を調整することができます。



注記

コンテナに制限が設定されていない場合には、これらの上書きは影響を与えません。デフォルトの制限で (個別プロジェクトごとに、またはプロジェクトテンプレートを使用して) **LimitRange** オブジェクトを作成し、上書きが適用されるようにします。

上書き後も、コンテナの制限および要求は、プロジェクトのいずれかの **LimitRange** オブジェクトで引き続き検証される必要があります。たとえば、開発者が最小限度に近い制限を指定し、要求を最小限度よりも低い値に上書きすることで、Pod が禁止される可能性があります。この最適でないユーザーエクスペリエンスは、今後の作業で対応する必要がありますが、現時点ではこの機能および **LimitRange** オブジェクトを注意して設定してください。

4.5.2. ノードのオーバーコミットについて

オーバーコミット環境では、最適なシステム動作を提供できるようにノードを適切に設定する必要があります。

ノードが起動すると、メモリー管理用のカーネルの調整可能なフラグが適切に設定されます。カーネルは、物理メモリーが不足しない限り、メモリーの割り当てに失敗することはありません。

この動作を確認するため、OpenShift Container Platform は、**vm.overcommit_memory** パラメーターを **1** に設定し、デフォルトのオペレーティングシステムの設定を上書きすることで、常にメモリーをオーバーコミットするようにカーネルを設定します。

また、OpenShift Container Platform は **vm.panic_on_oom** パラメーターを **0** に設定することで、メモリーが不足したときでもカーネルがパニックにならないようにします。0 の設定は、Out of Memory (OOM) 状態のときに oom_killer を呼び出すようカーネルに指示します。これにより、優先順位に基づいてプロセスを強制終了します。

現在の設定は、ノードに以下のコマンドを実行して表示できます。

```
$ sysctl -a |grep commit
```

出力例

```
#...
vm.overcommit_memory = 0
#...
```

```
$ sysctl -a |grep panic
```

出力例

```
#...
vm.panic_on_oom = 0
#...
```



注記

上記のフラグはノード上にすでに設定されているはずであるため、追加のアクションは不要です。

各ノードに対して以下の設定を実行することもできます。

- CPU CFS クォータを使用した CPU 制限の無効化または実行
- システムプロセスのリソース予約
- Quality of Service (QoS) 層でのメモリー予約

4.6. ノード Taint を使用した POD 配置の制御

taint および toleration により、ノードはノード上でスケジュールする必要のある (またはスケジュールすべきでない) Pod を制御できます。

4.6.1. taint および toleration について

taint により、ノードは Pod に一致する toleration がない場合に Pod のスケジュールを拒否することができます。

taint は **Node** 仕様 (**NodeSpec**) でノードに適用され、toleration は **Pod** 仕様 (**PodSpec**) で Pod に適用されます。taint をノードに適用する場合、スケジューラーは Pod が taint を容認しない限り、Pod をそのノードに配置することができません。

ノード仕様の taint の例

```
apiVersion: v1
kind: Node
metadata:
  name: my-node
#...
spec:
  taints:
  - effect: NoExecute
    key: key1
    value: value1
#...
```

Pod 仕様での toleration の例

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
  - key: "key1"
    operator: "Equal"
    value: "value1"
    effect: "NoExecute"
    tolerationSeconds: 3600
#...
```

taint および toleration は、key、value、および effect で構成されます。

表4.1 taint および toleration コンポーネント

パラメーター	説明
key	key には、253 文字までの文字列を使用できます。キーは文字または数字で開始する必要があり、文字、数字、ハイフン、ドットおよびアンダースコアを含めることができます。
value	value には、63 文字までの文字列を使用できます。値は文字または数字で開始する必要があり、文字、数字、ハイフン、ドットおよびアンダースコアを含めることができます。

パラメーター	説明						
effect	<p>effect は以下のいずれかにすることができます。</p> <table> <tr> <td>NoSchedule ^[1]</td><td> <ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールされません。 ノードの既存 Pod はそのままになります。 </td></tr> <tr> <td>PreferNoSchedule</td><td> <ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールされる可能性がありますが、スケジューラーはスケジュールしないようにします。 ノードの既存 Pod はそのままになります。 </td></tr> <tr> <td>NoExecute</td><td> <ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールできません。 一致する toleration を持たないノードの既存 Pod は削除されます。 </td></tr> </table>	NoSchedule ^[1]	<ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールされません。 ノードの既存 Pod はそのままになります。 	PreferNoSchedule	<ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールされる可能性がありますが、スケジューラーはスケジュールしないようにします。 ノードの既存 Pod はそのままになります。 	NoExecute	<ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールできません。 一致する toleration を持たないノードの既存 Pod は削除されます。
NoSchedule ^[1]	<ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールされません。 ノードの既存 Pod はそのままになります。 						
PreferNoSchedule	<ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールされる可能性がありますが、スケジューラーはスケジュールしないようにします。 ノードの既存 Pod はそのままになります。 						
NoExecute	<ul style="list-style-type: none"> taint に一致しない新規 Pod はノードにスケジュールできません。 一致する toleration を持たないノードの既存 Pod は削除されます。 						
operator	<table> <tr> <td>Equal</td><td>key/value/effect パラメーターは一致する必要があります。これがデフォルトです。</td></tr> <tr> <td>Exists</td><td>key/effect パラメーターは一致する必要があります。いずれかに一致する value パラメーターを空のままにする必要があります。</td></tr> </table>	Equal	key/value/effect パラメーターは一致する必要があります。これがデフォルトです。	Exists	key/effect パラメーターは一致する必要があります。いずれかに一致する value パラメーターを空のままにする必要があります。		
Equal	key/value/effect パラメーターは一致する必要があります。これがデフォルトです。						
Exists	key/effect パラメーターは一致する必要があります。いずれかに一致する value パラメーターを空のままにする必要があります。						

1. **NoSchedule** taint をコントロールプレーンノードに追加すると、ノードには、デフォルトで追加される **node-role.kubernetes.io/master=:NoSchedule** taint が必要です。
以下に例を示します。

```

apiVersion: v1
kind: Node
metadata:
  annotations:
    machine.openshift.io/machine: openshift-machine-api/ci-ln-62s7gtb-f76d1-v8jxv-master-0
    machineconfiguration.openshift.io/currentConfig: rendered-master-
cdc1ab7da414629332cc4c3926e6e59c
    name: my-node
#...
spec:
  taints:

```

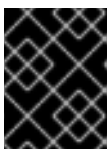
```
- effect: NoSchedule
  key: node-role.kubernetes.io/master
#...
```

toleration は taint と一致します。

- **operator** パラメーターが **Equal** に設定されている場合:
 - **key** パラメーターが同じである。
 - **value** パラメーターが同じである。
 - **effect** パラメーターが同じである。
- **operator** パラメーターが **Exists** に設定されている場合:
 - **key** パラメーターが同じである。
 - **effect** パラメーターが同じである。

以下の taint は OpenShift Container Platform に組み込まれています。

- **node.kubernetes.io/not-ready**: ノードは準備状態にありません。これはノード条件 **Ready=False** に対応します。
- **node.kubernetes.io/unreachable**: ノードはノードコントローラーから到達不能です。これはノード条件 **Ready=Unknown** に対応します。
- **node.kubernetes.io/memory-pressure**: ノードにはメモリー不足の問題が発生しています。これはノード条件 **MemoryPressure=True** に対応します。
- **node.kubernetes.io/disk-pressure**: ノードにはディスク不足の問題が発生しています。これはノード条件 **DiskPressure=True** に対応します。
- **node.kubernetes.io/network-unavailable**: ノードのネットワークは使用できません。
- **node.kubernetes.io/unschedulable**: ノードはスケジュールが行えません。
- **node.cloudprovider.kubernetes.io/uninitialized**: ノードコントローラーが外部のクラウドプロバイダーを使用して起動すると、この taint はノード上に設定され、使用不可能とマークされます。cloud-controller-manager のコントローラーがこのノードを初期化した後に、kubelet がこの taint を削除します。
- **node.kubernetes.io/pid-pressure**: ノードが pid 不足の状態です。これはノード条件 **PIDPressure=True** に対応します。



重要

OpenShift Container Platform では、デフォルトの pid.available **evictionHard** は設定されません。

4.6.1.1. Pod のエビクションを遅延させる toleration (秒数) の使用方法

Pod 仕様または **MachineSet** に **tolerationSeconds** パラメーターを指定して、Pod がエビクションされる前にノードにバインドされる期間を指定できます。effect が **NoExecute** の taint がノードに追加さ

れる場合、`taint` を容認する Pod に **`tolerationSeconds`** パラメーターがある場合、Pod は期限切れになるまで退避されません。

出力例

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
  - key: "key1"
    operator: "Equal"
    value: "value1"
    effect: "NoExecute"
    tolerationSeconds: 3600
#...
```

ここで、この Pod が実行中であるものの、一致する容 `toleration` がない場合、Pod は 3,600 秒間バインドされたままとなり、その後に退避されます。`taint` が期限前に削除される場合、Pod は退避されません。

4.6.1.2. 複数の `taint` の使用方法

複数の `taint` を同じノードに、複数の `toleration` を同じ Pod に配置することができます。OpenShift Container Platform は複数の `taint` と `toleration` を以下のように処理します。

- Pod に一致する `toleration` のある `taint` を処理します。
- 残りの一致しないティン `taint` は Pod について以下の `effect` を持ちます。
 - `effect` が **NoSchedule** の一致しない `taint` が 1 つ以上ある場合、OpenShift Container Platform は Pod をノードにスケジュールできません。
 - `effect` が **NoSchedule** の一致しない `taint` がなく、`effect` が **PreferNoSchedule** の一致しない `taint` が 1 つ以上ある場合、OpenShift Container Platform は Pod のノードへのスケジュールを試行しません。
 - `effect` が **NoExecute** の `taint` が 1 つ以上ある場合、OpenShift Container Platform は Pod をノードから退避するか (ノードですでに実行中の場合)、または Pod のそのノードへのスケジュールが実行されません (ノードでまだ実行されていない場合)。
 - `taint` を容認しない Pod はすぐに退避されます。
 - Pod の仕様に **`tolerationSeconds`** を指定せずに `taint` を容認する Pod は永久にバインドされたままになります。
 - 指定された **`tolerationSeconds`** を持つティン `taint` を容認する Pod は指定された期間バインドされます。

以下に例を示します。

- 以下の `taint` をノードに追加します。

```
$ oc adm taint nodes node1 key1=value1:NoSchedule
```

```
$ oc adm taint nodes node1 key1=value1:NoExecute
```

```
$ oc adm taint nodes node1 key2=value2:NoSchedule
```

- Pod には以下の toleration があります。

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
    - key: "key1"
      operator: "Equal"
      value: "value1"
      effect: "NoSchedule"
    - key: "key1"
      operator: "Equal"
      value: "value1"
      effect: "NoExecute"
#...
```

この場合、3 つ目の taint に一致する toleration がないため、Pod はノードにスケジュールできません。Pod はこの taint の追加時にノードですでに実行されている場合は実行が継続されます。3 つ目の taint は 3 つの taint の中で Pod で容認されない唯一の taint であるためです。

4.6.1.3. Pod のスケジューリングとノードの状態 (Taint Nodes By Condition) について

Taint Nodes By Condition (状態別のノードへの taint) 機能はデフォルトで有効にされており、これはメモリー不足やディスク不足などの状態を報告するノードを自動的に taint します。ノードが状態を報告すると、その状態が解消するまで taint が追加されます。taint に **NoSchedule** の effect がある場合、ノードが一致する toleration を持つまでそのノードに Pod をスケジュールすることはできません。

スケジューラーは、Pod をスケジュールする前に、ノードでこれらの taint の有無をチェックします。taint がある場合、Pod は別のノードにスケジュールされます。スケジューラーは実際のノードの状態ではなく taint をチェックするので、適切な Pod toleration を追加して、スケジューラーがこのようなノードの状態を無視するように設定します。

デーモンセットコントローラーは、以下の toleration をすべてのデーモンに自動的に追加し、下位互換性を確保します。

- node.kubernetes.io/memory-pressure
- node.kubernetes.io/disk-pressure
- node.kubernetes.io/unschedulable (1.10 以降)
- node.kubernetes.io/network-unavailable (ホストネットワークのみ)

デーモンセットには任意の toleration を追加することも可能です。



注記

コントロールプレーンは、QoS クラスを持つ Pod に **node.kubernetes.io/memory-pressure** toleration も追加します。これは、Kubernetes が **Guaranteed** または **Burstable** QoS クラスで Pod を管理するためです。新しい **BestEffort** Pod は、影響を受けるノードにスケジュールされません。

4.6.1.4. Pod の状態別エビクションについて (Taint-Based Eviction)

Taint-Based Eviction 機能はデフォルトで有効にされており、これは **not-ready** および **unreachable** などの特定の状態にあるノードから Pod を退避します。ノードがこうした状態のいずれかになると、OpenShift Container Platform は taint をノードに自動的に追加して、Pod の退避および別のノードでの再スケジュールを開始します。

Taint Based Eviction には **NoExecute** の effect があり、その taint を容認しない Pod はすぐに退避され、これを容認する Pod は退避されません (Pod が **tolerationSeconds** パラメーターを使用しない場合に限りです)。

tolerationSeconds パラメーターを使用すると、ノード状態が設定されたノードに Pod がどの程度の期間バインドされるかを指定することができます。**tolerationSeconds** の期間後もこの状態が続くと、taint はノードに残り続け、一致する toleration を持つ Pod は退避されます。**tolerationSeconds** の期間前にこの状態が解消される場合、一致する toleration を持つ Pod は削除されません。

値なしで **tolerationSeconds** パラメーターを使用する場合、Pod は not ready(準備未完了) および unreachable(到達不能) のノードの状態が原因となり退避されることはありません。



注記

OpenShift Container Platform は、レートが制限された方法で Pod を退避し、マスターがノードからパーティション化される場合などのシナリオで発生する大規模な Pod エビクションを防ぎます。

デフォルトでは、特定のゾーン内の 55% を超えるノードが健全でない場合、ノードライフサイクルコントローラーが、そのゾーンの状態を **PartialDisruption** に変更し、Pod の退避率を低下させます。小規模なクラスター (デフォルトでは 50 ノード以下) がこの状態になると、このゾーンのノードは taint されず、退避が停止されます。

詳細は、Kubernetes ドキュメントの [Rate limits on eviction](#) を参照してください。

OpenShift Container Platform は、**node.kubernetes.io/not-ready** および **node.kubernetes.io/unreachable** の toleration を、**Pod** 設定がいずれかの toleration を指定しない限り、自動的に **tolerationSeconds=300** に追加します。

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
    - key: node.kubernetes.io/not-ready
      operator: Exists
      effect: NoExecute
      tolerationSeconds: 300 1
```

```
- key: node.kubernetes.io/unreachable
  operator: Exists
  effect: NoExecute
  tolerationSeconds: 300
#...
```

- 1 これらの toleration は、ノード状態の問題のいずれかが検出された後、デフォルトの Pod 動作のバインドを 5 分間維持できるようにします。

これらの toleration は必要に応じて設定できます。たとえば、アプリケーションに多数のローカル状態がある場合、ネットワークのパーティション化などに伴い、Pod をより長い時間ノードにバインドさせる必要があるかもしれません。これにより、パーティションを回復させることができ、Pod のエビクションを回避できます。

デーモンセットによって起動する Pod は、**tolerationSeconds** が指定されない以下の taint の **NoExecute** toleration を使用して作成されます。

- **node.kubernetes.io/unreachable**
- **node.kubernetes.io/not-ready**

その結果、デーモンセット Pod は、これらのノードの状態が原因で退避されることはありません。

4.6.1.5. すべての taint の許容

key と **values** のパラメーターを指定せずに **operator: "Exists"** toleration を追加することで、すべての taint を許容するように Pod を設定できます。この toleration のある Pod は taint を持つノードから削除されません。

すべての taint を容認するための Pod 仕様

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
    - operator: "Exists"
#...
```

4.6.2. taint および toleration の追加

toleration を Pod に、taint をノードに追加することで、ノードはノード上でスケジュールする必要のある (またはスケジュールすべきでない) Pod を制御できます。既存の Pod およびノードの場合、最初に toleration を Pod に追加してから taint をノードに追加して、toleration を追加する前に Pod がノードから削除されないようにする必要があります。

手順

1. Pod 仕様を **tolerations** スタンザを含めるように編集して、toleration を Pod に追加します。

Equal 演算子を含む Pod 設定ファイルのサンプル

■

```

apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
    - key: "key1" ❶
      value: "value1"
      operator: "Equal"
      effect: "NoExecute"
      tolerationSeconds: 3600 ❷
#...

```

- ❶ **taint および toleration コンポーネント** の表で説明されている toleration パラメーターです。
- ❷ **tolerationSeconds** パラメーターは、退避する前に Pod をどの程度の期間ノードにバインドさせるかを指定します。

以下に例を示します。

Exists 演算子を含む Pod 設定ファイルのサンプル

```

apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
    - key: "key1"
      operator: "Exists" ❶
      effect: "NoExecute"
      tolerationSeconds: 3600
#...

```

- ❶ **Exists** Operator は **value** を取りません。

この例では、taint を、キー **key1**、値 **value1**、および taint effect **NoExecute** を持つ **node1** に taint を配置します。

2. **taint および toleration コンポーネント** の表で説明されているパラメーターと共に以下のコマンドを使用して taint をノードに追加します。

```
$ oc adm taint nodes <node_name> <key>=<value>:<effect>
```

以下に例を示します。

```
$ oc adm taint nodes node1 key1=value1:NoExecute
```

このコマンドは、キー **key1**、値 **value1**、および effect **NoExecute** を持つ taint を **node1** に配置します。

注記

NoSchedule taint をコントロールプレーンノードに追加すると、ノードには、デフォルトで追加される **node-role.kubernetes.io/master=:NoSchedule** taint が必要です。

以下に例を示します。

```
apiVersion: v1
kind: Node
metadata:
  annotations:
    machine.openshift.io/machine: openshift-machine-api/ci-ln-62s7gtb-f76d1-
v8jxv-master-0
    machineconfiguration.openshift.io/currentConfig: rendered-master-
cdc1ab7da414629332cc4c3926e6e59c
    name: my-node
  #...
spec:
  taints:
    - effect: NoSchedule
      key: node-role.kubernetes.io/master
  #...
```

Pod の toleration はノードの taint に一致します。いずれかの toleration のある Pod は **node1** にスケジュールできます。

4.6.2.1. コンピュートマシンセットを使用した taint および toleration の追加

コンピュートマシンセットを使用して taint をノードに追加できます。**MachineSet** オブジェクトに関連付けられるすべてのノードが taint で更新されます。toleration は、ノードに直接追加された taint と同様に、コンピュートマシンセットによって追加される taint に応答します。

手順

1. **Pod** 仕様を **tolerations** スタンザを含めるように編集して、toleration を Pod に追加します。

Equal 演算子を含む Pod 設定ファイルのサンプル

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
  #...
spec:
  tolerations:
    - key: "key1" ❶
      value: "value1"
      operator: "Equal"
      effect: "NoExecute"
      tolerationSeconds: 3600 ❷
```

#...

- 1 **taint** および **toleration** コンポーネント の表で説明されている **toleration** パラメーターです。
- 2 **tolerationSeconds** パラメーターは、退避する前に Pod をどの程度の期間ノードにバインドさせるかを指定します。

以下に例を示します。

Exists 演算子を含む Pod 設定ファイルのサンプル

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
  - key: "key1"
    operator: "Exists"
    effect: "NoExecute"
    tolerationSeconds: 3600
#...
```

2. taint を **MachineSet** オブジェクトに追加します。
 - a. taint を付けるノードの **MachineSet** YAML を編集するか、新規 **MachineSet** オブジェクトを作成できます。

```
$ oc edit machineset <machineset>
```

- b. taint を **spec.template.spec** セクションに追加します。

コンピュートマシンセット仕様の taint の例

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
  name: my-machineset
#...
spec:
#...
  template:
#...
    spec:
      taints:
      - effect: NoExecute
        key: key1
        value: value1
#...
```

この例では、キー **key1**、値 **value1**、および taint effect **NoExecute** を持つ taint をノードに配置します。

- c. コンピュートマシンセットを 0 にスケールダウンします。

```
$ oc scale --replicas=0 machineset <machineset> -n openshift-machine-api
```

ヒント

または、以下の YAML を適用してコンピュートマシンセットをスケーリングすることもできます。

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
  name: <machineset>
  namespace: openshift-machine-api
spec:
  replicas: 0
```

マシンが削除されるまで待機します。

- d. コンピュートマシンセットを随時スケールアップします。

```
$ oc scale --replicas=2 machineset <machineset> -n openshift-machine-api
```

または、以下を実行します。

```
$ oc edit machineset <machineset> -n openshift-machine-api
```

マシンが起動するまで待ちます。taint は **MachineSet** オブジェクトに関連付けられたノードに追加されます。

4.6.2.2. taint および toleration 使用してユーザーをノードにバインドする

ノードのセットを特定のユーザーセットによる排他的な使用のために割り当てる必要がある場合、toleration をそれらの Pod に追加します。次に、対応する taint をそれらのノードに追加します。toleration が設定された Pod は、taint が付けられたノードまたはクラスター内の他のノードを使用できます。

Pod が taint が付けられたノードのみにスケジュールされるようにするには、ラベルを同じノードセットに追加し、ノードのアフィニティを Pod に追加し、Pod がそのラベルの付いたノードのみにスケジュールできるようにします。

手順

ノードをユーザーの使用可能な唯一のノードとして設定するには、以下を実行します。

1. 対応する taint をそれらのノードに追加します。
以下に例を示します。

```
$ oc adm taint nodes node1 dedicated=groupName:NoSchedule
```

ヒント

または、以下の YAML を適用して taint を追加できます。

```
kind: Node
apiVersion: v1
metadata:
  name: my-node
#...
spec:
  taints:
    - key: dedicated
      value: groupName
      effect: NoSchedule
#...
```

2. カスタムアドミッションコントローラーを作成して toleration を Pod に追加します。

4.6.2.3. ノードセクターおよび toleration を使用したプロジェクトの作成

ノードセクターおよび toleration (アノテーションとして設定されたもの) を使用するプロジェクトを作成して、Pod の特定のノードへの配置を制御できます。プロジェクトで作成された後続のリソースは、toleration に一致する taint を持つノードでスケジュールされます。

前提条件

- コンピュートマシンセットを使用するか、ノードを直接編集して、ノード選択のラベルが1つ以上のノードに追加されている。
- コンピュートマシンセットを使用するか、ノードを直接編集することによって、taint が1つ以上のノードに追加されました。

手順

1. **metadata.annotations** セクションにノードセクターおよび toleration を指定して、**Project** リソース定義を作成します。

project.yaml ファイルの例

```
kind: Project
apiVersion: project.openshift.io/v1
metadata:
  name: <project_name> ❶
  annotations:
    openshift.io/node-selector: '<label>' ❷
    scheduler.alpha.kubernetes.io/defaultTolerations: >-
      [{"operator": "Exists", "effect": "NoSchedule", "key":
        "<key_name>"}] ❸
    ]
```

- ❶ プロジェクト名。
- ❷ デフォルトのノードセクターラベル。

- 3 taint および toleration コンポーネントの表で説明されている toleration パラメーターです。この例では、**NoSchedule** の effect を使用します。これにより、ノード上の既存の

2. **oc apply** コマンドを使用してプロジェクトを作成します。

```
$ oc apply -f project.yaml
```

<project_name> namespace で作成された後続のリソースは指定されたノードにスケジュールされます。

関連情報

- [ノードに手動で、または コンピュートマシンセットを使用して taint と toleration を追加する](#)
- [プロジェクトスコープのノードセクターの作成](#)
- [Operator ワークロードの Pod の配置](#)

4.6.2.4. taint および toleration を使用して特殊ハードウェアを持つノードを制御する

ノードの小規模なサブセットが特殊ハードウェアを持つクラスターでは、taint および toleration を使用して、特殊ハードウェアを必要としない Pod をそれらのノードから切り離し、特殊ハードウェアを必要とする Pod をそのままにすることができます。また、特殊ハードウェアを必要とする Pod に対して特定のノードを使用することを要求することもできます。

これは、特殊ハードウェアを必要とする Pod に toleration を追加し、特殊ハードウェアを持つノードに taint を付けることで実行できます。

手順

特殊ハードウェアを持つノードが特定の Pod 用に予約されるようにするには、以下を実行します。

1. toleration を特別なハードウェアを必要とする Pod に追加します。
以下に例を示します。

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
    - key: "disktype"
      value: "ssd"
      operator: "Equal"
      effect: "NoSchedule"
      tolerationSeconds: 3600
#...
```

2. 以下のコマンドのいずれかを使用して、特殊ハードウェアを持つノードに taint を設定します。

```
$ oc adm taint nodes <node-name> disktype=ssd:NoSchedule
```

または、以下を実行します。

```
$ oc adm taint nodes <node-name> disktype=ssd:PreferNoSchedule
```

ヒント

または、以下の YAML を適用して taint を追加できます。

```
kind: Node
apiVersion: v1
metadata:
  name: my_node
#...
spec:
  taints:
    - key: disktype
      value: ssd
      effect: PreferNoSchedule
#...
```

4.6.3. taint および toleration の削除

必要に応じてノードから taint を、Pod から toleration をそれぞれ削除できます。最初に toleration を Pod に追加してから taint をノードに追加して、toleration を追加する前に Pod がノードから削除されないようにする必要があります。

手順

taint および toleration を削除するには、以下を実行します。

1. ノードから taint を削除するには、以下を実行します。

```
$ oc adm taint nodes <node-name> <key>-
```

以下に例を示します。

```
$ oc adm taint nodes ip-10-0-132-248.ec2.internal key1-
```

出力例

```
node/ip-10-0-132-248.ec2.internal untainted
```

2. Pod から toleration を削除するには、toleration を削除するための **Pod** 仕様を編集します。

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
#...
spec:
  tolerations:
    - key: "key2"
      operator: "Exists"
```

```
effect: "NoExecute"
tolerationSeconds: 3600
#...
```

4.7. ノードセクターの使用による特定ノードへの POD の配置

ノードセクターは、ノードのカスタムラベルと Pod で指定されるセクターを使用して定義されるキー/値のペアのマップを指定します。

Pod がノードで実行する要件を満たすには、Pod にはノードのラベルと同じキー/値のペアがなければなりません。

4.7.1. ノードセクターについて

Pod でノードセクターを使用し、ノードでラベルを使用して、Pod がスケジュールされる場所を制御できます。ノードセクターにより、OpenShift Container Platform は一致するラベルが含まれるノード上に Pod をスケジュールします。

ノードセクターを使用して特定の Pod を特定のノードに配置し、クラスタースコープのノードセクターを使用して特定ノードの新規 Pod をクラスター内の任意の場所に配置し、プロジェクトノードを使用して新規 Pod を特定ノードのプロジェクトに配置できます。

たとえば、クラスター管理者は、作成するすべての Pod にノードセクターを追加して、アプリケーション開発者が地理的に最も近い場所にあるノードにのみ Pod をデプロイできるインフラストラクチャーを作成できます。この例では、クラスターは2つのリージョンに分散する5つのデータセンターで構成されます。米国では、ノードに **us-east**、**us-central**、または **us-west** のラベルを付けます。アジア太平洋リージョン (APAC) では、ノードに **apac-east** または **apac-west** のラベルを付けます。開発者は、Pod がこれらのノードにスケジュールされるように、作成する Pod にノードセクターを追加できます。

Pod オブジェクトにノードセクターが含まれる場合でも、一致するラベルを持つノードがない場合、Pod はスケジュールされません。

重要

同じ Pod 設定でノードセクターとノードのアフィニティを使用している場合は、以下のルールが Pod のノードへの配置を制御します。

- **nodeSelector** と **nodeAffinity** の両方を設定する場合、Pod が候補ノードでスケジュールされるにはどちらの条件も満たしている必要があります。
- **nodeAffinity** タイプに関連付けられた複数の **nodeSelectorTerms** を指定する場合、**nodeSelectorTerms** のいずれかが満たされている場合に Pod をノードにスケジュールすることができます。
- **nodeSelectorTerms** に関連付けられた複数の **matchExpressions** を指定する場合、すべての **matchExpressions** が満たされている場合にのみ Pod をノードにスケジュールすることができます。

特定の Pod およびノードのノードセクター

ノードセクターおよびラベルを使用して、特定の Pod がスケジュールされるノードを制御できます。

ノードセクターおよびラベルを使用するには、まずノードにラベルを付けて Pod がスケジュール解除されないようにしてから、ノードセクターを Pod に追加します。



注記

ノードセクターを既存のスケジュールされている Pod に直接追加することはできません。デプロイメント設定などの Pod を制御するオブジェクトにラベルを付ける必要があります。

たとえば、以下の **Node** オブジェクトには **region: east** ラベルがあります。

ラベルを含む Node オブジェクトのサンプル

```
kind: Node
apiVersion: v1
metadata:
  name: ip-10-0-131-14.ec2.internal
  selfLink: /api/v1/nodes/ip-10-0-131-14.ec2.internal
  uid: 7bc2580a-8b8e-11e9-8e01-021ab4174c74
  resourceVersion: '478704'
  creationTimestamp: '2019-06-10T14:46:08Z'
  labels:
    kubernetes.io/os: linux
    failure-domain.beta.kubernetes.io/zone: us-east-1a
    node.openshift.io/os_version: '4.5'
    node-role.kubernetes.io/worker: "
    failure-domain.beta.kubernetes.io/region: us-east-1
    node.openshift.io/os_id: rhcos
    beta.kubernetes.io/instance-type: m4.large
    kubernetes.io/hostname: ip-10-0-131-14
    beta.kubernetes.io/arch: amd64
    region: east ❶
    type: user-node
#...
```

❶ Pod ノードセクターに一致するラベル。

Pod には **type: user-node, region: east** ノードセクターがあります。

ノードセクターが含まれる Pod オブジェクトのサンプル

```
apiVersion: v1
kind: Pod
metadata:
  name: s1
#...
spec:
  nodeSelector: ❶
    region: east
    type: user-node
#...
```

❶ ノードトラベルに一致するノードセクター。ノードには、各ノードセクターのラベルが必要です。

サンプル Pod 仕様を使用して Pod を作成する場合、これはサンプルノードでスケジュールできます。

クラスタースコープのデフォルトノードセクター

デフォルトのクラスタースコープのノードセクターを使用する場合、クラスターで Pod を作成すると、OpenShift Container Platform はデフォルトのノードセクターを Pod に追加し、一致するラベルのあるノードで Pod をスケジュールします。

たとえば、以下の **Scheduler** オブジェクトにはデフォルトのクラスタースコープの **region=east** および **type=user-node** ノードセクターがあります。

スケジューラー Operator カスタムリソースの例

```
apiVersion: config.openshift.io/v1
kind: Scheduler
metadata:
  name: cluster
#...
spec:
  defaultNodeSelector: type=user-node,region=east
#...
```

クラスター内のノードには **type=user-node,region=east** ラベルがあります。

Node オブジェクトの例

```
apiVersion: v1
kind: Node
metadata:
  name: ci-ln-qg1il3k-f76d1-hlmhl-worker-b-df2s4
#...
labels:
  region: east
  type: user-node
#...
```

ノードセクターを持つ Pod オブジェクトの例

```
apiVersion: v1
kind: Pod
metadata:
  name: s1
#...
spec:
  nodeSelector:
    region: east
#...
```

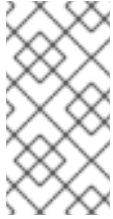
サンプルクラスターでサンプル Pod 仕様を使用して Pod を作成する場合、Pod はクラスタースコープのノードセクターで作成され、ラベルが付けられたノードにスケジュールされます。

ラベルが付けられたノード上の Pod を含む Pod リストの例

NAME	READY	STATUS	RESTARTS	AGE	IP	NODE
------	-------	--------	----------	-----	----	------

NOMINATED NODE READINESS GATES

```
pod-s1 1/1 Running 0 20s 10.131.2.6 ci-ln-qg1il3k-f76d1-hlmhl-worker-b-df2s4
<none> <none>
```

**注記**

Pod を作成するプロジェクトにプロジェクトノードセクターがある場合、そのセクターはクラスタースコープのセクターよりも優先されます。Pod にプロジェクトノードセクターがない場合、Pod は作成されたり、スケジュールされたりしません。

プロジェクトノードセクター

プロジェクトノードセクターを使用する場合、このプロジェクトで Pod を作成すると、OpenShift Container Platform はノードセクターを Pod に追加し、Pod を一致するラベルを持つノードでスケジュールします。クラスタースコープのデフォルトノードセクターがない場合、プロジェクトノードセクターが優先されます。

たとえば、以下のプロジェクトには **region=east** ノードセクターがあります。

Namespace オブジェクトの例

```
apiVersion: v1
kind: Namespace
metadata:
  name: east-region
  annotations:
    openshift.io/node-selector: "region=east"
#...
```

以下のノードには **type=user-node,region=east** ラベルがあります。

Node オブジェクトの例

```
apiVersion: v1
kind: Node
metadata:
  name: ci-ln-qg1il3k-f76d1-hlmhl-worker-b-df2s4
#...
labels:
  region: east
  type: user-node
#...
```

Pod をこのサンプルプロジェクトでサンプル Pod 仕様を使用して作成する場合、Pod はプロジェクトノードセクターで作成され、ラベルが付けられたノードにスケジュールされます。

Pod オブジェクトの例

```
apiVersion: v1
kind: Pod
metadata:
  namespace: east-region
#...
```

```
spec:
  nodeSelector:
    region: east
    type: user-node
#...
```

ラベルが付けられたノード上の Pod を含む Pod リストの例

```
NAME      READY   STATUS    RESTARTS   AGE   IP            NODE
NOMINATED NODE READINESS GATES
pod-s1    1/1     Running   0           20s   10.131.2.6    ci-ln-qg1il3k-f76d1-hlmhl-worker-b-df2s4
<none>    <none>
```

Pod に異なるノードセクターが含まれる場合、プロジェクトの Pod は作成またはスケジュールされません。たとえば、以下の Pod をサンプルプロジェクトにデプロイする場合、これは作成されません。

無効なノードセクターを持つ Pod オブジェクトの例

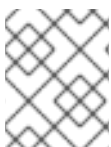
```
apiVersion: v1
kind: Pod
metadata:
  name: west-region
#...
spec:
  nodeSelector:
    region: west
#...
```

4.7.2. ノードセクターの使用による Pod 配置の制御

Pod でノードセクターを使用し、ノードでラベルを使用して、Pod がスケジュールされる場所を制御できます。ノードセクターにより、OpenShift Container Platform は一致するラベルが含まれるノード上に Pod をスケジュールします。

ラベルをノード、コンピュータマシンセット、またはマシン設定に追加します。コンピュータマシンセットにラベルを追加すると、ノードまたはマシンが停止した場合に、新規ノードにそのラベルが追加されます。ノードまたはマシン設定に追加されるラベルは、ノードまたはマシンが停止すると維持されません。

ノードセクターを既存 Pod に追加するには、ノードセクターを **ReplicaSet** オブジェクト、**DaemonSet** オブジェクト、**StatefulSet** オブジェクト、**Deployment** オブジェクト、または **DeploymentConfig** オブジェクトなどの Pod の制御オブジェクトに追加します。制御オブジェクト下の既存 Pod は、一致するラベルを持つノードで再作成されます。新規 Pod を作成する場合、ノードセクターを Pod 仕様に直接追加できます。Pod に制御オブジェクトがない場合は、Pod を削除し、Pod 仕様を編集して、Pod を再作成する必要があります。



注記

ノードセクターを既存のスケジュールされている Pod に直接追加することはできません。

前提条件

ノードセクターを既存 Pod に追加するには、Pod の制御オブジェクトを判別します。たとえば、**router-default-66d5cf9464-m2g75** Pod は **router-default-66d5cf9464** レプリカセットによって制御されます。

```
$ oc describe pod router-default-66d5cf9464-7pwkc
```

出力例

```
kind: Pod
apiVersion: v1
metadata:
#...
Name:          router-default-66d5cf9464-7pwkc
Namespace:     openshift-ingress
# ...
Controlled By: ReplicaSet/router-default-66d5cf9464
# ...
```

Web コンソールでは、Pod YAML の **ownerReferences** に制御オブジェクトをリスト表示します。

```
apiVersion: v1
kind: Pod
metadata:
  name: router-default-66d5cf9464-7pwkc
# ...
ownerReferences:
- apiVersion: apps/v1
  kind: ReplicaSet
  name: router-default-66d5cf9464
  uid: d81dd094-da26-11e9-a48a-128e7edf0312
  controller: true
  blockOwnerDeletion: true
# ...
```

手順

1. コンピュータマシンセットを使用するか、ノードを直接編集してラベルをノードに追加します。
 - **MachineSet** オブジェクトを使用して、ノードの作成時にコンピュータマシンセットによって管理されるノードにラベルを追加します。
 - a. 以下のコマンドを実行してラベルを **MachineSet** オブジェクトに追加します。

```
$ oc patch MachineSet <name> --type='json' -
p='[{"op": "add", "path": "/spec/template/spec/metadata/labels", "value": {"<key>": "<value>", "<key>": "<value>"}}]' -n openshift-machine-api
```

以下に例を示します。

```
$ oc patch MachineSet abc612-msrtw-worker-us-east-1c --type=json -
p='[{"op":"add","path":"/spec/template/spec/metadata/labels", "value":{"type":"user-
node","region":"east"}}]' -n openshift-machine-api
```

ヒント

あるいは、以下の YAML を適用してコンピュートマシンセットにラベルを追加することもできます。

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
  name: xf2bd-infra-us-east-2a
  namespace: openshift-machine-api
spec:
  template:
    spec:
      metadata:
        labels:
          region: "east"
          type: "user-node"
#...
```

- b. **oc edit** コマンドを使用して、ラベルが **MachineSet** オブジェクトに追加されていることを確認します。
以下に例を示します。

```
$ oc edit MachineSet abc612-msrtw-worker-us-east-1c -n openshift-machine-api
```

MachineSet オブジェクトの例

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet

# ...

spec:
# ...
  template:
    metadata:
# ...
      spec:
        metadata:
          labels:
            region: east
            type: user-node
# ...
```

- ラベルをノードに直接追加します。
 - a. ノードの **Node** オブジェクトを編集します。

```
$ oc label nodes <name> <key>=<value>
```

■

たとえば、ノードにラベルを付けるには、以下を実行します。

```
$ oc label nodes ip-10-0-142-25.ec2.internal type=user-node region=east
```

ヒント

あるいは、以下の YAML を適用してノードにラベルを追加することもできます。

```
kind: Node
apiVersion: v1
metadata:
  name: hello-node-6fbccf8d9
labels:
  type: "user-node"
  region: "east"
#...
```

b. ラベルがノードに追加されていることを確認します。

```
$ oc get nodes -l type=user-node,region=east
```

出力例

```
NAME                                STATUS ROLES  AGE  VERSION
ip-10-0-142-25.ec2.internal Ready  worker  17m  v1.25.0
```

2. 一致するノードセクターを Pod に追加します。

- ノードセクターを既存 Pod および新規 Pod に追加するには、ノードセクターを Pod の制御オブジェクトに追加します。

ラベルを含む ReplicaSet オブジェクトのサンプル

```
kind: ReplicaSet
apiVersion: apps/v1
metadata:
  name: hello-node-6fbccf8d9
# ...
spec:
# ...
template:
  metadata:
    creationTimestamp: null
  labels:
    ingresscontroller.operator.openshift.io/deployment-ingresscontroller: default
    pod-template-hash: 66d5cf9464
  spec:
    nodeSelector:
      kubernetes.io/os: linux
      node-role.kubernetes.io/worker: "
      type: user-node ❶
#...
```

■

1 ノードセクターを追加します。

- ノードセクターを特定の新規 Pod に追加するには、セクターを **Pod** オブジェクトに直接追加します。

ノードセクターを持つ Pod オブジェクトの例

```
apiVersion: v1
kind: Pod
metadata:
  name: hello-node-6fbccf8d9
#...
spec:
  nodeSelector:
    region: east
    type: user-node
#...
```



注記

ノードセクターを既存のスケジュールされている Pod に直接追加することはできません。

4.7.3. クラスタスコープのデフォルトノードセクターの作成

クラスター内の作成されたすべての Pod を特定のノードに制限するために、デフォルトのクラスタスコープのノードセクターをノード上のラベルと共に Pod で使用することができます。

クラスタスコープのノードセクターを使用する場合、クラスターで Pod を作成すると、OpenShift Container Platform はデフォルトのノードセクターを Pod に追加し、一致するラベルのあるノードで Pod をスケジュールします。

スケジューラー Operator カスタムリソース (CR) を編集して、クラスタスコープのノードセクターを設定します。ラベルをノード、コンピュートマシンセット、またはマシン設定に追加します。コンピュートマシンセットにラベルを追加すると、ノードまたはマシンが停止した場合に、新規ノードにそのラベルが追加されます。ノードまたはマシン設定に追加されるラベルは、ノードまたはマシンが停止すると維持されません。



注記

Pod にキーと値のペアを追加できます。ただし、デフォルトキーの異なる値を追加することはできません。

手順

デフォルトのクラスタスコープのセクターを追加するには、以下を実行します。

- スケジューラー Operator CR を編集して、デフォルトのクラスタスコープのノードクラスターを追加します。

```
$ oc edit scheduler cluster
```

ノードセクターを含むスケジューラー Operator CR のサンプル

```

apiVersion: config.openshift.io/v1
kind: Scheduler
metadata:
  name: cluster
...
spec:
  defaultNodeSelector: type=user-node,region=east ❶
  mastersSchedulable: false

```

- ❶ 適切な **<key>:<value>** ペアが設定されたノードセクターを追加します。

この変更を加えた後に、**openshift-kube-apiserver** プロジェクトの Pod の再デプロイを待機します。これには数分の時間がかかる場合があります。デフォルトのクラスター全体のノードセクターは、Pod の再起動まで有効になりません。

2. コンピュートマシンセットを使用するか、ノードを直接編集してラベルをノードに追加します。
 - コンピュートマシンセットを使用して、ノードの作成時にコンピュートマシンセットによって管理されるノードにラベルを追加します。
 - a. 以下のコマンドを実行してラベルを **MachineSet** オブジェクトに追加します。

```

$ oc patch MachineSet <name> --type='json' -
p=[{"op":"add","path":"/spec/template/spec/metadata/labels", "value":{"<key>="
<value>","<key>="<value>"}]}] -n openshift-machine-api ❶

```

- ❶ それぞれのラベルに **<key>/<value>** ペアを追加します。

以下に例を示します。

```

$ oc patch MachineSet ci-ln-l8nry52-f76d1-hl7m7-worker-c --type='json' -
p=[{"op":"add","path":"/spec/template/spec/metadata/labels", "value":{"type":"user-
node","region":"east"}}] -n openshift-machine-api

```

ヒント

あるいは、以下の YAML を適用してコンピュートマシンセットにラベルを追加することもできます。

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
  name: <machineset>
  namespace: openshift-machine-api
spec:
  template:
    spec:
      metadata:
        labels:
          region: "east"
          type: "user-node"
```

- b. **oc edit** コマンドを使用して、ラベルが **MachineSet** オブジェクトに追加されていることを確認します。
以下に例を示します。

```
$ oc edit MachineSet abc612-msrtw-worker-us-east-1c -n openshift-machine-api
```

MachineSet オブジェクトの例

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
...
spec:
  ...
  template:
    metadata:
    ...
    spec:
      metadata:
        labels:
          region: east
          type: user-node
  ...
```

- c. **0** にスケールダウンし、ノードをスケールアップして、そのコンピュートマシンセットに関連付けられたノードを再デプロイします。
以下に例を示します。

```
$ oc scale --replicas=0 MachineSet ci-ln-l8nry52-f76d1-hl7m7-worker-c -n openshift-machine-api
```

```
$ oc scale --replicas=1 MachineSet ci-ln-l8nry52-f76d1-hl7m7-worker-c -n openshift-machine-api
```

- d. ノードの準備ができ、利用可能な状態になったら、**oc get** コマンドを使用してラベルがノードに追加されていることを確認します。

```
$ oc get nodes -l <key>=<value>
```

以下に例を示します。

```
$ oc get nodes -l type=user-node
```

出力例

```
NAME                                STATUS ROLES  AGE  VERSION
ci-ln-l8nry52-f76d1-hl7m7-worker-c-vmqzp Ready  worker  61s  v1.25.0
```

- ラベルをノードに直接追加します。
 - a. ノードの **Node** オブジェクトを編集します。

```
$ oc label nodes <name> <key>=<value>
```

たとえば、ノードにラベルを付けるには、以下を実行します。

```
$ oc label nodes ci-ln-l8nry52-f76d1-hl7m7-worker-b-tgq49 type=user-node
region=east
```

ヒント

あるいは、以下の YAML を適用してノードにラベルを追加することもできます。

```
kind: Node
apiVersion: v1
metadata:
  name: <node_name>
labels:
  type: "user-node"
  region: "east"
```

- b. **oc get** コマンドを使用して、ラベルがノードに追加されていることを確認します。

```
$ oc get nodes -l <key>=<value>,<key>=<value>
```

以下に例を示します。

```
$ oc get nodes -l type=user-node,region=east
```

出力例

```
NAME                                STATUS ROLES  AGE  VERSION
ci-ln-l8nry52-f76d1-hl7m7-worker-b-tgq49 Ready  worker  17m  v1.25.0
```

4.7.4. プロジェクトスコープのノードセクターの作成

プロジェクトで作成されたすべての Pod をラベルが付けられたノードに制限するために、プロジェクトのノードセクターをノード上のラベルと共に使用できます。

このプロジェクトで Pod を作成する場合、OpenShift Container Platform はノードセクターをプロジェクトの Pod に追加し、プロジェクトの一致するラベルを持つノードで Pod をスケジュールします。クラスタースコープのデフォルトノードセクターがない場合、プロジェクトノードセクターが優先されます。

You add node selectors to a project by editing the **Namespace** object to add the **openshift.io/node-selector** parameter. ラベルをノード、コンピュータマシンセット、またはマシン設定に追加します。コンピュータマシンセットにラベルを追加すると、ノードまたはマシンが停止した場合に、新規ノードにそのラベルが追加されます。ノードまたはマシン設定に追加されるラベルは、ノードまたはマシンが停止すると維持されません。

Pod オブジェクトにノードセクターが含まれる場合でも、一致するノードセクターを持つプロジェクトがない場合、Pod はスケジュールされません。その仕様から Pod を作成すると、以下のメッセージと同様のエラーが表示されます。

エラーメッセージの例

Error from server (Forbidden): error when creating "pod.yaml": pods "pod-4" is forbidden: pod node label selector conflicts with its project node label selector



注記

Pod にキーと値のペアを追加できます。ただし、プロジェクトキーに異なる値を追加することはできません。

手順

デフォルトのプロジェクトノードセクターを追加するには、以下を実行します。

1. namespace を作成するか、既存の namespace を編集して **openshift.io/node-selector** パラメーターを追加します。

```
$ oc edit namespace <name>
```

出力例

```
apiVersion: v1
kind: Namespace
metadata:
  annotations:
    openshift.io/node-selector: "type=user-node,region=east" ❶
    openshift.io/description: ""
    openshift.io/display-name: ""
    openshift.io/requester: kube:admin
    openshift.io/sa.scc.mcs: s0:c30,c5
    openshift.io/sa.scc.supplemental-groups: 1000880000/10000
    openshift.io/sa.scc.uid-range: 1000880000/10000
  creationTimestamp: "2021-05-10T12:35:04Z"
  labels:
```

```
kubernetes.io/metadata.name: demo
name: demo
resourceVersion: "145537"
uid: 3f8786e3-1fcb-42e3-a0e3-e2ac54d15001
spec:
  finalizers:
  - kubernetes
```

- 1 適切な **<key>:<value>** ペアを持つ **openshift.io/node-selector** を追加します。

2. コンピュートマシンセットを使用するか、ノードを直接編集してラベルをノードに追加します。

- **MachineSet** オブジェクトを使用して、ノードの作成時にコンピュートマシンセットによって管理されるノードにラベルを追加します。

- a. 以下のコマンドを実行してラベルを **MachineSet** オブジェクトに追加します。

```
$ oc patch MachineSet <name> --type='json' -
p='[{"op": "add", "path": "/spec/template/spec/metadata/labels", "value": {"<key>": "<value>", "<key>": "<value>"}}]' -n openshift-machine-api
```

以下に例を示します。

```
$ oc patch MachineSet ci-ln-l8nry52-f76d1-hl7m7-worker-c --type='json' -
p='[{"op": "add", "path": "/spec/template/spec/metadata/labels", "value": {"type": "user-node", "region": "east"}}]' -n openshift-machine-api
```

ヒント

あるいは、以下の YAML を適用してコンピュートマシンセットにラベルを追加することもできます。

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
  name: <machineset>
  namespace: openshift-machine-api
spec:
  template:
    spec:
      metadata:
        labels:
          region: "east"
          type: "user-node"
```

- b. **oc edit** コマンドを使用して、ラベルが **MachineSet** オブジェクトに追加されていることを確認します。
以下に例を示します。

```
$ oc edit MachineSet ci-ln-l8nry52-f76d1-hl7m7-worker-c -n openshift-machine-api
```

出力例

```

apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
...
spec:
...
  template:
    metadata:
...
    spec:
      metadata:
        labels:
          region: east
          type: user-node

```

- c. そのコンピュータマシンセットに関連付けられているノードを再デプロイします。
以下に例を示します。

```
$ oc scale --replicas=0 MachineSet ci-ln-l8nry52-f76d1-hl7m7-worker-c -n openshift-machine-api
```

```
$ oc scale --replicas=1 MachineSet ci-ln-l8nry52-f76d1-hl7m7-worker-c -n openshift-machine-api
```

- d. ノードの準備ができ、利用可能な状態になったら、**oc get** コマンドを使用してラベルがノードに追加されていることを確認します。

```
$ oc get nodes -l <key>=<value>
```

以下に例を示します。

```
$ oc get nodes -l type=user-node,region=east
```

出力例

```

NAME                                STATUS ROLES  AGE  VERSION
ci-ln-l8nry52-f76d1-hl7m7-worker-c-vmqzp Ready  worker  61s  v1.25.0

```

- ラベルをノードに直接追加します。
 - a. **Node** オブジェクトを編集してラベルを追加します。

```
$ oc label <resource> <name> <key>=<value>
```

たとえば、ノードにラベルを付けるには、以下を実行します。

```
$ oc label nodes ci-ln-l8nry52-f76d1-hl7m7-worker-c-tgq49 type=user-node region=east
```

ヒント

あるいは、以下の YAML を適用してノードにラベルを追加することもできます。

```
kind: Node
apiVersion: v1
metadata:
  name: <node_name>
labels:
  type: "user-node"
  region: "east"
```

- b. **oc get** コマンドを使用して、ラベルが **Node** オブジェクトに追加されていることを確認します。

```
$ oc get nodes -l <key>=<value>
```

以下に例を示します。

```
$ oc get nodes -l type=user-node,region=east
```

出力例

NAME	STATUS	ROLES	AGE	VERSION
ci-ln-l8nry52-f76d1-hl7m7-worker-b-tgq49	Ready	worker	17m	v1.25.0

関連情報

- [ノードセレクターおよび toleration を使用したプロジェクトの作成](#)

4.8. POD トポロジー分散制約を使用した POD 配置の制御

Pod トポロジーの分散制約を使用すると、ノード、ゾーン、リージョン、またはその他のユーザー定義のトポロジードメイン全体にわたる Pod の配置を詳細に制御できます。障害ドメイン全体に Pod を分散すると、高可用性とより効率的なリソース利用を実現できます。

4.8.1. 使用例

- 管理者として、ワークロードを 2 個から 15 個の Pod 間で自動的にスケーリングしたいと考えています。Pod が 2 つしかない場合は、単一障害点を回避するために、Pod が同じノードに配置されないようにする必要があります。
- 管理者として、レイテンシーとネットワークコストを削減するために、Pod を複数のインフラストラクチャーゾーンに均等に分散し、問題が発生した場合にクラスターが自己修復できることを確認したいと考えています。

4.8.2. 重要な留意事項

- OpenShift Container Platform クラスター内の Pod は、デプロイメント、ステートフルセット、デーモンセットなどの **ワークロードコントローラー** によって管理されます。これらのコントローラーは、クラスター内のノード間で Pod がどのように分散およびスケーリングされるかなど、Pod のグループの望ましい状態を定義します。混乱を避けるために、グループ内のすべ

ての Pod に同じ Pod トポロジーの分散制約を設定する必要があります。デプロイメントなどのワークロードコントローラーを使用する場合、通常は Pod テンプレートがこれを処理します。

- 異なる Pod トポロジーの分散制約を混在させると、OpenShift Container Platform の動作が混同され、トラブルシューティングが困難になる可能性があります。トポロジードメイン内のすべてのノードに一貫したラベルが付けられていることを確認することで、これを回避できます。OpenShift Container Platform は、**kubernetes.io/hostname** などのよく知られたラベルを自動的に入力します。これにより、ノードに手動でラベルを付ける必要がなくなります。これらのラベルは重要なトポロジー情報を提供し、クラスター全体で一貫したノードラベル付けを保証します。
- 制約により、分散される際に同じ namespace 内の Pod のみが一致し、グループ化されます。
- 複数の Pod トポロジー分散制約を指定できますが、それらが互いに競合しないようにする必要があります。Pod を配置するには、すべての Pod トポロジー分散制約を満たしている必要があります。

4.8.3. skew と maxSkew

スキューとは、ゾーンやノードなどの異なるトポロジードメイン間で指定されたラベルセクターに一致する Pod の数の差を指します。

スキューは、各ドメイン内の Pod の数と、スケジュールされている Pod の数が最も少ないドメイン内の Pod 数との絶対差をとることで、各ドメインごとに計算されます。**maxSkew** 値を設定すると、スケジューラーはバランスの取れた Pod 分散を維持するようになります。

4.8.3.1. スキューの計算例

3つのゾーン (A、B、C) があり、これらのゾーンに Pod を均等に分散したいと考えています。ゾーン A に Pod が 5 個、ゾーン B に Pod が 3 個、ゾーン C に Pod が 2 個ある場合、偏りを見つけるには、各ゾーンに現在ある Pod の数から、スケジュールされている Pod の数が最も少ないドメインの Pod の数を減算します。つまり、ゾーン A のスキューは 3、ゾーン B のスキューは 1、ゾーン C のスキューは 0 です。

4.8.3.2. maxSkew パラメーター

maxSkew パラメーターは、任意の 2 つのトポロジードメイン間の Pod 数の最大許容差、つまりスキューを定義します。**maxSkew** が 1 に設定されている場合、トポロジードメイン内の Pod の数は、他のドメインとの差が 1 を超えてはなりません。スキューが **maxSkew** を超える場合、スケジューラーは制約に従ってスキューを減らす方法で新しい Pod を配置しようとします。

前のスキュー計算例を使用すると、スキュー値はデフォルトの **maxSkew** 値 1 を超えます。スケジューラーは、スキューを減らして、負荷がバランスよく分散されるように、ゾーン B とゾーン C に新しい Pod を配置し、トポロジードメインがスキュー 1 を超えないようにします。

4.8.4. Pod トポロジー分散制約の設定例

グループ化する Pod を指定し、それらの Pod が分散されるトポロジードメインと、許可できるスキューを指定します。

以下の例は、Pod トポロジー設定分散制約の設定を示しています。

指定されたラベルに一致する Pod をゾーンに基づいて分散する例

■

```

apiVersion: v1
kind: Pod
metadata:
  name: my-pod
  labels:
    region: us-east
spec:
  securityContext:
    runAsNonRoot: true
    seccompProfile:
      type: RuntimeDefault
  topologySpreadConstraints:
  - maxSkew: 1 ❶
    topologyKey: topology.kubernetes.io/zone ❷
    whenUnsatisfiable: DoNotSchedule ❸
    labelSelector: ❹
      matchLabels:
        region: us-east ❺
      matchLabelKeys:
      - my-pod-label ❻
  containers:
  - image: "docker.io/ocpqe/hello-pod"
    name: hello-pod
    securityContext:
      allowPrivilegeEscalation: false
    capabilities:
      drop: [ALL]

```

- ❶ 任意の 2 つのトポロジードメイン間の Pod 数の最大差。デフォルトは **1** で、**0** の値を指定することはできません。
- ❷ ノードラベルのキー。このキーと同じ値を持つノードは同じトポロジーにあると見なされます。
- ❸ 分散制約を満たさない場合に Pod を処理する方法です。デフォルトは **DoNotSchedule** であり、これはスケジューラーに Pod をスケジュールしないように指示します。**ScheduleAnyway** に設定して Pod を依然としてスケジュールできますが、スケジューラーはクラスターがさらに不均衡な状態になるのを防ぐためにスキューの適用を優先します。
- ❹ 制約を満たすために、分散される際に、このラベルセクターに一致する Pod はグループとしてカウントされ、認識されます。ラベルセクターを指定してください。指定しないと、Pod が一致しません。
- ❺ 今後適切にカウントされるようにするには、この **Pod** 仕様がこのラベルセクターに一致するようにラベルを設定していることも確認してください。
- ❻ 拡散を計算する Pod を選択するための Pod ラベルキーのリスト。

単一 Pod トポロジーの分散制約を示す例

```

kind: Pod
apiVersion: v1
metadata:
  name: my-pod
  labels:

```

```

    region: us-east
spec:
  topologySpreadConstraints:
  - maxSkew: 1
    topologyKey: topology.kubernetes.io/zone
    whenUnsatisfiable: DoNotSchedule
  labelSelector:
    matchLabels:
      region: us-east
  containers:
  - image: "docker.io/ocpqe/hello-pod"
    name: hello-pod

```

前の例では、Pod トポロジーの分散制約が1つある **Pod** 仕様を定義しています。これは **region: us-east** というラベルが付いた Pod で一致し、ゾーン間で分散され、スキューの **1** を指定し、これらの要件を満たさない場合に Pod をスケジュールしません。

複数の Pod トポロジー分散制約を示す例

```

kind: Pod
apiVersion: v1
metadata:
  name: my-pod-2
  labels:
    region: us-east
spec:
  topologySpreadConstraints:
  - maxSkew: 1
    topologyKey: node
    whenUnsatisfiable: DoNotSchedule
  labelSelector:
    matchLabels:
      region: us-east
  - maxSkew: 1
    topologyKey: rack
    whenUnsatisfiable: DoNotSchedule
  labelSelector:
    matchLabels:
      region: us-east
  containers:
  - image: "docker.io/ocpqe/hello-pod"
    name: hello-pod

```

上記の例では、**Pod** トポロジー分散制約が2つある Pod 仕様を定義します。どちらも **region: us-east** というラベルの付いた Pod に一致し、スキューを **1** に指定し、これらの要件を満たしていない場合は Pod はスケジュールされません。

最初の制約は、ユーザー定義ラベルの **node** に基づいて Pod を分散し、2つ目の制約はユーザー定義ラベルの **rack** に基づいて Pod を分散します。Pod がスケジュールされるには、両方の制約を満たす必要があります。

4.8.5. 関連情報

- [ノードでラベルを更新する方法について](#)

4.9. DESCHEDULER を使用した POD のエビクト

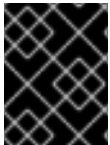
スケジューラー は、新しい Pod をホストするのに最適なノードを決定するために使用されますが、デスケジューラーは、実行中の Pod を削除して、Pod をより適切なノードに再スケジュールできるようにするために使用できます。

4.9.1. descheduler について

descheduler を使用して Pod を特定のストラテジーに基づいて退避し、Pod がより適切なノードに再スケジュールされるようにできます。

以下のような状況では、実行中の Pod のスケジュールを解除することに利点があります。

- ノードの使用率が低くなっているか、使用率が高くなっている。
- taint またはラベルなどの、Pod およびノードアフィニティーの各種要件が変更され、当初のスケジュールの意思決定が特定のノードに適さなくなっている。
- ノードの障害により、Pod を移動する必要がある。
- 新規ノードがクラスターに追加されている。
- Pod が再起動された回数が多すぎる。



重要

descheduler は退避された Pod の置き換えをスケジュールしません。スケジューラーは、退避された Pod に対してこのタスクを自動的に実行します。

descheduler がノードから Pod を退避することを決定する際には、以下の一般的なメカニズムを使用します。

- **openshift-*** および **kube-system** namespace の Pod は退避されることがありません。
- **priorityClassName** が **system-cluster-critical** または **system-node-critical** に設定されている Critical Pod は退避されることがありません。
- レプリケーションコントローラー、レプリカセット、デプロイメント、またはジョブの一部ではない静的な Pod、ミラーリングされた Pod、またはスタンドアロンの Pod は、再作成されないために退避されません。
- デモンセットに関連付けられた Pod は退避されることがありません。
- ローカルストレージを持つ Pod は退避されることがありません。
- Best effort Pod は、Burstable および Guaranteed Pod の前に退避されます。
- **descheduler.alpha.kubernetes.io/evict** アノテーションを持つすべてのタイプの Pod は退避の対象になります。このアノテーションはエビクションを防ぐチェックを上書きするために使用され、ユーザーは退避する Pod を選択できます。ユーザーは、Pod を再作成する方法と、Pod が再作成されるかどうかを認識している必要があります。
- Pod の Disruption Budget (PDB) が適用される Pod は、スケジュール解除が PDB に違反する場合には退避されません。Pod は、エビクションサブリソースを使用して PDB を処理することで退避されます。

4.9.2. descheduler プロファイル

以下の descheduler ストラテジーを利用できます。

AffinityAndTaints

このプロファイルは、Pod 間のアンチアフィニティー、ノードアフィニティー、およびノードの taint に違反する Pod を退避します。

これにより、以下のストラテジーが有効になります。

- **RemovePodsViolatingInterPodAntiAffinity:** Pod 間のアンチアフィニティーに違反する Pod を削除します。
- **RemovePodsViolatingNodeAffinity:** ノードのアフィニティーに違反する Pod を削除します。
- **RemovePodsViolatingNodeTaints:** ノード上の **NoSchedule** taint に違反する Pod を削除します。
ノードのアフィニティータイプが **requiredDuringSchedulingIgnoredDuringExecution** の Pod は削除されます。

TopologyAndDuplicates

このプロファイルは、ノード間で同様の Pod または同じトポロジードメインの Pod を均等に分散できるように Pod を退避します。

これにより、以下のストラテジーが有効になります。

- **RemovePodsViolatingTopologySpreadConstraint:** 均等に分散されていないとポロジードメインを見つけ、**DoNotSchedule** 制約を違反している場合により大きなものから Pod の退避を試行します。
- **RemoveDuplicates:** 1つの Pod のみが同じノードで実行されているレプリカセット、レプリケーションコントローラー、デプロイメントまたはジョブに関連付けられます。追加の Pod がある場合、それらの重複 Pod はクラスターに Pod を効果的に分散できるようにエビクトされます。

LifecycleAndUtilization

このプロファイルは長時間実行される Pod を退避し、ノード間のリソース使用状況のバランスを取ります。

これにより、以下のストラテジーが有効になります。

- **RemovePodsHavingTooManyRestarts:** コンテナが何度も再起動された Pod を削除します。
すべてのコンテナ (Init コンテナを含む) での再起動の合計が 100 を超える Pod。
- **LowNodeUtilization:** 使用率の低いノードを検出し、可能な場合は過剰に使用されているノードから Pod を退避し、退避された Pod の再作成がそれらの使用率の低いノードでスケジュールされるようにします。
ノードは、使用率がすべてのしきい値 (CPU、メモリー、Pod の数) で 20% 未満の場合に使用率が低いと見なされます。

ノードは、使用率がすべてのしきい値 (CPU、メモリー、Pod の数) について 50% を超える場合に過剰に使用されていると見なされます。

- **PodLifeTime:** 古くなり過ぎた Pod をエビクトします。

デフォルトでは、24 時間以上経過した Pod は削除されます。Pod のライフタイム値をカスタマイズできます。

SoftTopologyAndDuplicates

このプロファイルは **TopologyAndDuplicates** と同じですが、**whenUnsatisfiable: ScheduleAnyway** などのソフトポロジリー制約のある Pod も削除の対象と見なされる点が異なります。



注記

SoftTopologyAndDuplicates と **TopologyAndDuplicates** の両方を有効にしないでください。両方を有効にすると、競合が生じます。

EvictPodsWithLocalStorage

このプロファイルにより、ローカルストレージを備えた Pod が削除の対象になります。

EvictPodsWithPVC

このプロファイルを使用すると、永続的なボリュームクレームを持つ Pod をエビクションの対象にすることができます。**Kubernetes NFS Subdir External Provisioner** を使用している場合は、プロビジョナーがインストールされているnamespaceに除外されたnamespaceを追加する必要があります。

4.9.3. Descheduler のインストール

descheduler はデフォルトで利用できません。descheduler を有効にするには、Kube Descheduler Operator を OperatorHub からインストールし、1 つ以上の descheduler プロファイルを有効にする必要があります。

デフォルトで、descheduler は予測モードで実行されます。つまり、これは Pod エビクションのみをシミュレートします。Pod 退避を実行するには、descheduler のモードを automatic に変更する必要があります。



重要

クラスターでホストされたコントロールプレーンを有効にしている場合は、カスタム優先度のしきい値を設定して、ホストされたコントロールプレーンの namespace の Pod が削除される可能性を下げます。ホストされたコントロールプレーンの優先度クラスの中で優先度値が最も低い (**100000000**) ため、優先度しきい値クラス名を **hypershift-control-plane** に設定します。

前提条件

- クラスター管理者の権限。
- OpenShift Container Platform Web コンソールにアクセスできる。

手順

1. OpenShift Container Platform Web コンソールにログインします。
2. Kube Descheduler Operator に必要な namespace を作成します。
 - a. **Administration** → **Namespaces** に移動し、**Create Namespace** をクリックします。

- b. Name フィールドに **openshift-kube-descheduler-operator** を入力し、Labels フィールドに **openshift.io/cluster-monitoring=true** を入力して descheduler メトリクスを有効にし、**Create** をクリックします。
3. Kube Descheduler Operator をインストールします。
 - a. **Operators** → **OperatorHub** に移動します。
 - b. **Kube Descheduler Operator** をフィルターボックスに入力します。
 - c. **Kube Descheduler Operator** を選択し、**Install** をクリックします。
 - d. **Install Operator** ページで、**A specific namespace on the cluster**を選択します。ドロップダウンメニューから **openshift-kube-descheduler-operator** を選択します。
 - e. **Update Channel** および **Approval Strategy** の値を必要な値に調整します。
 - f. **Install** をクリックします。
4. descheduler インスタンスを作成します。
 - a. **Operators** → **Installed Operators** ページから、**Kube Descheduler Operator** をクリックします。
 - b. **Kube Descheduler** タブを選択し、**Create KubeDescheduler** をクリックします。
 - c. 必要に応じて設定を編集します。
 - i. エビクションをシミュレーションせずに Pod をエビクトするには、**Mode** フィールドを **Automatic** に変更します。
 - ii. **Profiles** セクションを展開し、1つ以上のプロファイルを選択して有効にします。**AffinityAndTaints** プロファイルはデフォルトで有効になっています。**Add Profile** をクリックして、追加のプロファイルを選択します。



注記

TopologyAndDuplicates と **SoftTopologyAndDuplicates** の両方を有効にしないでください。両方を有効にすると、競合が生じます。

- iii. オプション: **Profile Customizations** セクションを拡張して、Descheduler の任意の設定を行います。
 - **LifecycleAndUtilization** プロファイルのカスタム Pod ライフタイム値を設定します。**podLifetime** フィールドを使用して、数値と有効な単位 (**s**、**m**、または **h**) を設定します。デフォルトの Pod の有効期間は 24 時間 (**24 h**) です。
 - カスタム優先度しきい値を設定して、Pod の優先度が指定された優先度レベルよりも低い場合にのみ、Pod を削除対象と見なします。**thresholdPriority** フィールドを使用して数値の優先度しきい値を設定するか、**thresholdPriorityClassName** フィールドを使用して特定の優先度クラス名を指定します。



注記

デスケジューラーに **thresholdPriority** と **thresholdPriorityClassName** の両方を指定しないでください。

- デスケジューラー操作から除外または含める特定の namespace を設定します。**namespaces** フィールドを展開し、namespace を **除外** リストまたは **包含** リストに追加します。除外する namespace のリストまたは追加する namespace のリストのみを設定できます。保護されている namespace (**openshift-***、**kube-system**、**hypershift**) はデフォルトで除外されることに注意してください。



重要

LowNodeUtilization ストラテジーは、namespace の除外をサポートしていません。**LowNodeUtilization** ストラテジーを有効にする **LifecycleAndUtilization** プロファイルが設定されている場合、保護されている namespace であっても namespace は除外されません。**LowNodeUtilization** ストラテジーが有効になっているときに保護されている namespace からのエビクションを回避するには、優先度クラス名を **system-cluster-critical** または **system-node-critical** に設定します。

- 実験的: **LowNodeUtilization** ストラテジーの使用率および過度化のしきい値を設定します。**devLowNodeUtilizationThresholds** フィールドを使用して、以下のいずれかの値を設定します。
 - **Low**: 10% が十分に活用されておらず、30% が過剰に活用されている
 - **Medium**: 20% が十分に活用されておらず、50% が過剰に活用されている
 - **High**: 40% が十分に活用されておらず、70% が過剰に活用されている



注記

この設定は実験段階にあり、実稼働環境では使用しないでください。

- iv. オプション: **Descheduling Interval Seconds** フィールドを使用して、Descheduler の実行間の秒数を変更します。デフォルトは **3600** 秒です。

- d. **Create** をクリックします。

また、後で OpenShift CLI (**oc**) を使用して、Descheduler のプロファイルおよび設定を設定することもできます。Web コンソールから Descheduler インスタンスを作成する際にプロファイルを調整しない場合、**AffinityAndTaints** プロファイルはデフォルトで有効にされます。

4.9.4. Descheduler プロファイルの設定

descheduler が Pod の退避に使用するプロファイルを設定できます。

前提条件

- クラスター管理者の権限

手順

1. **KubeDescheduler** オブジェクトを編集します。

```
$ oc edit kubedeschedulers.operator.openshift.io cluster -n openshift-kube-descheduler-operator
```

2. **spec.profiles** セクションに1つ以上のプロファイルを指定します。

```
apiVersion: operator.openshift.io/v1
kind: KubeDescheduler
metadata:
  name: cluster
  namespace: openshift-kube-descheduler-operator
spec:
  deschedulingIntervalSeconds: 3600
  logLevel: Normal
  managementState: Managed
  operatorLogLevel: Normal
  mode: Predictive
  profileCustomizations:
    namespaces:
      excluded:
        - my-namespace
  podLifetime: 48h
  thresholdPriorityClassName: my-priority-class-name
  profiles:
    - AffinityAndTaints
    - TopologyAndDuplicates
    - LifecycleAndUtilization
    - EvictPodsWithLocalStorage
    - EvictPodsWithPVC
```

- ① オプション: デフォルトでは、descheduler は Pod を退避させません。Pod を退避するには、**mode** を **Automatic** に設定します。
- ② オプション: descheduler 操作に含めるか、除外するように、ユーザーが作成した namespace の一覧を設定します。**excluded** namespace のリストを設定するには **exclude** を使用するか、含める namespace のリストを設定するには **included** を使用します。保護されている namespace (**openshift-***、**kube-system**、**hypershift**) はデフォルトで除外されることに注意してください。



重要

LowNodeUtilization ストラテジーは、namespace の除外をサポートしていません。**LowNodeUtilization** ストラテジーを有効にする **LifecycleAndUtilization** プロファイルが設定されている場合、保護されている namespace であっても namespace は除外されません。**LowNodeUtilization** ストラテジーが有効になっているときに保護されている namespace からのエビクションを回避するには、優先度クラス名を **system-cluster-critical** または **system-node-critical** に設定します。

- ③ オプション: **LifecycleAndUtilization** プロファイルのカスタム Pod ライフタイム値を有効にします。有効な単位は **s**、**m**、または **h** です。デフォルトの Pod の有効期間は 24 時間です。
- ④ オプション: 優先順位のしきい値を指定して、優先順位のしきい値を指定して、それらの

- 5 1つ以上のプロファイルを追加して有効にします。使用可能なプロファイル: **AffinityAndTaints**、**TopologyAndDuplicates**、**LifecycleAndUtilization**、**SoftTopology**
- 6 **TopologyAndDuplicates** と **SoftTopologyAndDuplicates** の両方を有効にしないでください。両方を有効にすると、競合が生じます。

複数のプロファイルを有効にすることができますが、プロファイルを指定する順番は重要ではありません。

3. 変更を適用するためにファイルを保存します。

4.9.5. descheduler の間隔の設定

descheduler の実行間隔を設定できます。デフォルトは 3600 秒 (1 時間) です。

前提条件

- クラスター管理者の権限

手順

1. **KubeDescheduler** オブジェクトを編集します。

```
$ oc edit kubedeschedulers.operator.openshift.io cluster -n openshift-kube-descheduler-operator
```

2. **deschedulingIntervalSeconds** フィールドを必要な値に更新します。

```
apiVersion: operator.openshift.io/v1
kind: KubeDescheduler
metadata:
  name: cluster
  namespace: openshift-kube-descheduler-operator
spec:
  deschedulingIntervalSeconds: 3600 1
...
```

- 1 descheduler の実行間隔を秒単位で設定します。このフィールドの値 **0** は descheduler を一度実行し、終了します。

3. 変更を適用するためにファイルを保存します。

4.9.6. Descheduler のアンインストール





descheduler インスタンスを削除し、Kube Descheduler Operator をアンインストールして descheduler をクラスターから削除できます。この手順では、**KubeDescheduler** CRD および **openshift-kube-descheduler-operator** namespace もクリーンアップします。

前提条件

- クラスター管理者の権限。

- OpenShift Container Platform Web コンソールにアクセスできる。

手順

1. OpenShift Container Platform Web コンソールにログインします。
2. `descheduler` インスタンスを削除します。
 - a. **Operators** → **Installed Operators** ページから、**Kube Descheduler Operator** をクリックします。
 - b. **Kube Descheduler** タブを選択します。
 - c. **cluster** エントリーの横にあるオプションメニュー  をクリックし、**Delete KubeDescheduler** を選択します。
 - d. 確認ダイアログで **Delete** をクリックします。
3. **Kube Descheduler Operator** をアンインストールします。
 - a. **Operators** → **Installed Operators** に移動します。
 - b. **Kube Descheduler Operator** エントリーの横にあるオプションメニュー  をクリックし、**Uninstall Operator** を選択します。
 - c. 確認ダイアログで、**Uninstall** をクリックします。
4. **openshift-kube-descheduler-operator** namespace を削除します。
 - a. **Administration** → **Namespaces** に移動します。
 - b. **openshift-kube-descheduler-operator** をフィルターボックスに入力します。
 - c. **openshift-kube-descheduler-operator** エントリーの横にあるオプションメニュー  をクリックし、**Delete Namespace** を選択します。
 - d. 確認ダイアログで **openshift-kube-descheduler-operator** を入力し、**Delete** をクリックします。
5. **KubeDescheduler** CRD を削除します。
 - a. **Administration** → **Custom Resource Definitions** に移動します。
 - b. **KubeDescheduler** をフィルターボックスに入力します。
 - c. **KubeDescheduler** エントリーの横にあるオプションメニュー  をクリックし、**Delete CustomResourceDefinition** を選択します。
 - d. 確認ダイアログで **Delete** をクリックします。

4.10. セカンダリースケジューラー

4.10.1. セカンダリースケジューラーの概要

Secondary Scheduler Operator をインストールして、デフォルトのスケジューラーと共にカスタムのセカンダリースケジューラーを実行して Pod をスケジューリングすることができます。

4.10.1.1. Secondary Scheduler Operator について

Secondary Scheduler Operator for Red Hat OpenShift は、OpenShift Container Platform にカスタムのセカンダリースケジューラーをデプロイする方法を提供します。セカンダリースケジューラーは、デフォルトのスケジューラーと共に実行され、Pod をスケジューリングします。Pod 設定は、使用するスケジューラーを指定できます。

カスタムスケジューラーには `/bin/kube-scheduler` バイナリーが必要であり、[Kubernetes スケジューリングフレームワーク](#) をベースとする必要があります。



重要

Secondary Scheduler Operator を使用してカスタムセカンダリースケジューラーを OpenShift Container Platform にデプロイできますが、Red Hat はカスタムセカンダリースケジューラーの機能を直接サポートしません。

Secondary Scheduler Operator は、セカンダリースケジューラーに必要なデフォルトのロールとロールバインディングを作成します。セカンダリースケジューラーの **KubeSchedulerConfiguration** リソースを設定することにより、有効または無効にするスケジューリングプラグインを指定できます。

4.10.2. Secondary Scheduler Operator for Red Hat OpenShift のリリースノート

Secondary Scheduler Operator for Red Hat OpenShift を使用すると、カスタムのセカンダリースケジューラーを OpenShift Container Platform クラスターにデプロイできます。

以下のリリースノートは、Secondary Scheduler Operator for Red Hat OpenShift の開発履歴を記録したものです。

詳細は、[Secondary Scheduler Operator について](#) を参照してください。

4.10.2.1. Red Hat OpenShift 1.1.5 のセカンダリースケジューラー Operator のリリースノート

発行日：2025 年 11 月 5 日

以下のアドバイザリーは、Red Hat OpenShift 1.1.5 のセカンダリースケジューラー Operator で利用できます。

- [RHBA-2025:19779](#)

4.10.2.1.1. 新機能および機能拡張

- このリリースでは、Secondary Scheduler Operator のベースイメージが再ビルドされ、そのイメージのグレードが改善されます。

4.10.2.1.2. 既知の問題

- 現時点で、Secondary Scheduler Operator を使用して設定マップ、CRD、RBAC ポリシーなどの追加のリソースをデプロイできません。カスタムセカンダリースケジューラーに必要なロールとロールバインディング以外のリソースは、外部から適用する必要があります。(WRK LDS-645)

4.10.2.2. Secondary Scheduler Operator for Red Hat OpenShift 1.4.0 のリリースノート

発行日: 2024 年 11 月 26 日

SSecondary Scheduler Operator for Red Hat OpenShift 1.4.0 では、次のアドバイザリーが利用可能です。

- [RHEA-2025:8163](#)

4.10.2.2.1. バグ修正

- Secondary Scheduler Operator のこのリリースでは、Common Vulnerabilities and Exposures (CVE) に対処しています。

4.10.2.2.2. 既知の問題

- 現時点で、Secondary Scheduler Operator を使用して設定マップ、CRD、RBAC ポリシーなどの追加のリソースをデプロイできません。カスタムセカンダリースケジューラーに必要なロールとロールバインディング以外のリソースは、外部から適用する必要があります。(WRK LDS-645)

4.10.2.3. Red Hat OpenShift 1.1.3 の Secondary Scheduler Operator のリリースノート

発行日: 2025 年 10 月 22 日

以下のアドバイザリーは、Red Hat OpenShift 1.1.3 の Secondary Scheduler Operator で利用できます。

- [RHSA-2023:5933](#)

4.10.2.3.1. バグ修正

- Secondary Scheduler Operator のこのリリースでは、Common Vulnerabilities and Exposures (CVE) に対処しています。

4.10.2.3.2. 既知の問題

- 現時点で、Secondary Scheduler Operator を使用して設定マップ、CRD、RBAC ポリシーなどの追加のリソースをデプロイできません。カスタムセカンダリースケジューラーに必要なロールとロールバインディング以外のリソースは、外部から適用する必要があります。(WRK LDS-645)

4.10.2.4. Red Hat OpenShift 1.1.2 の Secondary Scheduler Operator のリリースノート

発行日: 2025 年 8 月 6 日

以下のアドバイザリーは、Red Hat OpenShift 1.1.2 の セカンダリースケジューラー Operator で利用できます。

- [RHSA-2023:4657](#)

4.10.2.4.1. バグ修正

- Secondary Scheduler Operator のこのリリースでは、いくつかの Common Vulnerabilities and Exposures (CVE) に対処しています。

4.10.2.4.2. 既知の問題

- 現時点で、Secondary Scheduler Operator を使用して設定マップ、CRD、RBAC ポリシーなどの追加のリソースをデプロイできません。カスタムセカンダリースケジューラーに必要なロールとロールバインディング以外のリソースは、外部から適用する必要があります。(WRKLD5-645)

4.10.2.5. Red Hat OpenShift 1.1.0 のセカンダリースケジューラー Operator のリリースノート

発行日: 2025 年 9 月 30 日

以下のアドバイザリーは、Red Hat OpenShift 1.1.0 のセカンダリースケジューラー Operator で利用できます。

- [RHSA-2022:6152](#)

4.10.2.5.1. 新機能および機能拡張

- Secondary Scheduler Operator のセキュリティーコンテキスト設定は、[Pod のセキュリティーアドミッションの実施](#)に準拠するように更新されました。

4.10.2.5.2. 既知の問題

- 現時点で、Secondary Scheduler Operator を使用して設定マップ、CRD、RBAC ポリシーなどの追加のリソースをデプロイできません。カスタムセカンダリースケジューラーに必要なロールとロールバインディング以外のリソースは、外部から適用する必要があります。(BZ#2071684)

4.10.3. セカンダリースケジューラーを使用した Pod のスケジューリング

OpenShift Container Platform でカスタムのセカンダリースケジューラーを実行するには、Secondary Scheduler Operator をインストールし、セカンダリースケジューラーをデプロイし、セカンダリースケジューラーを Pod 定義に設定します。

4.10.3.1. Secondary Scheduler Operator のインストール

Web コンソールを使用して、Secondary Scheduler Operator for Red Hat OpenShift をインストールできます。

前提条件

- **cluster-admin** 権限でクラスターにアクセスできる。
- OpenShift Container Platform Web コンソールにアクセスできる。

手順

1. OpenShift Container Platform Web コンソールにログインします。
2. Secondary Scheduler Operator for Red Hat OpenShift に必要な namespace を作成します。

- a. **Administration** → **Namespaces** に移動し、**Create Namespace** をクリックします。
 - b. **Name** フィールドに **openshift-secondary-scheduler-operator** を入力し、**Create** をクリックします。
3. **Secondary Scheduler Operator for Red Hat OpenShift** をインストールします。
- a. **Operators** → **OperatorHub** に移動します。
 - b. フィルターボックスに **Secondary Scheduler Operator for Red Hat OpenShift** と入力します。
 - c. **Secondary Scheduler Operator for Red Hat OpenShift** を選択し、**Install** をクリックします。
 - d. **Install Operator** ページで以下を行います。
 - i. **Update チャンネル** は **stable** に設定され、Red Hat OpenShift 用の **Secondary Scheduler Operator** の最新の安定したリリースをインストールします。
 - ii. **クラスターで特定の namespace** を選択し、ドロップダウンメニューから **openshift-secondary-scheduler-operator** を選択します。
 - iii. **Update approval strategy** を選択します。
 - **Automatic** ストラテジーを使用すると、新しいバージョンが利用可能になったときに、Operator Lifecycle Manager (OLM) によって Operator を自動的に更新できます。
 - **Manual** ストラテジーには、Operator の更新を承認するための適切な認証情報を持つユーザーが必要です。
 - iv. **Install** をクリックします。

検証

1. **Operators** → **Installed Operators** に移動します。
2. **Secondary Scheduler Operator for Red Hat OpenShift** がリスト表示され、その **Status** が **Succeeded** であることを確認します。

4.10.3.2. セカンダリースケジューラーのデプロイ

Secondary Scheduler Operator のインストール後に、セカンダリースケジューラーをデプロイできます。

前提条件

- **cluster-admin** 権限でクラスターにアクセスできる。
- OpenShift Container Platform Web コンソールにアクセスできる。
- Secondary Scheduler Operator for Red Hat OpenShift がインストールされている。

手順

1. OpenShift Container Platform Web コンソールにログインします。

2. セカンダリースケジューラーの設定を保持する設定マップを作成します。

- a. **Workloads** → **ConfigMaps** に移動します。
- b. **Create ConfigMap** をクリックします。
- c. YAML エディターで、必要な **KubeSchedulerConfiguration** 設定が含まれる設定マップ定義を入力します。以下に例を示します。

```

apiVersion: v1
kind: ConfigMap
metadata:
  name: "secondary-scheduler-config"
  namespace: "openshift-secondary-scheduler-operator"
data:
  "config.yaml": |
    apiVersion: kubescheduler.config.k8s.io/v1
    kind: KubeSchedulerConfiguration
    leaderElection:
      leaderElect: false
    profiles:
      - schedulerName: secondary-scheduler
        plugins:
          score:
            disabled:
              - name: NodeResourcesBalancedAllocation
              - name: NodeResourcesLeastAllocated

```

- ① 設定マップの名前。これは、**SecondaryScheduler** CR の作成時に **Scheduler Config** フィールドで使用されます。
- ② 設定マップは **openshift-secondary-scheduler-operator** namespace に作成される必要があります。
- ③ セカンダリースケジューラーの **KubeSchedulerConfiguration** リソース。詳細は、Kubernetes API ドキュメントの [KubeSchedulerConfiguration](#) を参照してください。
- ④ セカンダリースケジューラーの名前。**spec.schedulerName** フィールドをこの値に設定する Pod はこのセカンダリースケジューラーでスケジュールされます。
- ⑤ セカンダリースケジューラーに対して有効または無効にするプラグイン。デフォルトのスケジューリングプラグインのリストは、Kubernetes ドキュメントの [スケジューリングプラグイン](#) を参照してください。

- d. **Create** をクリックします。

3. **SecondaryScheduler** CR を作成します。

- a. **Operators** → **Installed Operators** に移動します。
- b. **Secondary Scheduler Operator for Red Hat OpenShift** を選択します。
- c. **Secondary Scheduler** タブを選択し、**Create SecondaryScheduler** をクリックします。

- d. **Name** フィールドはデフォルトで **cluster** に設定されます。この名前は変更しないでください。
- e. **Scheduler Config** フィールドは **secondary-scheduler-config** にデフォルト設定されます。この値は、この手順で先に作成した設定マップの名前と一致していることを確認してください。
- f. **Scheduler Image** フィールドにカスタムスケジューラーのイメージ名を入力します。



重要

Red Hat では、カスタムのセカンダリースケジューラーの機能を直接サポートしません。

- g. **Create** をクリックします。

4.10.3.3. セカンダリースケジューラーを使用した Pod のスケジューリング

セカンダリースケジューラーを使用して Pod をスケジューリングするには、Pod 定義の **schedulerName** フィールドを設定します。

前提条件

- **cluster-admin** 権限でクラスターにアクセスできる。
- OpenShift Container Platform Web コンソールにアクセスできる。
- Secondary Scheduler Operator for Red Hat OpenShift がインストールされている。
- セカンダリースケジューラーが設定されています。

手順

1. OpenShift Container Platform Web コンソールにログインします。
2. **Workloads** → **Pods** に移動します。
3. **Create Pod** をクリックします。
4. YAML エディターで、必要な Pod 設定を入力し、**schedulerName** フィールドを追加します。

```
apiVersion: v1
kind: Pod
metadata:
  name: nginx
  namespace: default
spec:
  containers:
  - name: nginx
    image: nginx:1.14.2
    ports:
    - containerPort: 80
  schedulerName: secondary-scheduler 1
```

- 1 **schedulerName** フィールドは、セカンダリースケジューラーの設定時に設定マップで定義される名前と一致する必要があります。

5. **Create** をクリックします。

検証

1. OpenShift CLI にログインします。
2. 以下のコマンドを使用して Pod を記述します。

```
$ oc describe pod nginx -n default
```

出力例

```
Name:      nginx
Namespace: default
Priority:   0
Node:      ci-ln-t0w4r1k-72292-xkqs4-worker-b-xqkxp/10.0.128.3
...
Events:
  Type     Reason            Age   From          Message
  ----     -
  Normal   Scheduled         12s   secondary-scheduler Successfully assigned default/nginx to ci-ln-t0w4r1k-72292-xkqs4-worker-b-xqkxp
  ...
```

3. イベントテーブルで、**Successfully assigned <namespace>/<pod_name> to <node_name>** のようなメッセージが表示されたイベントを見つけます。
4. "From" 列で、デフォルトのスケジューラーではなく、イベントがセカンダリースケジューラーから生成されたことを確認します。



注記

openshift-secondary-scheduler-namespace の **secondary-scheduler-*** Pod ログをチェックして、Pod がセカンダリースケジューラーによってスケジューリングされていることを確認することもできます。

4.10.4. Secondary Scheduler Operator のアンインストール

Secondary Scheduler Operator for Red Hat OpenShift をアンインストールし、関連リソースを削除することで、OpenShift Container Platform から Operator を削除できます。

4.10.4.1. Secondary Scheduler Operator のアンインストール


Web コンソールを使用して、Secondary Scheduler Operator for Red Hat OpenShift をアンインストールできます。

前提条件

- **cluster-admin** 権限でクラスターにアクセスできる。

- OpenShift Container Platform Web コンソールにアクセスできる。
- Secondary Scheduler Operator for Red Hat OpenShift がインストールされている。

手順

1. OpenShift Container Platform Web コンソールにログインします。
2. Secondary Scheduler Operator for Red Hat OpenShift をアンインストールします。
 - a. **Operators** → **Installed Operators** に移動します。
 - b. **セカンダリースケジューラーの Operator** エントリーの隣にあるオプションメニュー  をクリックし、**Operator のアンインストール** をクリックします。
 - c. 確認ダイアログで、**Uninstall** をクリックします。



4.10.4.2. Secondary Scheduler Operator リソースの削除

必要に応じて、Secondary Scheduler Operator for Red Hat OpenShift をアンインストールした後、クラスターから関連リソースを削除できます。

前提条件

- **cluster-admin** 権限でクラスターにアクセスできる。
- OpenShift Container Platform Web コンソールにアクセスできる。

手順

1. OpenShift Container Platform Web コンソールにログインします。
2. Secondary Scheduler Operator によってインストールされた CRD を削除します。
 - a. **Administration** → **CustomResourceDefinitions** に移動します。
 - b. **Name** フィールドに **SecondaryScheduler** を入力して CRD をフィルターします。
 - c. **SecondaryScheduler** CRD の横にある Options メニュー  をクリックし、**Delete Custom Resource Definition** を選択します。
3. **openshift-secondary-scheduler-operator** namespace を削除します。
 - a. **Administration** → **Namespaces** に移動します。
 - b. **openshift-secondary-scheduler-operator** の横にあるオプションメニュー  をクリックし、**namespace の削除** を選択します。
 - c. 確認ダイアログで、フィールドに **openshift-secondary-scheduler-operator** を入力し、**Delete** をクリックします。

第5章 ジョブと DAEMONSET の使用

5.1. デーモンセットによるノード上でのバックグラウンドタスクの自動的な実行

管理者は、デーモンセットを作成して OpenShift Container Platform クラスター内の特定の、またはすべてのノードで Pod のレプリカを実行するために使用できます。

デーモンセットは、すべて (または一部) のノードで Pod のコピーが確実に実行されるようにします。ノードがクラスターに追加されると、Pod がクラスターに追加されます。ノードがクラスターから削除されると、Pod はガベージコレクションによって削除されます。デーモンセットを削除すると、デーモンセットによって作成された Pod がクリーンアップされます。

デーモンセットを使用して共有ストレージを作成し、クラスター内のすべてのノードでロギング Pod を実行するか、すべてのノードでモニターエージェントをデプロイできます。

セキュリティ上の理由から、クラスター管理者とプロジェクト管理者がデーモンセットを作成できます。

デーモンセットの詳細は、[Kubernetes ドキュメント](#) を参照してください。



重要

デーモンセットのスケジューリングにはプロジェクトのデフォルトノードセクターとの互換性がありません。これを無効にしない場合、デーモンセットはデフォルトのノードセクターとのマージによって制限されます。これにより、マージされたノードセクターで選択解除されたノードで Pod が頻繁に再作成されるようになり、クラスターに不要な負荷が加わります。

5.1.1. デフォルトスケジューラーによるスケジュール

デーモンセットは、適格なすべてのノードで Pod のコピーが確実に実行されるようにします。通常は、Pod が実行されるノードは Kubernetes のスケジューラーが選択します。ただし、デーモンセット Pod はデーモンセットコントローラーによって作成され、スケジュールされます。その結果、以下のような問題が生じています。

- Pod の動作に一貫性がない。スケジューリングを待機している通常の Pod は、作成されると Pending 状態になりますが、デーモンセット Pod は作成されても **Pending** 状態になりません。これによりユーザーに混乱が生じます。
- Pod のプリエンプションがデフォルトのスケジューラーで処理される。プリエンプションが有効にされると、デーモンセットコントローラーは Pod の優先順位とプリエンプションを考慮することなくスケジューリングの決定を行います。

ScheduleDaemonSetPods 機能は、OpenShift Container Platform でデフォルトで有効にされます。これにより、**spec.nodeName** の条件 (term) ではなく **NodeAffinity** の条件 (term) をデーモンセット Pod に追加することで、デーモンセットコントローラーではなくデフォルトのスケジューラーを使用してデーモンセットをスケジュールすることができます。その後、デフォルトのスケジューラーは、Pod をターゲットホストにバインドさせるために使用されます。デーモンセット Pod のノードアフィニティがすでに存在する場合、これは置き換えられます。デーモンセットコントローラーは、デーモンセット Pod を作成または変更する場合にのみこれらの操作を実行し、デーモンセットの **spec.template** は一切変更されません。

kind: Pod

```

apiVersion: v1
metadata:
  name: hello-node-6fbccf8d9-9tmzr
#...
spec:
  nodeAffinity:
    requiredDuringSchedulingIgnoredDuringExecution:
      nodeSelectorTerms:
        - matchFields:
            - key: metadata.name
              operator: In
              values:
                - target-host-name
#...

```

さらに、**node.kubernetes.io/unschedulable:NoSchedule** の toleration がデーモンセット Pod に自動的に追加されます。デフォルトのスケジューラーは、デーモンセット Pod をスケジュールする際に、スケジュールできないノードを無視します。

5.1.2. デーモンセットの作成

デーモンセットの作成時に、**nodeSelector** フィールドは、デーモンセットがレプリカをデプロイする必要のあるノードを指定するために使用されます。

前提条件

- デーモンセットの使用を開始する前に、namespace のアノテーション **openshift.io/node-selector** を空の文字列に設定することで、namespace のプロジェクトスコープのデフォルトのノードセクターを無効にします。

```

$ oc patch namespace myproject -p \
  '{"metadata": {"annotations": {"openshift.io/node-selector": ""}}}'

```

ヒント

または、以下の YAML を適用して、プロジェクト全体で namespace のデフォルトのノードセクターを無効にすることもできます。

```

apiVersion: v1
kind: Namespace
metadata:
  name: <namespace>
  annotations:
    openshift.io/node-selector: ""
#...

```

- 新規プロジェクトを作成している場合は、デフォルトのノードセクターを上書きします。

```

$ oc adm new-project <name> --node-selector=""

```

手順

デーモンセットを作成するには、以下を実行します。

1. デーモンセット yaml ファイルを定義します。

```

apiVersion: apps/v1
kind: DaemonSet
metadata:
  name: hello-daemonset
spec:
  selector:
    matchLabels:
      name: hello-daemonset ❶
  template:
    metadata:
      labels:
        name: hello-daemonset ❷
    spec:
      nodeSelector: ❸
        role: worker
      containers:
        - image: openshift/hello-openshift
          imagePullPolicy: Always
          name: registry
          ports:
            - containerPort: 80
              protocol: TCP
          resources: {}
          terminationMessagePath: /dev/termination-log
      serviceAccount: default
      terminationGracePeriodSeconds: 10
#...
```

- ❶ デーモンセットに属する Pod を判別するラベルセレクターです。
- ❷ Pod テンプレートのラベルセレクターです。上記のラベルセレクターに一致している必要があります。
- ❸ Pod レプリカをデプロイする必要があるノードを判別するノードセレクターです。一致するラベルがこのノードに存在する必要があります。

2. デーモンセットオブジェクトを作成します。

```
$ oc create -f daemonset.yaml
```

3. Pod が作成されていることを確認し、各 Pod に Pod レプリカがあることを確認するには、以下を実行します。

a. daemonset Pod を検索します。

```
$ oc get pods
```

出力例

```

hello-daemonset-cx6md 1/1    Running 0    2m
hello-daemonset-e3md9 1/1    Running 0    2m
```

b. Pod がノードに配置されていることを確認するために Pod を表示します。

```
$ oc describe pod/hello-daemonset-cx6md|grep Node
```

出力例

```
Node:      openshift-node01.hostname.com/10.14.20.134
```

```
$ oc describe pod/hello-daemonset-e3md9|grep Node
```

出力例

```
Node:      openshift-node02.hostname.com/10.14.20.137
```

重要

- デーモンセット Pod テンプレートを更新しても、既存の Pod レプリカには影響はありません。
- デーモンセットを削除してから、異なるテンプレートと同じラベルセクターを使用して新規のデーモンセットを作成する場合に、既存の Pod レプリカでラベルが一致していると認識するため、既存の Pod レプリカは更新されず、Pod テンプレートで一致しない場合でも新しいレプリカが作成されます。
- ノードのラベルを変更する場合には、デーモンセットは新しいラベルと一致するノードに Pod を追加し、新しいラベルと一致しないノードから Pod を削除します。

デーモンセットを更新するには、古いレプリカまたはノードを削除して新規の Pod レプリカの作成を強制的に実行します。

5.2. ジョブの使用による POD でのタスクの実行

`job` は、OpenShift Container Platform クラスターのタスクを実行します。

ジョブは、タスクの全体的な進捗状況を追跡し、進行中、完了、および失敗した各 Pod の情報を使用してその状態を更新します。ジョブを削除するとそのジョブによって作成された Pod のレプリカがクリーンアップされます。ジョブは Kubernetes API の一部で、他のオブジェクトタイプ同様に `oc` コマンドで管理できます。

ジョブ仕様のサンプル

```
apiVersion: batch/v1
kind: Job
metadata:
  name: pi
spec:
  parallelism: 1
  completions: 1
  activeDeadlineSeconds: 1800
  backoffLimit: 6
  template:
```

1

2

3

4

5

```

metadata:
  name: pi
spec:
  containers:
  - name: pi
    image: perl
    command: ["perl", "-Mbignum=bpi", "-wle", "print bpi(2000)"]
    restartPolicy: OnFailure
#...

```

- ① ジョブの Pod レプリカは並行して実行される必要があります。
- ② ジョブの完了をマークするには、Pod の正常な完了が必要です。
- ③ ジョブを実行できる最長期間。
- ④ ジョブの再試行回数。
- ⑤ コントローラーが作成する Pod のテンプレート。
- ⑥ Pod の再起動ポリシー。

関連情報

- Kubernetes ドキュメントの [ジョブ](#)

5.2.1. ジョブと cron ジョブについて

ジョブは、タスクの全体的な進捗状況を追跡し、進行中、完了、および失敗した各 Pod の情報を使用してその状態を更新します。ジョブを削除するとそのジョブによって作成された Pod がクリーンアップされます。ジョブは Kubernetes API の一部で、他のオブジェクトタイプ同様に **oc** コマンドで管理できます。

OpenShift Container Platform で一度だけ実行するオブジェクトを作成できるリソースタイプは 2 種類あります。

ジョブ

定期的なジョブは、タスクを作成しジョブが完了したことを確認する、一度だけ実行するオブジェクトです。

ジョブとして実行するには、主に以下のタスクタイプを使用できます。

- 非並列ジョブ:
 - Pod が失敗しない限り、単一の Pod のみを起動するジョブ。
 - このジョブは、Pod が正常に終了するとすぐに完了します。
- 固定の完了数が指定された並列ジョブ
 - 複数の Pod を起動するジョブ。
 - ジョブはタスク全体を表し、1 から **completions** 値までの範囲内のそれぞれの値に対して 1 つの正常な Pod がある場合に完了します。
- ワークキューを含む並列ジョブ:

- 指定された Pod に複数の並列ワーカープロセスを持つジョブ。
- OpenShift Container Platform は Pod を調整し、それぞれの機能を判別するか、外部キューサービスを使用します。
- 各 Pod はそれぞれ、すべてのピア Pod が完了しているかどうかや、ジョブ全体が実行済みであることを判別することができます。
- ジョブからの Pod が正常な状態で終了すると、新規 Pod は作成されません。
- 1つ以上の Pod が正常な状態で終了し、すべての Pod が終了している場合、ジョブが正常に完了します。
- Pod が正常な状態で終了した場合、それ以外の Pod がこのタスクに対して機能したり、または出力を書き込むことはありません。Pod はすべて終了プロセスにあるはずで、各種のジョブを使用する方法の詳細は、Kubernetes ドキュメントの [Job Patterns](#) を参照してください。

Cron ジョブ

ジョブは、cron ジョブを使用して複数回実行するようにスケジュールすることが可能です。

cron ジョブ は、ユーザーがジョブの実行方法を指定することを可能にすることで、定期的なジョブを積み重ねます。Cron ジョブは [Kubernetes API](#) の一部であり、他のオブジェクトタイプと同様に **oc** コマンドで管理できます。

Cron ジョブは、バックアップの実行やメールの送信など周期的な繰り返しのタスクを作成する際に役立ちます。また、低アクティビティー期間にジョブをスケジュールする場合など、特定の時間に個別のタスクをスケジュールすることも可能です。cron ジョブは、cronjob コントローラーを実行するコントロールプレーンノードに設定されたタイムゾーンに基づいて **Job** オブジェクトを作成します。



警告

cron ジョブはスケジュールの実行時間ごとに約1回ずつ **Job** オブジェクトを作成しますが、ジョブの作成に失敗したり、2つのジョブが作成される場合があります。そのためジョブはべき等である必要があり、履歴制限を設定する必要があります。

5.2.1.1. ジョブの作成方法

どちらのリソースタイプにも、以下の主要な要素から構成されるジョブ設定が必要です。

- OpenShift Container Platform が作成する Pod を記述している Pod テンプレート。
- **parallelism** パラメーター。ジョブの実行に使用する、同時に実行される Pod の数を指定します。
 - 非並列ジョブの場合は、未設定のままにします。未設定の場合は、デフォルトの **1** に設定されます。

- **completions** パラメーター。ジョブを完了するために必要な、正常に完了した Pod の数を指定します。
 - 非並列ジョブの場合は、未設定のままにします。未設定の場合は、デフォルトの **1** に設定されます。
 - 固定の完了数を持つ並列ジョブの場合は、値を指定します。
 - ワークキューのある並列ジョブでは、未設定のままにします。未設定の場合、デフォルトは **parallelism** 値に設定されます。

5.2.1.2. ジョブの最長期間を設定する方法

ジョブの定義時に、**activeDeadlineSeconds** フィールドを設定して最長期間を定義できます。これは秒単位で指定され、デフォルトでは設定されません。設定されていない場合は、実施される最長期間はありません。

最長期間は、最初の Pod がスケジュールされた時点から計算され、ジョブが有効である期間を定義します。これは実行の全体の時間を追跡します。指定されたタイムアウトに達すると、OpenShift Container Platform がジョブを終了します。

5.2.1.3. 失敗した Pod のためのジョブのバックオフポリシーを設定する方法

ジョブは、設定の論理的なエラーなどの理由により再試行の設定回数を超えた後に失敗とみなされる場合があります。ジョブに関連付けられた失敗した Pod は 6 分を上限として指数関数的バックオフ遅延値 (**10s**、**20s**、**40s** ...) に基づいて再作成されます。この制限は、コントローラーのチェック間で失敗した Pod が新たに生じない場合に再設定されます。

ジョブの再試行回数を設定するには **spec.backoffLimit** パラメーターを使用します。

5.2.1.4. アーティファクトを削除するように cron ジョブを設定する方法

Cron ジョブはジョブや Pod などのアーティファクトリソースをそのままにすることがあります。ユーザーは履歴制限を設定して古いジョブとそれらの Pod が適切に消去されるようにすることが重要です。これに対応する 2 つのフィールドが cron ジョブ仕様にあります。

- **.spec.successfulJobsHistoryLimit**。保持する成功した終了済みジョブの数 (デフォルトは 3 に設定)。
- **.spec.failedJobsHistoryLimit**。保持する失敗した終了済みジョブの数 (デフォルトは 1 に設定)。

ヒント

- 必要なくなった cron ジョブを削除します。

```
$ oc delete cronjob/<cron_job_name>
```

これを実行することで、不要なアーティファクトの生成を防げます。

- **spec.suspend** を **true** に設定することで、その後の実行を中断することができます。その後のすべての実行は、**false** に再設定するまで中断されます。

5.2.1.5. 既知の制限

ジョブ仕様の再起動ポリシーは **Pod** にのみ適用され、**ジョブコントローラー** には適用されません。ただし、ジョブコントローラーはジョブを完了まで再試行するようハードコーディングされます。

そのため **restartPolicy: Never** または **--restart=Never** により、**restartPolicy: OnFailure** または **--restart=OnFailure** と同じ動作が実行されます。つまり、ジョブが失敗すると、成功するまで (または手動で破棄されるまで) 自動で再起動します。このポリシーは再起動するサブシステムのみを設定します。

Never ポリシーでは、**ジョブコントローラー** が再起動を実行します。それぞれの再試行時に、ジョブコントローラーはジョブステータスの失敗数を増分し、新規 Pod を作成します。これは、それぞれの試行が失敗するたびに Pod の数が増えることを意味します。

OnFailure ポリシーでは、**kubelet** が再起動を実行します。それぞれの試行によりジョブステータスの失敗数が増分する訳ではありません。さらに、**kubelet** は同じノードで Pod の起動に失敗したジョブを再試行します。

5.2.2. ジョブの作成

ジョブオブジェクトを作成して OpenShift Container Platform にジョブを作成します。

手順

ジョブを作成するには、以下を実行します。

1. 以下のような YAML ファイルを作成します。

```
apiVersion: batch/v1
kind: Job
metadata:
  name: pi
spec:
  parallelism: 1 ①
  completions: 1 ②
  activeDeadlineSeconds: 1800 ③
  backoffLimit: 6 ④
  template: ⑤
    metadata:
      name: pi
    spec:
      containers:
        - name: pi
          image: perl
          command: ["perl", "-Mbignum=bpi", "-wle", "print bpi(2000)"]
          restartPolicy: OnFailure ⑥
#...
```

- ① オプション: ジョブを並行して実行する Pod レプリカの数指定します。デフォルトは 1 です。
 - 非並列ジョブの場合は、未設定のままにします。未設定の場合は、デフォルトの 1 に設定されます。
- ② オプション: ジョブの完了をマークするために必要な Pod の正常な完了の数を指定します。

- 非並列ジョブの場合は、未設定のままにします。未設定の場合は、デフォルトの **1** に設定されます。
- 固定の完了数を持つ並列ジョブの場合、完了の数を指定します。
- ワークキューのある並列ジョブでは、未設定のままにします。未設定の場合、デフォルトは **parallelism** 値に設定されます。

3 オプション: ジョブを実行できる最大期間を指定します。

4 オプション: ジョブの再試行回数を指定します。このフィールドは、デフォルトでは 6 に設定されています。

5 コントローラーが作成する Pod のテンプレートを指定します。

6 Pod の再起動ポリシーを指定します。

- **Never**: ジョブを再起動しません。
- **OnFailure**: ジョブが失敗した場合にのみ再起動します。
- **Always**: ジョブを常に再起動します。
OpenShift Container Platform が失敗したコンテナに再起動ポリシーを使用する方法の詳細は、Kubernetes ドキュメントの [State の例](#) を参照してください。

2. ジョブを作成します。

```
$ oc create -f <file-name>.yaml
```



注記

oc create job を使用して単一コマンドからジョブを作成し、起動することもできます。以下のコマンドは直前の例に指定されている同じジョブを作成し、これを起動します。

```
$ oc create job pi --image=perl -- perl -Mbignum=bpi -wle 'print bpi(2000)'
```

5.2.3. cron ジョブの作成

ジョブオブジェクトを作成して OpenShift Container Platform に cron ジョブを作成します。

手順

cron ジョブを作成するには、以下を実行します。

1. 以下のような YAML ファイルを作成します。

```
apiVersion: batch/v1
kind: CronJob
metadata:
  name: pi
spec:
  schedule: "*/1 * * * *"
  timeZone: Etc/UTC
  concurrencyPolicy: "Replace"
```

1

2

3

```

startingDeadlineSeconds: 200
suspend: true
successfulJobsHistoryLimit: 3
failedJobsHistoryLimit: 1
jobTemplate:
  spec:
    template:
      metadata:
        labels:
          parent: "cronjobpi"
      spec:
        containers:
          - name: pi
            image: perl
            command: ["perl", "-Mbignum=bpi", "-wle", "print bpi(2000)"]
        restartPolicy: OnFailure
#...
```

- ① **cron 形式** で指定されたジョブのスケジュール。この例では、ジョブは毎分実行されます。
- ② スケジュールのオプションのタイムゾーン。有効なオプションは、[tz データベースのタイムゾーンのリスト](#) を参照してください。指定しない場合、Kubernetes コントローラーマネージャーは、ローカルタイムゾーンを基準にしてスケジュールを解釈します。この設定は、[テクノロジーレビュー](#) として提供されます。
- ③ オプションの同時実行ポリシー。cron ジョブ内での同時実行ジョブを処理する方法を指定します。以下の同時実行ポリシーの1つのみを指定できます。これが指定されない場合、同時実行を許可するようにデフォルト設定されます。
 - **Allow:** cron ジョブを同時に実行できます。
 - **Forbid:** 同時実行を禁止し、直前の実行が終了していない場合は次の実行を省略します。
 - **Replace:** 同時に実行されているジョブを取り消し、これを新規ジョブに置き換えます。
- ④ ジョブを開始するためのオプションの期限 (秒単位)(何らかの理由によりスケジュールされた時間が経過する場合)。ジョブの実行が行われない場合、ジョブの失敗としてカウントされます。これが指定されない場合は期間が設定されません。
- ⑤ cron ジョブの停止を許可するオプションのフラグ。これが **true** に設定されている場合、後続のすべての実行が停止されます。
- ⑥ 保持する成功した終了済みジョブの数 (デフォルトは 3 に設定)。
- ⑦ 保持する失敗した終了済みジョブの数 (デフォルトは 1 に設定)。
- ⑧ ジョブテンプレート。これはジョブの例と同様です。
- ⑨ この cron ジョブで生成されるジョブのラベルを設定します。
- ⑩ Pod の再起動ポリシー。ジョブコントローラーには適用されません。



注記

.spec.successfulJobsHistoryLimit と **.spec.failedJobsHistoryLimit** のフィールドはオプションです。これらのフィールドでは、完了したジョブと失敗したジョブのそれぞれを保存する数を指定します。デフォルトで、これらのジョブの保存数はそれぞれ **3** と **1** に設定されます。制限に **0** を設定すると、終了後に対応する種類のジョブのいずれも保持しません。

2. cron ジョブを作成します。

```
$ oc create -f <file-name>.yaml
```



注記

oc create cronjob を使用して単一コマンドから cron ジョブを作成し、起動することもできます。以下のコマンドは直前の例で指定されている同じ cron ジョブを作成し、これを起動します。

```
$ oc create cronjob pi --image=perl --schedule='*/1 * * * *' -- perl -Mbignum=bpi -wle  
'print bpi(2000)'
```

oc create cronjob で、**--schedule** オプションは [cron 形式](#) のスケジュールを受け入れます。

第6章 ノードの使用

6.1. OPENSIFT CONTAINER PLATFORM クラスター内のノードの閲覧とリスト表示

クラスターのすべてのノードをリスト表示し、ステータスや経過時間、メモリー使用量などの情報およびノードの詳細を取得できます。

ノード管理の操作を実行すると、CLI は実際のノードホストの表現であるノードオブジェクトと対話します。マスターはノードオブジェクトの情報をを使用してヘルスチェックでノードを検証します。

6.1.1. クラスター内のすべてのノードのリスト表示について

クラスター内のノードに関する詳細な情報を取得できます。

- 以下のコマンドは、すべてのノードをリスト表示します。

```
$ oc get nodes
```

以下の例は、正常なノードを持つクラスターです。

```
$ oc get nodes
```

出力例

NAME	STATUS	ROLES	AGE	VERSION
master.example.com	Ready	master	7h	v1.25.0
node1.example.com	Ready	worker	7h	v1.25.0
node2.example.com	Ready	worker	7h	v1.25.0

以下の例は、正常でないノードが1つ含まれるクラスターです。

```
$ oc get nodes
```

出力例

NAME	STATUS	ROLES	AGE	VERSION
master.example.com	Ready	master	7h	v1.25.0
node1.example.com	NotReady,SchedulingDisabled	worker	7h	v1.25.0
node2.example.com	Ready	worker	7h	v1.25.0

NotReady ステータスをトリガーする条件は、このセクションの後半で説明します。

- **-o wide** オプションは、ノードに関する追加情報を提供します。

```
$ oc get nodes -o wide
```

出力例

NAME	STATUS	ROLES	AGE	VERSION	INTERNAL-IP	EXTERNAL-IP
OS-IMAGE				KERNEL-VERSION		CONTAINER-

RUNTIME

```

master.example.com Ready master 171m v1.25.0 10.0.129.108 <none> Red Hat
Enterprise Linux CoreOS 48.83.202103210901-0 (Ootpa) 4.18.0-240.15.1.el8_3.x86_64
cri-o://1.25.0-30.rhaos4.10.gitf2f339d.el8-dev
node1.example.com Ready worker 72m v1.25.0 10.0.129.222 <none> Red Hat
Enterprise Linux CoreOS 48.83.202103210901-0 (Ootpa) 4.18.0-240.15.1.el8_3.x86_64
cri-o://1.25.0-30.rhaos4.10.gitf2f339d.el8-dev
node2.example.com Ready worker 164m v1.25.0 10.0.142.150 <none> Red Hat
Enterprise Linux CoreOS 48.83.202103210901-0 (Ootpa) 4.18.0-240.15.1.el8_3.x86_64
cri-o://1.25.0-30.rhaos4.10.gitf2f339d.el8-dev

```

- 以下のコマンドは、単一のノードに関する情報をリスト表示します。

```
$ oc get node <node>
```

以下に例を示します。

```
$ oc get node node1.example.com
```

出力例

NAME	STATUS	ROLES	AGE	VERSION
node1.example.com	Ready	worker	7h	v1.25.0

- 以下のコマンドを実行すると、現在の状態の理由を含む、特定ノードの詳細情報を取得できます。

```
$ oc describe node <node>
```

以下に例を示します。

```
$ oc describe node node1.example.com
```

出力例

```

Name:          node1.example.com ❶
Roles:         worker ❷
Labels:        beta.kubernetes.io/arch=amd64 ❸
               beta.kubernetes.io/instance-type=m4.large
               beta.kubernetes.io/os=linux
               failure-domain.beta.kubernetes.io/region=us-east-2
               failure-domain.beta.kubernetes.io/zone=us-east-2a
               kubernetes.io/hostname=ip-10-0-140-16
               node-role.kubernetes.io/worker=
Annotations:   cluster.k8s.io/machine: openshift-machine-api/ahardin-worker-us-east-2a-
               q5dzc ❹
               machineconfiguration.openshift.io/currentConfig: worker-
               309c228e8b3a92e2235edd544c62fea8
               machineconfiguration.openshift.io/desiredConfig: worker-
               309c228e8b3a92e2235edd544c62fea8
               machineconfiguration.openshift.io/state: Done
               volumes.kubernetes.io/controller-managed-attach-detach: true
CreationTimestamp: Wed, 13 Feb 2019 11:05:57 -0500

```

```

Taints:          <none> 5
Unschedulable:   false
Conditions:      6
  Type           Status LastHeartbeatTime           LastTransitionTime           Reason
Message
-----
  OutOfDisk      False  Wed, 13 Feb 2019 15:09:42 -0500  Wed, 13 Feb 2019 11:05:57 -
0500  KubeletHasSufficientDisk  kubelet has sufficient disk space available
  MemoryPressure False  Wed, 13 Feb 2019 15:09:42 -0500  Wed, 13 Feb 2019 11:05:57
-0500  KubeletHasSufficientMemory  kubelet has sufficient memory available
  DiskPressure   False  Wed, 13 Feb 2019 15:09:42 -0500  Wed, 13 Feb 2019 11:05:57 -
0500  KubeletHasNoDiskPressure  kubelet has no disk pressure
  PIDPressure    False  Wed, 13 Feb 2019 15:09:42 -0500  Wed, 13 Feb 2019 11:05:57 -
0500  KubeletHasSufficientPID  kubelet has sufficient PID available
  Ready          True   Wed, 13 Feb 2019 15:09:42 -0500  Wed, 13 Feb 2019 11:07:09 -0500
KubeletReady          kubelet is posting ready status
Addresses:      7
  InternalIP:    10.0.140.16
  InternalDNS:    ip-10-0-140-16.us-east-2.compute.internal
  Hostname:      ip-10-0-140-16.us-east-2.compute.internal
Capacity:      8
  attachable-volumes-aws-ebs: 39
  cpu:            2
  hugepages-1Gi:  0
  hugepages-2Mi:  0
  memory:         8172516Ki
  pods:           250
Allocatable:
  attachable-volumes-aws-ebs: 39
  cpu:              1500m
  hugepages-1Gi:    0
  hugepages-2Mi:    0
  memory:           7558116Ki
  pods:             250
System Info:   9
  Machine ID:    63787c9534c24fde9a0cde35c13f1f66
  System UUID:   EC22BF97-A006-4A58-6AF8-0A38DEEA122A
  Boot ID:       f24ad37d-2594-46b4-8830-7f7555918325
  Kernel Version: 3.10.0-957.5.1.el7.x86_64
  OS Image:      Red Hat Enterprise Linux CoreOS 410.8.20190520.0 (Ootpa)
  Operating System: linux
  Architecture:  amd64
  Container Runtime Version: cri-o://1.25.0-0.6.dev.rhaos4.3.git9ad059b.el8-rc2
  Kubelet Version: v1.25.0
  Kube-Proxy Version: v1.25.0
  PodCIDR:        10.128.4.0/24
  ProviderID:      aws:///us-east-2a/i-04e87b31dc6b3e171
Non-terminated Pods: (12 in total) 10
  Namespace           Name           CPU Requests  CPU Limits
Memory Requests  Memory Limits
-----
  openshift-cluster-node-tuning-operator tuned-hdl5q    0 (0%)      0 (0%)      0
(0%)      0 (0%)
  openshift-dns        dns-default-l69zr 0 (0%)      0 (0%)      0 (0%)

```

```

0 (0%)
openshift-image-registry      node-ca-9hmcg                0 (0%)    0 (0%)    0
(0%)      0 (0%)
openshift-ingress             router-default-76455c45c-c5ptv  0 (0%)    0 (0%)    0
(0%)      0 (0%)
openshift-machine-config-operator  machine-config-daemon-cvqw9      20m (1%)    0
(0%)      50Mi (0%)    0 (0%)
openshift-marketplace         community-operators-f67fh        0 (0%)    0 (0%)
0 (0%)      0 (0%)
openshift-monitoring           alertmanager-main-0              50m (3%)    50m (3%)
210Mi (2%)    10Mi (0%)
openshift-monitoring           node-exporter-l7q8d              10m (0%)    20m (1%)
20Mi (0%)    40Mi (0%)
openshift-monitoring           prometheus-adapter-75d769c874-hvb85  0 (0%)    0
(0%)      0 (0%)    0 (0%)
openshift-multus               multus-kw8w5                     0 (0%)    0 (0%)    0 (0%)
0 (0%)
openshift-sdn                  ovs-t4dsn                       100m (6%)    0 (0%)    300Mi
(4%)      0 (0%)
openshift-sdn                  sdn-g79hg                       100m (6%)    0 (0%)    200Mi
(2%)      0 (0%)

```

Allocated resources:

(Total limits may be over 100 percent, i.e., overcommitted.)

Resource	Requests	Limits
cpu	380m (25%)	270m (18%)
memory	880Mi (11%)	250Mi (3%)
attachable-volumes-aws-ebs	0	0

Events:

11

Type	Reason	Age	From	Message
Normal	NodeHasSufficientPID	6d (x5 over 6d)	kubelet, m01.example.com	Node m01.example.com status is now: NodeHasSufficientPID
Normal	NodeAllocatableEnforced	6d	kubelet, m01.example.com	Updated Node Allocatable limit across pods
Normal	NodeHasSufficientMemory	6d (x6 over 6d)	kubelet, m01.example.com	Node m01.example.com status is now: NodeHasSufficientMemory
Normal	NodeHasNoDiskPressure	6d (x6 over 6d)	kubelet, m01.example.com	Node m01.example.com status is now: NodeHasNoDiskPressure
Normal	NodeHasSufficientDisk	6d (x6 over 6d)	kubelet, m01.example.com	Node m01.example.com status is now: NodeHasSufficientDisk
Normal	NodeHasSufficientPID	6d	kubelet, m01.example.com	Node m01.example.com status is now: NodeHasSufficientPID
Normal	Starting	6d	kubelet, m01.example.com	Starting kubelet.

#...

- 1 ノードの名前。
- 2 ノードのロール (**master** または **worker** のいずれか)。
- 3 ノードに適用されたラベル。
- 4 ノードに適用されるアノテーション。
- 5 ノードに適用された taint。

- 6 ノードの状態およびステータス。**conditions** スタンザには、**Ready**、**PIDPressure**、**MemoryPressure**、**DiskPressure**、および **OutOfDisk** ステータスがリスト表示されます。これらの状態は、このセクションの後半で説明します。
- 7 ノードの IP アドレスとホスト名。
- 8 Pod のリソースと割り当て可能なリソース。
- 9 ノードホストに関する情報。
- 10 ノードの Pod。
- 11 ノードが報告したイベント。



注記

新しく作成されたマスターノードや更新されたマスターノードに、コントロールプレーンラベルは自動的に追加されません。ノードにコントロールプレーンラベルを使用する必要がある場合は、ラベルを手動で設定できます。詳細は、[関連資料](#) セクションの **ノードのラベルの更新方法** を参照してください。

ノードの情報の中でも、とりわけ以下のノードの状態がこのセクションで説明されるコマンドの出力に表示されます。

表6.1 ノードの状態

条件	説明
Ready	true の場合、ノードは正常であり、Pod を受け入れることのできる準備状態にあります。 false の場合、ノードは正常ではなく、Pod を受け入れません。 unknown の場合、ノードコントローラーは node-monitor-grace-period (デフォルトは 40 秒) の間にハートビートをノードから受信しませんでした。
DiskPressure	true の場合、ディスク容量は低くなります。
MemoryPressure	true の場合、ノードのメモリーは低くなります。
PIDPressure	true の場合、ノードのプロセスが多すぎます。
OutOfDisk	true の場合、ノードには新しい Pod を追加するためのノード上の空きスペースが十分にありません。
NetworkUnavailable	true の場合、ノードのネットワークは正しく設定されていません。
NotReady	true の場合、コンテナのランタイムやネットワークなど基本のコンポーネントのいずれかに問題が発生しているか、それらがまだ設定されていません。
SchedulingDisabled	ノードに配置するように Pod をスケジュールすることができません。

関連情報

- [ノードでラベルを更新する方法について](#)

6.1.2. クラスターでのノード上の Pod のリスト表示

特定のノード上のすべての Pod をリスト表示できます。

手順

- 選択したノードのすべてまたは選択した Pod をリスト表示するには、以下を実行します。

```
$ oc get pod --selector=<nodeSelector>
```

```
$ oc get pod --selector=kubernetes.io/os
```

または、以下を実行します。

```
$ oc get pod -l=<nodeSelector>
```

```
$ oc get pod -l kubernetes.io/os=linux
```

- 終了した Pod を含む、特定のノード上のすべての Pod をリスト表示するには、以下を実行します。

```
$ oc get pod --all-namespaces --field-selector=spec.nodeName=<nodename>
```

6.1.3. ノードのメモリーと CPU 使用統計の表示

コンテナのランタイム環境を提供する、ノードに関する使用状況の統計を表示できます。これらの使用状況の統計には CPU、メモリー、およびストレージの消費量が含まれます。

前提条件

- 使用状況の統計を表示するには、**cluster-reader** 権限が必要です。
- 使用状況の統計を表示するには、メトリクスをインストールしている必要があります。

手順

- 使用状況の統計を表示するには、以下を実行します。

```
$ oc adm top nodes
```

出力例

NAME	CPU(cores)	CPU%	MEMORY(bytes)	MEMORY%
ip-10-0-12-143.ec2.compute.internal	1503m	100%	4533Mi	61%
ip-10-0-132-16.ec2.compute.internal	76m	5%	1391Mi	18%
ip-10-0-140-137.ec2.compute.internal	398m	26%	2473Mi	33%
ip-10-0-142-44.ec2.compute.internal	656m	43%	6119Mi	82%

```
ip-10-0-146-165.ec2.compute.internal 188m    12%    3367Mi    45%
ip-10-0-19-62.ec2.compute.internal  896m    59%    5754Mi    77%
ip-10-0-44-193.ec2.compute.internal  632m    42%    5349Mi    72%
```

- ラベルの付いたノードの使用状況の統計を表示するには、以下を実行します。

```
$ oc adm top node --selector=
```

フィルターに使用するセレクター (ラベルクエリー) を選択する必要があります。=、==、および != をサポートします。

6.2. ノードの使用

管理者は、複数のタスクを実行して、クラスターを効率化できます。

6.2.1. ノード上の Pod を退避させる方法

Pod を退避させると、所定のノードからすべての Pod または選択した Pod を移行できます。

退避させることができるのは、レプリケーションコントローラーが管理している Pod のみです。レプリケーションコントローラーは、他のノードに新しい Pod を作成し、指定されたノードから既存の Pod を削除します。

ベア Pod、つまりレプリケーションコントローラーが管理していない Pod はデフォルトで影響を受けません。Pod セレクターを指定すると Pod のサブセットを退避できます。Pod セレクターはラベルに基づくので、指定したラベルを持つすべての Pod を退避できます。

手順

- Pod の退避を実行する前に、ノードをスケジュール対象外としてマークします。
 - ノードをスケジューリング対象外としてマークします。

```
$ oc adm cordon <node1>
```

出力例

```
node/<node1> cordoned
```

- ノードのステータスが **Ready,SchedulingDisabled** であることを確認します。

```
$ oc get node <node1>
```

出力例

```
NAME          STATUS          ROLES    AGE    VERSION
<node1>      Ready,SchedulingDisabled  worker   1d     v1.25.0
```

- 以下の方法のいずれかを使用して Pod を退避します。

- 1つ以上のノードで、すべてまたは選択した Pod を退避します。

```
$ oc adm drain <node1> <node2> [--pod-selector=<pod_selector>]
```

- **--force** オプションを使用してベア Pod の削除を強制的に実行します。**true** に設定されると、Pod がレプリケーションコントローラー、レプリカセット、ジョブ、デーモンセット、またはステートフルセットで管理されていない場合でも削除が実行されます。

```
$ oc adm drain <node1> <node2> --force=true
```

- **--grace-period** を使用して、各 Pod を正常に終了するための期間 (秒単位) を設定します。負の値の場合には、Pod に指定されるデフォルト値が使用されます。

```
$ oc adm drain <node1> <node2> --grace-period=-1
```

- **true** に設定された **--ignore-daemonsets** フラグを使用してデーモンセットが管理する Pod を無視します。

```
$ oc adm drain <node1> <node2> --ignore-daemonsets=true
```

- **--timeout** を使用して、中止する前の待機期間を設定します。値 **0** は無限の時間を設定します。

```
$ oc adm drain <node1> <node2> --timeout=5s
```

- **--delete-emptydir-data** フラグを **true** に設定して、**emptyDir** ボリュームを使用する Pod がある場合にも Pod を削除します。ローカルデータはノードがドレイン (解放) される場合に削除されます。

```
$ oc adm drain <node1> <node2> --delete-emptydir-data=true
```

- **true** に設定された **--dry-run** オプションを使用して、実際に退避を実行せずに移行するオブジェクトをリスト表示します。

```
$ oc adm drain <node1> <node2> --dry-run=true
```

特定のノード名 (例: **<node1> <node2>**) を指定する代わりに、**--selector=<node_selector>** オプションを使用し、選択したノードで Pod を退避することができます。

3. 完了したら、ノードにスケジュール対象のマークを付けます。

```
$ oc adm uncordon <node1>
```

6.2.2. ノードでラベルを更新する方法について

ノード上の任意のラベルを更新できます。

ノードラベルは、ノードがマシンによってバックアップされている場合でも、ノードが削除されると永続しません。



注記

MachineSet への変更は、コンピュータマシンセットが所有する既存のマシンには適用されません。たとえば、編集されたか、既存の **MachineSet** に追加されたラベルは、マシンセットに関連付けられた既存マシンおよびノードには伝播しません。

- 以下のコマンドは、ノードのラベルを追加または更新します。

```
$ oc label node <node> <key_1>=<value_1> ... <key_n>=<value_n>
```

以下に例を示します。

```
$ oc label nodes webconsole-7f7f6 unhealthy=true
```

ヒント

以下の YAML を適用してラベルを適用することもできます。

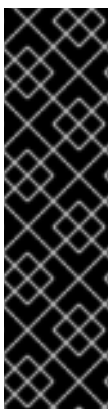
```
kind: Node
apiVersion: v1
metadata:
  name: webconsole-7f7f6
  labels:
    unhealthy: 'true'
#...
```

- 以下のコマンドは、namespace 内のすべての Pod を更新します。

```
$ oc label pods --all <key_1>=<value_1>
```

以下に例を示します。

```
$ oc label pods --all status=unhealthy
```



重要

OpenShift Container Platform 4.12 以降の新しくインストールされたクラスターには、コントロールプレーンノードに **node-role.kubernetes.io/control-plane** ラベルと **node-role.kubernetes.io/master** ラベルの両方がデフォルトで含まれています。

OpenShift Container Platform バージョン 4.12 より前では、**node-role.kubernetes.io/control-plane** ラベルはデフォルトでは追加されません。したがって、以前のバージョンからアップグレードしたクラスターのコントロールプレーンノードに、**node-role.kubernetes.io/control-plane** ラベルを手動で追加する必要があります。

6.2.3. ノードをスケジュール対象外 (Unschedulable) またはスケジュール対象 (Schedulable) としてマークする方法

デフォルトで、**Ready** ステータスの正常なノードはスケジュール対象としてマークされます。つまり、新規 Pod をこのノードに配置できます。手動でノードをスケジュール対象外としてマークすると、新規 Pod のノードでのスケジュールがブロックされます。ノード上の既存 Pod には影響がありません。

- 以下のコマンドは、ノードをスケジュール対象外としてマークします。

出力例

```
$ oc adm cordon <node>
```

以下に例を示します。

```
$ oc adm cordon node1.example.com
```

出力例

```
node/node1.example.com cordoned
```

NAME	LABELS	STATUS
node1.example.com	kubernetes.io/hostname=node1.example.com	Ready,SchedulingDisabled

- 以下のコマンドは、現時点でスケジュール対象外のノードをスケジュール対象としてマークします。

```
$ oc adm uncordon <node1>
```

または、特定のノード名 (たとえば **<node>**) を指定する代わりに、**--selector=**<node_selector>**** オプションを使用して選択したノードをスケジュール対象またはスケジュール対象外としてマークすることができます。

6.2.4. アプリケーション Pod をドレインせずにノードを再起動した場合の単一ノード OpenShift クラスターでのエラーの処理

単一ノードの OpenShift クラスターおよび OpenShift Container Platform クラスター一般では、最初にノードをドレインせずにノードの再起動が発生してしまう可能性があります。これは、デバイスを要求するアプリケーション Pod が **UnexpectedAdmissionError** エラーで失敗した場合に発生する可能性があります。**Deployment**、**ReplicaSet**、または **DaemonSet** エラーが報告されるのは、これらのデバイスを必要とするアプリケーション Pod が、それらのデバイスにサービスを提供する Pod より前に開始されるためです。Pod の再起動の順序を制御できません。

この動作は想定範囲内ですが、正常にデプロイできなかった場合でも、Pod がクラスター上に残る可能性があります。Pod は、引き続き **UnexpectedAdmissionError** を報告します。この問題は、アプリケーション Pod が通常 **Deployment**、**ReplicaSet**、または **DaemonSet** に含まれるため、軽減されます。Pod がこのエラー状態にある場合は、別のインスタンスが実行されているはずなので、ほとんど問題はありません。**Deployment**、**ReplicaSet**、または **DaemonSet** に Pod が属していれば、後続の Pod の正常な作成と実行が保証され、アプリケーションのデプロイも正常に行われます。

このような Pod が正常に終了するように、アップストリームで作業が進行されます。この作業が解決されるまで、単一ノードの OpenShift クラスターで失敗した Pod を削除するには、以下のコマンドを実行します。

```
$ oc delete pods --field-selector status.phase=Failed -n <POD_NAMESPACE>
```



注記

単一ノードの OpenShift クラスターでは、ノードをドレインするオプションは利用できません。

関連情報

- [ノード上の Pod を退避させる方法](#)

6.2.5. ノードの削除

6.2.5.1. クラスターからのノードの削除

OpenShift Container Platform クラスターからノードを削除するには、適切な **MachineSet** オブジェクトをスケールダウンします。



重要

クラスターがクラウドプロバイダーと統合されている場合、ノードを削除するには対応するマシンを削除する必要があります。このタスクに **oc delete node** コマンドは使用しないでください。

CLI を使用してノードを削除する場合、ノードオブジェクトは Kubernetes で削除されますが、ノード自体にある Pod は削除されません。レプリケーションコントローラーで管理されていないベア Pod は、OpenShift Container Platform からアクセスできなくなります。レプリケーションコントローラーで管理されるベア Pod は、他の利用可能なノードに再スケジュールされます。ローカルのマニフェスト Pod は削除する必要があります。



注記

ベアメタルでクラスターを実行している場合、**MachineSet** オブジェクトを編集してノードを削除することはできません。コンピュータマシンセットは、クラスターがクラウドプロバイダーに統合されている場合にのみ利用できます。代わりに、ノードを手作業で削除する前に、ノードをスケジュール解除し、ドレイン (解放) する必要があります。

手順

1. 次のコマンドを実行して、クラスター内のコンピュータマシンセットを表示します。

```
$ oc get machinesets -n openshift-machine-api
```

コンピュータマシンセットは、**<cluster-id>-worker-<aws-region-az>** の形式で一覧表示されます。

2. 次のいずれかの方法で、コンピュータマシンセットをスケールダウンします。

- 次のコマンドを実行して、スケールダウンするレプリカ数を指定します。

```
$ oc scale --replicas=2 machineset <machine-set-name> -n openshift-machine-api
```

- 次のコマンドを実行して、コンピュータマシンセットのカスタムリソースを編集します。

```
$ oc edit machineset <machine-set-name> -n openshift-machine-api
```

出力例

```
apiVersion: machine.openshift.io/v1beta1
kind: MachineSet
metadata:
  # ...
  name: <machine-set-name>
  namespace: openshift-machine-api
  # ...
spec:
  replicas: 2 1
  # ...
```

- 1** スケールダウンするレプリカ数を指定します。

関連情報

- [コンピュートマシンセットの手動スケーリング](#)

6.2.5.2. ベアメタルクラスターからのノードの削除

CLI を使用してノードを削除する場合、ノードオブジェクトは Kubernetes で削除されますが、ノード自体にある Pod は削除されません。レプリケーションコントローラーで管理されないベア Pod は、OpenShift Container Platform からアクセスできなくなります。レプリケーションコントローラーで管理されるベア Pod は、他の利用可能なノードに再スケジュールされます。ローカルのマニフェスト Pod は削除する必要があります。

手順

以下の手順を実行して、ベアメタルで実行されている OpenShift Container Platform クラスターからノードを削除します。

1. ノードをスケジューリング対象外としてマークします。

```
$ oc adm cordon <node_name>
```

2. ノード上のすべての Pod の drain (Pod の退避) を実行します。

```
$ oc adm drain <node_name> --force=true
```

このステップは、ノードがオフラインまたは応答しない場合に失敗する可能性があります。ノードが応答しない場合でも、共有ストレージに書き込むワークロードを実行している可能性があります。データの破損を防ぐには、続行する前に物理ハードウェアの電源を切ります。

3. クラスターからノードを削除します。

```
$ oc delete node <node_name>
```

ノードオブジェクトはクラスターから削除されていますが、これは再起動後や kubelet サービスが再起動される場合にクラスターに再び参加することができます。ノードとそのすべてのデータを永続的に削除するには、[ノードの使用を停止](#)する必要があります。

4. 物理ハードウェアを電源を切っている場合は、ノードがクラスターに再度加わるように、そのハードウェアを再びオンに切り替えます。

6.3. ノードの管理

OpenShift Container Platform は、KubeletConfig カスタムリソース (CR) を使用してノードの設定を管理します。**KubeletConfig** オブジェクトのインスタンスを作成すると、マネージドのマシン設定がノードの設定を上書きするために作成されます。



注記

リモートマシンにログインして設定を変更する方法はサポートされていません。

6.3.1. ノードの変更

クラスターまたはマシンプールを設定を変更するには、カスタムリソース定義 (CRD) または **kubeletConfig** オブジェクトを作成する必要があります。OpenShift Container Platform は、Machine Config Controller を使用して、変更をクラスターに適用するために CRD を使用して導入された変更を監視します。



注記

kubeletConfig オブジェクトのフィールドは、アップストリームの Kubernetes から kubelet に直接渡されるため、これらのフィールドの検証は kubelet 自体によって直接処理されます。これらのフィールドの有効な値は、関連する Kubernetes のドキュメントを参照してください。**kubeletConfig** オブジェクトの値が無効な場合、クラスターノードが使用できなくなる可能性があります。

手順

1. 設定する必要があるノードタイプの静的な CRD、Machine Config Pool に関連付けられたラベルを取得します。以下のいずれかの手順を実行します。
 - a. 必要なマシン設定プールの現在のラベルをチェックします。
以下に例を示します。

```
$ oc get machineconfigpool --show-labels
```

出力例

NAME	CONFIG	UPDATED	UPDATING	DEGRADED
master	rendered-master-e05b81f5ca4db1d249a1bf32f9ec24fd	True	False	
False	operator.machineconfiguration.openshift.io/required-for-upgrade=			
worker	rendered-worker-f50e78e1bc06d8e82327763145bfcf62	True	False	
False				

- b. 必要なマシン設定プールにカスタムラベルを追加します。
以下に例を示します。

```
$ oc label machineconfigpool worker custom-kubelet=enabled
```

2. 設定の変更に **kubeletconfig** カスタムリソース (CR) を作成します。
以下に例を示します。

custom-config CR の設定例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: custom-config ❶
spec:
  machineConfigPoolSelector:
    matchLabels:
      custom-kubelet: enabled ❷
  kubeletConfig: ❸
    podsPerCore: 10
    maxPods: 250
    systemReserved:
      cpu: 2000m
      memory: 1Gi
#...
```

- ❶ CR に名前を割り当てます。
- ❷ 設定変更を適用するラベルを指定します。これは、マシン設定プールに追加するラベルになります。
- ❸ 変更する必要がある新しい値を指定します。

3. CR オブジェクトを作成します。

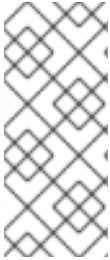
```
$ oc create -f <file-name>
```

以下に例を示します。

```
$ oc create -f master-kube-config.yaml
```

ほとんどの [Kubelet 設定オプション](#) はユーザーが設定できます。以下のオプションは上書きが許可されていません。

- CgroupDriver
- ClusterDNS
- ClusterDomain
- StaticPodPath

**注記**

単一ノードに 50 を超えるイメージが含まれている場合、Pod のスケジューリングがノード間で不均衡になる可能性があります。これは、ノード上のイメージのリストがデフォルトで 50 に短縮されているためです。**KubeletConfig** オブジェクトを編集し、**nodeStatusMaxImages** の値を **-1** に設定して、イメージの制限を無効にすることができます。

6.3.2. スケジュール対象としてのコントロールプレーンノードの設定

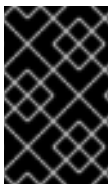
コントロールプレーンノードをスケジュール可能に設定できます。つまり、新しい Pod をマスターノードに配置できます。デフォルトでは、コントロールプレーンノードはスケジュール対象ではありません。

マスターをスケジュール対象 (Schedulable) に設定できますが、ワーカーノードを保持する必要があります。

**注記**

ワーカーノードのない OpenShift Container Platform をベアメタルクラスターにデプロイできます。この場合、コントロールプレーンノードはデフォルトでスケジュール対象としてマークされます。

mastersSchedulable フィールドを設定することで、コントロールプレーンノードをスケジュール対象として許可または禁止できます。

**重要**

コントロールプレーンノードをデフォルトのスケジュール不可からスケジュール可に設定するには、追加のサブスクリプションが必要です。これは、コントロールプレーンノードがワーカーノードになるためです。

手順

1. **schedulers.config.openshift.io** リソースを編集します。

```
$ oc edit schedulers.config.openshift.io cluster
```

2. **mastersSchedulable** フィールドを設定します。

```
apiVersion: config.openshift.io/v1
kind: Scheduler
metadata:
  creationTimestamp: "2019-09-10T03:04:05Z"
  generation: 1
  name: cluster
  resourceVersion: "433"
  selfLink: /apis/config.openshift.io/v1/schedulers/cluster
  uid: a636d30a-d377-11e9-88d4-0a60097bee62
spec:
  mastersSchedulable: false 1
status: {}
#...
```

- 1 コントロールプレーンノードがスケジューラ対象 (Schedulable) になることを許可する場合は **true** に設定し、コントロールプレーンノードがスケジューラ対象になることを拒否する場合は、**false** に設定します。

3. 変更を適用するためにファイルを保存します。

6.3.3. SELinux ブール値の設定

OpenShift Container Platform を使用すると、Red Hat Enterprise Linux CoreOS(RHCOS) ノードで SELinux ブール値を有効または無効にできます。次の手順では、Machine Config Operator(MCO) を使用してノード上の SELinux ブール値を変更する方法を説明します。この手順では、ブール値の例として **container_manage_cgroup** を使用します。この値は、必要なブール値に変更できます。

前提条件

- OpenShift CLI (oc) がインストールされている。

手順

1. 次の例に示すように、**MachineConfig** オブジェクトを使用して新しい YAML ファイルを作成します。

```
apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfig
metadata:
  labels:
    machineconfiguration.openshift.io/role: worker
  name: 99-worker-setsebool
spec:
  config:
    ignition:
      version: 3.2.0
    systemd:
      units:
        - contents: |
            [Unit]
            Description=Set SELinux booleans
            Before=kubelet.service

            [Service]
            Type=oneshot
            ExecStart=/sbin/setsebool container_manage_cgroup=on
            RemainAfterExit=true

            [Install]
            WantedBy=multi-user.target graphical.target
          enabled: true
          name: setsebool.service
#...
```

2. 次のコマンドを実行して、新しい **MachineConfig** オブジェクトを作成します。

```
$ oc create -f 99-worker-setsebool.yaml
```



注記

MachineConfig オブジェクトに変更を適用すると、変更が適用された後、影響を受けるすべてのノードが正常に再起動します。

6.3.4. ノードへのカーネル引数の追加

特殊なケースとして、クラスターのノードセットにカーネル引数を追加する必要がある場合があります。これは十分に注意して実行する必要があり、設定する引数による影響を十分に理解している必要があります。

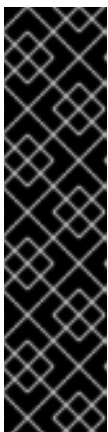


警告

カーネル引数を正しく使用しないと、システムが起動不可能になる可能性があります。

設定可能なカーネル引数の例には、以下が含まれます。

- **nosmt**: カーネルの対称マルチスレッド (SMT) を無効にします。マルチスレッドは、各 CPU の複数の論理スレッドを許可します。潜在的なクロススレッド攻撃に関連するリスクを減らすために、マルチテナント環境での **nosmt** の使用を検討できます。SMT を無効にすることは、基本的にパフォーマンスよりもセキュリティを重視する選択をしていることになります。
- **systemd.unified_cgroup_hierarchy**: [Linux コントロールグループバージョン 2](#) (cgroup v2) を有効にします。cgroup v2 は、カーネル [コントロールグループ](#) の次のバージョンであり、複数の改善を提供します。



重要

OpenShift Container Platform cgroups バージョン 2 のサポートはテクノロジープレビュー機能です。テクノロジープレビュー機能は、Red Hat 製品のサービスレベルアグリーメント (SLA) の対象外であり、機能的に完全ではないことがあります。Red Hat は、実稼働環境でこれらを使用することを推奨していません。テクノロジープレビュー機能は、最新の製品機能をいち早く提供して、開発段階で機能のテストを行い、フィードバックを提供していただくことを目的としています。

Red Hat のテクノロジープレビュー機能のサポート範囲に関する詳細は、[テクノロジープレビュー機能のサポート範囲](#) を参照してください。

- **enforcing=0**: SELinux (Security Enhanced Linux) を Permissive モードで実行するように設定します。Permissive モードでは、システムは、SELinux が読み込んだセキュリティポリシーを実行しているかのように動作します。これには、オブジェクトのラベル付けや、アクセスを拒否したエントリをログに出力するなどの動作が含まれますが、いずれの操作も拒否される訳ではありません。Permissive モードは、実稼働システムでの使用はサポートされませんが、デバッグには役に立ちます。

**警告**

実稼働環境の RHCOS での SELinux の無効化はサポートされていません。ノード上で SELinux が無効になったら、再プロビジョニングしてから実稼働クラスターに再び追加する必要があります。

カーネル引数の一覧と説明は、[Kernel.org カーネルパラメーター](https://www.kernel.org/doc/Documentation/kernel-parameters.txt) を参照してください。

次の手順では、以下を特定する **MachineConfig** オブジェクトを作成します。

- カーネル引数を追加する一連のマシン。この場合、ワーカーロールを持つマシン。
- 既存のカーネル引数の最後に追加されるカーネル引数。
- マシン設定のリストで変更が適用される場所を示すラベル。

前提条件

- 作業用の OpenShift Container Platform クラスターに対する管理者権限が必要です。

手順

1. OpenShift Container Platform クラスターの既存の **MachineConfig** をリスト表示し、マシン設定にラベルを付ける方法を判別します。

```
$ oc get MachineConfig
```

出力例

NAME	GENERATEDBYCONTROLLER
IGNITIONVERSION AGE	
00-master 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0
00-worker 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0
01-master-container-runtime 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
01-master-kubelet 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
01-worker-container-runtime 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
01-worker-kubelet 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
99-master-generated-registries 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
99-master-ssh 3.2.0 40m	
99-worker-generated-registries 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
99-worker-ssh 3.2.0 40m	
rendered-master-23e785de7587df95a4b517e0647e5ab7	

```
52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0      33m
rendered-worker-5d596d9293ca3ea80c896a1191735bb1
52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0      33m
```

2. カーネル引数を識別する **MachineConfig** オブジェクトファイルを作成します (例: **05-worker-kernelarg-selinuxpermissive.yaml**)。

```
apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfig
metadata:
  labels:
    machineconfiguration.openshift.io/role: worker 1
  name: 05-worker-kernelarg-selinuxpermissive 2
spec:
  kernelArguments:
    - enforcing=0 3
```

- 1** 新しいカーネル引数をワーカーノードのみに適用します。
- 2** マシン設定 (05) 内の適切な場所を特定するための名前が指定されます (SELinux permissive モードを設定するためにカーネル引数を追加します)。
- 3** 正確なカーネル引数を **enforcing=0** として特定します。

3. 新規のマシン設定を作成します。

```
$ oc create -f 05-worker-kernelarg-selinuxpermissive.yaml
```

4. マシン設定で新規の追加内容を確認します。

```
$ oc get MachineConfig
```

出力例

NAME	GENERATEDBY	CONTROLLER
IGNITIONVERSION AGE		
00-master	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	3.2.0
33m		
00-worker	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	3.2.0
33m		
01-master-container-runtime	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	
3.2.0 33m		
01-master-kubelet	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	
3.2.0 33m		
01-worker-container-runtime	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	
3.2.0 33m		
01-worker-kubelet	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	
3.2.0 33m		
05-worker-kernelarg-selinuxpermissive		3.2.0 105s
99-master-generated-registries	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	
3.2.0 33m		
99-master-ssh		3.2.0 40m
99-worker-generated-registries	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9	

```

3.2.0      33m
99-worker-ssh                                3.2.0      40m
rendered-master-23e785de7587df95a4b517e0647e5ab7
52dd3ba6a9a527fc3ab42afac8d12b693534c8c9  3.2.0      33m
rendered-worker-5d596d9293ca3ea80c896a1191735bb1
52dd3ba6a9a527fc3ab42afac8d12b693534c8c9  3.2.0      33m

```

5. ノードを確認します。

```
$ oc get nodes
```

出力例

```

NAME                                STATUS              ROLES    AGE   VERSION
ip-10-0-136-161.ec2.internal        Ready              worker   28m   v1.25.0
ip-10-0-136-243.ec2.internal        Ready              master   34m   v1.25.0
ip-10-0-141-105.ec2.internal        Ready,SchedulingDisabled worker   28m   v1.25.0
ip-10-0-142-249.ec2.internal        Ready              master   34m   v1.25.0
ip-10-0-153-11.ec2.internal         Ready              worker   28m   v1.25.0
ip-10-0-153-150.ec2.internal        Ready              master   34m   v1.25.0

```

変更が適用されているため、各ワーカーノードのスケジューリングが無効にされていることを確認できます。

6. ワーカーノードのいずれかに移動し、(ホストの **/proc/cmdline** 内の) カーネルコマンドライン引数をリスト表示して、カーネル引数が機能していることを確認します。

```
$ oc debug node/ip-10-0-141-105.ec2.internal
```

出力例

```

Starting pod/ip-10-0-141-105ec2internal-debug ...
To use host binaries, run `chroot /host`

sh-4.2# cat /host/proc/cmdline
BOOT_IMAGE=/ostree/rhcos-... console=tty0 console=ttyS0,115200n8
rootflags=defaults,prjquota rw root=UUID=fd0... ostree=/ostree/boot.0/rhcos/16...
coreos.oem.id=qemu coreos.oem.id=ec2 ignition.platform.id=ec2 enforcing=0

sh-4.2# exit

```

enforcing=0 引数が他のカーネル引数に追加されていることを確認できるはずです。

6.3.5. ノードでのスワップメモリー使用の有効化



重要

ノードでスワップメモリーの使用を有効にできるのは、テクノロジープレビュー機能のみです。テクノロジープレビュー機能は、Red Hat 製品のサービスレベルアグリーメント (SLA) の対象外であり、機能的に完全ではないことがあります。Red Hat は、実稼働環境でこれらを使用することを推奨していません。テクノロジープレビュー機能は、最新の製品機能をいち早く提供して、開発段階で機能のテストを行い、フィードバックを提供していただくことを目的としています。

Red Hat のテクノロジープレビュー機能のサポート範囲に関する詳細は、[テクノロジープレビュー機能のサポート範囲](#) を参照してください。

ノードごとに OpenShift Container Platform ワークロードの swap メモリー使用量を有効にすることができます。



警告

スワップメモリーを有効にすると、ワークロードのパフォーマンスとリソース不足の処理に悪影響を与える可能性があります。コントロールプレーンノードでスワップメモリーを有効化しないでください。

スワップメモリーを有効にするには、**kubeletconfig** カスタムリソース (CR) を作成して、**swapbehavior** パラメーターを設定します。制限付きまたは無制限のスワップメモリーを設定できます。

- 制限付き: **LimitedSwap** 値を使用して、使用できるスワップメモリーワークロード量を制限します。OpenShift Container Platform によって管理されていないノード上のワークロードは、引き続きスワップメモリーを使用できます。**LimitedSwap** の動作は、ノードが Linux コントロールグループ [バージョン 1\(cgroups v1\)](#) または [バージョン 2\(cgroup v2\)](#) で実行されているかどうかによって異なります。
 - cgroup v1: OpenShift Container Platform ワークロードは、設定されている場合、Pod のメモリー制限まで、メモリーとスワップの任意の組み合わせを使用できます。
 - cgroup v2: OpenShift Container Platform ワークロードはスワップメモリーを使用できません。
- Unlimited: **UnlimitedSwap** 値を使用して、ワークロードがシステム制限まで、要求したスワップメモリーを使用できるようにします。

この設定がないと、スワップメモリーが存在する場合は kubelet が開始されないため、ノードでスワップメモリーを有効にする前に、OpenShift Container Platform でスワップメモリーを有効にする必要があります。ノードにスワップメモリーが存在しない場合、OpenShift Container Platform でスワップメモリーを有効にしても効果はありません。

前提条件

- バージョン 4.10 以降を使用する OpenShift Container Platform クラスターが実行中である。
- 管理者権限を持つユーザーとしてクラスターにログインしている。

- クラスターで **TechPreviewNoUpgrade** 機能セットを有効にしている (ノード → クラスターの操作 → フィーチャーゲートを使用した機能の有効化 を参照)。



注記

TechPreviewNoUpgrade 機能セットを有効にすると元に戻すことができなくなり、マイナーバージョンの更新ができなくなります。これらの機能セットは、実稼働クラスターでは推奨されません。

- ノードで cgroup v2 が有効になっている場合は、**swapaccount = 1** カーネル引数を設定して、ノードでスワップアカウンティングを有効にする必要があります。

手順

1. スワップメモリーを許可するマシン設定プールにカスタムラベルを適用します。

```
$ oc label machineconfigpool worker kubelet-swap=enabled
```

2. カスタムリソース (CR) を作成し、スワップ設定を有効にして設定します。

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: swap-config
spec:
  machineConfigPoolSelector:
    matchLabels:
      kubelet-swap: enabled
  kubeletConfig:
    failSwapOn: false ①
    memorySwap:
      swapBehavior: LimitedSwap ②
#...
```

① **false** に設定すると、関連付けられたノードでスワップメモリーを使用できるようになります。スワップメモリーの使用を無効にするには、**true** に設定します。

② スワップメモリーの動作を指定します。指定しない場合、デフォルトは **LimitedSwap** です。

3. マシンでスワップメモリーを有効にします。

6.3.6. RHOSP ホストから別の RHOSP ホストへのコントロールプレーンノードの移行

コントロールプレーンノードをある Red Hat Open Stack Platform (RHOSP) ノードから別のノードに移動するスクリプトを実行できます。

前提条件

- 環境変数 **OS_CLOUD** は、**clouds.yaml** ファイル内の管理者認証情報を含む **clouds** エントリーを参照します。

- 環境変数 **KUBECONFIG** は、管理用 OpenShift Container Platform 認証情報を含む設定を参照します。

手順

- コマンドラインから、次のスクリプトを実行します。

```
#!/usr/bin/env bash

set -Eeuo pipefail

if [ $# -lt 1 ]; then
    echo "Usage: '$0 node_name'"
    exit 64
fi

# Check for admin OpenStack credentials
openstack server list --all-projects >/dev/null || { >&2 echo "The script needs OpenStack admin
credentials. Exiting"; exit 77; }

# Check for admin OpenShift credentials
oc adm top node >/dev/null || { >&2 echo "The script needs OpenShift admin credentials. Exiting"; exit
77; }

set -x

declare -r node_name="$1"
declare server_id
server_id="$(openstack server list --all-projects -f value -c ID -c Name | grep "$node_name" | cut -d ' '
-f1)"
readonly server_id

# Drain the node
oc adm cordon "$node_name"
oc adm drain "$node_name" --delete-emptydir-data --ignore-daemonsets --force

# Power off the server
oc debug "node/${node_name}" -- chroot /host shutdown -h 1

# Verify the server is shut off
until openstack server show "$server_id" -f value -c status | grep -q 'SHUTOFF'; do sleep 5; done

# Migrate the node
openstack server migrate --wait "$server_id"

# Resize the VM
openstack server resize confirm "$server_id"

# Wait for the resize confirm to finish
until openstack server show "$server_id" -f value -c status | grep -q 'SHUTOFF'; do sleep 5; done

# Restart the VM
openstack server start "$server_id"

# Wait for the node to show up as Ready:
until oc get node "$node_name" | grep -q "^[${node_name}][:space:]+\+Ready"; do sleep 5; done
```

```
# Uncordon the node
oc adm uncordon "$node_name"

# Wait for cluster operators to stabilize
until oc get co -o go-template='status: {{ range .items }}{{ range .status.conditions }}{{ if eq .type "Degraded" }}{{ if ne .status "False" }}DEGRADED{{ end }}{{ else if eq .type "Progressing" }}{{ if ne .status "False" }}PROGRESSING{{ end }}{{ else if eq .type "Available" }}{{ if ne .status "True" }}NOTAVAILABLE{{ end }}{{ end }}{{ end }}{{ end }}{{ end }}' | grep -qv \
(DEGRADED\|PROGRESSING\|NOTAVAILABLE)'; do sleep 5; done
```

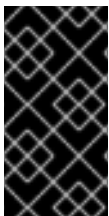
スクリプトが完了すると、コントロールプレーンマシンは新しい RHOSP ノードに移行されます。

6.4. ノードあたりの POD の最大数の管理

OpenShift Container Platform では、ノードのプロセッサコアの数に基づいて、ノードで実行可能な Pod の数、ハード制限、またはその両方を設定できます。両方のオプションを使用した場合、より低い値の方がノード上の Pod の数を制限します。

両方のオプションが使用されている場合、2つの値の低い方の値により、ノード上の Pod 数が制限されます。これらの値を超えると、以下の状態が生じる可能性があります。

- CPU 使用率の増大。
- Pod のスケジューリングの速度が遅くなる。
- (ノードのメモリー量によって) メモリー不足のシナリオが生じる可能性。
- IP アドレスのプールを消費する。
- リソースのオーバーコミット、およびこれによるアプリケーションのパフォーマンスの低下。



重要

Kubernetes では、単一コンテナを保持する Pod は実際には 2 つのコンテナを使用します。2 つ目のコンテナは実際のコンテナの起動前にネットワークを設定するために使用されます。そのため、10 の Pod を使用するシステムでは、実際には 20 のコンテナが実行されていることになります。



注記

クラウドプロバイダーからのディスク IOPS スロットリングは CRI-O および kubelet に影響を与える可能性があります。ノード上に多数の I/O 集約型 Pod が実行されている場合、それらはオーバーロードする可能性があります。ノード上のディスク I/O を監視し、ワークロード用に十分なスループットを持つボリュームを使用することが推奨されます。

podsPerCore パラメーターは、ノードのプロセッサコアの数に基づいて、ノードが実行できる Pod の数を設定します。たとえば、4 プロセッサコアを搭載したノードで **podsPerCore** が **10** に設定される場合、このノードで許可される Pod の最大数は **40** になります。

```
kubeletConfig:
  podsPerCore: 10
```

podsWithCore を **0** に設定すると、この制限が無効になります。デフォルトは **0** です。**podsWithCore** パラメーターの値は、**maxPods** パラメーターの値を超えることはできません。

maxPods パラメーターは、ノードのプロパティに関係なく、ノードが実行できる Pod の数を固定値に設定します。

```
kubeletConfig:
  maxPods: 250
```

6.4.1. ノードあたりの Pod の最大数の設定

podsWithCore および **maxPods** の 2 つのパラメーターはノードに対してスケジュールできる Pod の最大数を制御します。両方のオプションを使用した場合、より低い値の方がノード上の Pod の数を制限します。

たとえば、**podsWithCore** が 4 つのプロセッサコアを持つノード上で、**10** に設定されていると、ノード上で許容される Pod の最大数は 40 になります。

前提条件

1. 次のコマンドを入力して、設定するノードタイプの静的な **MachineConfigPool** CRD に関連付けられたラベルを取得します。

```
$ oc edit machineconfigpool <name>
```

以下に例を示します。

```
$ oc edit machineconfigpool worker
```

出力例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfigPool
metadata:
  creationTimestamp: "2022-11-16T15:34:25Z"
  generation: 4
  labels:
    pools.operator.machineconfiguration.openshift.io/worker: "" ❶
  name: worker
#...
```

- ❶ Labels の下にラベルが表示されます。

ヒント

ラベルが存在しない場合は、次のようなキー/値のペアを追加します。

```
$ oc label machineconfigpool worker custom-kubelet=small-pods
```

手順

1. 設定変更のためのカスタムリソース (CR) を作成します。

max-pods CR の設定例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: set-max-pods ❶
spec:
  machineConfigPoolSelector:
    matchLabels:
      pools.operator.machineconfiguration.openshift.io/worker: "" ❷
  kubeletConfig:
    podsPerCore: 10 ❸
    maxPods: 250 ❹
#...
```

- ❶ CR に名前を割り当てます。
- ❷ マシン設定プールからラベルを指定します。
- ❸ ノードがプロセッサコアの数に基づいて実行できる Pod の数を指定します。
- ❹ ノードのプロパティにかかわらず、ノードが実行できる Pod 数を固定値に指定します。



注記

podsPerCore を 0 に設定すると、この制限が無効になります。

上記の例では、**podsPerCore** のデフォルト値は **10** であり、**maxPods** のデフォルト値は **250** です。つまり、ノードのコア数が 25 以上でない限り、デフォルトにより **podsPerCore** が制限要素になります。

2. 以下のコマンドを実行して CR を作成します。

```
$ oc create -f <file_name>.yaml
```

検証

1. 変更が適用されるかどうかを確認するために、**MachineConfigPool** CRD を一覧表示します。変更が Machine Config Controller によって取得されると、**UPDATING** 列で **True** と報告されます。

```
$ oc get machineconfigpools
```

出力例

NAME	CONFIG	UPDATED	UPDATING	DEGRADED
master	master-9cc2c72f205e103bb534	False	False	False
worker	worker-8cecd1236b33ee3f8a5e	False	True	False

変更が完了すると、**UPDATED** 列で **True** と報告されます。

```
$ oc get machineconfigpools
```

出力例

NAME	CONFIG	UPDATED	UPDATING	DEGRADED
master	master-9cc2c72f205e103bb534	False	True	False
worker	worker-8cecd1236b33ee3f8a5e	True	False	False

6.5. NODE TUNING OPERATOR の使用

Node Tuning Operator を説明し、この Operator を使用し、Tuned デーモンのオーケストレーションを実行してノードレベルのチューニングを管理する方法を説明します。

Node Tuning Operator は、TuneD デーモンを調整することでノードレベルのチューニングを管理し、Performance Profile コントローラーを使用して低レイテンシーのパフォーマンスを実現するのに役立ちます。ほとんどの高パフォーマンスアプリケーションでは、一定レベルのカーネルのチューニングが必要です。Node Tuning Operator は、ノードレベルの `sysctl` の統一された管理インターフェイスをユーザーに提供し、ユーザーが指定するカスタムチューニングを追加できるよう柔軟性を提供します。

Operator は、コンテナ化された OpenShift Container Platform の TuneD デーモンを Kubernetes デーモンセットとして管理します。これにより、カスタムチューニング仕様が、デーモンが認識する形式でクラスターで実行されるすべてのコンテナ化された TuneD デーモンに渡されます。デーモンは、ノードごとに1つずつ、クラスターのすべてのノードで実行されます。

コンテナ化された TuneD デーモンによって適用されるノードレベルの設定は、プロファイルの変更をトリガーするイベントで、または終了シグナルの受信および処理によってコンテナ化された TuneD デーモンが正常に終了する際にロールバックされます。

Node Tuning Operator は、パフォーマンスプロファイルコントローラーを使用して自動チューニングを実装し、OpenShift Container Platform アプリケーションの低レイテンシーパフォーマンスを実現します。クラスター管理者は、以下のようなノードレベルの設定を定義するパフォーマンスプロファイルを設定します。

- カーネルを `kernel-rt` に更新します。
- ハウスキーピング用の CPU を選択します。
- 実行中のワークロード用の CPU を選択します。



注記

現在、CPU 負荷分散の無効化は `cgroup v2` ではサポートされていません。その結果、`cgroup v2` が有効になっている場合は、パフォーマンスプロファイルから望ましい動作が得られない可能性があります。パフォーマンスプロファイルを使用している場合は、`cgroup v2` を有効にすることは推奨されません。

Node Tuning Operator は、バージョン 4.1 以降における標準的な OpenShift Container Platform インストールの一部となっています。



注記

OpenShift Container Platform の以前のバージョンでは、Performance Addon Operator を使用して自動チューニングを実装し、OpenShift アプリケーションの低レイテンシーパフォーマンスを実現していました。OpenShift Container Platform 4.11 以降では、この機能は Node Tuning Operator の一部です。

6.5.1. Node Tuning Operator 仕様サンプルへのアクセス

このプロセスを使用して Node Tuning Operator 仕様サンプルにアクセスします。

手順

- 次のコマンドを実行して、Node Tuning Operator 仕様の例にアクセスします。

```
oc get tuned.tuned.openshift.io/default -o yaml -n openshift-cluster-node-tuning-operator
```

デフォルトの CR は、OpenShift Container Platform プラットフォームの標準的なノードレベルのチューニングを提供することを目的としており、Operator 管理の状態を設定するためにのみ変更できます。デフォルト CR へのその他のカスタム変更は、Operator によって上書きされます。カスタムチューニングの場合は、独自のチューニングされた CR を作成します。新規に作成された CR は、ノード/Pod ラベルおよびプロファイルの優先順位に基づいて OpenShift Container Platform ノードに適用されるデフォルトの CR およびカスタムチューニングと組み合わせられます。



警告

特定の状況で Pod ラベルのサポートは必要なチューニングを自動的に配信する便利な方法ですが、この方法は推奨されず、とくに大規模なクラスターにおいて注意が必要です。デフォルトの調整された CR は Pod ラベル一致のない状態で提供されます。カスタムプロファイルが Pod ラベル一致のある状態で作成される場合、この機能はその時点で有効になります。Pod ラベル機能は、Node Tuning Operator の将来のバージョンで非推奨になる予定です。

6.5.2. カスタムチューニング仕様

Operator のカスタムリソース (CR) には 2 つの重要なセクションがあります。1 つ目のセクションの **profile:** は TuneD プロファイルおよびそれらの名前のリストです。2 つ目の **recommend:** は、プロファイル選択ロジックを定義します。

複数のカスタムチューニング仕様は、Operator の namespace に複数の CR として共存できます。新規 CR の存在または古い CR の削除は Operator によって検出されます。既存のカスタムチューニング仕様はすべてマージされ、コンテナ化された TuneD デーモンの適切なオブジェクトは更新されます。

管理状態

Operator 管理の状態は、デフォルトの Tuned CR を調整して設定されます。デフォルトで、Operator は Managed 状態であり、**spec.managementState** フィールドはデフォルトの Tuned CR に表示されません。Operator Management 状態の有効な値は以下のとおりです。

- Managed: Operator は設定リソースが更新されるとそのオペランドを更新します。

- Unmanaged: Operator は設定リソースへの変更を無視します。
- Removed: Operator は Operator がプロビジョニングしたオペランドおよびリソースを削除します。

プロファイルデータ

profile: セクションは、TuneD プロファイルおよびそれらの名前をリスト表示します。

```
profile:
- name: tuned_profile_1
  data: |
    # TuneD profile specification
    [main]
    summary=Description of tuned_profile_1 profile

    [sysctl]
    net.ipv4.ip_forward=1
    # ... other sysctl's or other TuneD daemon plugins supported by the containerized TuneD

# ...

- name: tuned_profile_n
  data: |
    # TuneD profile specification
    [main]
    summary=Description of tuned_profile_n profile

    # tuned_profile_n profile settings
```

推奨プロファイル

profile: 選択ロジックは、CR の **recommend:** セクションによって定義されます。 **recommend:** セクションは、選択基準に基づくプロファイルの推奨項目のリストです。

```
recommend:
<recommend-item-1>
# ...
<recommend-item-n>
```

リストの個別項目:

```
- machineConfigLabels: ❶
  <mcLabels> ❷
  match: ❸
  <match> ❹
  priority: <priority> ❺
  profile: <tuned_profile_name> ❻
  operand: ❼
  debug: <bool> ❽
  tunedConfig:
    reapply_sysctl: <bool> ❾
```

- 1 オプション。
- 2 キー/値の **MachineConfig** ラベルのディクショナリー。キーは一意である必要があります。
- 3 省略する場合は、優先度の高いプロファイルが最初に一致するか、**machineConfigLabels** が設定されていない限り、プロファイルの一致が想定されます。
- 4 オプションのリスト。
- 5 プロファイルの順序付けの優先度。数値が小さいほど優先度が高くなります (0 が最も高い優先度になります)。
- 6 一致に適用する TuneD プロファイル。例: **tuned_profile_1**
- 7 オプションのオペランド設定。
- 8 TuneD デーモンのデバッグオンまたはオフを有効にします。オプションは、オンの場合は **true**、オフの場合は **false** です。デフォルトは **false** です。
- 9 TuneD デーモンの **reapply_sysctl** 機能をオンまたはオフにします。オプションは on で **true**、オフの場合は **false** です。

<match> は、以下のように再帰的に定義されるオプションの一覧です。

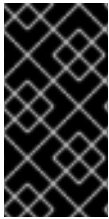
```
- label: <label_name> 1
  value: <label_value> 2
  type: <label_type> 3
  <match> 4
```

- 1 ノードまたは Pod のラベル名。
- 2 オプションのノードまたは Pod のラベルの値。省略されている場合も、<label_name> があるだけで一致条件を満たします。
- 3 オプションのオブジェクトタイプ (**node** または **pod**)。省略されている場合は、**node** が想定されます。
- 4 オプションの <match> リスト。

<match> が省略されない場合、ネストされたすべての <match> セクションが **true** に評価される必要もあります。そうでない場合には **false** が想定され、それぞれの <match> セクションのあるプロファイルは適用されず、推奨されません。そのため、ネスト化 (子の <match> セクション) は論理 AND 演算子として機能します。これとは逆に、<match> 一覧のいずれかの項目が一致する場合は、<match> の一覧全体が **true** に評価されます。そのため、リストは論理 OR 演算子として機能します。

machineConfigLabels が定義されている場合は、マシン設定プールベースのマッチングが指定の **recommend**: 一覧の項目に対してオンになります。<mcLabels> はマシン設定のラベルを指定します。マシン設定は、プロファイル <tuned_profile_name> にカーネル起動パラメーターなどのホスト設定を適用するために自動的に作成されます。この場合は、マシン設定セクターが <mcLabels> に一致するすべてのマシン設定プールを検索し、プロファイル <tuned_profile_name> を確認されるマシン設定プールが割り当てられるすべてのノードに設定する必要があります。マスターロールとワーカーのロールの両方を持つノードをターゲットにするには、マスターロールを使用する必要があります。

リスト項目の **match** および **machineConfigLabels** は論理 OR 演算子によって接続されます。**match** 項目は、最初にショートサーキット方式で評価されます。そのため、**true** と評価される場合、**machineConfigLabels** 項目は考慮されません。



重要

マシン設定プールベースのマッチングを使用する場合は、同じハードウェア設定を持つノードを同じマシン設定プールにグループ化することが推奨されます。この方法に従わない場合は、TuneD オペランドが同じマシン設定プールを共有する 2 つ以上のノードの競合するカーネルパラメーターを計算する可能性があります。

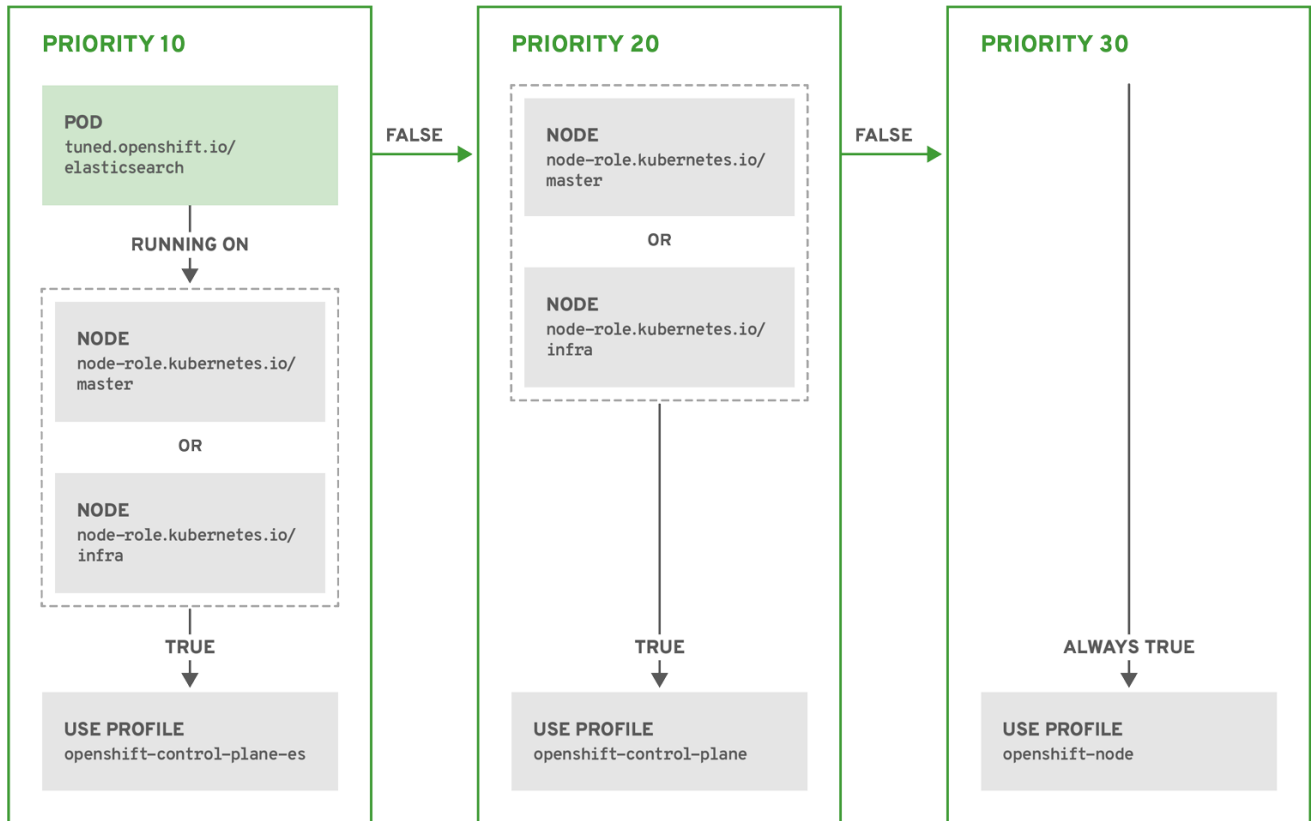
例: ノード/Pod ラベルベースのマッチング

```
- match:
  - label: tuned.openshift.io/elasticsearch
    match:
      - label: node-role.kubernetes.io/master
      - label: node-role.kubernetes.io/infra
    type: pod
  priority: 10
  profile: openshift-control-plane-es
- match:
  - label: node-role.kubernetes.io/master
  - label: node-role.kubernetes.io/infra
  priority: 20
  profile: openshift-control-plane
- priority: 30
  profile: openshift-node
```

上記のコンテナ化された TuneD デーモンの CR は、プロファイルの優先順位に基づいてその **recommend.conf** ファイルに変換されます。最も高い優先順位 (10) を持つプロファイルは **openshift-control-plane-es** であるため、これが最初に考慮されます。指定されたノードで実行されるコンテナ化された TuneD デーモンは、同じノードに **tuned.openshift.io/elasticsearch** ラベルが設定された Pod が実行されているかどうかを確認します。これがない場合は、<match> セクション全体が **false** として評価されます。このラベルを持つこのような Pod がある場合に、<match> セクションが **true** に評価されるようにするには、ノードラベルを **node-role.kubernetes.io/master** または **node-role.kubernetes.io/infra** にする必要もあります。

優先順位が 10 のプロファイルのラベルが一致した場合は、**openshift-control-plane-es** プロファイルが適用され、その他のプロファイルは考慮されません。ノード/Pod ラベルの組み合わせが一致しない場合は、2 番目に高い優先順位プロファイル (**openshift-control-plane**) が考慮されます。このプロファイルは、コンテナ化された TuneD Pod が **node-role.kubernetes.io/master** または **node-role.kubernetes.io/infra** ラベルを持つノードで実行される場合に適用されます。

最後に、プロファイル **openshift-node** には最低の優先順位である 30 が設定されます。これには <match> セクションがないため、常に一致します。これは、より高い優先順位の他のプロファイルが指定されたノードで一致しない場合に **openshift-node** プロファイルを設定するために、最低の優先順位のノードが適用される汎用的な (catch-all) プロファイルとして機能します。



OPENSIFT_10_0319

例: マシン設定プールベースのマッチング

```

apiVersion: tuned.openshift.io/v1
kind: Tuned
metadata:
  name: openshift-node-custom
  namespace: openshift-cluster-node-tuning-operator
spec:
  profile:
  - data: |
      [main]
      summary=Custom OpenShift node profile with an additional kernel parameter
      include=openshift-node
      [bootloader]
      cmdline_openshift_node_custom=+skew_tick=1
      name: openshift-node-custom

  recommend:
  - machineConfigLabels:
      machineconfiguration.openshift.io/role: "worker-custom"
    priority: 20
    profile: openshift-node-custom
  
```

ノードの再起動を最小限にするには、ターゲットノードにマシン設定プールのノードセクターが一致するラベルを使用してラベルを付け、上記の Tuned CR を作成してから、最後にカスタムのマシン設定プール自体を作成します。

クラウドプロバイダー固有の TuneD プロファイル

この機能により、すべてのクラウドプロバイダー固有のノードに、OpenShift Container Platform クラスター上の特定のクラウドプロバイダーに合わせて特別に調整された TuneD プロファイルを簡単に割り当てることができます。これは、追加のノードラベルを追加したり、ノードをマシン設定プールにグループ化したりせずに実行できます。

この機能は、`<cloud-provider>://<cloud-provider-specific-id>` の形式で `spec.providerID` ノードオブジェクト値を利用して、NTO オペランドコンテナの `<cloud-provider>` の値で `/var/lib/tuned/provider` ファイルを書き込みます。その後、このファイルのコンテンツは TuneD により、プロバイダー `provider-<cloud-provider>` プロファイル (存在する場合) を読み込むために使用されます。

`openshift-control-plane` および `openshift-node` プロファイルの両方の設定を継承する `openshift` プロファイルは、条件付きプロファイルの読み込みを使用してこの機能を使用するよう更新されるようになりました。NTO や TuneD はまだ、クラウドプロバイダー固有のプロファイルを提供していません。ただし、すべてのクラウドプロバイダー固有のクラスターノードに適用されるカスタムプロファイル `provider-<cloud-provider>` を作成することができます。

GCE クラウドプロバイダープロファイルの例

```
apiVersion: tuned.openshift.io/v1
kind: Tuned
metadata:
  name: provider-gce
  namespace: openshift-cluster-node-tuning-operator
spec:
  profile:
    - data: |
        [main]
        summary=GCE Cloud provider-specific profile
        # Your tuning for GCE Cloud provider goes here.
      name: provider-gce
```



注記

プロファイルの継承により、`provider-<cloud-provider>` プロファイルで指定された設定は、`openshift` プロファイルとその子プロファイルによって上書きされます。

6.5.3. クラスターに設定されるデフォルトのプロファイル

以下は、クラスターに設定されるデフォルトのプロファイルです。

```
apiVersion: tuned.openshift.io/v1
kind: Tuned
metadata:
  name: default
  namespace: openshift-cluster-node-tuning-operator
spec:
  profile:
    - data: |
        [main]
        summary=Optimize systems running OpenShift (provider specific parent profile)
        include=-provider-$(f:exec:cat:/var/lib/tuned/provider},openshift
      name: openshift
    recommend:
```

```
- profile: openshift-control-plane
  priority: 30
  match:
  - label: node-role.kubernetes.io/master
  - label: node-role.kubernetes.io/infra
- profile: openshift-node
  priority: 40
```

OpenShift Container Platform 4.9 以降では、すべての OpenShift TuneD プロファイルが TuneD パッケージに含まれています。**oc exec** コマンドを使用して、これらのプロファイルの内容を表示できます。

```
$ oc exec $tuned_pod -n openshift-cluster-node-tuning-operator -- find /usr/lib/tuned/openshift{-control-plane,-node} -name tuned.conf -exec grep -H ^ {} \;
```

6.5.4. サポートされている TuneD デーモンプラグイン

[main] セクションを除き、以下の TuneD プラグインは、Tuned CR の **profile:** セクションで定義されたカスタムプロファイルを使用する場合にサポートされます。

- audio
- cpu
- disk
- eeepc_she
- modules
- mounts
- net
- scheduler
- scsi_host
- selinux
- sysctl
- sysfs
- usb
- video
- vm
- bootloader

これらのプラグインの一部によって提供される動的チューニング機能の中に、サポートされていない機能があります。以下の TuneD プラグインは現時点でサポートされていません。

- script

- systemd



注記

TuneD ブートローダープラグインは、Red Hat Enterprise Linux CoreOS (RHCOS) ワーカーノードのみをサポートします。

関連情報

- [利用可能な TuneD プラグイン](#)
- [TuneD を使い始める](#)

6.6. ノードの修復、フェンシング、メンテナンス

カーネルのハングやネットワークインターフェイスコントローラー (NIC) の障害などをはじめとするノードレベルの障害が発生した場合、クラスターに必要な作業は減少せず、影響を受けたノードからのワークロードをどこかで再起動する必要があります。これらのワークロードに影響を与える障害は、データの損失、破損、またはその両方のリスクを伴います。ワークロードの復元 (**remediation**) とノードの復元を開始する前にノードを分離 (**fencing**) することが重要です。

ノードの修復、フェンシング、メンテナンスの詳細は、[Red Hat OpenShift のワークロードの可用性](#) を参照してください。

6.7. ノードの再起動について

プラットフォームで実行されているアプリケーションを停止せずにノードを再起動するには、まず Pod の退避を実行することが重要です。ルーティング階層によって可用性が高くなっている Pod には、何も実行する必要はありません。ストレージ (通常はデータベース) を必要とするその他の Pod には、1つの Pod が一時的にオフラインになってもそれらの Pod が作動状態を維持できることを確認する必要があります。ステートフルな Pod の回復性はアプリケーションごとに異なりますが、いずれの場合でも、ノードのアンチアフィニティー (node anti-affinity) を使用して Pod が使用可能なノードにわたって適切に分散するようにスケジューラーを設定することが重要になります。

別の課題として、ルーターやレジストリーのような重要なインフラストラクチャーを実行しているノードを処理する方法を検討する必要があります。同じノードの退避プロセスが適用されますが、一部のエッジケースを理解しておくことが重要です。

6.7.1. 重要なインフラストラクチャーを実行するノードの再起動について

ルーター Pod、レジストリー Pod、モニタリング Pod などの重要な OpenShift Container Platform インフラストラクチャーコンポーネントをホストするノードを再起動する場合、これらのコンポーネントを実行するために少なくとも3つのノードが利用可能であることを確認します。

以下のシナリオは、2つのノードのみが利用可能な場合に、どのように OpenShift Container Platform で実行されているアプリケーションでサービスの中断が生じ得るかを示しています。

- ノード A がスケジューリング対象外としてマークされており、すべての Pod の退避が行われている。
- このノードで実行されているレジストリー Pod がノード B に再デプロイされる。ノード B が両方のレジストリー Pod を実行しています。
- ノード B はスケジューリング対象外としてマークされ、退避が行われる。

- ノード B の 2 つの Pod エンドポイントを公開するサービスは、それらがノード A に再デプロイされるまでの短い期間にすべてのエンドポイントを失う。

インフラストラクチャーコンポーネントの 3 つのノードを使用する場合、このプロセスではサービスの中断が生じません。しかし、Pod のスケジューリングにより、退避してローテーションに戻される最後のノードにはレジストリー Pod がありません。他のノードのいずれかには 2 つのレジストリー Pod があります。3 番目のレジストリー Pod を最後のノードでスケジュールするには、Pod のアンチアフィニティーを使用してスケジューラーが同じノード上で 2 つのレジストリー Pod を見つけるのを防ぎます。

関連情報

- Pod のアンチアフィニティーの詳細は、[アフィニティールールとアンチアフィニティールール](#)を使用して、他の Pod を基準にして Pod を配置する を参照してください。

6.7.2. Pod のアンチアフィニティーを使用するノードの再起動

Pod のアンチアフィニティーは、ノードのアンチアフィニティーとは若干異なります。ノードのアンチアフィニティーの場合、Pod のデプロイ先となる適切な場所が他にない場合には違反が生じる可能性があります。Pod のアンチアフィニティーの場合は required (必須) または preferred (優先) のいずれかに設定できます。

これが有効になっていると、2 つのインフラストラクチャーノードのみが利用可能で、1 つのノードが再起動される場合に、コンテナイメージレジストリー Pod は他のノードで実行できなくなります。**oc get pods** は、適切なノードが利用可能になるまで Pod を Unready (準備が未完了) として報告します。ノードが利用可能になり、すべての Pod が Ready (準備ができています) 状態に戻ると、次のノードを再起動することができます。

手順

Pod のアンチアフィニティーを使用してノードを再起動するには、以下の手順を実行します。

1. ノードの仕様を編集して Pod のアンチアフィニティーを設定します。

```
apiVersion: v1
kind: Pod
metadata:
  name: with-pod-antiaffinity
spec:
  affinity:
    podAntiAffinity: ❶
    preferredDuringSchedulingIgnoredDuringExecution: ❷
  - weight: 100 ❸
    podAffinityTerm:
      labelSelector:
        matchExpressions:
          - key: registry ❹
            operator: In ❺
            values:
              - default
      topologyKey: kubernetes.io/hostname
#...
```

- ❶ Pod のアンチアフィニティーを設定するためのスタンザです。

- 2 preferred (優先) ルールを定義します。
- 3 preferred (優先) ルールの重みを指定します。最も高い重みを持つノードが優先されます。
- 4 アンチアフィニティルールが適用される時を決定する Pod ラベルの説明です。ラベルのキーおよび値を指定します。
- 5 演算子は、既存 Pod のラベルと新規 Pod の仕様の **matchExpression** パラメーターの値のセットの間の関係を表します。これには **In**、**NotIn**、**Exists**、または **DoesNotExist** のいずれかを使用できます。

この例では、コンテナイメージレジストリー Pod に **registry=default** のラベルがあることを想定しています。Pod のアンチアフィニティでは任意の Kubernetes の一致式を使用できます。

2. スケジューリングポリシーファイルで、**MatchInterPodAffinity** スケジューラー述語を有効にします。
3. ノードの正常な再起動を実行します。

6.7.3. ルーターを実行しているノードを再起動する方法について

ほとんどの場合、OpenShift Container Platform ルーターを実行している Pod はホストポートを公開します。

PodFitsPorts スケジューラー述語は、同じポートを使用するルーター Pod が同じノード上で実行できないようにし、Pod のアンチアフィニティが確保されるようにします。ルーターが高可用性を確保するために IP フェイルオーバーに依存する場合は、他に必要な設定等はありません。

高可用性のための AWS Elastic Load Balancing のような外部サービスに依存するルーター Pod の場合は、ルーターの再起動に対応するサービスが必要になります。

ルーター Pod でホストのポートが設定されていないということも稀にあります。この場合は、インフラストラクチャーノードに関する推奨される再起動プロセスに従う必要があります。

6.7.4. ノードを正常に再起動する

ノードを再起動する前に、ノードでのデータ損失を回避するために、etcd データをバックアップすることを推奨します。



注記

シングルノード OpenShift クラスターの場合、クラスターを管理するために **kubeconfig** ファイルに証明書を含めるのではなく、ユーザーが **oc login** コマンドを実行する必要があります。そのため、ノードをスケジューリング対象から除外して drain (Pod の退避) を実行した後、**oc adm** コマンドが使用できなくなる可能性があります。これは、スケジューリング対象から除外する操作が原因で、**openshift-oauth-apiserver** Pod が実行されなくなるためです。以下の手順で示したように、SSH を使用してノードにアクセスできます。

シングルノード OpenShift クラスターでは、スケジューリング対象からの除外時および drain (Pod の退避) の実行時に Pod を再スケジューリングすることはできません。しかし、そうすることで、Pod、特にワークロード Pod が適切に停止し、関連するリソースを解放する時間を得ることができます。

手順

ノードのグレースフル再起動を実行するには、次の手順を実行します。

1. ノードをスケジューリング対象外としてマークします。

```
$ oc adm cordon <node1>
```

2. ノードの drain (Pod の退避) を実行して、実行中のすべての Pod を削除します。

```
$ oc adm drain <node1> --ignore-daemonsets --delete-emptydir-data --force
```

カスタムの Pod Disruption Budget (PDB) に関連する Pod を退避できないというエラーが表示される場合があります。

エラーの例

```
error when evicting pods/"rails-postgresql-example-1-72v2w" -n "rails" (will retry after 5s):
Cannot evict pod as it would violate the pod's disruption budget.
```

この場合、drain コマンドを再度実行し、**disable-eviction** フラグを追加し、PDB チェックを省略します。

```
$ oc adm drain <node1> --ignore-daemonsets --delete-emptydir-data --force --disable-
eviction
```

3. デバッグモードでノードにアクセスします。

```
$ oc debug node/<node1>
```

4. ルートディレクトリーを **/host** に変更します。

```
$ chroot /host
```

5. ノードを再起動します。

```
$ systemctl reboot
```

すぐに、ノードは **NotReady** 状態になります。



注記

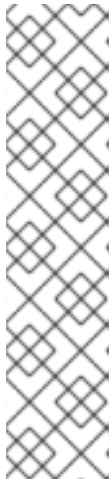
一部のシングルノード OpenShift クラスターでは、**openshift-oauth-apiserver** Pod が実行されていないため、ノードの遮断およびドレイン後に **oc** コマンドが使用できない場合があります。SSH でノードに接続し、リブートを実行することができます。

```
$ ssh core@<master-node>.<cluster_name>.<base_domain>
```

```
$ sudo systemctl reboot
```

- 再起動が完了したら、以下のコマンドを実行して、ノードをスケジューリング可能な状態にします。

```
$ oc adm uncordon <node1>
```



注記

一部のシングルノード OpenShift クラスターでは、**openshift-oauth-apiserver** Pod が実行されていないため、ノードの遮断およびドレイン後に **oc** コマンドが使用できない場合があります。SSH を使用してノードに接続し、ノードの遮断を解除します。

```
$ ssh core@<target_node>
```

```
$ sudo oc adm uncordon <node> --kubeconfig /etc/kubernetes/static-pod-resources/kube-apiserver-certs/secrets/node-kubeconfigs/localhost.kubeconfig
```

- ノードの準備ができていることを確認します。

```
$ oc get node <node1>
```

出力例

```
NAME      STATUS    ROLES    AGE    VERSION
<node1>   Ready    worker   6d22h  v1.18.3+b0068a8
```

関連情報

etcd データのバックアップの詳細は、[etcd データのバックアップ](#) を参照してください。

6.8. ガベージコレクションを使用しているノードリソースの解放

管理者は、OpenShift Container Platform を使用し、ガベージコレクションによってリソースを解放することにより、ノードを効率的に実行することができます。

OpenShift Container Platform ノードは、2 種類のガベージコレクションを実行します。

- コンテナのガベージコレクション: 終了したコンテナを削除します。
- イメージのガベージコレクション: 実行中のどの Pod から参照されていないイメージを削除します。

6.8.1. 終了したコンテナがガベージコレクションによって削除される仕組みについて

コンテナのガベージコレクションは、エビクションしきい値を使用して、終了したコンテナを削除します。

エビクションしきい値がガーベージコレクションに設定されていると、ノードは Pod のコンテナが API から常にアクセス可能な状態になるよう試みます。Pod が削除された場合、コンテナも削除されます。コンテナは Pod が削除されず、エビクションしきい値に達していない限り保持されます。ノードがディスク不足 (disk pressure) の状態になっていると、コンテナが削除され、それらのログは **oc logs** を使用してアクセスできなくなります。

- **eviction-soft** - ソフトエビクションのしきい値は、エビクションしきい値と要求される管理者指定の猶予期間を組み合わせます。
- **eviction-hard** - ハードエビクションのしきい値には猶予期間がなく、検知されると、OpenShift Container Platform はすぐにアクションを実行します。

以下の表は、エビクションしきい値のリストです。

表6.2 コンテナのガベージコレクションを設定するための変数

ノードの状態	エビクションシグナル	説明
MemoryPressure	memory.available	ノードで利用可能なメモリー。
DiskPressure	<ul style="list-style-type: none"> ● nodefs.available ● nodefs.inodesFree ● imagefs.available ● imagefs.inodesFree 	ノードのルートファイルシステム (nodefs) またはイメージファイルシステム (imagefs) で利用可能なディスク領域または i ノード。

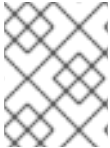


注記

evictionHard の場合、これらのパラメーターをすべて指定する必要があります。すべてのパラメーターを指定しないと、指定したパラメーターのみが適用され、ガベージコレクションが正しく機能しません。

ノードがソフトエビクションしきい値の上限と下限の間で変動し、その関連する猶予期間を超えていない場合、対応するノードは、**true** と **false** の間で常に変動します。したがって、スケジューラーは適切なスケジュールを決定できない可能性があります。

この変動を防ぐには、**evictionpressure-transition-period** フラグを使用して、OpenShift Container Platform が不足状態から移行するまでにかかる時間を制御します。OpenShift Container Platform は、false 状態に切り替わる前の指定された期間に、エビクションしきい値を指定された不足状態に一致するように設定しません。



注記

evictionPressureTransitionPeriod パラメーターを **0** に設定すると、デフォルト値の 5 分が設定されます。エビクション不足移行期間を 0 秒に設定することはできません。

6.8.2. イメージがガベージコレクションによって削除される仕組みについて

イメージガベージコレクションは、実行中の Pod によって参照されていないイメージを削除します。

OpenShift Container Platform は、**cAdvisor** によって報告されたディスク使用量に基づいて、ノードから削除するイメージを決定します。

イメージのガベージコレクションのポリシーは、以下の 2 つの条件に基づいています。

- イメージのガベージコレクションをトリガーするディスク使用量のパーセンテージ (整数で表される) です。デフォルトは 85 です。
- イメージのガベージコレクションが解放しようとするディスク使用量のパーセンテージ (整数で表される) です。デフォルトは 80 です。

イメージのガベージコレクションのために、カスタムリソースを使用して、次の変数のいずれかを変更することができます。

表6.3 イメージのガベージコレクションを設定するための変数

設定	説明
imageMinimumGauge	ガベージコレクションによって削除されるまでの未使用のイメージの有効期間。デフォルトは、2m です。
imageGCHighThresholdPercent	イメージのガベージコレクションをトリガーするディスク使用量のパーセンテージ (整数で表される) です。デフォルトは 85 です。この値は imageGCLowThresholdPercent 値より大きくする必要があります。
imageGCLowThresholdPercent	イメージのガベージコレクションが解放しようとするディスク使用量のパーセンテージ (整数で表される) です。デフォルトは 80 です。この値は、 imageGCHighThresholdPercent 値より小さくする必要があります。

以下の 2 つのイメージリストがそれぞれのガベージコレクターの実行で取得されます。

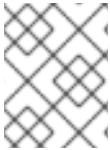
1. 1 つ以上の Pod で現在実行されているイメージのリスト
2. ホストで利用可能なイメージのリスト

新規コンテナの実行時に新規のイメージが表示されます。すべてのイメージにはタイムスタンプのマークが付けられます。イメージが実行中 (上記の最初の一覧) か、新規に検出されている (上記の 2 番目の一覧) 場合、これには現在の時間のマークが付けられます。残りのイメージには以前のタイムスタンプのマークがすでに付けられています。すべてのイメージはタイムスタンプで並び替えられます。

コレクションが開始されると、停止条件を満たすまでイメージが最も古いものから順番に削除されます。

6.8.3. コンテナおよびイメージのガベージコレクションの設定

管理者は、**kubeletConfig** オブジェクトを各マシン設定プール用に作成し、OpenShift Container Platform によるガベージコレクションの実行方法を設定できます。



注記

OpenShift Container Platform は、各マシン設定プールの **kubeletConfig** オブジェクトを1つのみサポートします。

次のいずれかの組み合わせを設定できます。

- コンテナのソフトエビクション
- コンテナのハードエビクション
- イメージのエビクション

コンテナのガベージコレクションは終了したコンテナを削除します。イメージガベージコレクションは、実行中の Pod によって参照されていないイメージを削除します。

前提条件

1. 次のコマンドを入力して、設定するノードタイプの静的な **MachineConfigPool** CRD に関連付けられたラベルを取得します。

```
$ oc edit machineconfigpool <name>
```

以下に例を示します。

```
$ oc edit machineconfigpool worker
```

出力例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfigPool
metadata:
  creationTimestamp: "2022-11-16T15:34:25Z"
  generation: 4
  labels:
    pools.operator.machineconfiguration.openshift.io/worker: "" 1
  name: worker
#...
```

- 1 Labels の下にラベルが表示されます。

ヒント

ラベルが存在しない場合は、次のようなキー/値のペアを追加します。

```
$ oc label machineconfigpool worker custom-kubelet=small-pods
```

手順

1. 設定変更のためのカスタムリソース (CR) を作成します。



重要

ファイルシステムが1つの場合、または `/var/lib/kubelet` と `/var/lib/containers/` が同じファイルシステムにある場合、最も大きな値の設定が満たされるとエビクションがトリガーされます。ファイルシステムはエビクションをトリガーします。

コンテナのガベージコレクション CR のサンプル設定:

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: worker-kubeconfig ❶
spec:
  machineConfigPoolSelector:
    matchLabels:
      pools.operator.machineconfiguration.openshift.io/worker: "" ❷
  kubeletConfig:
    evictionSoft: ❸
      memory.available: "500Mi" ❹
      nodefs.available: "10%"
      nodefs.inodesFree: "5%"
      imagefs.available: "15%"
      imagefs.inodesFree: "10%"
    evictionSoftGracePeriod: ❺
      memory.available: "1m30s"
      nodefs.available: "1m30s"
      nodefs.inodesFree: "1m30s"
      imagefs.available: "1m30s"
      imagefs.inodesFree: "1m30s"
    evictionHard: ❻
      memory.available: "200Mi"
      nodefs.available: "5%"
      nodefs.inodesFree: "4%"
      imagefs.available: "10%"
      imagefs.inodesFree: "5%"
    evictionPressureTransitionPeriod: 3m ❼
    imageMinimumGCAge: 5m ❽
    imageGCHighThresholdPercent: 80 ❾
    imageGCLowThresholdPercent: 75 ❿
#...
```

- ❶ オブジェクトの名前。
- ❷ マシン設定プールからラベルを指定します。
- ❸ コンテナのガベージコレクションの場合: エビクションのタイプ: **evictionSoft** または **evictionHard**。
- ❹ コンテナのガベージコレクションの場合: 特定のエビクショントリガー信号に基づくエビクションしきい値。

- 5 コンテナのガベージコレクションの場合: ソフトエビクションの猶予期間。このパラメーターは、**eviction-hard** には適用されません。
- 6 コンテナのガベージコレクションの場合: 特定のエビクショントリガー信号に基づくエビクションしきい値。**evictionHard** の場合、これらのパラメーターをすべて指定する必要があります。すべてのパラメーターを指定しないと、指定したパラメーターのみが適用され、ガベージコレクションが正しく機能しません。
- 7 コンテナのガベージコレクションの場合: エビクションプレッシャー状態から移行するまでの待機時間。**evictionPressureTransitionPeriod** パラメーターを **0** に設定すると、デフォルト値の 5 分が設定されます。
- 8 イメージのガベージコレクションの場合: イメージがガベージコレクションによって削除されるまでの、未使用のイメージの最小保存期間。
- 9 イメージガベージコレクションの場合: イメージガベージコレクションは、(整数で表される) 指定されたディスク使用率でトリガーされます。この値は **imageGCLowThresholdPercent** 値より大きくする必要があります。
- 10 イメージガベージコレクションの場合: イメージガベージコレクションは、(整数で表される) 指定されたディスク使用率までリソースの解放を試みます。この値は、**imageGCHighThresholdPercent** 値より小さくする必要があります。

2. 以下のコマンドを実行して CR を作成します。

```
$ oc create -f <file_name>.yaml
```

以下に例を示します。

```
$ oc create -f gc-container.yaml
```

出力例

```
kubeletconfig.machineconfiguration.openshift.io/gc-container created
```

検証

1. 次のコマンドを入力して、ガベージコレクションがアクティブであることを確認します。カスタムリソースで指定した Machine Config Pool では、変更が完全に実行されるまで **UPDATING** が 'true' と表示されます。

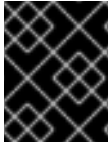
```
$ oc get machineconfigpool
```

出力例

```
NAME      CONFIG                                UPDATED  UPDATING
master    rendered-master-546383f80705bd5aeaba93  True     False
worker    rendered-worker-b4c51bb33cdae6fc4a6a5  False    True
```

6.9. OPENSIFT CONTAINER PLATFORM クラスター内のノードへのリソース割り当て

より信頼性の高いスケジューリングを実現し、ノードにおけるリソースのオーバーコミットを最小限にするために、**kubelet** および **kube-proxy** などの基礎となるノードのコンポーネント、および **sshd** および **NetworkManager** などの残りのシステムコンポーネントに使用される CPU およびメモリーリソースの一部を予約します。予約するリソースを指定して、スケジューラーに、ノードが Pod で使用できる残りの CPU およびメモリーリソースの詳細を提供します。OpenShift Container Platform がノードに **最適な system-reserved CPU およびメモリーリソースを自動的に決定できるようにする** ことも、ノードに **最適なリソースを手動で決定して設定する** こともできます。



重要

リソース値を手動で設定するには、kubelet config CR を使用する必要があります。machine config CR は使用できません。

6.9.1. ノードにリソースを割り当てる方法について

OpenShift Container Platform 内のノードコンポーネントの予約された CPU とメモリーリソースは、2つのノード設定に基づいています。

設定	説明
kube-reserved	この設定は OpenShift Container Platform では使用されません。確保する予定の CPU およびメモリーリソースを system-reserved 設定に追加します。
system-reserved	この設定は、CRI-O および Kubelet などのノードコンポーネントおよびシステムコンポーネント用に予約するリソースを特定します。デフォルト設定は、OpenShift Container Platform および Machine Config Operator のバージョンによって異なります。 machine-config-operator リポジトリでデフォルトの systemReserved パラメーターを確認します。

フラグが設定されていない場合、デフォルトが使用されます。いずれのフラグも設定されていない場合、割り当てられるリソースは、割り当て可能なリソースの導入前であるためにノードの容量に設定されます。



注記

reservedSystemCPUs パラメーターを使用して予約される CPU は、**kube-reserved** または **system-reserved** を使用した割り当てには使用できません。

6.9.1.1. OpenShift Container Platform による割り当てられたリソースの計算方法

割り当てられたリソースの量は、以下の数式に基づいて計算されます。

$$[\text{Allocatable}] = [\text{Node Capacity}] - [\text{system-reserved}] - [\text{Hard-Eviction-Thresholds}]$$



注記

Allocatable の値がノードレベルで Pod に対して適用されるために、**Hard-Eviction-Thresholds** を **Allocatable** から差し引くと、システムの信頼性が強化されます。

Allocatable が負の値の場合、これは **0** に設定されます。

各ノードは、コンテナランタイムおよび kubelet によって利用されるシステムリソースを報告します。**system-reserved** パラメーターの設定を簡素化するには、ノード要約 API を使用してノードに使用するリソースを表示します。ノードの要約は `/api/v1/nodes/<node>/proxy/stats/summary` で利用できます。

6.9.1.2. ノードによるリソースの制約の適用方法

ノードは、Pod が設定された割り当て可能な値に基づいて消費できるリソースの合計量を制限できます。この機能は、Pod がシステムサービス (コンテナランタイム、ノードエージェントなど) で必要とされる CPU およびメモリーリソースを使用することを防ぎ、ノードの信頼性を大幅に強化します。ノードの信頼性を強化するために、管理者はリソースの使用に関するターゲットに基づいてリソースを確保する必要があります。

ノードは、quality of service を適用する新規の cgroup 階層を使用してリソースの制約を適用します。すべての Pod は、システムデーモンから切り離された専用の cgroup 階層で起動されます。

管理者は quality of service のある Pod と同様にシステムデーモンを処理する必要があります。システムデーモンは、境界となる制御グループ内でバーストする可能性があり、この動作はクラスターのデプロイメントの一部として管理される必要があります。**system-reserved** で CPU およびメモリーリソースの量を指定し、システムデーモンの CPU およびメモリーリソースを予約します。



注記

system-reserved 制限を適用すると、重要なシステムサービスが CPU およびメモリーリソースを受信できなくなることがあります。その結果、重要なシステムサービスは、out-of-memory killer によって終了する可能性があります。そのため、正確な推定値を判別するためにノードの徹底的なプロファイリングを実行した場合や、そのグループのプロセスが out-of-memory killer によって終了する場合に重要なシステムサービスが確実に復元できる場合にのみ **system-reserved** を適用することが推奨されます。

6.9.1.3. エビクションのしきい値について

ノードがメモリー不足の状態にある場合、ノード全体、およびノードで実行されているすべての Pod に影響が及ぶ可能性があります。たとえば、メモリーの予約量を超える量を使用するシステムデーモンは、メモリー不足のイベントを引き起こす可能性があります。システムのメモリー不足のイベントを防止するか、それが発生する可能性を軽減するために、ノードはリソース不足の処理 (out-of-resource handling) を行います。

--eviction-hard フラグで一部のメモリーを予約することができます。ノードは、ノードのメモリー可用性が絶対値またはパーセンテージを下回る場合は常に Pod の退避を試行します。システムデーモンがノードに存在しない場合、Pod はメモリーの **capacity - eviction-hard** に制限されます。このため、メモリー不足の状態になる前にエビクションのバッファとして確保されているリソースは Pod で利用することはできません。

以下の例は、割り当て可能なノードのメモリーに対する影響を示しています。

- ノード容量: **32Gi**
- **--system-reserved** is **3Gi**
- **--eviction-hard** は **100Mi** に設定される。

このノードについては、有効なノードの割り当て可能な値は **28.9Gi** です。ノードおよびシステムコンポーネントが予約分をすべて使い切る場合、Pod に利用可能なメモリーは **28.9Gi** となり、この使用量を超える場合に kubelet は Pod を退避します。

トップレベルの cgroup でノードの割り当て可能分 (**28.9Gi**) を適用する場合、Pod は **28.9Gi** を超えることはできません。エビクションは、システムデーモンが **3.1Gi** よりも多くのメモリーを消費しない限り実行されません。

上記の例ではシステムデーモンが予約分すべてを使い切らない場合も、ノードのエビクションが開始される前に、Pod では境界となる cgroup からの memcg OOM による強制終了が発生します。この状況で QoS をより効果的に実行するには、ノードですべての Pod のトップレベルの cgroup に対し、ハードエビクションしきい値が **Node Allocatable + Eviction Hard Thresholds** になるよう適用できます。

システムデーモンがすべての予約分を使い切らない場合で、Pod が **28.9Gi** を超えるメモリーを消費する場合、ノードは Pod を常に退避します。エビクションが時間内に生じない場合には、Pod が **29Gi** のメモリーを消費すると OOM による強制終了が生じます。

6.9.1.4. スケジューラーがリソースの可用性を判別する方法

スケジューラーは、**node.Status.Capacity** ではなく **node.Status.Allocatable** の値を使用して、ノードが Pod スケジューリングの候補になるかどうかを判別します。

デフォルトで、ノードはそのマシン容量をクラスターで完全にスケジューリング可能であるとして報告します。

関連情報

- [Kubelet パラメーターを編集するための KubeletConfig CR の作成](#)
- [OpenShift Container Platform クラスター内のノードへのリソース割り当て](#)

6.9.2. ノードのリソースの自動割り当て

OpenShift Container Platform は、特定のマシン設定プールに関連付けられたノードに最適な **system-reserved** CPU およびメモリーリソースを自動的に判別し、ノードの起動時にそれらの値を使用してノードを更新できます。デフォルトでは、**system-reserved** CPU は **500m** で、**system-reserved** メモリーは **1Gi** です。

ノード上で **system-reserved** リソースを自動的に判断して割り当てるには、**KubeletConfig** カスタムリソース (CR) を作成して **autoSizingReserved: true** パラメーターを設定します。各ノードのスクリプトにより、各ノードにインストールされている CPU およびメモリーの容量に基づいて、予約されたそれぞれのリソースに最適な値が計算されます。増加した容量を考慮に入れたスクリプトでは、予約リソースにもこれに対応する増加を反映させることが必要になります。

最適な **system-reserved** 設定を自動的に判別することで、クラスターが効率的に実行され、CRI-O や kubelet などのシステムコンポーネントのリソース不足によりノードが失敗することを防ぐことができます。この際、値を手動で計算し、更新する必要はありません。

この機能はデフォルトで無効にされています。

前提条件

1. 次のコマンドを入力して、設定するノードタイプの静的な **MachineConfigPool** オブジェクトに関連付けられたラベルを取得します。

■

```
$ oc edit machineconfigpool <name>
```

以下に例を示します。

```
$ oc edit machineconfigpool worker
```

出力例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfigPool
metadata:
  creationTimestamp: "2022-11-16T15:34:25Z"
  generation: 4
  labels:
    pools.operator.machineconfiguration.openshift.io/worker: "" ❶
  name: worker
#...
```

- ❶ ラベルが **Labels** の下に表示されます。

ヒント

適切なラベルが存在しない場合は、次のようなキーと値のペアを追加します。

```
$ oc label machineconfigpool worker custom-kubelet=small-pods
```

手順

1. 設定変更のためのカスタムリソース (CR) を作成します。

リソース割り当て CR の設定例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: dynamic-node ❶
spec:
  autoSizingReserved: true ❷
  machineConfigPoolSelector:
    matchLabels:
      pools.operator.machineconfiguration.openshift.io/worker: "" ❸
#...
```

- ❶ CR に名前を割り当てます。
- ❷ **true** に設定された **autoSizingReserved** パラメーターを追加し、OpenShift Container Platform が指定されたラベルに関連付けられたノード上で **system-reserved** リソースを自動的に判別し、割り当てることができます。それらのノードでの自動割り当てを無効にするには、このパラメーターを **false** に設定します。
- ❸ 「前提条件」セクションで設定したマシン設定プールからラベルを指定します。マシン設

上記の例では、すべてのワーカーノードでリソースの自動割り当てを有効にします。OpenShift Container Platform はノードをドレイン (解放) し、kubelet 設定を適用してノードを再起動します。

2. 次のコマンドを入力して CR を作成します。

```
$ oc create -f <file_name>.yaml
```

検証

1. 次のコマンドを入力して、設定したノードにログインします。

```
$ oc debug node/<node_name>
```

2. **/host** をデバッグシェル内のルートディレクトリとして設定します。

```
# chroot /host
```

3. **/etc/node-sizing.env** ファイルを表示します。

出力例

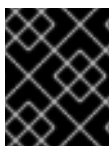
```
SYSTEM_RESERVED_MEMORY=3Gi
SYSTEM_RESERVED_CPU=0.08
```

kubelet は、**/etc/node-sizing.env** ファイルの **system-reserved** 値を使用します。上記の例では、ワーカーノードには **0.08** CPU および 3 Gi のメモリーが割り当てられます。更新が適用されるまでに数分の時間がかかることがあります。

6.9.3. ノードのリソースの手動割り当て

OpenShift Container Platform は、割り当てに使用する CPU およびメモリーリソースタイプをサポートします。**ephemeral-resource** リソースタイプもサポートされています。**cpu** タイプの場合、リソース数量をコア単位で指定します (例: **200m**、**0.5**、**1**)。 **memory** および **ephemeral-storage** の場合、リソース数量をバイト単位で指定します (例: **200Ki**、**50Mi**、**5Gi**)。デフォルトでは、**system-reserved** CPU は **500m** で、**system-reserved** メモリーは **1Gi** です。

管理者は、kubelet config カスタムリソース (CR) を使用して、一連の **<resource_type>=<resource_quantity>** ペア (例: **cpu=200m,memory=512Mi**) を設定できます。



重要

リソース値を手動で設定するには、kubelet config CR を使用する必要があります。machine config CR は使用できません。

推奨される **system-reserved** 値の詳細は、[推奨される system-reserved 値](#) を参照してください。

前提条件

1. 次のコマンドを入力して、設定するノードタイプの静的な **MachineConfigPool** CRD に関連付けられたラベルを取得します。

```
$ oc edit machineconfigpool <name>
```

以下に例を示します。

```
$ oc edit machineconfigpool worker
```

出力例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfigPool
metadata:
  creationTimestamp: "2022-11-16T15:34:25Z"
  generation: 4
  labels:
    pools.operator.machineconfiguration.openshift.io/worker: "" ❶
  name: worker
#...
```

❶ Labels の下にラベルが表示されます。

ヒント

ラベルが存在しない場合は、次のようなキー/値のペアを追加します。

```
$ oc label machineconfigpool worker custom-kubelet=small-pods
```

手順

1. 設定変更のためのカスタムリソース (CR) を作成します。

リソース割り当て CR の設定例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: set-allocatable ❶
spec:
  machineConfigPoolSelector:
    matchLabels:
      pools.operator.machineconfiguration.openshift.io/worker: "" ❷
  kubeletConfig:
    systemReserved: ❸
    cpu: 1000m
    memory: 1Gi
#...
```

❶ CR に名前を割り当てます。

❷ マシン設定プールからラベルを指定します。

❸

ノードコンポーネントおよびシステムコンポーネント用に予約するリソースを指定します。

2. 以下のコマンドを実行して CR を作成します。

```
$ oc create -f <file_name>.yaml
```

6.10. クラスター内のノードに特定の CPU を割り当てる

[static CPU マネージャーポリシー](#) を使用すると、クラスター内の特定のノードで使用するために特定の CPU を予約できます。たとえば、24 CPU のあるシステムでは、コントロールプレーン用に 0-3 の番号が付けられた CPU を予約して、コンピュートノードが CPU 4-23 を使用できるようにすることができます。

6.10.1. ノードの CPU の予約

特定のノード用に予約される CPU のリストを明示的に定義するには、**KubeletConfig** カスタムリソース (CR) を作成して **reservedSystemCPUs** パラメーターを定義します。このリストは、**systemReserved** パラメーターを使用して予約されている CPU よりも優先されます。

手順

1. 設定する必要があるノードタイプの Machine Config Pool (MCP) に関連付けられたラベルを取得します。

```
$ oc describe machineconfigpool <name>
```

以下に例を示します。

```
$ oc describe machineconfigpool worker
```

出力例

```
Name:      worker
Namespace:
Labels:    machineconfiguration.openshift.io/mco-built-in=
           pools.operator.machineconfiguration.openshift.io/worker= 1
Annotations: <none>
API Version: machineconfiguration.openshift.io/v1
Kind:      MachineConfigPool
#...
```

- 1 MCP ラベルを取得します。

2. **KubeletConfig** CR の YAML ファイルを作成します。

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: set-reserved-cpus 1
spec:
```

```
kubeletConfig:
  reservedSystemCPUs: "0,1,2,3" ❷
  machineConfigPoolSelector:
    matchLabels:
      pools.operator.machineconfiguration.openshift.io/worker: "" ❸
  #...
```

- ❶ CR の名前を指定します。
- ❷ MCP に関連付けられたノード用に予約する CPU のコア ID を指定します。
- ❸ MCP からラベルを指定します。

3. CR オブジェクトを作成します。

```
$ oc create -f <file_name>.yaml
```

関連情報

- **systemReserved** パラメーターの詳細は、[OpenShift Container Platform クラスター内のノードへのリソース割り当て](#) を参照してください。

6.11. KUBELET の TLS セキュリティープロファイルの有効化

TLS (Transport Layer Security) セキュリティープロファイルを使用して、kubelet が HTTP サーバーとして機能している際に必要とする TLS 暗号を定義できます。kubelet はその HTTP/GRPC サーバーを使用して Kubernetes API サーバーと通信し、コマンドを Pod に送信して kubelet 経由で Pod で exec コマンドを実行します。

TLS セキュリティープロファイルは、kubelet と Kubernetes API サーバー間の通信を保護するために、Kubernetes API サーバーが kubelet に接続する際に使用しなければならない TLS 暗号を定義します。



注記

デフォルトで、kubelet が Kubernetes API サーバーでクライアントとして動作する場合、TLS パラメーターを API サーバーと自動的にネゴシエートします。

6.11.1. TLS セキュリティープロファイルについて

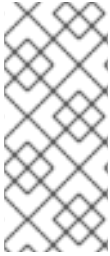
TLS (Transport Layer Security) セキュリティープロファイルを使用して、さまざまな OpenShift Container Platform コンポーネントに必要な TLS 暗号を定義できます。OpenShift Container Platform の TLS セキュリティープロファイルは、[Mozilla が推奨する設定](#) に基づいています。

コンポーネントごとに、以下の TLS セキュリティープロファイルのいずれかを指定できます。

表6.4 TLS セキュリティープロファイル

プロファイル	説明
--------	----

プロファイル	説明
Old	<p>このプロファイルは、レガシークライアントまたはライブラリーでの使用を目的としています。このプロファイルは、Old 後方互換性の推奨設定に基づいています。</p> <p>Old プロファイルには、最小 TLS バージョン 1.0 が必要です。</p> <div>注記<p>Ingress Controller の場合、TLS の最小バージョンは 1.0 から 1.1 に変換されます。</p></div>
Intermediate	<p>このプロファイルは、Ingress Controller、kubelet、およびコントロールプレーンのデフォルトの TLS セキュリティプロファイルです。このプロファイルは、Intermediate 互換性の推奨設定に基づいています。</p> <p>Intermediate プロファイルには、最小 TLS バージョン 1.2 が必要です。</p> <div>注記<p>このプロファイルは、大多数のクライアントに推奨される設定です。</p></div>
Modern	<p>このプロファイルは、下位互換性を必要としない最新のクライアントで使用することを目的としています。このプロファイルは、Modern compatibilityの推奨設定に基づいています。</p> <p>Modern プロファイルには、最小 TLS バージョン 1.3 が必要です。</p>
Custom	<p>このプロファイルを使用すると、使用する TLS バージョンと暗号を定義できます。</p> <div>警告<p>無効な設定により問題が発生する可能性があるため、Custom プロファイルを使用する際には注意してください。</p></div>



注記

事前定義されたプロファイルタイプのいずれかを使用する場合、有効なプロファイル設定はリリース間で変更される可能性があります。たとえば、リリース X.Y.Z にデプロイされた Intermediate プロファイルを使用する仕様が、リリース X.Y.Z+1 へのアップグレードにより、新規のプロファイル設定が適用され、ロールアウトが生じる可能性があります。

6.11.2. kubelet の TLS セキュリティープロファイルの設定

HTTP サーバーとしての動作時に kubelet の TLS セキュリティープロファイルを設定するには、**KubeletConfig** カスタムリソース (CR) を作成して特定のノード用に事前定義済みの TLS セキュリティープロファイルまたはカスタム TLS セキュリティープロファイルを指定します。TLS セキュリティープロファイルが設定されていない場合には、TLS セキュリティープロファイルは **Intermediate** になります。

ワーカーノードで Old TLS セキュリティープロファイルを設定する KubeletConfig CR のサンプル

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
# ...
spec:
  tlsSecurityProfile:
    old: {}
    type: Old
  machineConfigPoolSelector:
    matchLabels:
      pools.operator.machineconfiguration.openshift.io/worker: ""
# ...
```

設定済みのノードの **kubelet.conf** ファイルで、設定済みの TLS セキュリティープロファイルの暗号化および最小 TLS セキュリティープロファイルを確認できます。

前提条件

- **cluster-admin** ロールを持つユーザーとしてクラスターにアクセスできる。

手順

1. **KubeletConfig** CR を作成し、TLS セキュリティープロファイルを設定します。

Custom プロファイル用の KubeletConfig CR のサンプル

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: set-kubelet-tls-security-profile
spec:
  tlsSecurityProfile:
    type: Custom ①
    custom: ②
      ciphers: ③
        - ECDHE-ECDSA-CHACHA20-POLY1305
```

```
- ECDHE-RSA-CHACHA20-POLY1305
- ECDHE-RSA-AES128-GCM-SHA256
- ECDHE-ECDSA-AES128-GCM-SHA256
minTLSVersion: VersionTLS11
machineConfigPoolSelector:
  matchLabels:
    pools.operator.machineconfiguration.openshift.io/worker: "" 4
#...
```

- 1 TLS セキュリティープロファイルタイプ (**Old**、**Intermediate**、または **Custom**) を指定します。デフォルトは **Intermediate** です。
- 2 選択したタイプに適切なフィールドを指定します。
 - **old:** {}
 - **intermediate:** {}
 - **custom:**
- 3 **custom** タイプには、TLS 暗号のリストと最小許容 TLS バージョンを指定します。
- 4 オプション: TLS セキュリティープロファイルを適用するノードのマシン設定プールラベルを指定します。

2. KubeletConfig オブジェクトを作成します。

```
$ oc create -f <filename>
```

クラスター内のワーカーノードの数によっては、設定済みのノードが1つずつ再起動されるのを待機します。

検証

プロファイルが設定されていることを確認するには、ノードが **Ready** になってから以下の手順を実行します。

1. 設定済みノードのデバッグセッションを開始します。

```
$ oc debug node/<node_name>
```

2. **/host** をデバッグシェル内のルートディレクトリーとして設定します。

```
sh-4.4# chroot /host
```

3. **kubelet.conf** ファイルを表示します。

```
sh-4.4# cat /etc/kubernetes/kubelet.conf
```

出力例

```
"kind": "KubeletConfiguration",
"apiVersion": "kubelet.config.k8s.io/v1beta1",
```

```
#...
"tlsCipherSuites": [
  "TLS_ECDHE_ECDSA_WITH_AES_128_GCM_SHA256",
  "TLS_ECDHE_RSA_WITH_AES_128_GCM_SHA256",
  "TLS_ECDHE_ECDSA_WITH_AES_256_GCM_SHA384",
  "TLS_ECDHE_RSA_WITH_AES_256_GCM_SHA384",
  "TLS_ECDHE_ECDSA_WITH_CHACHA20_POLY1305_SHA256",
  "TLS_ECDHE_RSA_WITH_CHACHA20_POLY1305_SHA256"
],
"tlsMinVersion": "VersionTLS12",
#...
```

6.12. MACHINE CONFIG DAEMON メトリック

Machine Config Daemon は Machine Config Operator の一部です。これはクラスター内のすべてのノードで実行されます。Machine Config Daemon は、各ノードの設定変更および更新を管理します。

6.12.1. Machine Config Daemon メトリック

OpenShift Container Platform 4.3 以降、Machine Config Daemon はメトリックのセットを提供します。これらのメトリクスには、Prometheus クラスターモニタリングスタックを使用してアクセスできます。

以下の表では、これらのメトリクスのセットを説明しています。一部のエントリーには、特定のログを取得するためのコマンドが含まれています。ただし、最も包括的なログのセットは、**oc adm must-gather** コマンドを使用して入手できます。



注記

Name 列と Description 列に * が付いているメトリクスは、パフォーマンスの問題を引き起こす可能性のある重大なエラーを表します。このような問題により、更新およびアップグレードが続行されなくなる可能性があります。

表6.5 MCO メトリクス

名前	形式	説明	備考
mcd_host_os_and_version	[[string{"os", "version"}]	RHCOS や RHEL など、MCD が実行されている OS を示します。RHCOS の場合、バージョンは指定されます。	

名前	形式	説明	備考
mcd_drain_err*		ドレイン (解放) の失敗時に受信されるエラーをログに記録します。*	<p>ドレイン (解放) が成功するには、複数回試行する必要がある可能性があります、最終的にドレイン (解放) に失敗すると更新を続行できなくなります。ドレイン (解放) にかかる時間を示す drain_time メトリクスはトラブルシューティングに役立つ可能性があります。</p> <p>詳細な調査を実行するには、以下を実行してログを表示します。</p> <pre>\$ oc logs -f -n openshift-machine-config-operator machine-config-daemon- <hash> -c machine-config-daemon</pre>
mcd_pivot_err*	<code>[]string{"err", "node", "pivot_target"}</code>	ピボットで発生するログ。*	<p>ピボットのエラーにより、OS のアップグレードを続行できなくなる可能性があります。</p> <p>さらに調査するには、次のコマンドを実行して machine-config-daemon コンテナからのログを確認します。</p> <pre>\$ oc logs -f -n openshift-machine-config-operator machine-config-daemon- <hash> -c machine-config-daemon</pre>
mcd_state	<code>[]string{"state", "reason"}</code>	指定ノードの Machine Config Daemon の状態。状態のオプションとして、"Done"、"Working"、および "Degraded" があります。"Degraded" の場合は、理由も含まれます。	<p>詳細な調査を実行するには、以下を実行してログを表示します。</p> <pre>\$ oc logs -f -n openshift-machine-config-operator machine-config-daemon- <hash> -c machine-config-daemon</pre>

名前	形式	説明	備考
mcd_kubelet_state*		kubelet の正常性に関する失敗をログに記録します。*	<p>これは、失敗数が 0 で空になることが予想されます。失敗数が 2 を超えると、しきい値を超えたことを示すエラーが出されます。これは kubelet の正常性に関連した問題の可能性を示します。</p> <p>詳細な調査を行うには、以下のコマンドを実行してノードにアクセスし、そのすべてのログを表示します。</p> <p>\$ oc debug node/<node> — chroot /host journalctl -u kubelet</p>
mcd_reboot_err*	[[]string{"message", "err", "node"}]	再起動の失敗と対応するエラーをログに記録します。*	<p>これは空になることが予想されますが、これは再起動が成功したことを示します。</p> <p>詳細な調査を実行するには、以下を実行してログを表示します。</p> <p>\$ oc logs -f -n openshift-machine-config-operator machine-config-daemon-<hash> -c machine-config-daemon</p>
mcd_update_state	[[]string{"config", "err"}]	設定更新の成功または失敗、および対応するエラーをログに記録します。	<p>予想される値は rendered-master/rendered-worker-XXXX です。更新に失敗すると、エラーが表示されます。</p> <p>詳細な調査を実行するには、以下を実行してログを表示します。</p> <p>\$ oc logs -f -n openshift-machine-config-operator machine-config-daemon-<hash> -c machine-config-daemon</p>

関連情報

- [モニタリングの概要](#)
- [クラスターに関するデータの収集](#)

6.13. インフラストラクチャーノードの作成

重要

高度なマシン管理およびスケール機能は、Machine API が動作しているクラスターでのみ使用できます。user-provisioned infrastructure を持つクラスターでは、Machine API を使用するために追加の検証と設定が必要です。

インフラストラクチャープラットフォームタイプが **none** のクラスターでは、Machine API を使用できません。この制限は、クラスターに接続されている計算マシンが、この機能をサポートするプラットフォームにインストールされている場合でも適用されます。このパラメーターは、インストール後に変更することはできません。

クラスターのプラットフォームタイプを表示するには、以下のコマンドを実行します。

```
$ oc get infrastructure cluster -o jsonpath='{.status.platform}'
```

インフラストラクチャーマシンセットを使用して、デフォルトのルーター、統合コンテナイメージレジストリー、およびクラスターメトリクスおよびモニタリングのコンポーネントなどのインフラストラクチャーコンポーネントのみをホストするマシンを作成できます。これらのインフラストラクチャーマシンは、環境の実行に必要なサブスクリプションの合計数にカウントされません。

実稼働デプロイメントでは、インフラストラクチャーコンポーネントを保持するために3つ以上のマシンセットをデプロイすることが推奨されます。OpenShift Logging と Red Hat OpenShift Service Mesh の両方が Elasticsearch をデプロイします。これには、3つのインスタンスを異なるノードにインストールする必要があります。これらの各ノードは、高可用性のために異なるアベイラビリティゾーンにデプロイできます。この設定には、可用性ゾーンごとに1つずつ、合計3つの異なるマシンセットが必要です。複数のアベイラビリティゾーンを持たないグローバル Azure リージョンでは、アベイラビリティセットを使用して高可用性を確保できます。

注記

インフラストラクチャーノードに **NoSchedule** taint を追加すると、そのノードで実行されている既存の DNS Pod は **misscheduled** としてマークされます。 [misscheduled DNS Pod に対する toleration の追加](#) または削除を行う必要があります。

6.13.1. OpenShift Container Platform インフラストラクチャーコンポーネント

セルフマネージド Red Hat OpenShift の各サブスクリプションには、OpenShift Container Platform とその他の OpenShift 関連コンポーネントのエンタイトルメントが含まれています。これらのエンタイトルメントは、OpenShift Container Platform のコントロールプレーンおよびインフラストラクチャーのワークロードを実行するために含まれています。サイジング時にこれらのエンタイトルメントを考慮する必要はありません。

インフラストラクチャーノードとしての要件を満たし、含まれるエンタイトルメントを使用するには、(エンドユーザーのアプリケーションに含まれない) クラスターをサポートするコンポーネントだけを、それらのインスタンス上で実行します。たとえば、次のコンポーネントがあります。

- Kubernetes および OpenShift Container Platform コントロールプレーンサービス
- デフォルトルーター
- 統合コンテナイメージレジストリー

- HAProxy ベースの Ingress Controller
- ユーザー定義プロジェクトのモニタリング用のコンポーネントを含む、クラスターメトリクスの収集またはモニタリングサービス
- クラスター集計ロギング
- Red Hat Quay
- Red Hat OpenShift Data Foundation
- Red Hat Advanced Cluster Management for Kubernetes
- Kubernetes 用 Red Hat Advanced Cluster Security
- Red Hat OpenShift GitOps
- Red Hat OpenShift Pipelines
- Red Hat OpenShift Service Mesh

他のコンテナ、Pod またはコンポーネントを実行するノードは、サブスクリプションが適用される必要のあるワーカーノードです。

インフラストラクチャーノードおよびインフラストラクチャーノードで実行できるコンポーネントの詳細は、[OpenShift sizing and subscription guide for enterprise Kubernetes](#) の「Red Hat OpenShift control plane and infrastructure nodes」セクションを参照してください。

インフラストラクチャーノードを作成するには、[マシンセットを使用する](#) か、[ノードにラベルを付ける](#) か、[マシン設定プールを使用します](#)。

6.13.1.1. 専用インフラストラクチャーノードの作成



重要

installer-provisioned infrastructure 環境またはコントロールプレーンノードが Machine API によって管理されるクラスターの場合は、「インフラストラクチャーマシンセットの作成」を参照してください。

クラスターの要件によっては、インフラストラクチャー (infra) ノードをプロビジョニングする必要があります。インストールプログラムによってプロビジョニングされるのは、コントロールプレーンとワーカーノードだけです。ワーカーノードは、ラベル付けによってインフラストラクチャーノードとして指定できます。その後、taint と toleration を使用して、適切なワークロードをインフラストラクチャーノードに移動できます。詳細は、「インフラストラクチャーマシンセットへのリソースの移動」を参照してください。

必要に応じて、クラスター全体のデフォルトのノードセクターを作成できます。デフォルトのノードセクターは、すべての namespace で作成された Pod に適用され、Pod の既存のノードセクターと重なります。これにより、Pod のセクターがさらに制約されます。

重要

デフォルトのノードセクターのキーが Pod のラベルのキーと競合する場合、デフォルトのノードセクターは適用されません。

ただし、Pod がスケジュール対象外になる可能性のあるデフォルトノードセクターを設定しないでください。たとえば、Pod のラベルが **node-role.kubernetes.io/master=""** などの別のノードロールに設定されている場合、デフォルトのノードセクターを **node-role.kubernetes.io/infra=""** などの特定のノードロールに設定すると、Pod がスケジュール不能になる可能性があります。このため、デフォルトのノードセクターを特定のノードロールに設定する際には注意が必要です。

または、プロジェクトノードセクターを使用して、クラスター全体でのノードセクターの競合を避けることができます。

手順

1. インフラストラクチャーノードとして機能する必要があるワーカーノードにラベルを追加します。

```
$ oc label node <node-name> node-role.kubernetes.io/infra=""
```

2. 該当するノードに **infra** ロールがあるかどうかを確認します。

```
$ oc get nodes
```

3. オプション: クラスター全体のデフォルトのノードセクターを作成します。

- a. **Scheduler** オブジェクトを編集します。

```
$ oc edit scheduler cluster
```

- b. 適切なノードセクターと共に **defaultNodeSelector** フィールドを追加します。

```
apiVersion: config.openshift.io/v1
kind: Scheduler
metadata:
  name: cluster
spec:
  defaultNodeSelector: node-role.kubernetes.io/infra="" ❶
# ...
```

- ❶ この例のノードセクターは、デフォルトでインフラストラクチャーノードに Pod をデプロイします。

- c. 変更を適用するためにファイルを保存します。

これで、インフラストラクチャーリソースを新しいインフラストラクチャーノードに移動できるようになりました。また、新しいインフラストラクチャーノード上の不要なワークロードやノードに属さないワークロードを削除してください。「OpenShift Container Platform インフラストラクチャーコンポーネント」で、インフラストラクチャーノードでの使用がサポートされているワークロードのリストを参照してください。

内建情報

- [リソースのインフラストラクチャマシンセットへの移行](#)

第7章 コンテナの使用

7.1. コンテナについて

OpenShift Container Platform アプリケーションの基本的な単位は **コンテナ** と呼ばれています。Linux [コンテナテクノロジー](#) は、指定されたリソースのみと対話するために実行中のプロセスを分離する軽量なメカニズムです。

数多くのアプリケーションインスタンスは、相互のプロセス、ファイル、ネットワークなどを可視化せずに単一ホストのコンテナで実行される可能性があります。通常、コンテナは任意のワークロードに使用されますが、各コンテナは Web サーバーまたはデータベースなどの (通常は "マイクロサービス" と呼ばれることが多い) 単一サービスを提供します。

Linux カーネルは数年にわたりコンテナテクノロジーの各種機能を統合してきました。OpenShift Container Platform および Kubernetes は複数ホストのインストール間でコンテナのオーケストレーションを実行する機能を追加します。

7.1.1. コンテナおよび RHEL カーネルメモリーについて

Red Hat Enterprise Linux (RHEL) の動作により、CPU 使用率の高いノードのコンテナは、予想以上に多いメモリーを消費しているように見える可能性があります。メモリー消費量の増加は、RHEL カーネルの **kmem_cache** によって引き起こされる可能性があります。RHEL カーネルは、それぞれの cgroup に **kmem_cache** を作成します。パフォーマンスの強化のために、**kmem_cache** には **cpu_cache** と任意の NUMA ノードのノードキャッシュが含まれます。これらのキャッシュはすべてカーネルメモリーを消費します。

これらのキャッシュに保存されるメモリーの量は、システムが使用する CPU の数に比例します。結果として、CPU の数が増えると、より多くのカーネルメモリーがこれらのキャッシュに保持されます。これらのキャッシュのカーネルメモリーの量が増えると、OpenShift Container Platform コンテナで設定済みのメモリー制限を超える可能性があり、これにより、コンテナが強制終了される可能性があります。

カーネルメモリーの問題によりコンテナが失われないようにするには、コンテナが十分なメモリーを要求することを確認します。以下の式を使用して、**kmem_cache** が消費するメモリー量を見積ることができます。この場合、**nproc** は、**nproc** コマンドで報告される利用可能なプロセス数です。コンテナの要求の上限が低くなる場合、この値にコンテナメモリーの要件を加えた分になります。

$\$(nproc) \times 1/2 \text{ MiB}$

7.1.2. コンテナエンジンとコンテナランタイムについて

コンテナエンジン は、コマンドラインオプションやイメージのプルなど、ユーザーの要求を処理するソフトウェアです。コンテナエンジンは、**コンテナランタイム** (下位レベルの**コンテナランタイム** とも呼ばれる) を使用して、コンテナのデプロイと操作に必要なコンポーネントを実行および管理します。コンテナエンジンまたはコンテナランタイムとやり取りする必要はほとんどありません。



注記

OpenShift Container Platform のドキュメントでは、コンテナランタイムという用語を使用して、下位レベルのコンテナ **ランタイム** を指します。他のドキュメントでは、コンテナエンジンをコンテナランタイムと呼んでいる場合があります。

OpenShift Container Platform は、コンテナエンジンとして CRI-O を使用し、コンテナランタイムとして runC または crun を使用します。デフォルトのコンテナランタイムは runC です。どちらのコンテナランタイムも、[Open Container Initiative \(OCI\)](#) ランタイム仕様に準拠しています。

CRI-O は Kubernetes ネイティブコンテナエンジン実装です。これはオペレーティングシステムに密接に統合し、Kubernetes の効率的で最適化されたエクスペリエンスを提供します。CRI-O コンテナエンジンは、各 OpenShift Container Platform クラスターノードで systemd サービスとして実行されます。

Docker によって開発され、Open Container Project によって維持されている runC は、Go で記述された軽量で移植可能なコンテナランタイムです。Red Hat によって開発された crun は、完全に C で記述された高速で低メモリーのコンテナランタイムです。OpenShift Container Platform 4.12 の時点で、2 つのいずれかを選択できます。



重要

crun コンテナランタイムのサポートはテクノロジープレビュー機能としてのみご利用いただけます。テクノロジープレビュー機能は、Red Hat 製品のサービスレベルアグリーメント (SLA) の対象外であり、機能的に完全ではないことがあります。Red Hat は、実稼働環境でこれらを使用することを推奨していません。テクノロジープレビュー機能は、最新の製品機能をいち早く提供して、開発段階で機能のテストを行い、フィードバックを提供していただくことを目的としています。

Red Hat のテクノロジープレビュー機能のサポート範囲に関する詳細は、[テクノロジープレビュー機能のサポート範囲](#) を参照してください。

crun は、runC に対して次のようないくつかの改善点があります。

- 小さいバイナリー
- より迅速な処理
- メモリーのフットプリントが小さい。

runC には、次のような利点があります。

- 最も一般的な OCI コンテナランタイム。
- 生産期間が長くなります。
- CRI-O のデフォルトのコンテナランタイム。

必要に応じて、2 つのコンテナランタイム間を移動できます。

使用するコンテナランタイムを設定する方法は、[CRI-O パラメーターの編集に使用する ContainerRuntimeConfig CR の作成](#) を参照してください。

7.2. POD のデプロイ前の、INIT コンテナの使用によるタスクの実行

OpenShift Container Platform は、Init コンテナを提供します。このコンテナは、アプリケーションコンテナの前に実行される特殊なコンテナであり、アプリのイメージに存在しないユーティリティまたはセットアップスクリプトを含めることができます。

7.2.1. Init コンテナについて

Pod の残りの部分がデプロイされる前に、init コンテナリソースを使用して、タスクを実行することができます。

Pod は、アプリケーションコンテナに加えて、init コンテナを持つことができます。Init コンテナにより、セットアップスクリプトとバインディングコードを再編成できます。

Init コンテナは以下のことを行うことができます。

- セキュリティー上の理由のためにアプリケーションコンテナイメージに含めることが望ましくないユーティリティーを含めることができ、それらを実行できます。
- アプリのイメージに存在しないセットアップに必要なユーティリティーまたはカスタムコードを含めることができます。たとえば、単に Sed、Awk、Python、Dig のようなツールをセットアップ時に使用するために別のイメージからイメージを作成する必要はありません。
- Linux namespace を使用して、アプリケーションコンテナがアクセスできないシークレットへのアクセスなど、アプリケーションコンテナとは異なるファイルシステムビューを設定できます。

各 Init コンテナは、次のコンテナが起動する前に正常に完了している必要があります。そのため、Init コンテナには、一連の前提条件が満たされるまでアプリケーションコンテナの起動をブロックしたり、遅延させたりする簡単な方法となります。

たとえば、以下は Init コンテナを使用するいくつかの方法になります。

- 以下のようなシェルコマンドでサービスが作成されるまで待機します。

```
for i in {1..100}; do sleep 1; if dig myservice; then exit 0; fi; done; exit 1
```

- 以下のようなコマンドを使用して、Downward API からリモートサーバーにこの Pod を登録します。

```
$ curl -X POST
http://$MANAGEMENT_SERVICE_HOST:$MANAGEMENT_SERVICE_PORT/register -d
'instance=$( )&ip=$( )'
```

- **sleep 60** のようなコマンドを使用して、アプリケーションコンテナが起動するまでしばらく待機します。
- Git リポジトリのクローンをボリュームに作成します。
- 設定ファイルに値を入力し、テンプレートツールを実行して、主要なアプリコンテナの設定ファイルを動的に生成します。たとえば、設定ファイルに POD_IP の値を入力し、Jinja を使用して主要なアプリ設定ファイルを生成します。

詳細は、[Kubernetes ドキュメント](#) を参照してください。

7.2.2. Init コンテナの作成

以下の例は、2 つの init コンテナを持つ単純な Pod の概要を示しています。1 つ目は **myservice** を待機し、2 つ目は **mydb** を待機します。両方のコンテナが完了すると、Pod が開始されます。

手順

1. Init コンテナの Pod を作成します。

- a. 以下のような YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: myapp-pod
  labels:
    app: myapp
spec:
  containers:
    - name: myapp-container
      image: registry.access.redhat.com/ubi8/ubi:latest
      command: ['sh', '-c', 'echo The app is running! && sleep 3600']
  initContainers:
    - name: init-myservice
      image: registry.access.redhat.com/ubi8/ubi:latest
      command: ['sh', '-c', 'until getent hosts myservice; do echo waiting for myservice; sleep
2; done;']
    - name: init-mysdb
      image: registry.access.redhat.com/ubi8/ubi:latest
      command: ['sh', '-c', 'until getent hosts mysdb; do echo waiting for mysdb; sleep 2;
done;']
# ...
```

- b. Pod を作成します。

```
$ oc create -f myapp.yaml
```

- c. Pod のステータスを表示します。

```
$ oc get pods
```

出力例

NAME	READY	STATUS	RESTARTS	AGE
myapp-pod	0/1	Init:0/2	0	5s

Pod のステータス **Init:0/2** は、2 つのサービスを待機していることを示します。

2. **myservice** サービスを作成します。

- a. 以下のような YAML ファイルを作成します。

```
kind: Service
apiVersion: v1
metadata:
  name: myservice
spec:
  ports:
    - protocol: TCP
      port: 80
      targetPort: 9376
```

- b. Pod を作成します。

```
$ oc create -f myservice.yaml
```

- c. Pod のステータスを表示します。

```
$ oc get pods
```

出力例

NAME	READY	STATUS	RESTARTS	AGE
myapp-pod	0/1	Init:1/2	0	5s

Pod のステータス **Init:1/2** は、1つのサービス (この場合は **mydb** サービス) を待機していることを示します。

3. **mydb** サービスを作成します。

- a. 以下のような YAML ファイルを作成します。

```
kind: Service
apiVersion: v1
metadata:
  name: mydb
spec:
  ports:
    - protocol: TCP
      port: 80
      targetPort: 9377
```

- b. Pod を作成します。

```
$ oc create -f mydb.yaml
```

- c. Pod のステータスを表示します。

```
$ oc get pods
```

出力例

NAME	READY	STATUS	RESTARTS	AGE
myapp-pod	1/1	Running	0	2m

Pod のステータスは、サービスを待機しておらず、実行中であることを示していました。

7.3. ボリュームの使用によるコンテナデータの永続化

コンテナ内のファイルは一時的なものです。そのため、コンテナがクラッシュしたり停止したりした場合は、データが失われます。**ボリューム** を使用すると、Pod 内のコンテナが使用しているデータを永続化できます。ボリュームはディレクトリーであり、Pod 内のコンテナからアクセスすることができます。ここでは、データが Pod の有効期間中保存されます。

7.3.1. ボリュームについて

ボリュームとは Pod およびコンテナで利用可能なマウントされたファイルシステムのことであり、これらは数多くのホストのローカルまたはネットワーク割り当てストレージのエンドポイントでサポートされる場合があります。コンテナはデフォルトで永続性がある訳ではなく、それらのコンテンツは再起動時にクリアされます。

ボリュームのファイルシステムにエラーが含まれないようにし、かつエラーが存在する場合はそれを修復するために、OpenShift Container Platform は **mount** ユーティリティーの前に **fsck** ユーティリティーを起動します。これはボリュームを追加するか、既存ボリュームを更新する際に実行されます。

最も単純なボリュームタイプは **emptyDir** です。これは、単一マシンの一時的なディレクトリーです。管理者はユーザーによる Pod に自動的に割り当てられる永続ボリュームの要求を許可することもできます。



注記

emptyDir ボリュームストレージは、FSGroup パラメーターがクラスター管理者によって有効にされている場合は Pod の FSGroup に基づいてクォータで制限できます。

7.3.2. OpenShift Container Platform CLI によるボリュームの操作

CLI コマンド **oc set volume** を使用して、レプリケーションコントローラーやデプロイメント設定などの Pod テンプレートを持つオブジェクトのボリュームおよびボリュームマウントを追加し、削除することができます。また、Pod または Pod テンプレートを持つオブジェクトのボリュームをリスト表示することもできます。

oc set volume コマンドは以下の一般的な構文を使用します。

```
$ oc set volume <object_selection> <operation> <mandatory_parameters> <options>
```

オブジェクトの選択

oc set volume コマンドの **object_selection** パラメーターには、次のいずれかを指定します。

表7.1 オブジェクトの選択

構文	説明	例
<object_type> <name>	タイプ <object_type> の <name> を選択します。	deploymentConfig registry
<object_type>/<name>	タイプ <object_type> の <name> を選択します。	deploymentConfig/registry
<object_type>--selector=<object_label_selector>	所定のラベルセクターに一致するタイプ <object_type> のリソースを選択します。	deploymentConfig--selector="name=registry"
<object_type> --all	タイプ <object_type> のすべてのリソースを選択します。	deploymentConfig --all

構文	説明	例
-f または --filename=<file_name>	リソースを編集するために使用するファイル名、ディレクトリー、または URL です。	-f registry-deployment-config.json

操作

oc set volume コマンドの **operation** パラメーターに **--add** または **--remove** を指定します。

必須パラメーター

いずれの必須パラメーターも選択された操作に固有のものであり、これらは後のセクションで説明します。

オプション

いずれのオプションも選択された操作に固有のものであり、これらは後のセクションで説明します。

7.3.3. Pod のボリュームとボリュームマウントのリスト表示

Pod または Pod テンプレートのボリュームおよびボリュームマウントをリスト表示することができます。

手順

ボリュームをリスト表示するには、以下の手順を実行します。

```
$ oc set volume <object_type>/<name> [options]
```

ボリュームのサポートされているオプションをリスト表示します。

オプション	説明	デフォルト
--name	ボリュームの名前。	
-c, --containers	名前でコンテナを選択します。すべての文字に一致するワイルドカード '*' を取ることもできます。	'*'

以下に例を示します。

- Pod **p1** のすべてのボリュームをリスト表示するには、以下を実行します。

```
$ oc set volume pod/p1
```

- すべてのデプロイメント設定で定義されるボリューム **v1** をリスト表示するには、以下の手順を実行します。

```
$ oc set volume dc --all --name=v1
```

7.3.4. Pod へのボリュームの追加

Pod にボリュームとボリュームマウントを追加することができます。

手順

ボリューム、ボリュームマウントまたはそれらの両方を Pod テンプレートに追加するには、以下を実行します。

```
$ oc set volume <object_type>/<name> --add [options]
```

表7.2 ボリュームを追加するためのサポートされるオプション

オプション	説明	デフォルト
--name	ボリュームの名前。	指定がない場合は、自動的に生成されます。
-t, --type	ボリュームソースの名前。サポートされる値は emptyDir 、 hostPath 、 secret 、 configmap 、 persistentVolumeClaim または projected です。	emptyDir
-c, --containers	名前でコンテナを選択します。すべての文字に一致するワイルドカード '*' を取ることもできます。	'*'
-m, --mount-path	選択されたコンテナ内のマウントパス。コンテナのルート (/) や、ホストとコンテナで同じパスにはマウントしないでください。これは、コンテナに十分な特権が付与されている場合に、ホストシステムを破壊する可能性があります (例: ホストの /dev/pts ファイル)。ホストをマウントするには、 /host を使用するのが安全です。	
--path	ホストパス。 --type=hostPath の必須パラメーターです。コンテナのルート (/) や、ホストとコンテナで同じパスにはマウントしないでください。これは、コンテナに十分な特権が付与されている場合に、ホストシステムを破壊する可能性があります (例: ホストの /dev/pts ファイル)。ホストをマウントするには、 /host を使用するのが安全です。	

オプション	説明	デフォルト
--secret-name	シークレットの名前。-- type=secret の必須パラメータです。	
--configmap-name	configmap の名前。-- type=configmap の必須のパラメータです。	
--claim-name	永続ボリューム要求の名前。-- type=persistentVolumeClaim の必須パラメータです。	
--source	JSON 文字列としてのボリュームソースの詳細。必要なボリュームソースが --type でサポートされない場合に推奨されます。	
-o, --output	サーバー上で更新せずに変更したオブジェクトを表示します。サポートされる値は json 、 yaml です。	
--output-version	指定されたバージョンで変更されたオブジェクトを出力します。	api-version

以下に例を示します。

- 新規ボリュームソース **emptyDir** を **registry DeploymentConfig** オブジェクトに追加するには、以下を実行します。

```
$ oc set volume dc/registry --add
```

ヒント

あるいは、以下の YAML を適用してボリュームを追加できます。

例7.1 ボリュームを追加したデプロイメント設定の例

```
kind: DeploymentConfig
apiVersion: apps.openshift.io/v1
metadata:
  name: registry
  namespace: registry
spec:
  replicas: 3
  selector:
    app: httpd
  template:
    metadata:
      labels:
        app: httpd
    spec:
      volumes: ❶
      - name: volume-pppsw
        emptyDir: {}
      containers:
      - name: httpd
        image: >-
          image-registry.openshift-image-registry.svc:5000/openshift/httpd:latest
        ports:
        - containerPort: 8080
          protocol: TCP
```

❶ ボリュームソース **emptyDir** を追加します。

- レプリケーションコントローラー **r1** のシークレット **secret1** を使用してボリューム **v1** を追加し、コンテナ内の **/data** でマウントするには、以下を実行します。

```
$ oc set volume rc/r1 --add --name=v1 --type=secret --secret-name='secret1' --mount-path=/data
```

ヒント

あるいは、以下の YAML を適用してボリュームを追加できます。

例7.2 ボリュームおよびシークレットを追加したレプリケーションコントローラーの例

```
kind: ReplicationController
apiVersion: v1
metadata:
  name: example-1
  namespace: example
spec:
  replicas: 0
  selector:
    app: httpd
    deployment: example-1
    deploymentconfig: example
  template:
    metadata:
      creationTimestamp: null
    labels:
      app: httpd
      deployment: example-1
      deploymentconfig: example
    spec:
      volumes: ❶
      - name: v1
        secret:
          secretName: secret1
          defaultMode: 420
      containers:
      - name: httpd
        image: >-
          image-registry.openshift-image-registry.svc:5000/openshift/httpd:latest
        volumeMounts: ❷
        - name: v1
          mountPath: /data
```

❶ ボリュームおよびシークレットを追加します。

❷ コンテナのマウントパスを追加します。

- 要求名 **pvc1** を使用して既存の永続ボリューム **v1** をディスク上のデプロイメント設定 **dc.json** に追加し、ボリュームをコンテナ **c1** の **/data** にマウントし、サーバー上で **DeploymentConfig** オブジェクトを更新します。

```
$ oc set volume -f dc.json --add --name=v1 --type=persistentVolumeClaim \
  --claim-name=pvc1 --mount-path=/data --containers=c1
```

ヒント

あるいは、以下の YAML を適用してボリュームを追加できます。

例7.3 永続ボリュームが追加されたデプロイメント設定の例

```
kind: DeploymentConfig
apiVersion: apps.openshift.io/v1
metadata:
  name: example
  namespace: example
spec:
  replicas: 3
  selector:
    app: httpd
  template:
    metadata:
      labels:
        app: httpd
    spec:
      volumes:
        - name: volume-pppsw
          emptyDir: {}
        - name: v1 ❶
          persistentVolumeClaim:
            claimName: pvc1
      containers:
        - name: httpd
          image: >-
            image-registry.openshift-image-registry.svc:5000/openshift/httpd:latest
          ports:
            - containerPort: 8080
              protocol: TCP
          volumeMounts: ❷
            - name: v1
              mountPath: /data
```

❶ `pvc1` という名前の永続ボリューム要求を追加します。

❷ コンテナのマウントパスを追加します。

- すべてのレプリケーションコントローラー向けにリビジョン 5125c45f9f563 を使い、Git リポジトリ <https://github.com/namespace1/project1> に基づいてボリューム v1 を追加するには、以下の手順を実行します。

```
$ oc set volume rc --all --add --name=v1 \
  --source='{ "gitRepo": {
    "repository": "https://github.com/namespace1/project1",
    "revision": "5125c45f9f563"
  } }
```

7.3.5. Pod 内のボリュームとボリュームマウントの更新

Pod 内のボリュームとボリュームマウントを変更することができます。

手順

--overwrite オプションを使用して、既存のボリュームを更新します。

```
$ oc set volume <object_type>/<name> --add --overwrite [options]
```

以下に例を示します。

- レプリケーションコントローラー **r1** の既存ボリューム **v1** を既存の永続ボリューム要求 **pvc1** に置き換えるには、以下の手順を実行します。

```
$ oc set volume rc/r1 --add --overwrite --name=v1 --type=persistentVolumeClaim --claim-name=pvc1
```

ヒント

または、以下の YAML を適用してボリュームを置き換えることもできます。

例7.4 pvc1 という名前の永続ボリューム要求を持つレプリケーションコントローラーの例

```
kind: ReplicationController
apiVersion: v1
metadata:
  name: example-1
  namespace: example
spec:
  replicas: 0
  selector:
    app: httpd
    deployment: example-1
    deploymentconfig: example
  template:
    metadata:
      labels:
        app: httpd
        deployment: example-1
        deploymentconfig: example
    spec:
      volumes:
        - name: v1 1
          persistentVolumeClaim:
            claimName: pvc1
      containers:
        - name: httpd
          image: >-
            image-registry.openshift-image-registry.svc:5000/openshift/httpd:latest
          ports:
            - containerPort: 8080
              protocol: TCP
          volumeMounts:
            - name: v1
              mountPath: /data
```

1 永続ボリューム要求を **pvc1** に設定します。

- **DeploymentConfig** オブジェクトの **d1** のマウントポイントを、ボリューム **v1** の **/opt** に変更するには、以下を実行します。

```
$ oc set volume dc/d1 --add --overwrite --name=v1 --mount-path=/opt
```

ヒント

または、以下の YAML を適用してマウントポイントを変更できます。

例7.5 マウントポイントが **opt** に設定されたデプロイメント設定の例

```
kind: DeploymentConfig
apiVersion: apps.openshift.io/v1
metadata:
  name: example
  namespace: example
spec:
  replicas: 3
  selector:
    app: httpd
  template:
    metadata:
      labels:
        app: httpd
    spec:
      volumes:
        - name: volume-pppsw
          emptyDir: {}
        - name: v2
          persistentVolumeClaim:
            claimName: pvc1
        - name: v1
          persistentVolumeClaim:
            claimName: pvc1
      containers:
        - name: httpd
          image: >-
            image-registry.openshift-image-registry.svc:5000/openshift/httpd:latest
          ports:
            - containerPort: 8080
              protocol: TCP
          volumeMounts: ❶
            - name: v1
              mountPath: /opt
```

❶ マウントポイントを **/opt** に設定します。

7.3.6. Pod からのボリュームおよびボリュームマウントの削除

Pod からボリュームまたはボリュームマウントを削除することができます。

手順

Pod テンプレートからボリュームを削除するには、以下を実行します。

```
$ oc set volume <object_type>/<name> --remove [options]
```

表7.3 ボリュームを削除するためにサポートされるオプション

オプション	説明	デフォルト
--name	ボリュームの名前。	
-c, --containers	名前でコンテナを選択します。すべての文字に一致するワイルドカード '*' を取ることもできます。	'*'
--confirm	複数のボリュームを1度に削除することを示します。	
-o, --output	サーバー上で更新せずに変更したオブジェクトを表示します。サポートされる値は json 、 yaml です。	
--output-version	指定されたバージョンで変更されたオブジェクトを出力します。	api-version

以下に例を示します。

- **DeploymentConfig** オブジェクトの **d1** からボリューム **v1** を削除するには、以下を実行します。

```
$ oc set volume dc/d1 --remove --name=v1
```

- **DeploymentConfig** オブジェクトの **d1** の **c1** のコンテナからボリューム **v1** をアンマウントし、**d1** のコンテナで参照されていない場合にボリューム **v1** を削除するには、以下の手順を実行します。

```
$ oc set volume dc/d1 --remove --name=v1 --containers=c1
```

- レプリケーションコントローラー **r1** のすべてのボリュームを削除するには、以下の手順を実行します。

```
$ oc set volume rc/r1 --remove --confirm
```

7.3.7. Pod 内での複数の用途のためのボリュームの設定

ボリュームを、単一 Pod で複数の使用目的のためにボリュームを共有するように設定できます。この場合、**volumeMounts.subPath** プロパティを使用し、ボリュームのルートの代わりにボリューム内に **subPath** 値を指定します。



注記

既存のスケジュールされた Pod に **subPath** パラメーターを追加することはできません。

手順

1. ボリューム内のファイルのリストを表示するには、**oc rsh** コマンドを実行します。

```
$ oc rsh <pod>
```

出力例

```
sh-4.2$ ls /path/to/volume/subpath/mount
example_file1 example_file2 example_file3
```

2. **subPath** を指定します。

subPath パラメーターを含む Pod 仕様の例

```
apiVersion: v1
kind: Pod
metadata:
  name: my-site
spec:
  containers:
    - name: mysql
      image: mysql
      volumeMounts:
        - mountPath: /var/lib/mysql
          name: site-data
          subPath: mysql ❶
    - name: php
      image: php
      volumeMounts:
        - mountPath: /var/www/html
          name: site-data
          subPath: html ❷
  volumes:
    - name: site-data
      persistentVolumeClaim:
        claimName: my-site-data
```

❶ データベースは **mysql** フォルダーに保存されます。

❷ HTML コンテンツは **html** フォルダーに保存されます。

7.4. PROJECTED ボリュームによるボリュームのマッピング

Projected ボリューム は、いくつかの既存のボリュームソースを同じディレクトリーにマップします。

以下のタイプのボリュームソースをデプロイメントできます。

- シークレット
- Config Map
- Downward API



注記

すべてのソースは Pod と同じ namespace に置かれる必要があります。

7.4.1. Projected ボリュームについて

Projected ボリュームはこれらのボリュームソースの任意の組み合わせを単一ディレクトリーにマップし、ユーザーの以下の実行を可能にします。

- 単一ボリュームを、複数のシークレットのキー、設定マップ、および Downward API 情報で自動的に設定し、各種の情報ソースで単一ディレクトリーを合成できるようにします。
- 各項目のパスを明示的に指定して、単一ボリュームを複数シークレットのキー、設定マップ、および Downward API 情報で設定し、ユーザーがボリュームの内容を完全に制御できるようにします。



重要

RunAsUser パーミッションが Linux ベースの Pod のセキュリティコンテキストに設定されている場合、Projected ファイルには、コンテナユーザー所有権を含む適切なパーミッションが設定されます。ただし、Windows の同等の **RunAsUsername** パーミッションが Windows Pod に設定されている場合、kubelet は Projected ボリュームのファイルに正しい所有権を設定できません。

そのため、Windows Pod のセキュリティコンテキストに設定された **RunAsUsername** パーミッションは、OpenShift Container Platform で実行される Windows の Projected ボリュームには適用されません。

以下の一般的なシナリオは、Projected ボリュームを使用する方法を示しています。

設定マップ、シークレット、Downward API

Projected ボリュームを使用すると、パスワードが含まれる設定データでコンテナをデプロイできます。これらのリソースを使用するアプリケーションは、Red Hat OpenStack Platform (RHOSP) を Kubernetes にデプロイしている可能性があります。設定データは、サービスが実稼働用またはテストで使用されるかによって異なった方法でアセンブルされる必要がある可能性があります。Pod に実稼働またはテストのラベルが付けられている場合、Downward API セクター **metadata.labels** を使用して適切な RHOSP 設定を生成できます。

設定マップ + シークレット

Projected ボリュームにより、設定データおよびパスワードを使用してコンテナをデプロイできます。たとえば、設定マップを、Vault パスワードファイルを使用して暗号解除する暗号化された機密タスクで実行する場合があります。

ConfigMap + Downward API.

Projected ボリュームにより、Pod 名 (**metadata.name** セクターで選択可能) を含む設定を生成できます。このアプリケーションは IP トラッキングを使用せずに簡単にソースを判別できるよう要求と共に Pod 名を渡すことができます。

シークレット + Downward API

Projected ボリュームにより、Pod の namespace (**metadata.namespace** セクターで選択可能) を暗号化するためのパブリックキーとしてシークレットを使用できます。この例では、Operator はこのアプリケーションを使用し、暗号化されたトランスポートを使用せずに namespace 情報を安全に送信できるようになります。

7.4.1.1. Pod 仕様の例

以下は、Projected ボリュームを作成するための **Pod** 仕様の例です。

シークレット、Downward API および設定マップを含む Pod

```
apiVersion: v1
kind: Pod
metadata:
  name: volume-test
spec:
  containers:
  - name: container-test
    image: busybox
    volumeMounts: ❶
    - name: all-in-one
      mountPath: "/projected-volume" ❷
      readOnly: true ❸
  volumes: ❹
  - name: all-in-one ❺
    projected:
      defaultMode: 0400 ❻
      sources:
      - secret:
          name: mysecret ❼
          items:
          - key: username
            path: my-group/my-username ❽
      - downwardAPI: ❾
          items:
          - path: "labels"
            fieldRef:
              fieldPath: metadata.labels
          - path: "cpu_limit"
            resourceFieldRef:
              containerName: container-test
              resource: limits.cpu
      - configMap: ❿
          name: myconfigmap
          items:
          - key: config
            path: my-group/my-config
            mode: 0777 ⓫
```

- ❶ シークレットを必要とする各コンテナの **volumeMounts** セクションを追加します。
- ❷ シークレットが表示される未使用ディレクトリーのパスを指定します。
- ❸ **readOnly** を **true** に設定します。
- ❹ それぞれの Projected ボリュームソースをリスト表示するために **volumes** ブロックを追加します。
- ❺ ボリュームの名前を指定します。
- ❻ ファイルに実行パーミッションを設定します。

- 7 シークレットを追加します。シークレットオブジェクトの名前を追加します。使用する必要のあるそれぞれのシークレットはリスト表示される必要があります。
- 8 **mountPath** の下にシークレットへのパスを指定します。ここで、シークレットファイルは **/projected-volume/my-group/my-username** になります。
- 9 Downward API ソースを追加します。
- 10 ConfigMap ソースを追加します。
- 11 特定のデプロイメントにおけるモードを設定します。



注記

Pod に複数のコンテナがある場合、それぞれのコンテナには **volumeMounts** セクションが必要ですが、1つの **volumes** セクションのみが必要になります。

デフォルト以外のパーミッションモデルが設定された複数シークレットを含む Pod

```
apiVersion: v1
kind: Pod
metadata:
  name: volume-test
spec:
  containers:
    - name: container-test
      image: busybox
      volumeMounts:
        - name: all-in-one
          mountPath: "/projected-volume"
          readOnly: true
  volumes:
    - name: all-in-one
      projected:
        defaultMode: 0755
        sources:
          - secret:
              name: mysecret
              items:
                - key: username
                  path: my-group/my-username
          - secret:
              name: mysecret2
              items:
                - key: password
                  path: my-group/my-password
                  mode: 511
```



注記

defaultMode は、各ボリュームソースではなく、Projected ボリュームのレベルでのみ指定できます。ただし、上記のように、個々の投影ごとに **mode** を明示的に設定することは可能です。

7.4.1.2. パスに関する留意事項

設定されるパスが同一である場合のキー間の競合

複数のキーを同じパスで設定する場合、Pod 仕様は有効な仕様として受け入れられません。以下の例では、**mysecret** および **myconfigmap** に指定されるパスは同じです。

```
apiVersion: v1
kind: Pod
metadata:
  name: volume-test
spec:
  containers:
    - name: container-test
      image: busybox
      volumeMounts:
        - name: all-in-one
          mountPath: "/projected-volume"
          readOnly: true
  volumes:
    - name: all-in-one
      projected:
        sources:
          - secret:
              name: mysecret
              items:
                - key: username
                  path: my-group/data
          - configMap:
              name: myconfigmap
              items:
                - key: config
                  path: my-group/data
```

ボリュームファイルのパスに関連する以下の状況を検討しましょう。

設定されたパスのないキー間の競合

上記のシナリオの場合と同様に、実行時の検証が実行される唯一のタイミングはすべてのパスが Pod の作成時に認識される時です。それ以外の場合は、競合の発生時に指定された最新のリソースがこれより前のすべてのものを上書きします (これは Pod 作成後に更新されるリソースでも同様です)。

一方のパスが明示的に指定され、もう一方のパスが自動的に投影される場合の競合

ユーザーが指定したパスが、自動的に投影されるデータのパスと一致して競合が発生した場合、前述のように、後から処理されるリソースが先行するリソースを上書きします。

7.4.2. Pod の Projected ボリュームの設定

Projected ボリュームを作成する場合は、**Projected ボリュームについて** で説明されているボリュームファイルパスの状態を考慮します。

以下の例では、Projected ボリュームを使用して、既存のシークレットボリュームソースをマウントする方法が示されています。以下の手順は、ローカルファイルからユーザー名およびパスワードのシークレットを作成するために実行できます。その後に、シークレットを同じ共有ディレクトリーにマウントするために Projected ボリュームを使用して1つのコンテナを実行する Pod を作成します。

このユーザー名とパスワードの値には、**base64** でエンコードされた任意の有効な文字列を使用できます。

以下の例は、base64 の **admin** を示しています。

```
$ echo -n "admin" | base64
```

出力例

```
YWRtaW4=
```

以下の例は、base64 のパスワード **1f2d1e2e67df** を示しています。

```
$ echo -n "1f2d1e2e67df" | base64
```

出力例

```
MWYyZDFIMmU2N2Rm
```

手順

既存のシークレットボリュームソースをマウントするために Projected ボリュームを使用するには、以下を実行します。

1. シークレットを作成します。
 - a. 次のような YAML ファイルを作成し、パスワードとユーザー情報を適切に置き換えます。

```
apiVersion: v1
kind: Secret
metadata:
  name: mysecret
type: Opaque
data:
  pass: MWYyZDFIMmU2N2Rm
  user: YWRtaW4=
```

- b. 以下のコマンドを使用してシークレットを作成します。

```
$ oc create -f <secrets-filename>
```

以下に例を示します。

```
$ oc create -f secret.yaml
```

出力例

```
secret "mysecret" created
```

- c. シークレットが以下のコマンドを使用して作成されていることを確認できます。

```
$ oc get secret <secret-name>
```

以下に例を示します。

```
$ oc get secret mysecret
```

出力例

```
NAME      TYPE      DATA   AGE
myscret   Opaque    2       17h
```

```
$ oc get secret <secret-name> -o yaml
```

以下に例を示します。

```
$ oc get secret mysecret -o yaml
```

```
apiVersion: v1
data:
  pass: MWYyZDFIMmU2N2Rm
  user: YWRtaW4=
kind: Secret
metadata:
  creationTimestamp: 2017-05-30T20:21:38Z
  name: mysecret
  namespace: default
  resourceVersion: "2107"
  selfLink: /api/v1/namespaces/default/secrets/mysecret
  uid: 959e0424-4575-11e7-9f97-fa163e4bd54c
type: Opaque
```

2. Projected ボリュームを持つ Pod を作成します。

a. **volumes** セクションを含む、次のような YAML ファイルを作成します。

```
kind: Pod
metadata:
  name: test-projected-volume
spec:
  containers:
    - name: test-projected-volume
      image: busybox
      args:
        - sleep
        - "86400"
      volumeMounts:
        - name: all-in-one
          mountPath: "/projected-volume"
          readOnly: true
      securityContext:
        allowPrivilegeEscalation: false
        capabilities:
          drop:
            - ALL
  volumes:
```

```
- name: all-in-one
  projected:
    sources:
      - secret:
          name: mysecret ❶
```

❶ 作成されたシークレットの名前。

b. 設定ファイルから Pod を作成します。

```
$ oc create -f <your_yaml_file>.yaml
```

以下に例を示します。

```
$ oc create -f secret-pod.yaml
```

出力例

```
pod "test-projected-volume" created
```

3. Pod コンテナが実行中であることを確認してから、Pod への変更を確認します。

```
$ oc get pod <name>
```

以下に例を示します。

```
$ oc get pod test-projected-volume
```

出力は以下のようになります。

出力例

```
NAME                READY   STATUS    RESTARTS   AGE
test-projected-volume 1/1     Running   0           14s
```

4. 別のターミナルで、**oc exec** コマンドを使用し、実行中のコンテナに対してシェルを開きます。

```
$ oc exec -it <pod> <command>
```

以下に例を示します。

```
$ oc exec -it test-projected-volume -- /bin/sh
```

5. シェルで、**projected-volumes** ディレクトリーに投影されたソースが含まれていることを確認します。

```
/ # ls
```

出力例

```
■
```

bin	home	root	tmp
dev	proc	run	usr
etc	projected-volume	sys	var

7.5. コンテナによる API オブジェクト使用の許可

Downward API は、OpenShift Container Platform に結合せずにコンテナが API オブジェクトの情報を使用できるメカニズムです。この情報には、Pod の名前、namespace およびリソース値が含まれます。コンテナは、環境変数やボリュームプラグインを使用して Downward API からの情報を使用できます。

7.5.1. Downward API の使用によるコンテナへの Pod 情報の公開

Downward API には、Pod の名前、プロジェクト、リソースの値などの情報が含まれます。コンテナは、環境変数やボリュームプラグインを使用して Downward API からの情報を使用できます。

Pod 内のフィールドは、**FieldRef** API タイプを使用して選択されます。**FieldRef** には 2 つのフィールドがあります。

フィールド	説明
fieldPath	Pod に関連して選択するフィールドのパスです。
apiVersion	fieldPath セレクターの解釈に使用する API バージョンです。

現時点で v1 API の有効なセレクターには以下が含まれます。

セレクター	説明
metadata.name	Pod の名前です。これは環境変数およびボリュームでサポートされています。
metadata.namespace	Pod の namespace です。これは環境変数およびボリュームでサポートされています。
metadata.labels	Pod のラベルです。これはボリュームでのみサポートされ、環境変数ではサポートされていません。
metadata.annotations	Pod のアノテーションです。これはボリュームでのみサポートされ、環境変数ではサポートされていません。
status.podIP	Pod の IP です。これは環境変数でのみサポートされ、ボリュームではサポートされていません。

apiVersion フィールドは、指定されていない場合は、対象の Pod テンプレートの API バージョンにデフォルト設定されます。

7.5.2. Downward API を使用してコンテナの値を使用する方法について

コンテナは、環境変数やボリュームプラグインを使用して API の値を使用することができます。選択する方法により、コンテナは以下を使用できます。

- Pod の名前
- Pod プロジェクト/namespace
- Pod のアノテーション
- Pod のラベル

アノテーションとラベルは、ボリュームプラグインのみを使用して利用できます。

7.5.2.1. 環境変数の使用によるコンテナ値の使用

コンテナの環境変数を設定する際に、**EnvVar** タイプの **valueFrom** フィールド (タイプは **EnvVarSource**) を使用して、変数の値が **value** フィールドで指定されるリテラル値ではなく、**FieldRef** ソースからの値になるように指定します。

この方法で使用できるのは Pod の定数属性のみです。変数の値の変更についてプロセスに通知する方法でプロセスを起動すると、環境変数を更新できなくなるためです。環境変数を使用してサポートされるフィールドには、以下が含まれます。

- Pod の名前
- Pod プロジェクト/namespace

手順

1. コンテナで使用する環境変数を含む新しい Pod 仕様を作成します。
 - a. 次のような **pod.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-env-test-pod
spec:
  containers:
    - name: env-test-container
      image: gcr.io/google_containers/busybox
      command: [ "/bin/sh", "-c", "env" ]
      env:
        - name: MY_POD_NAME
          valueFrom:
            fieldRef:
              fieldPath: metadata.name
        - name: MY_POD_NAMESPACE
          valueFrom:
            fieldRef:
              fieldPath: metadata.namespace
      restartPolicy: Never
  # ...
```

- b. **pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f pod.yaml
```

検証

- コンテナのログで **MY_POD_NAME** および **MY_POD_NAMESPACE** の値を確認します。

```
$ oc logs -p dapi-env-test-pod
```

7.5.2.2. ボリュームプラグインを使用したコンテナ値の使用

コンテナは、ボリュームプラグインを使用して API 値を使用できます。

コンテナは、以下を使用できます。

- Pod の名前
- Pod プロジェクト/namespace
- Pod のアノテーション
- Pod のラベル

手順

ボリュームプラグインを使用するには、以下の手順を実行します。

- コンテナで使用する環境変数を含む新しい Pod 仕様を作成します。
 - 次のような **volume-pod.yaml** ファイルを作成します。

```
kind: Pod
apiVersion: v1
metadata:
  labels:
    zone: us-east-coast
    cluster: downward-api-test-cluster1
    rack: rack-123
  name: dapi-volume-test-pod
  annotations:
    annotation1: "345"
    annotation2: "456"
spec:
  containers:
    - name: volume-test-container
      image: gcr.io/google_containers/busybox
      command: ["sh", "-c", "cat /tmp/etc/pod_labels /tmp/etc/pod_annotations"]
      volumeMounts:
        - name: podinfo
          mountPath: /tmp/etc
          readOnly: false
  volumes:
    - name: podinfo
      downwardAPI:
```

```

defaultMode: 420
items:
- fieldRef:
    fieldPath: metadata.name
  path: pod_name
- fieldRef:
    fieldPath: metadata.namespace
  path: pod_namespace
- fieldRef:
    fieldPath: metadata.labels
  path: pod_labels
- fieldRef:
    fieldPath: metadata.annotations
  path: pod_annotations
restartPolicy: Never
# ...

```

- b. **volume-pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f volume-pod.yaml
```

検証

- コンテナのログを確認し、設定されたフィールドの有無を確認します。

```
$ oc logs -p dapi-volume-test-pod
```

出力例

```

cluster=downward-api-test-cluster1
rack=rack-123
zone=us-east-coast
annotation1=345
annotation2=456
kubernetes.io/config.source=api

```

7.5.3. Downward API を使用してコンテナリソースを使用する方法について

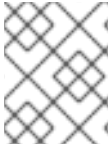
Pod の作成時に、Downward API を使用してコンピューティングリソースの要求および制限に関する情報を挿入し、イメージおよびアプリケーションの作成者が特定の環境用のイメージを適切に作成できるようにします。

環境変数またはボリュームプラグインを使用してこれを実行できます。

7.5.3.1. 環境変数を使用したコンテナリソースの使用

Pod を作成するときは、Downward API を使用し、環境変数を使用してコンピューティングリソースの要求と制限に関する情報を挿入できます。

Pod 設定の作成時に、**spec.container** フィールド内の **resources** フィールドの内容に対応する環境変数を指定します。



注記

リソース制限がコンテナ設定に含まれていない場合、Downward API はデフォルトでノードの CPU およびメモリの割り当て可能な値に設定されます。

手順

1. 注入するリソースを含む新しい Pod 仕様を作成します。
 - a. 次のような **pod.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-env-test-pod
spec:
  containers:
    - name: test-container
      image: gcr.io/google_containers/busybox:1.24
      command: [ "/bin/sh", "-c", "env" ]
      resources:
        requests:
          memory: "32Mi"
          cpu: "125m"
        limits:
          memory: "64Mi"
          cpu: "250m"
      env:
        - name: MY_CPU_REQUEST
          valueFrom:
            resourceFieldRef:
              resource: requests.cpu
        - name: MY_CPU_LIMIT
          valueFrom:
            resourceFieldRef:
              resource: limits.cpu
        - name: MY_MEM_REQUEST
          valueFrom:
            resourceFieldRef:
              resource: requests.memory
        - name: MY_MEM_LIMIT
          valueFrom:
            resourceFieldRef:
              resource: limits.memory
# ...
```

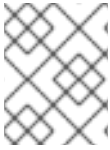
- b. **pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f pod.yaml
```

7.5.3.2. ボリュームプラグインを使用したコンテナリソースの使用

Pod を作成するときは、Downward API を使用し、ボリュームプラグインを使用してコンピューティングリソースの要求と制限に関する情報を挿入できます。

Pod 設定の作成時に、**spec.volumes.downwardAPI.items** フィールドを使用して **spec.resources** フィールドに対応する必要なリソースを記述します。



注記

リソース制限がコンテナ設定に含まれていない場合、Downward API はデフォルトでノードの CPU およびメモリーの割り当て可能な値に設定されます。

手順

1. 注入するリソースを含む新しい Pod 仕様を作成します。
 - a. 次のような **pod.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-env-test-pod
spec:
  containers:
    - name: client-container
      image: gcr.io/google_containers/busybox:1.24
      command: ["sh", "-c", "while true; do echo; if [[ -e /etc/cpu_limit ]]; then cat
/et /cpu_limit; fi; if [[ -e /etc/cpu_request ]]; then cat /etc/cpu_request; fi; if [[ -e
/et /mem_limit ]]; then cat /etc/mem_limit; fi; if [[ -e /etc/mem_request ]]; then cat
/et /mem_request; fi; sleep 5; done"]
      resources:
        requests:
          memory: "32Mi"
          cpu: "125m"
        limits:
          memory: "64Mi"
          cpu: "250m"
        volumeMounts:
          - name: podinfo
            mountPath: /etc
            readOnly: false
      volumes:
        - name: podinfo
          downwardAPI:
            items:
              - path: "cpu_limit"
                resourceFieldRef:
                  containerName: client-container
                  resource: limits.cpu
              - path: "cpu_request"
                resourceFieldRef:
                  containerName: client-container
                  resource: requests.cpu
              - path: "mem_limit"
                resourceFieldRef:
                  containerName: client-container
                  resource: limits.memory
              - path: "mem_request"
                resourceFieldRef:
                  containerName: client-container
```

```
resource: requests.memory
# ...
```

- b. **volume-pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f volume-pod.yaml
```

7.5.4. Downward API を使用したシークレットの使用

Pod の作成時に、Downward API を使用してシークレットを挿入し、イメージおよびアプリケーションの作成者が特定の環境用のイメージを作成できるようにできます。

手順

1. 注入するシークレットを作成します。

- a. 次のような **secret.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Secret
metadata:
  name: mysecret
data:
  password: <password>
  username: <username>
type: kubernetes.io/basic-auth
```

- b. **secret.yaml** ファイルからシークレットオブジェクトを作成します。

```
$ oc create -f secret.yaml
```

2. 上記の **Secret** オブジェクトから **username** フィールドを参照する Pod を作成します。

- a. 次のような **pod.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-env-test-pod
spec:
  containers:
    - name: env-test-container
      image: gcr.io/google_containers/busybox
      command: [ "/bin/sh", "-c", "env" ]
      env:
        - name: MY_SECRET_USERNAME
          valueFrom:
            secretKeyRef:
              name: mysecret
              key: username
      restartPolicy: Never
# ...
```

- b. **pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f pod.yaml
```

検証

- コンテナのログで **MY_SECRET_USERNAME** の値を確認します。

```
$ oc logs -p dapi-env-test-pod
```

7.5.5. Downward API を使用した設定マップの使用

Pod の作成時に、Downward API を使用して設定マップの値を挿入し、イメージおよびアプリケーションの作成者が特定の環境用のイメージを作成することができるようにすることができます。

手順

1. 注入する値を含む config map を作成します。
 - a. 次のような **configmap.yaml** ファイルを作成します。

```
apiVersion: v1
kind: ConfigMap
metadata:
  name: myconfigmap
data:
  mykey: myvalue
```

- b. **configmap.yaml** ファイルから config map を作成します。

```
$ oc create -f configmap.yaml
```

2. 上記の config map を参照する Pod を作成します。
 - a. 次のような **pod.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-env-test-pod
spec:
  containers:
    - name: env-test-container
      image: gcr.io/google_containers/busybox
      command: [ "/bin/sh", "-c", "env" ]
      env:
        - name: MY_CONFIGMAP_VALUE
          valueFrom:
            configMapKeyRef:
              name: myconfigmap
              key: mykey
      restartPolicy: Always
  # ...
```

- b. **pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f pod.yaml
```

検証

- コンテナのログで **MY_CONFIGMAP_VALUE** の値を確認します。

```
$ oc logs -p dapi-env-test-pod
```

7.5.6. 環境変数の参照

Pod の作成時に、**\$()** 構文を使用して事前に定義された環境変数の値を参照できます。環境変数の参照が解決されない場合、値は提供された文字列のままになります。

手順

1. 既存の環境変数を参照する Pod を作成します。
 - a. 次のような **pod.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-env-test-pod
spec:
  containers:
    - name: env-test-container
      image: gcr.io/google_containers/busybox
      command: [ "/bin/sh", "-c", "env" ]
      env:
        - name: MY_EXISTING_ENV
          value: my_value
        - name: MY_ENV_VAR_REF_ENV
          value: $(MY_EXISTING_ENV)
      restartPolicy: Never
# ...
```

- b. **pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f pod.yaml
```

検証

- コンテナのログで **MY_ENV_VAR_REF_ENV** 値を確認します。

```
$ oc logs -p dapi-env-test-pod
```

7.5.7. 環境変数の参照のエスケープ

Pod の作成時に、二重ドル記号を使用して環境変数の参照をエスケープできます。次に値は指定された値の単一ドル記号のバージョンに設定されます。

手順

1. 既存の環境変数を参照する Pod を作成します。
 - a. 次のような **pod.yaml** ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: dapi-env-test-pod
spec:
  containers:
    - name: env-test-container
      image: gcr.io/google_containers/busybox
      command: ["/bin/sh", "-c", "env"]
      env:
        - name: MY_NEW_ENV
          value: $$$(SOME_OTHER_ENV)
      restartPolicy: Never
  # ...
```

- b. **pod.yaml** ファイルから Pod を作成します。

```
$ oc create -f pod.yaml
```

検証

- コンテナのログで **MY_NEW_ENV** 値を確認します。

```
$ oc logs -p dapi-env-test-pod
```

7.6. OPENSIFT CONTAINER PLATFORM コンテナへの/からのファイルのコピー

CLI を使用して、**rsync** コマンドでコンテナのリモートディレクトリーにローカルファイルをコピーするか、そのディレクトリーからローカルファイルをコピーすることができます。

7.6.1. ファイルをコピーする方法について

oc rsync コマンドまたは **remote sync** は、バックアップと復元を実行するためにデータベースアーカイブを Pod にコピー、または Pod からコピーするのに役立つツールです。また、実行中の Pod がソースファイルのホットリロードをサポートする場合に、ソースコードの変更を開発のデバッグ目的で実行中の Pod にコピーするためにも、**oc rsync** を使用できます。

```
$ oc rsync <source> <destination> [-c <container>]
```

7.6.1.1. 要件

Copy Source の指定

oc rsync コマンドのソース引数はローカルディレクトリーまたは Pod ディレクトリーのいずれかを示す必要があります。個々のファイルはサポートされていません。
Pod ディレクトリーを指定する場合、ディレクトリー名の前に Pod 名を付ける必要があります。

```
<pod name>:<dir>
```

ディレクトリー名がパスセパレーター (/) で終了する場合、ディレクトリーの内容のみが宛先にコピーされます。それ以外の場合は、ディレクトリーとその内容が宛先にコピーされます。

Copy Destination の指定

oc rsync コマンドの宛先引数はディレクトリーを参照する必要があります。ディレクトリーが存在せず、**rsync** がコピーに使用される場合、ディレクトリーが作成されます。

宛先でのファイルの削除

--delete フラグは、ローカルディレクトリーにないリモートディレクトリーにあるファイルを削除するために使用できます。

ファイル変更に関する継続的な同期

--watch オプションを使用すると、コマンドはソースパスでファイルシステムの変更をモニターし、変更が生じるとそれらを同期します。この引数を指定すると、コマンドは無期限に実行されます。同期は短い非表示期間の後に実行され、急速に変化するファイルシステムによって同期呼び出しが継続的に実行されないようにします。

--watch オプションを使用する場合、動作は通常 **oc rsync** に渡される引数の使用を含め **oc rsync** を繰り返し手動で起動する場合と同様になります。そのため、**--delete** などの **oc rsync** の手動の呼び出しで使用される同じフラグでこの動作を制御できます。

7.6.2. コンテナへの/からのファイルのコピー

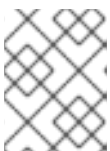
コンテナへの/からのローカルファイルのコピーのサポートは CLI に組み込まれています。

前提条件

oc rsync を使用する場合は、以下の点に注意してください。

- rsync がインストールされていること。**oc rsync** コマンドは、クライアントマシンおよびリモートコンテナ上に存在する場合は、ローカルの **rsync** ツールを使用。**rsync** がローカルまたはリモートコンテナ内に見つからない場合、**tar** アーカイブがローカルに作成され、**tar** ユーティリティーを使用してファイルを展開するコンテナに送信されます。リモートコンテナで **tar** を利用できない場合は、コピーに失敗します。

tar のコピー方法は **oc rsync** と同様に機能する訳ではありません。たとえば、**oc rsync** は、宛先ディレクトリーが存在しない場合にはこれを作成し、ソースと宛先間の差分のファイルのみを送信します。



注記

Windows では、**cwRsync** クライアントが **oc rsync** コマンドで使用するためにインストールされ、PATH に追加される必要があります。

手順

- ローカルディレクトリーを Pod ディレクトリーにコピーするには、以下の手順を実行します。

```
$ oc rsync <local-dir> <pod-name>:/<remote-dir> -c <container-name>
```

以下に例を示します。

```
$ oc rsync /home/user/source devpod1234:/src -c user-container
```

- Pod ディレクトリーをローカルディレクトリーにコピーするには、以下の手順を実行します。

```
$ oc rsync devpod1234:/src /home/user/source
```

出力例

```
$ oc rsync devpod1234:/src/status.txt /home/user/
```

7.6.3. 高度な Rsync 機能の使用

oc rsync コマンドは、標準の **rsync** よりも利用可能なコマンドラインオプションが限られています。**oc rsync** で利用できない標準の **rsync** コマンドラインオプションを使用する必要がある場合 (例: **-exclude-from=FILE** オプション)、以下のように回避策として標準 **rsync** の **--rsh (-e)** オプション、または **RSYNC_RSH** 環境変数を使用できる場合があります。

```
$ rsync --rsh='oc rsh' --exclude-from=<file_name> <local-dir> <pod-name>:/<remote-dir>
```

または

RSYNC_RSH 変数をエクスポートします。

```
$ export RSYNC_RSH='oc rsh'
```

次に、rsync コマンドを実行します。

```
$ rsync --exclude-from=<file_name> <local-dir> <pod-name>:/<remote-dir>
```

上記の例のいずれも標準の **rsync** をリモートシェルプログラムとして **oc rsh** を使用するように設定してリモート Pod に接続できるようにします。これらは **oc rsync** を実行する代替方法となります。

7.7. OPENSIFT CONTAINER PLATFORM コンテナでのリモートコマンドの実行

OpenShift Container Platform コンテナでリモートコマンドを実行するために、CLI を使用することができます。

7.7.1. コンテナでのリモートコマンドの実行

リモートコンテナコマンド実行のサポートは CLI に組み込まれています。

手順

コンテナでコマンドを実行するには、以下の手順を実行します。

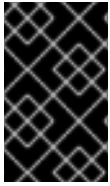
```
$ oc exec <pod> [-c <container>] -- <command> [<arg_1> ... <arg_n>]
```

以下に例を示します。

```
$ oc exec mypod date
```

出力例

```
Thu Apr 9 02:21:53 UTC 2015
```



重要

[セキュリティ保護の理由](#)により、**oc exec** コマンドは、コマンドが **cluster-admin** ユーザーによって実行されている場合を除き、特権付きコンテナにアクセスしようとしても機能しません。

7.7.2. クライアントからのリモートコマンドを開始するためのプロトコル

クライアントは要求を Kubernetes API サーバーに対して実行してコンテナのリモートコマンドの実行を開始します。

```
/proxy/nodes/<node_name>/exec/<namespace>/<pod>/<container>?command=<command>
```

上記の URL には以下が含まれます。

- **<node_name>** はノードの FQDN です。
- **<namespace>** はターゲット Pod のプロジェクトです。
- **<pod>** はターゲット Pod の名前です。
- **<container>** はターゲットコンテナの名前です。
- **<command>** は実行される必要なコマンドです。

以下に例を示します。

```
/proxy/nodes/node123.openshift.com/exec/myns/mypod/mycontainer?command=date
```

さらに、クライアントはパラメーターを要求に追加して以下を指示します。

- クライアントはリモートクライアントのコマンドに入力を送信する (標準入力: stdin)。
- クライアントのターミナルは TTY である。
- リモートコンテナのコマンドは標準出力 (stdout) からクライアントに出力を送信する。
- リモートコンテナのコマンドは標準エラー出力 (stderr) からクライアントに出力を送信する。

exec 要求の API サーバーへの送信後、クライアントは多重化ストリームをサポートするものに接続をアップグレードします。現在の実装では **HTTP/2** を使用しています。

クライアントは標準入力 (stdin)、標準出力 (stdout)、および標準エラー出力 (stderr) 用にそれぞれのストリームを作成します。ストリームを区別するために、クライアントはストリームの **streamType** ヘッダーを **stdin**、**stdout**、または **stderr** のいずれかに設定します。

リモートコマンド実行要求の処理が終了すると、クライアントはすべてのストリームやアップグレードされた接続および基礎となる接続を閉じます。

7.8. コンテナ内のアプリケーションにアクセスするためのポート転送の使用

OpenShift Container Platform は、Pod へのポート転送をサポートします。

7.8.1. ポート転送について

CLI を使用して 1 つ以上のローカルポートを Pod に転送できます。これにより、指定されたポートまたはランダムなポートでローカルにリッスンでき、Pod の所定ポートへ/からデータを転送できます。

ポート転送のサポートは、CLI に組み込まれています。

```
$ oc port-forward <pod> [<local_port>:]<remote_port> [...[<local_port_n>:]<remote_port_n>]
```

CLI はユーザーによって指定されたそれぞれのローカルポートでリッスンし、以下で説明されているプロトコルで転送を実行します。

ポートは以下の形式を使用して指定できます。

5000	クライアントはポート 5000 でローカルにリッスンし、Pod の 5000 に転送します。
6000:5000	クライアントはポート 6000 でローカルにリッスンし、Pod の 5000 に転送します。
:5000 または 0:5000	クライアントは空きのローカルポートを選択し、Pod の 5000 に転送します。

OpenShift Container Platform は、クライアントからのポート転送要求を処理します。要求を受信すると、OpenShift Container Platform は応答をアップグレードし、クライアントがポート転送ストリームを作成するまで待機します。OpenShift Container Platform が新規ストリームを受信したら、ストリームと Pod のポート間でデータをコピーします。

アーキテクチャーの観点では、Pod のポートに転送するためのいくつかのオプションがあります。サポートされている OpenShift Container Platform 実装はノードホストで直接 **nsenter** を直接呼び出して、Pod ネットワークの namespace に入ってから、**socat** を呼び出してストリームと Pod のポート間でデータをコピーします。ただし、カスタムの実装には、**nsenter** および **socat** を実行する **helper** Pod の実行を含めることができ、その場合は、それらのバイナリーをホストにインストールする必要はありません。

7.8.2. ポート転送の使用

CLI を使用して、1 つ以上のローカルポートの Pod へのポート転送を実行できます。

手順

以下のコマンドを使用して、Pod 内の指定されたポートでリッスンします。

```
$ oc port-forward <pod> [<local_port>:]<remote_port> [...[<local_port_n>:]<remote_port_n>]
```

以下に例を示します。

- 以下のコマンドを使用して、ポート **5000** および **6000** でローカルにリッスンし、Pod のポート **5000** および **6000** との間でデータを転送します。

```
$ oc port-forward <pod> 5000 6000
```

出力例

```
Forwarding from 127.0.0.1:5000 -> 5000
Forwarding from [::1]:5000 -> 5000
Forwarding from 127.0.0.1:6000 -> 6000
Forwarding from [::1]:6000 -> 6000
```

- 以下のコマンドを使用して、ポート **8888** でローカルにリッスンし、Pod の **5000** に転送します。

```
$ oc port-forward <pod> 8888:5000
```

出力例

```
Forwarding from 127.0.0.1:8888 -> 5000
Forwarding from [::1]:8888 -> 5000
```

- 以下のコマンドを使用して、空きポートでローカルにリッスンし、Pod の **5000** に転送します。

```
$ oc port-forward <pod> :5000
```

出力例

```
Forwarding from 127.0.0.1:42390 -> 5000
Forwarding from [::1]:42390 -> 5000
```

または、以下を実行します。

```
$ oc port-forward <pod> 0:5000
```

7.8.3. クライアントからのポート転送を開始するためのプロトコル

クライアントは Kubernetes API サーバーに対して要求を実行して Pod へのポート転送を実行します。

```
/proxy/nodes/<node_name>/portForward/<namespace>/<pod>
```

上記の URL には以下が含まれます。

- **<node_name>** はノードの FQDN です。
- **<namespace>** はターゲット Pod の namespace です。
- **<pod>** はターゲット Pod の名前です。

以下に例を示します。

```
/proxy/nodes/node123.openshift.com/portForward/myns/mypod
```

ポート転送要求を API サーバーに送信した後に、クライアントは多重化ストリームをサポートするものに接続をアップグレードします。現在の実装では [Hypertext Transfer Protocol Version 2 \(HTTP/2\)](#) を使用しています。

クライアントは Pod のターゲットポートを含む **port** ヘッダーでストリームを作成します。ストリームに書き込まれるすべてのデータは kubelet 経由でターゲット Pod およびポートに送信されます。同様に、転送された接続で Pod から送信されるすべてのデータはクライアントの同じストリームに送信されます。

クライアントは、ポート転送要求が終了するとすべてのストリーム、アップグレードされた接続および基礎となる接続を閉じます。

7.9. コンテナでの SYSCTL の使用

Sysctl の設定は Kubernetes を通じて公開され、ユーザーは実行時に特定のカーネルパラメーターを変更することができます。namespace を使用する sysctl のみを Pod 上で独立して設定できます。sysctl が namespace に属さない、つまり **ノードレベル** である場合は、Node Tuning Operator を使用するなど、sysctl を設定する別の方法を使用する必要があります。

ネットワーク sysctl は特殊な sysctl カテゴリーです。ネットワーク sysctl には、以下が含まれます。

- すべてのネットワークで有効な、**net.ipv4.ip_local_port_range** のようなシステム全体の sysctl。これらは、ノード上の各 Pod に対して個別に設定できます。
- 特定の Pod の特定の追加ネットワークインターフェイスにのみ適用されるインターフェイス固有の sysctl (**net.ipv4.conf.IFNAME.accept_local** など)。これらは、追加のネットワーク設定ごとに個別に設定できます。ネットワークインターフェイスの作成後に **tuning-cni** で設定を使用して、これらを設定します。

さらに **安全** とみなされる sysctl のみがデフォルトでホワイトリストに入れられます。他の **安全でない** sysctl はノードで手動で有効にし、ユーザーが使用できるようにできます。

関連情報

sysctl を設定していて、それがノードレベルでない場合は、[Node Tuning Operator の使用](#) セクションで該当する手順に関する情報を確認できます。

7.9.1. sysctl について

Linux では、管理者は sysctl インターフェイスを使用してランタイム時にカーネルパラメーターを変更することができます。パラメーターは **/proc/sys/** 仮想プロセスファイルシステムから利用できます。これらのパラメーターは以下を含む各種のサブシステムを対象とします。

- カーネル (共通の接頭辞: **kernel.**)
- ネットワーク (共通の接頭辞: **net.**)
- 仮想メモリー (共通の接頭辞: **vm.**)
- MDADM (共通の接頭辞: **dev.**)

追加のサブシステムは、[カーネルのドキュメント](#) で説明されています。すべてのパラメーターの一覧を表示するには、以下のコマンドを実行します。

```
$ sudo sysctl -a
```

7.9.2. namespace とノードレベルの sysctl

Linux カーネルでは、数多くの sysctl に **namespace** が使用されています。これは、それらをノードの各 Pod に対して個別に設定できることを意味します。namespace の使用は、sysctl を Kubernetes 内の Pod 環境でアクセス可能にするための要件になります。

以下の sysctl は namespace を使用するものとして知られている sysctl です。

- **kernel.shm***
- **kernel.msg***
- **kernel.sem**
- **fs.mqueue.***

また、**net.*** グループの大半の sysctl には namespace が使用されていることが知られています。それらの namespace の使用は、カーネルのバージョンおよびディストリビューターによって異なります。

namespace が使用されていない sysctl は **ノードレベル** と呼ばれており、クラスター管理者がノードの基礎となる Linux ディストリビューションを使用 (例: `/etc/sysctls.conf` ファイルを変更) するか、特権付きコンテナでデーモンセットを使用することによって手動で設定する必要があります。Node Tuning Operator を使用して **node-level** を設定できます。



注記

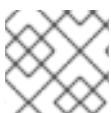
特殊な sysctl が設定されたノードに taint のマークを付けることを検討してください。これらの sysctl 設定を必要とするノードにのみ Pod をスケジュールします。taint および toleration 機能を使用してノードにマークを付けます。

7.9.3. 安全および安全でない sysctl

sysctl は **安全な** および **安全でない** sysctl に分類されます。

システム全体の sysctl を安全に考慮するには、namespace を指定する必要があります。namespace を使用した sysctl は namespace と Pod 間で分離されるようにします。1つの Pod に sysctl を設定する場合は、以下のいずれかを追加することはできません。

- この設定はノードのその他の Pod に影響を与えないものである。
- ノードの正常性に切り離す。
- この設定は Pod のリソース制限を超える CPU またはメモリーリソースの取得を許可しないものである。



注記

namespace を使用するだけでは、sysctl を安全に考慮するには不十分です。

OpenShift Container Platform で許可リストに追加されていない sysctl は、OpenShift Container Platform では安全でないと見なされます。

安全でない sysctl はデフォルトでは許可されません。システム全体の sysctl の場合、クラスター管理者はノードごとに手動で有効にする必要があります。無効にされた安全でない sysctl が設定された Pod はスケジュールされますが、起動されません。



注記

インターフェイス固有の安全でない sysctls を手動で有効にすることはできません。

OpenShift Container Platform は以下のシステム全体およびインターフェイス固有の安全な sysctl を許可された安全なリストに追加します。

表7.4 システム全体の安全な sysctl

sysctl	説明
kernel.shm_rmid_forced	1 に設定すると、現在の IPC namespace のすべての共有メモリーオブジェクトは自動的に IPC_RMID を使用します。詳細は、 shm_rmid_forced を参照してください。
net.ipv4.ip_local_port_range	TCP および UDP によって使用されるローカルポート範囲を定義して、ローカルポートを選択します。最初の番号は最初のポート番号で、2 番目の番号は最後のローカルポート番号になります。可能であれば、これらの数値は異なるパリティ (偶数値と奇数値) を持つ方が良いでしょう。 ip_unprivileged_port_start よりも大きくなければなりません。デフォルト値は、それぞれ 32768 および 60999 です。詳細は、 ip_local_port_range を参照してください。
net.ipv4.tcp_syncookies	net.ipv4.tcp_syncookies を設定すると、カーネルは、通常、半分に開いた接続キューが満杯になるまで TCP SYN パケットを処理します。この時点で、SYN クッキー機能が開始します。この機能により、サービス拒否攻撃下であっても、システムは有効な接続を受け入れることができます。詳細は、 tcp_syncookies を参照してください。
net.ipv4.ping_group_range	これにより、 ICMP_PROTO データグラムソケットがグループ範囲内のユーザーに制限されます。デフォルトは 1 0 で、nobody は root であっても ping ソケットを作成できます。詳細は、 ping_group_range を参照してください。
net.ipv4.ip_unprivileged_port_start	これは、ネットワーク namespace 内の最初の権限のないポートを定義します。特権ポートをすべて無効にするには、これを 0 に設定します。特権ポートは ip_local_port_range と重複できません。詳細は、 ip_unprivileged_port_start を参照してください。

表7.5 インターフェイス固有の安全な sysctl

sysctl	説明
net.ipv4.conf.IFNAME.accept_redirects	IPv4 ICMP リダイレクトメッセージを受信します。
net.ipv4.conf.IFNAME.accept_source_route	SRR (Strict Source Route) オプションの付いた IPv4 パケットを受け入れる。

sysctl	説明
net.ipv4.conf.IFNAME.arp_accept	ARP テーブルにない IPv4 アドレスで余計な ARP フレームの動作を定義します。 <ul style="list-style-type: none"> ● 0: ARP テーブルに新しいエントリーを作成しません。 ● 1: ARP テーブルに新しいエントリーを作成します。
net.ipv4.conf.IFNAME.arp_notify	IPv4 アドレスとデバイスの変更を通知するモードを定義します。
net.ipv4.conf.IFNAME.disable_policy	この IPv4 インターフェイスの IPSEC ポリシー (SPD) を無効にします。
net.ipv4.conf.IFNAME.secure_redirects	インターフェイスの現在のゲートウェイリストにリストされているゲートウェイに対する ICMP リダイレクトメッセージのみを受信します。
net.ipv4.conf.IFNAME.send_redirects	送信リダイレクトは、ノードがルーターとして動作する場合にのみ有効になります。つまり、ホストは ICMP リダイレクトメッセージを送信しないでください。これは、特定の宛先で利用可能なルーティングパスの改善をホストに通知するためにルーターによって使用されます。
net.ipv6.conf.IFNAME.accept_ra	IPv6 ルーター広告を受け入れ、それらを使用して自動設定します。また、ルーター要請の送信の可否を判断します。ルーターへの通知は、機能の設定がルーター広告を受け入れる場合にのみ送信されます。
net.ipv6.conf.IFNAME.accept_redirects	IPv6 ICMP リダイレクトメッセージを受信します。
net.ipv6.conf.IFNAME.accept_source_route	SRR オプションで IPv6 パケットを受信します。
net.ipv6.conf.IFNAME.arp_accept	ARP テーブルに存在しない IPv6 アドレスで余計な ARP フレームの動作を定義します。 <ul style="list-style-type: none"> ● 0: ARP テーブルに新しいエントリーを作成しません。 ● 1: ARP テーブルに新しいエントリーを作成します。
net.ipv6.conf.IFNAME.arp_notify	IPv6 アドレスとデバイスの変更を通知するモードを定義します。
net.ipv6.neigh.IFNAME.base_reachable_time_ms	このパラメーターは、IPv6 の neighbour テーブルで、IP マッピングの有効期間に対するハードウェアアドレスを制御します。
net.ipv6.neigh.IFNAME.retrans_time_ms	隣接する検出メッセージの再送信タイマーを設定します。

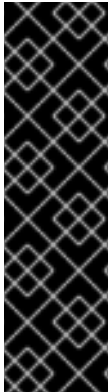


注記

tuning CNI プラグインを使用してこれらの値を設定する場合は、値 **IFNAME** をそのまま使用します。インターフェイス名は **IFNAME** トークンによって表され、ランタイム時にインターフェイスの実際の名前に置き換えられます。

7.9.4. インターフェイス固有の安全な **sysctls** リストの更新

OpenShift Container Platform では、インターフェイス固有の安全な **sysctls** のリストがあらかじめ定義されています。このリストを変更するには、**openshift-multus** namespace で **cni-sysctl-allowlist** を更新します。



重要

インターフェイス固有の安全な **sysctl** リストの更新のサポートは、テクノロジープレビュー機能のみです。テクノロジープレビュー機能は、Red Hat 製品のサービスレベルアグリーメント (SLA) の対象外であり、機能的に完全ではないことがあります。Red Hat は、実稼働環境でこれらを使用することを推奨していません。テクノロジープレビュー機能は、最新の製品機能をいち早く提供して、開発段階で機能のテストを行い、フィードバックを提供していただくことを目的としています。

Red Hat のテクノロジープレビュー機能のサポート範囲に関する詳細は、[テクノロジープレビュー機能のサポート範囲](#) を参照してください。

安全な **sysctls** の定義済みリストを変更するには、次の手順に従ってください。この手順では、デフォルトの許可リストを拡張する方法を説明します。

手順

1. 次のコマンドを実行して、既存の定義済みリストを表示します。

```
$ oc get cm -n openshift-multus cni-sysctl-allowlist -oyaml
```

予想される出力

```
apiVersion: v1
data:
  allowlist.conf: |-
    ^net.ipv4.conf.IFNAME.accept_redirects$
    ^net.ipv4.conf.IFNAME.accept_source_route$
    ^net.ipv4.conf.IFNAME.arp_accept$
    ^net.ipv4.conf.IFNAME.arp_notify$
    ^net.ipv4.conf.IFNAME.disable_policy$
    ^net.ipv4.conf.IFNAME.secure_redirects$
    ^net.ipv4.conf.IFNAME.send_redirects$
    ^net.ipv6.conf.IFNAME.accept_ra$
    ^net.ipv6.conf.IFNAME.accept_redirects$
    ^net.ipv6.conf.IFNAME.accept_source_route$
    ^net.ipv6.conf.IFNAME.arp_accept$
    ^net.ipv6.conf.IFNAME.arp_notify$
    ^net.ipv6.neigh.IFNAME.base_reachable_time_ms$
    ^net.ipv6.neigh.IFNAME.retrans_time_ms$
kind: ConfigMap
metadata:
```

```

annotations:
  kubernetes.io/description: |
    Sysctl allowlist for nodes.
  release.openshift.io/version: 4.12.0-0.nightly-2022-11-16-003434
creationTimestamp: "2022-11-17T14:09:27Z"
name: cni-sysctl-allowlist
namespace: openshift-multus
resourceVersion: "2422"
uid: 96d138a3-160e-4943-90ff-6108fa7c50c3

```

2. 次のコマンドを使用してリストを編集します。

```
$ oc edit cm -n openshift-multus cni-sysctl-allowlist -oyaml
```

たとえば、より厳密なリバースパス転送を実装できるようにするには、次のように `^net.ipv4.conf.IFNAME.rp_filter$` と `^net.ipv6.conf.IFNAME.rp_filter$` をリストに追加する必要があります。

```

# Please edit the object below. Lines beginning with a '#' will be ignored,
# and an empty file will abort the edit. If an error occurs while saving this file will be
# reopened with the relevant failures.
#
apiVersion: v1
data:
  allowlist.conf: |-
    ^net.ipv4.conf.IFNAME.accept_redirects$
    ^net.ipv4.conf.IFNAME.accept_source_route$
    ^net.ipv4.conf.IFNAME.arp_accept$
    ^net.ipv4.conf.IFNAME.arp_notify$
    ^net.ipv4.conf.IFNAME.disable_policy$
    ^net.ipv4.conf.IFNAME.secure_redirects$
    ^net.ipv4.conf.IFNAME.send_redirects$
    ^net.ipv4.conf.IFNAME.rp_filter$
    ^net.ipv6.conf.IFNAME.accept_ra$
    ^net.ipv6.conf.IFNAME.accept_redirects$
    ^net.ipv6.conf.IFNAME.accept_source_route$
    ^net.ipv6.conf.IFNAME.arp_accept$
    ^net.ipv6.conf.IFNAME.arp_notify$
    ^net.ipv6.neigh.IFNAME.base_reachable_time_ms$
    ^net.ipv6.neigh.IFNAME.retrans_time_ms$
    ^net.ipv6.conf.IFNAME.rp_filter$

```

3. 変更をファイルに保存して終了します。



注記

sysctl の削除もサポートされています。ファイルを編集し、**sysctl** または **sysctls** を削除してから、変更を保存して終了します。

検証

IPv4 のより厳密なリバースパス転送を強制するには、次の手順に従います。リバースパスフォワーディングの詳細は、[リバースパスフォワーディング](#) を参照してください。

1. 次の内容で、**reverse-path-fwd-example.yaml** などのネットワーク接続定義を作成します。

```

apiVersion: "k8s.cni.cncf.io/v1"
kind: NetworkAttachmentDefinition
metadata:
  name: tuningnad
  namespace: default
spec:
  config: '{
    "cniVersion": "0.4.0",
    "name": "tuningnad",
    "plugins": [{
      "type": "bridge"
    },
    {
      "type": "tuning",
      "sysctl": {
        "net.ipv4.conf.IFNAME.rp_filter": "1"
      }
    }
  ]
}'

```

2. 以下のコマンドを実行して yaml を適用します。

```
$ oc apply -f reverse-path-fwd-example.yaml
```

出力例

```
networkattachmentdefinition.k8s.cni.cncf.io/tuningnad created
```

3. 次の YAML を使用して、**examplepod.yaml** などの Pod を作成します。

```

apiVersion: v1
kind: Pod
metadata:
  name: example
  labels:
    app: httpd
  namespace: default
  annotations:
    k8s.v1.cni.cncf.io/networks: tuningnad ❶
spec:
  securityContext:
    runAsNonRoot: true
    seccompProfile:
      type: RuntimeDefault
  containers:
    - name: httpd
      image: 'image-registry.openshift-image-registry.svc:5000/openshift/httpd:latest'
      ports:
        - containerPort: 8080
      securityContext:
        allowPrivilegeEscalation: false

```

```
capabilities:
  drop:
  - ALL
```

- 1 設定済みの **NetworkAttachmentDefinition** の名前を指定します。

4. 以下のコマンドを実行して yamI を適用します。

```
$ oc apply -f examplepod.yaml
```

5. 次のコマンドを実行して、Pod が作成されていることを確認します。

```
$ oc get pod
```

出力例

```
NAME      READY   STATUS    RESTARTS   AGE
example   1/1     Running   0           47s
```

6. 次のコマンドを実行して、Pod にログインします。

```
$ oc rsh example
```

7. 設定された sysctl フラグの値を確認します。たとえば、次のコマンドを実行して値 **net.ipv4.conf.net1.rp_filter** を見つけます。

```
sh-4.4# sysctl net.ipv4.conf.net1.rp_filter
```

予想される出力

```
net.ipv4.conf.net1.rp_filter = 1
```

関連情報

- [チューニング CNI の設定](#)
- [Linux ネットワークドキュメント](#)

7.9.5. 安全な sysctl での Pod の起動

Pod の **securityContext** を使用して sysctl を Pod に設定できます。 **securityContext** は同じ Pod 内のすべてのコンテナに適用されます。

安全な sysctl はデフォルトで許可されます。

この例では、Pod **securityContext** を使用して以下の安全な sysctl を設定します。

- **kernel.shm_rmid_forced**
- **net.ipv4.ip_local_port_range**
- **net.ipv4.tcp_syncookies**

- **net.ipv4.ping_group_range**

**警告**

オペレーティングシステムが不安定になるのを防ぐには、変更の影響を確認している場合にのみ `sysctl` パラメーターを変更します。

以下の手順を使用して、設定される `sysctl` 設定で Pod を起動します。

**注記**

ほとんどの場合、既存の Pod 定義を変更し、**securityContext** 仕様を追加します。

手順

1. 以下の例のように、サンプル Pod を定義し、**securityContext** 仕様を追加する YAML ファイルの **sysctl_pod.yaml** を作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: sysctl-example
  namespace: default
spec:
  containers:
  - name: podexample
    image: centos
    command: ["bin/bash", "-c", "sleep INF"]
    securityContext:
      runAsUser: 2000 ①
      runAsGroup: 3000 ②
      allowPrivilegeEscalation: false ③
      capabilities: ④
      drop: ["ALL"]
    securityContext:
      runAsNonRoot: true ⑤
      seccompProfile: ⑥
      type: RuntimeDefault
    sysctls:
      - name: kernel.shm_rmid_forced
        value: "1"
      - name: net.ipv4.ip_local_port_range
        value: "32770 60666"
      - name: net.ipv4.tcp_syncookies
        value: "0"
      - name: net.ipv4.ping_group_range
        value: "0 200000000"
```

- ① **runAsUser** は、コンテナーが実行されるユーザー ID を制御します。

- 2 **runAsGroup** は、コンテナが実行されるプライマリグループ ID を制御します。
- 3 **allowPrivilegeEscalation** は、Pod が権限の昇格を許可するように要求できるかどうかを決定します。指定しない場合、デフォルトで true に設定されます。このブール値は、**no_new_privs** フラグがコンテナプロセスに設定されるかどうかを直接制御します。
- 4 **capabilities** は、完全な root アクセス権を与えることなく特権操作を許可します。このポリシーにより、すべての機能が Pod から削除されます。
- 5 **runAsNonRoot: true** は、コンテナが 0 以外の任意の UID を持つユーザーで実行されることを要求します。
- 6 **RuntimeDefault** は、Pod またはコンテナワークロードのデフォルトの seccomp プロファイルを有効にします。

2. 以下のコマンドを実行して Pod を作成します。

```
$ oc apply -f sysctl_pod.yaml
```

3. 次のコマンドを実行して、Pod が作成されていることを確認します。

```
$ oc get pod
```

出力例

```
NAME          READY  STATUS   RESTARTS  AGE
sysctl-example 1/1    Running    0          14s
```

4. 次のコマンドを実行して、Pod にログインします。

```
$ oc rsh sysctl-example
```

5. 設定された sysctl フラグの値を確認します。たとえば、以下のコマンドを実行して **kernel.shm_rmid_forced** の値を見つけます。

```
sh-4.4# sysctl kernel.shm_rmid_forced
```

予想される出力

```
kernel.shm_rmid_forced = 1
```

7.9.6. 安全でない sysctl での Pod の起動

安全でない sysctl が設定された Pod は、クラスター管理者がそのノードの安全でない sysctl を明示的に有効にしない限り、いずれのノードでも起動に失敗します。ノードレベルの sysctl の場合のように、それらの Pod を正しいノードにスケジューリングするには、**taint** および **toleration**、またはノードのラベルを使用します。

以下の例では Pod の **securityContext** を使用して安全な sysctl **kernel.shm_rmid_forced** および 2 つの安全でない sysctl **net.core.somaxconn** および **kernel.msgmax** を設定します。仕様では **安全な sysctl** と **安全でない sysctl** は区別されません。



警告

オペレーティングシステムが不安定になるのを防ぐには、変更の影響を確認している場合にのみ `sysctl` パラメーターを変更します。

以下の例は、安全な `sysctl` を Pod 仕様に追加する際に発生する内容を示しています。

手順

1. 以下の例のように、サンプル Pod を定義し、**securityContext** 仕様を追加する YAML ファイル **sysctl-example-unsafe.yaml** を作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: sysctl-example-unsafe
spec:
  containers:
  - name: podexample
    image: centos
    command: ["bin/bash", "-c", "sleep INF"]
    securityContext:
      runAsUser: 2000
      runAsGroup: 3000
      allowPrivilegeEscalation: false
      capabilities:
        drop: ["ALL"]
    securityContext:
      runAsNonRoot: true
    seccompProfile:
      type: RuntimeDefault
    sysctls:
      - name: kernel.shm_rmid_forced
        value: "0"
      - name: net.core.somaxconn
        value: "1024"
      - name: kernel.msgmax
        value: "65536"
```

2. 以下のコマンドを使用して Pod を作成します。

```
$ oc apply -f sysctl-example-unsafe.yaml
```

3. 以下のコマンドを使用して安全でない `sysctl` がノードに許可されないため、Pod がスケジュールされているがデプロイされないことを確認します。

```
$ oc get pod
```

出力例

■

NAME	READY	STATUS	RESTARTS	AGE
sysctl-example-unsafe	0/1	SysctlForbidden	0	14s

7.9.7. 安全でない sysctl の有効化

クラスター管理者は、高パフォーマンスまたはリアルタイムのアプリケーション調整などの非常に特殊な状況で特定の安全でない sysctl を許可することができます。

安全でない sysctl を使用する必要がある場合、クラスター管理者は特定のタイプのノードに対してそれらを個別に有効にする必要があります。sysctl には namespace を使用する必要があります。

Security Context Constraints の **allowedUnsafeSysctls** フィールドに sysctl または sysctl パターンのリストを指定することで、どの sysctl を Pod に設定するかをさらに制御できます。

- **allowedUnsafeSysctls** オプションは、高パフォーマンスやリアルタイムのアプリケーションチューニングなどの特定ニーズを管理します。



警告

安全でないという性質上、安全でない sysctl は各自の責任で使用されます。場合によっては、コンテナの正しくない動作やリソース不足、またはノードの破損などの深刻な問題が生じる可能性があります。

手順

1. 以下のコマンドを実行して、OpenShift Container Platform クラスターの既存の MachineConfig オブジェクトをリスト表示し、マシン設定にラベルを付ける方法を決定します。

```
$ oc get machineconfigpool
```

出力例

NAME	CONFIG	UPDATED	UPDATING	DEGRADED
MACHINECOUNT	READYMACHINECOUNT	UPDATEDMACHINECOUNT		
DEGRADEDMACHINECOUNT	AGE			
master	rendered-master-bfb92f0cd1684e54d8e234ab7423cc96	True	False	False
3	3	3	0	42m
worker	rendered-worker-21b6cb9a0f8919c88caf39db80ac1fce	True	False	False
3	3	3	0	42m

2. 以下のコマンドを実行して、安全でない sysctl が設定されたコンテナが実行されるマシン設定プールにラベルを追加します。

```
$ oc label machineconfigpool worker custom-kubelet=sysctl
```

3. **KubeletConfig** カスタムリソース (CR) を定義する YAML ファイル **set-sysctl-worker.yaml** を作成します。

```

apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: custom-kubelet
spec:
  machineConfigPoolSelector:
    matchLabels:
      custom-kubelet: sysctl ❶
  kubeletConfig:
    allowedUnsafeSysctls: ❷
      - "kernel.msg*"
      - "net.core.somaxconn"

```

- ❶ マシン設定プールからラベルを指定します。
- ❷ 許可する必要がある安全でない sysctl を一覧表示します。

4. 以下のコマンドを実行してオブジェクトを作成します。

```
$ oc apply -f set-sysctl-worker.yaml
```

5. 以下のコマンドを実行して、Machine Config Operator が新規のレンダリングされた設定を生成し、これをマシンに適用します。

```
$ oc get machineconfigpool worker -w
```

数分後、**UPDATING** のステータスが True から False に変化します。

NAME	CONFIG	UPDATED	UPDATING	DEGRADED
MACHINECOUNT	READYMACHINECOUNT	UPDATEDMACHINECOUNT		
DEGRADEDMACHINECOUNT	AGE			
worker	rendered-worker-f1704a00fc6f30d3a7de9a15fd68a800	False	True	False
3	2	2	0	71m
worker	rendered-worker-f1704a00fc6f30d3a7de9a15fd68a800	False	True	False
3	2	3	0	72m
worker	rendered-worker-0188658afe1f3a183ec8c4f14186f4d5	True	False	False
3	3	3	0	72m

6. 次の例に示すように、サンプルの Pod を定義する YAML ファイル **sysctl-example-safe-unsafe.yaml** を作成し、**securityContext** の仕様を追加します。

```

apiVersion: v1
kind: Pod
metadata:
  name: sysctl-example-safe-unsafe
spec:
  containers:
    - name: podexample
      image: centos
      command: ["bin/bash", "-c", "sleep INF"]
      securityContext:
        runAsUser: 2000
        runAsGroup: 3000

```

```

allowPrivilegeEscalation: false
capabilities:
  drop: ["ALL"]
securityContext:
  runAsNonRoot: true
seccompProfile:
  type: RuntimeDefault
sysctls:
- name: kernel.shm_rmid_forced
  value: "0"
- name: net.core.somaxconn
  value: "1024"
- name: kernel.msgmax
  value: "65536"

```

7. 以下のコマンドを実行して Pod を作成します。

```
$ oc apply -f sysctl-example-safe-unsafe.yaml
```

予想される出力

```

Warning: would violate PodSecurity "restricted:latest": forbidden sysctls
(net.core.somaxconn, kernel.msgmax)
pod/sysctl-example-safe-unsafe created

```

8. 次のコマンドを実行して、Pod が作成されていることを確認します。

```
$ oc get pod
```

出力例

```

NAME                READY STATUS RESTARTS AGE
sysctl-example-safe-unsafe 1/1   Running 0      19s

```

9. 次のコマンドを実行して、Pod にログインします。

```
$ oc rsh sysctl-example-safe-unsafe
```

10. 設定された sysctl フラグの値を確認します。たとえば、以下のコマンドを実行して **net.core.somaxconn** の値を見つけます。

```
sh-4.4# sysctl net.core.somaxconn
```

予想される出力

```
net.core.somaxconn = 1024
```

安全でない sysctl が許可され、値は更新された Pod 仕様の **securityContext** 仕様で定義されているように設定されるようになりました。

7.9.8. 関連情報

- [インターフェイスレベルのネットワーク sysctl の設定](#)
- [Node Tuning Operator の使用](#)

第8章 クラスターの操作

8.1. OPENSIFT CONTAINER PLATFORM クラスター内のシステムイベント情報の表示

OpenShift Container Platform のイベントは OpenShift Container Platform クラスターの API オブジェクトに対して発生するイベントに基づいてモデル化されます。

8.1.1. イベントについて

イベントにより、OpenShift Container Platform はリソースに依存しない方法で実際のイベントに関する情報を記録できます。また、開発者および管理者が統一された方法でシステムコンポーネントに関する情報を使用できるようにします。

8.1.2. CLI を使用したイベントの表示

CLI を使用し、特定のプロジェクト内のイベントのリストを取得できます。

手順

- プロジェクト内のイベントを表示するには、以下のコマンドを使用します。

```
$ oc get events [-n <project>] ❶
```

- ❶ プロジェクトの名前。

以下に例を示します。

```
$ oc get events -n openshift-config
```

出力例

LAST SEEN	TYPE	REASON	OBJECT	MESSAGE
97m	Normal	Scheduled	pod/dapi-env-test-pod	Successfully assigned openshift-config/dapi-env-test-pod to ip-10-0-171-202.ec2.internal
97m	Normal	Pulling	pod/dapi-env-test-pod	pulling image "gcr.io/google_containers/busybox"
97m	Normal	Pulled	pod/dapi-env-test-pod	Successfully pulled image "gcr.io/google_containers/busybox"
97m	Normal	Created	pod/dapi-env-test-pod	Created container
9m5s	Warning	FailedCreatePodSandBox	pod/dapi-volume-test-pod	Failed create pod sandbox: rpc error: code = Unknown desc = failed to create pod network sandbox k8s_dapi-volume-test-pod_openshift-config_6bc60c1f-452e-11e9-9140-0eec59c23068_0(748c7a40db3d08c07fb4f9eba774bd5effe5f0d5090a242432a73eee66ba9e22): Multus: Err adding pod to network "openshift-sdn": cannot set "openshift-sdn" iface to "eth0": no netns: failed to Statfs "/proc/33366/ns/net": no such file or directory
8m31s	Normal	Scheduled	pod/dapi-volume-test-pod	Successfully assigned openshift-config/dapi-volume-test-pod to ip-10-0-171-202.ec2.internal

- OpenShift Container Platform コンソールからプロジェクト内のイベントを表示するには、以下を実行します。

1. OpenShift Container Platform コンソールを起動します。
2. **Home → Events** をクリックし、プロジェクトを選択します。
3. イベントを表示するリソースに移動します。たとえば、**Home → Projects → <project-name> → <resource-name>** の順に移動します。
Pod やデプロイメントなどの多くのオブジェクトには、独自の **イベント** タブもあります。それらのタブには、オブジェクトに関連するイベントが表示されます。

8.1.3. イベントのリスト

このセクションでは、OpenShift Container Platform のイベントを説明します。

表8.1 設定イベント

名前	説明
FailedValidation	Pod 設定の検証に失敗しました。

表8.2 コンテナイベント

名前	説明
BackOff	バックオフ (再起動) によりコンテナが失敗しました。
Created	コンテナが作成されました。
Failed	プル/作成/起動が失敗しました。
Killing	コンテナを強制終了しています。
Started	コンテナが起動しました。
Preempting	他の Pod のプリエンプションを実行します。
ExceededGrace Period	コンテナランタイムは、指定の猶予期間以内に Pod を停止しませんでした。

表8.3 正常性に関するイベント

名前	説明
Unhealthy	コンテナが正常ではありません。

表8.4 イメージイベント

名前	説明
BackOff	バックオフ (コンテナ起動、イメージのプル)。
ErrImageNeverPull	イメージの NeverPull Policy の違反があります。
Failed	イメージのプルに失敗しました。
InspectFailed	イメージの検査に失敗しました。
Pulled	イメージのプルに成功し、コンテナイメージがマシンにすでに置かれています。
Pulling	イメージをプルしています。

表8.5 イメージマネージャーイベント

名前	説明
FreeDiskSpaceFailed	空きディスク容量に関連する障害が発生しました。
InvalidDiskCapacity	無効なディスク容量です。

表8.6 ノードイベント

名前	説明
FailedMount	ボリュームのマウントに失敗しました。
HostNetworkNotSupported	ホストのネットワークがサポートされていません。
HostPortConflict	ホスト/ポートの競合
KubeletSetupFailed	Kubelet のセットアップに失敗しました。
NilShaper	シェイパーが定義されていません。
NodeNotReady	ノードの準備ができていません。
NodeNotSchedulable	ノードがスケジュール可能ではありません。

名前	説明
NodeReady	ノードの準備ができています。
NodeSchedulable	ノードがスケジュール可能です。
NodeSelectorMismatching	ノードセクターの不一致があります。
OutOfDisk	ディスクの空き容量が不足しています。
Rebooted	ノードが再起動しました。
Starting	kubelet を起動しています。
FailedAttachVolume	ボリュームの割り当てに失敗しました。
FailedDetachVolume	ボリュームの割り当て解除に失敗しました。
VolumeResizeFailed	ボリュームの拡張/縮小に失敗しました。
VolumeResizeSuccessful	正常にボリュームを拡張/縮小しました。
FileSystemResizeFailed	ファイルシステムの拡張/縮小に失敗しました。
FileSystemResizeSuccessful	正常にファイルシステムが拡張/縮小されました。
FailedUnMount	ボリュームのマウント解除に失敗しました。
FailedMapVolume	ボリュームのマッピングに失敗しました。
FailedUnmapDevice	デバイスのマッピング解除に失敗しました。
AlreadyMountedVolume	ボリュームがすでにマウントされています。
SuccessfulDetachVolume	ボリュームの割り当てが正常に解除されました。

名前	説明
SuccessfulMountVolume	ボリュームが正常にマウントされました。
SuccessfulUnmountVolume	ボリュームのマウントが正常に解除されました。
ContainerGCFailed	コンテナのガベージコレクションに失敗しました。
ImageGCFailed	イメージのガベージコレクションに失敗しました。
FailedNodeAllocatableEnforcement	システム予約の Cgroup 制限の実施に失敗しました。
NodeAllocatableEnforced	システム予約の Cgroup 制限を有効にしました。
UnsupportedMountOption	マウントオプションが非対応です。
SandboxChanged	Pod のサンドボックスが変更されました。
FailedCreatePodSandbox	Pod のサンドボックスの作成に失敗しました。
FailedPodSandboxStatus	Pod サンドボックスの状態取得に失敗しました。

表8.7 Pod ワーカーイベント

名前	説明
FailedSync	Pod の同期が失敗しました。

表8.8 システムイベント

名前	説明
SystemOOM	クラスターに OOM (out of memory) 状態が発生しました。

表8.9 Pod に関するイベント

名前	説明
FailedKillPod	Pod の停止に失敗しました。
FailedCreatePodContainer	Pod コンテナの作成に失敗しました。
Failed	Pod データディレクトリーの作成に失敗しました。
NetworkNotReady	ネットワークの準備ができていません。
FailedCreate	作成エラー: <error-msg>
SuccessfulCreate	作成された Pod: <pod-name>
FailedDelete	削除エラー: <error-msg>
SuccessfulDelete	削除した Pod: <pod-id>

表8.10 Horizontal Pod Autoscaler に関するイベント

名前	説明
SelectorRequired	セレクターが必要です。
InvalidSelector	セレクターを適切な内部セレクターオブジェクトに変換できませんでした。
FailedGetObjectMetric	HPA はレプリカ数を計算できませんでした。
InvalidMetricSourceType	不明なメトリクスソースタイプです。
ValidMetricFound	HPA は正常にレプリカ数を計算できました。
FailedConvertHPA	指定の HPA への変換に失敗しました。
FailedGetScale	HPA コントローラーは、ターゲットの現在のスケーリングを取得できませんでした。

名前	説明
SucceededGetScale	HPA コントローラーは、ターゲットの現在のスケールを取得できました。
FailedComputeMetricsReplicas	表示されているメトリクスに基づく必要なレプリカ数の計算に失敗しました。
FailedRescale	新しいサイズ: <size> 、理由: <msg> 、エラー: <error-msg> 。
SuccessfulRescale	新しいサイズ: <size> 、理由: <msg> 。
FailedUpdateStatus	状況の更新に失敗しました。

表8.11 ネットワークイベント (openshift-sdn)

名前	説明
Starting	OpenShift SDN を開始します。
NetworkFailed	Pod のネットワークインターフェイスがなくなり、Pod が停止します。

表8.12 ネットワークイベント (kube-proxy)

名前	説明
NeedPods	サービスポート <serviceName>:<port> は Pod が必要です。

表8.13 ボリュームイベント

名前	説明
FailedBinding	利用可能な永続ボリュームがなく、ストレージクラスが設定されていません。
VolumeMismatch	ボリュームサイズまたはクラスが要求の内容と異なります。
VolumeFailedRecycle	再利用 Pod の作成エラー
VolumeRecycled	ボリュームの再利用時に発生します。

名前	説明
RecyclerPod	Pod の再利用時に発生します。
VolumeDelete	ボリュームの削除時に発生します。
VolumeFailedDelete	ボリュームの削除時のエラー。
ExternalProvisioning	要求のボリュームが手動または外部ソフトウェアでプロビジョニングされる場合に発生します。
ProvisioningFailed	ボリュームのプロビジョニングに失敗しました。
ProvisioningCleanupFailed	プロビジョニングしたボリュームの消去エラー
ProvisioningSucceeded	ボリュームが正常にプロビジョニングされる場合に発生します。
WaitForFirstConsumer	Pod のスケジューリングまでバインドが遅延します。

表8.14 ライフサイクルフック

名前	説明
FailedPostStartHook	ハンドラーが Pod の起動に失敗しました。
FailedPreStopHook	ハンドラーが pre-stop に失敗しました。
UnfinishedPreStopHook	Pre-stop フックが完了しませんでした。

表8.15 デプロイメント

名前	説明
DeploymentCancellationFailed	デプロイメントのキャンセルに失敗しました。
DeploymentCancelled	デプロイメントがキャンセルされました。

名前	説明
DeploymentCreated	新規レプリケーションコントローラーが作成されました。
IngressIPRangeFull	サービスに割り当てる Ingress IP がありません。

表8.16 スケジューラーイベント

名前	説明
FailedScheduling	Pod のスケジューリングに失敗: <pod-namespace>/<pod-name> 。このイベントは AssumePodVolumes の失敗、バインドの拒否など、複数の理由で発生します。
Preempted	ノード <node-name> にある <preemptor-namespace>/<preemptor-name>
Scheduled	<pod-name> が <node-name> に正常に割り当てられました。

表8.17 デーモンセットイベント

名前	説明
SelectingAll	このデーモンセットは全 Pod を選択しています。空でないセレクトターが必要です。
FailedPlacement	<node-name> への Pod の配置に失敗しました。
FailedDaemonPod	ノード <node-name> で問題のあるデーモン Pod <pod-name> が見つかりました。この Pod の終了を試行します。

表8.18 LoadBalancer サービスイベント

名前	説明
CreatingLoadBalancerFailed	ロードバランサーの作成エラー
DeletingLoadBalancer	ロードバランサーを削除します。
EnsuringLoadBalancer	ロードバランサーを確保します。
EnsuredLoadBalancer	ロードバランサーを確保しました。

名前	説明
UnAvailableLoadBalancer	LoadBalancer サービスに利用可能なノードがありません。
LoadBalancerSourceRanges	新規の LoadBalancerSourceRanges を表示します。例: <old-source-range> → <new-source-range>
LoadbalancerIP	新しい IP アドレスを表示します。例: <old-ip> → <new-ip>
ExternalIP	外部 IP アドレスを表示します。例: Added: <external-ip>
UID	新しい UID を表示します。例: <old-service-uid> → <new-service-uid>
ExternalTrafficPolicy	新しい ExternalTrafficPolicy を表示します。例: <old-policy> → <new-policy>
HealthCheckNodePort	新しい HealthCheckNodePort を表示します。例: <old-node-port> → new-node-port
UpdatedLoadBalancer	新規ホストでロードバランサーを更新しました。
LoadBalancerUpdateFailed	新規ホストでのロードバランサーの更新に失敗しました。
DeletingLoadBalancer	ロードバランサーを削除します。
DeletingLoadBalancerFailed	ロードバランサーの削除エラー。
DeletedLoadBalancer	ロードバランサーを削除しました。

8.2. OPENSIFT CONTAINER PLATFORM のノードが保持できる POD の数の見積り

クラスター管理者は、OpenShift Cluster Capacity Tool を使用して、現在のリソースが使い切られる前にそれらを増やすべくスケジュール可能な Pod 数を表示し、スケジュール可能な Pod 数を表示したり、Pod を今後スケジュールできるようにすることができます。この容量は、クラスター内の個別ノードからのものを集めたものであり、これには CPU、メモリー、ディスク領域などが含まれます。

8.2.1. OpenShift Cluster Capacity Tool について

OpenShift Cluster Capacity Tool は、より正確な見積もりを出すべく、スケジュールの一連の意思決定をシミュレーションし、リソースが使い切られる前にクラスターでスケジュールできる入力 Pod のインスタンス数を判別します。



注記

ノード間に分散しているすべてのリソースがカウントされないため、残りの割り当て可能な容量は概算となります。残りのリソースのみが分析対象となり、クラスターでのスケジュール可能な所定要件を持つ Pod のインスタンス数という点から消費可能な容量を見積もります。

Pod のスケジューリングはその選択およびアフィニティー条件に基づいて特定のノードセットだけがサポートされる可能性があります。そのため、クラスターでスケジュール可能な残りの Pod 数を見積もることが困難になる場合があります。

OpenShift Cluster Capacity Tool は、コマンドラインからスタンドアロンのユーティリティとして実行することも、OpenShift Container Platform クラスター内の Pod でジョブとして実行することもできます。これを Pod 内のジョブとしてツールを実行すると、介入なしに複数回実行することができます。

8.2.2. コマンドラインでの OpenShift Cluster Capacity Tool の実行

コマンドラインから OpenShift Cluster Capacity Tool を実行して、クラスターにスケジュール設定可能な Pod 数を見積もることができます。

ツールがリソース使用状況を見積もるために使用するサンプル Pod 仕様ファイルを作成します。pod spec はそのリソース要件を **limits** または **requests** として指定します。クラスター容量ツールは、Pod のリソース要件をその見積もりの分析に反映します。

前提条件

1. [OpenShift Cluster Capacity Tool](#) を実行します。これは、Red Hat エコシステムカタログからコンテナイメージとして入手できます。
2. サンプルの Pod 仕様ファイルを作成します。
 - a. 以下のような YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: small-pod
  labels:
    app: guestbook
    tier: frontend
spec:
  containers:
  - name: php-redis
    image: gcr.io/google-samples/gb-frontend:v4
    imagePullPolicy: Always
    resources:
      limits:
        cpu: 150m
        memory: 100Mi
      requests:
        cpu: 150m
        memory: 100Mi
```

- b. クラスターロールを作成します。

```
$ oc create -f <file_name>.yaml
```

以下に例を示します。

```
$ oc create -f pod-spec.yaml
```

手順

コマンドラインでクラスター容量ツールを使用するには、次のようにします。

1. ターミナルから、Red Hat レジストリーにログインします。

```
$ podman login registry.redhat.io
```

2. クラスター容量ツールのイメージをプルします。

```
$ podman pull registry.redhat.io/openshift4/ose-cluster-capacity
```

3. クラスター容量ツールを実行します。

```
$ podman run -v $HOME/.kube:/kube:Z -v $(pwd):/cc:Z ose-cluster-capacity \
/bin/cluster-capacity --kubeconfig /kube/config --<pod_spec>.yaml /cc/<pod_spec>.yaml \
--verbose
```

ここでは、以下ようになります。

<pod_spec>.yaml

使用する Pod の仕様を指定します。

verbose

クラスター内の各ノードでスケジュールできる Pod の数の詳細な説明を出力します。

出力例

```
small-pod pod requirements:
```

- CPU: 150m
- Memory: 100Mi

```
The cluster can schedule 88 instance(s) of the pod small-pod.
```

```
Termination reason: Unschedulable: 0/5 nodes are available: 2 Insufficient cpu,
3 node(s) had taint {node-role.kubernetes.io/master: }, that the pod didn't
tolerate.
```

```
Pod distribution among nodes:
```

```
small-pod
```

- 192.168.124.214: 45 instance(s)
- 192.168.124.120: 43 instance(s)

上記の例では、クラスターにスケジュールできる推定 Pod の数は 88 です。

8.2.3. OpenShift Cluster Capacity Tool を Pod 内のジョブとして実行する

OpenShift Cluster Capacity Tool を Pod 内のジョブとして実行すると、ユーザーの介入を必要とせずにツールを複数回実行できます。OpenShift Cluster Capacity Tool は、**ConfigMap** オブジェクトを使用してジョブとして実行します。

前提条件

[OpenShift Cluster Capacity Tool](#) をダウンロードしてインストールします。

手順

クラスター容量ツールを実行するには、以下の手順を実行します。

1. クラスターロールを作成します。
 - a. 以下のような YAML ファイルを作成します。

```
kind: ClusterRole
apiVersion: rbac.authorization.k8s.io/v1
metadata:
  name: cluster-capacity-role
rules:
- apiGroups: [""]
  resources: ["pods", "nodes", "persistentvolumeclaims", "persistentvolumes", "services",
"replicationcontrollers"]
  verbs: ["get", "watch", "list"]
- apiGroups: ["apps"]
  resources: ["replicasets", "statefulsets"]
  verbs: ["get", "watch", "list"]
- apiGroups: ["policy"]
  resources: ["poddisruptionbudgets"]
  verbs: ["get", "watch", "list"]
- apiGroups: ["storage.k8s.io"]
  resources: ["storageclasses"]
  verbs: ["get", "watch", "list"]
```

- b. 次のコマンドを実行して、クラスターのロールを作成します。

```
$ oc create -f <file_name>.yaml
```

以下に例を示します。

```
$ oc create sa cluster-capacity-sa
```

2. サービスアカウントを作成します。

```
$ oc create sa cluster-capacity-sa -n default
```

3. ロールをサービスアカウントに追加します。

```
$ oc adm policy add-cluster-role-to-user cluster-capacity-role \
  system:serviceaccount:<namespace>:cluster-capacity-sa
```

ここでは、以下のようになります。

<namespace>

Pod が配置されている namespace を指定します。

4. Pod 仕様を定義して、作成します。

a. 以下のような YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: small-pod
  labels:
    app: guestbook
    tier: frontend
spec:
  containers:
  - name: php-redis
    image: gcr.io/google-samples/gb-frontend:v4
    imagePullPolicy: Always
  resources:
    limits:
      cpu: 150m
      memory: 100Mi
    requests:
      cpu: 150m
      memory: 100Mi
```

b. 以下のコマンドを実行して Pod を作成します。

```
$ oc create -f <file_name>.yaml
```

以下に例を示します。

```
$ oc create -f pod.yaml
```

5. 以下のコマンドを実行して config map オブジェクトを作成します。

```
$ oc create configmap cluster-capacity-configmap \
  --from-file=pod.yaml=pod.yaml
```

クラスター容量分析は、**cluster-capacity-configmap** という名前の config map オブジェクトを使用してボリュームにマウントされ、入力 Pod 仕様ファイル **pod.yaml** はパス **/test-pod** のボリューム **test-volume** にマウントされます。

6. ジョブ仕様ファイルの以下のサンプルを使用して、ジョブを作成します。

a. 以下のような YAML ファイルを作成します。

```
apiVersion: batch/v1
kind: Job
metadata:
  name: cluster-capacity-job
spec:
  parallelism: 1
  completions: 1
  template:
```

```

metadata:
  name: cluster-capacity-pod
spec:
  containers:
    - name: cluster-capacity
      image: openshift/origin-cluster-capacity
      imagePullPolicy: "Always"
      volumeMounts:
        - mountPath: /test-pod
          name: test-volume
      env:
        - name: CC_INCLUSTER ❶
          value: "true"
      command:
        - "/bin/sh"
        - "-ec"
        - |
          /bin/cluster-capacity --podspec=/test-pod/pod.yaml --verbose
      restartPolicy: "Never"
  serviceAccountName: cluster-capacity-sa
  volumes:
    - name: test-volume
      configMap:
        name: cluster-capacity-configmap

```

❶ クラスター容量ツールにクラスター内で Pod として実行されていることを認識させる環境変数です。

ConfigMap の **pod.yaml** キーは **Pod** 仕様ファイル名と同じですが、これは必須ではありません。これを実行することで、入力 Pod 仕様ファイルは **/test-pod/pod.yaml** として Pod 内でアクセスできます。

b. 次のコマンドを実行して、クラスター容量イメージを Pod 内のジョブとして実行します。

```
$ oc create -f cluster-capacity-job.yaml
```

検証

1. ジョブログを確認し、クラスター内でスケジュールできる Pod の数を確認します。

```
$ oc logs jobs/cluster-capacity-job
```

出力例

```

small-pod pod requirements:
  - CPU: 150m
  - Memory: 100Mi

```

The cluster can schedule 52 instance(s) of the pod small-pod.

Termination reason: Unschedulable: No nodes are available that match all of the following predicates:: Insufficient cpu (2).

```

Pod distribution among nodes:
small-pod

```

- 192.168.124.214: 26 instance(s)
- 192.168.124.120: 26 instance(s)

8.3. 制限範囲によるリソース消費の制限

デフォルトで、コンテナは OpenShift Container Platform クラスターのバインドされていないコンピュータリソースで実行されます。制限範囲は、プロジェクト内の特定オブジェクトのリソースの消費を制限できます。

- Pod およびコンテナ: Pod およびそれらのコンテナの CPU およびメモリの最小および最大要件を設定できます。
- イメージストリーム: **ImageStream** オブジェクトのイメージおよびタグの数に制限を設定できます。
- イメージ: 内部レジストリーにプッシュできるイメージのサイズを制限することができます。
- 永続ボリューム要求 (PVC): 要求できる PVC のサイズを制限できます。

Pod が制限範囲で課される制約を満たさない場合、Pod を namespace に作成することはできません。

8.3.1. 制限範囲について

LimitRange オブジェクトで定義される制限範囲。プロジェクトのリソース消費を制限します。プロジェクトで、Pod、コンテナ、イメージ、イメージストリーム、または永続ボリューム要求 (PVC) の特定のリソース制限を設定できます。

すべてのリソース作成および変更要求は、プロジェクトのそれぞれの **LimitRange** オブジェクトに対して評価されます。リソースが列挙される制約のいずれかに違反する場合、そのリソースは拒否されます。

以下は、Pod、コンテナ、イメージ、イメージストリーム、または PVC のすべてのコンポーネントの制限範囲オブジェクトを示しています。同じオブジェクト内のこれらのコンポーネントのいずれかまたはすべての制限を設定できます。リソースを制御するプロジェクトごとに、異なる制限範囲オブジェクトを作成します。

コンテナの制限オブジェクトのサンプル

```
apiVersion: "v1"
kind: "LimitRange"
metadata:
  name: "resource-limits"
spec:
  limits:
    - type: "Container"
      max:
        cpu: "2"
        memory: "1Gi"
      min:
        cpu: "100m"
        memory: "4Mi"
      default:
        cpu: "300m"
        memory: "200Mi"
      defaultRequest:
```

```
cpu: "200m"
memory: "100Mi"
maxLimitRequestRatio:
cpu: "10"
```

8.3.1.1. コンポーネントの制限について

以下の例は、それぞれのコンポーネントの制限範囲パラメーターを示しています。これらの例は明確にするために使用されます。必要に応じて、いずれかまたはすべてのコンポーネントの単一の **LimitRange** オブジェクトを作成できます。

8.3.1.1.1. コンテナの制限

制限範囲により、Pod の各コンテナが特定のプロジェクトに要求できる最小および最大 CPU およびメモリーを指定できます。コンテナがプロジェクトに作成される場合、**Pod** 仕様のコンテナ CPU およびメモリー要求は **LimitRange** オブジェクトに設定される値に準拠する必要があります。そうでない場合には、Pod は作成されません。

- コンテナの CPU またはメモリーの要求および制限は、**LimitRange** オブジェクトで指定されるコンテナの **min** リソース制約以上である必要があります。
- コンテナの CPU またはメモリーの要求と制限は、**LimitRange** オブジェクトで指定されたコンテナの **max** リソース制約以下である必要があります。
LimitRange オブジェクトが **max** CPU を定義する場合、**Pod** 仕様に CPU **request** 値を定義する必要はありません。ただし、制限範囲で指定される最大 CPU 制約を満たす CPU **limit** 値を指定する必要があります。

- コンテナ制限の要求に対する比率は、**LimitRange** オブジェクトに指定されるコンテナの **maxLimitRequestRatio** 値以下である必要があります。
LimitRange オブジェクトで **maxLimitRequestRatio** 制約を定義する場合、新規コンテナには **request** および **limit** 値の両方が必要になります。OpenShift Container Platform は、**limit** を **request** で除算して制限の要求に対する比率を算出します。この値は、1 より大きい正の整数でなければなりません。

たとえば、コンテナの **limit** 値が **cpu: 500** で、**request** 値が **cpu: 100** である場合、**cpu** の要求に対する制限の比は **5** になります。この比率は **maxLimitRequestRatio** より小さいか等しくなければなりません。

Pod 仕様でコンテナリソースメモリーまたは制限を指定しない場合、制限範囲オブジェクトに指定されるコンテナの **default** または **defaultRequest** CPU およびメモリー値はコンテナに割り当てられます。

コンテナ **LimitRange** オブジェクトの定義

```
apiVersion: "v1"
kind: "LimitRange"
metadata:
  name: "resource-limits" ❶
spec:
  limits:
    - type: "Container"
      max:
        cpu: "2" ❷
        memory: "1Gi" ❸
```

```

min:
  cpu: "100m" ④
  memory: "4Mi" ⑤
default:
  cpu: "300m" ⑥
  memory: "200Mi" ⑦
defaultRequest:
  cpu: "200m" ⑧
  memory: "100Mi" ⑨
maxLimitRequestRatio:
  cpu: "10" ⑩

```

- ① LimitRange オブジェクトの名前です。
- ② Pod の単一コンテナが要求できる CPU の最大量です。
- ③ Pod の単一コンテナが要求できるメモリーの最大量です。
- ④ Pod の単一コンテナが要求できる CPU の最小量です。
- ⑤ Pod の単一コンテナが要求できるメモリーの最小量です。
- ⑥ コンテナが使用できる CPU のデフォルト量 (**Pod** 仕様に指定されていない場合)。
- ⑦ コンテナが使用できるメモリーのデフォルト量 (**Pod** 仕様に指定されていない場合)。
- ⑧ コンテナが要求できる CPU のデフォルト量 (**Pod** 仕様に指定されていない場合)。
- ⑨ コンテナが要求できるメモリーのデフォルト量 (**Pod** 仕様に指定されていない場合)。
- ⑩ コンテナの要求に対する制限の最大比率。

8.3.1.1.2. Pod の制限

制限範囲により、所定プロジェクトの Pod 全体でのすべてのコンテナの CPU およびメモリーの最小および最大の制限を指定できます。コンテナをプロジェクトに作成するには、**Pod** 仕様のコンテナ CPU およびメモリー要求は **LimitRange** オブジェクトに設定される値に準拠する必要があります。そうでない場合には、Pod は作成されません。

Pod 仕様でコンテナリソースメモリーまたは制限を指定しない場合、制限範囲オブジェクトに指定されるコンテナの **default** または **defaultRequest** CPU およびメモリー値はコンテナに割り当てられます。

Pod のすべてのコンテナにおいて、以下を満たしている必要があります。

- コンテナの CPU またはメモリーの要求および制限は、**LimitRange** オブジェクトに指定される Pod の **min** リソース制約以上である必要があります。
- コンテナの CPU またはメモリーの要求および制限は、**LimitRange** オブジェクトに指定される Pod の **max** リソース制約以下である必要があります。
- コンテナ制限の要求に対する比率は、**LimitRange** オブジェクトに指定される **maxLimitRequestRatio** 制約以下である必要があります。

Pod LimitRange オブジェクト定義

```
apiVersion: "v1"
kind: "LimitRange"
metadata:
  name: "resource-limits" ❶
spec:
  limits:
    - type: "Pod"
      max:
        cpu: "2" ❷
        memory: "1Gi" ❸
      min:
        cpu: "200m" ❹
        memory: "6Mi" ❺
      maxLimitRequestRatio:
        cpu: "10" ❻
```

- ❶ 制限範囲オブジェクトの名前です。
- ❷ すべてのコンテナにおいて Pod が要求できる CPU の最大量です。
- ❸ すべてのコンテナにおいて Pod が要求できるメモリーの最大量です。
- ❹ すべてのコンテナにおいて Pod が要求できる CPU の最小量です。
- ❺ すべてのコンテナにおいて Pod が要求できるメモリーの最小量です。
- ❻ コンテナの要求に対する制限の最大比率。

8.3.1.1.3. イメージの制限

LimitRange オブジェクトを使用すると、OpenShift イメージレジストリーにプッシュできるイメージの最大サイズを指定できます。

OpenShift イメージレジストリーにイメージをプッシュする場合、以下を満たす必要があります。

- イメージのサイズは、**LimitRange** オブジェクトで指定されるイメージの **max** サイズ以下である必要があります。

イメージ LimitRange オブジェクトの定義

```
apiVersion: "v1"
kind: "LimitRange"
metadata:
  name: "resource-limits" ❶
spec:
  limits:
    - type: openshift.io/Image
      max:
        storage: 1Gi ❷
```

- 1 **LimitRange** オブジェクトの名前。
- 2 OpenShift イメージレジストリーにプッシュできるイメージの最大サイズ。



注記

制限を超える Blob がレジストリーにアップロードされないようにするために、クォータを実施するようレジストリーを設定する必要があります。



警告

イメージのサイズは、アップロードされるイメージのマニフェストで常に表示される訳ではありません。これは、とりわけ Docker 1.10 以上で作成され、v2 レジストリーにプッシュされたイメージの場合に該当します。このようなイメージが古い Docker デーモンでプルされると、イメージマニフェストはレジストリーによってスキーマ v1 に変換されますが、この場合サイズ情報が欠落します。イメージに設定されるストレージの制限がこのアップロードを防ぐことはありません。

現在、[この問題](#) への対応が行われています。

8.3.1.1.4. イメージストリームの制限

LimitRange オブジェクトにより、イメージストリームの制限を指定できます。

各イメージストリームについて、以下が当てはまります。

- **ImageStream** 仕様のイメージタグ数は、**LimitRange** オブジェクトの **openshift.io/image-tags** 制約以下である必要があります。
- **ImageStream** 仕様のイメージへの一意の参照数は、制限範囲オブジェクトの **openshift.io/images** 制約以下である必要があります。

イメージストリーム **LimitRange** オブジェクト定義

```
apiVersion: "v1"
kind: "LimitRange"
metadata:
  name: "resource-limits" 1
spec:
  limits:
    - type: openshift.io/ImageStream
      max:
        openshift.io/image-tags: 20 2
        openshift.io/images: 30 3
```

- 1 **LimitRange** オブジェクトの名前。
- 2 イメージストリーム仕様の **imagestream.spec.tags** パラメーターの一意のイメージタグの最大

3 imagestream 仕様の imagestream.status.tags パラメーターの一意のイメージ参照の最大数。

openshift.io/image-tags リソースは、一意のイメージ参照を表します。使用できる参照は、**ImageStreamTag**、**ImageStreamImage** および **DockerImage** になります。タグは、**oc tag** および **oc import-image** コマンドを使用して作成できます。内部参照か外部参照であるかの区別はありません。ただし、**ImageStream** の仕様でタグ付けされる一意の参照はそれぞれ1回のみカウントされます。内部コンテナイメージレジストリーへのプッシュを制限しませんが、タグの制限に役立ちます。

openshift.io/images リソースは、イメージストリームのステータスに記録される一意のイメージ名を表します。これにより、OpenShift イメージレジストリーにプッシュできるイメージ数を制限できます。内部参照か外部参照であるかの区別はありません。

8.3.1.1.5. 永続ボリューム要求の制限

LimitRange オブジェクトにより、永続ボリューム要求 (PVC) で要求されるストレージを制限できます。

プロジェクトのすべての永続ボリューム要求において、以下が一致している必要があります。

- 永続ボリューム要求 (PVC) のリソース要求は、**LimitRange** オブジェクトに指定される PVC の **min** 制約以上である必要があります。
- 永続ボリューム要求 (PVC) のリソース要求は、**LimitRange** オブジェクトに指定される PVC の **max** 制約以下である必要があります。

PVC LimitRange オブジェクト定義

```
apiVersion: "v1"
kind: "LimitRange"
metadata:
  name: "resource-limits" ❶
spec:
  limits:
    - type: "PersistentVolumeClaim"
      min:
        storage: "2Gi" ❷
      max:
        storage: "50Gi" ❸
```

- ❶ **LimitRange** オブジェクトの名前。
- ❷ 永続ボリューム要求で要求できるストレージの最小量です。
- ❸ 永続ボリューム要求で要求できるストレージの最大量です。

8.3.2. 制限範囲の作成

制限範囲をプロジェクトに適用するには、以下を実行します。

1. 必要な仕様で **LimitRange** オブジェクトを作成します。

```
apiVersion: "v1"
```

```

kind: "LimitRange"
metadata:
  name: "resource-limits" ❶
spec:
  limits:
    - type: "Pod" ❷
      max:
        cpu: "2"
        memory: "1Gi"
      min:
        cpu: "200m"
        memory: "6Mi"
    - type: "Container" ❸
      max:
        cpu: "2"
        memory: "1Gi"
      min:
        cpu: "100m"
        memory: "4Mi"
      default: ❹
        cpu: "300m"
        memory: "200Mi"
      defaultRequest: ❺
        cpu: "200m"
        memory: "100Mi"
      maxLimitRequestRatio: ❻
        cpu: "10"
    - type: openshift.io/Image ❼
      max:
        storage: 1Gi
    - type: openshift.io/ImageStream ❽
      max:
        openshift.io/image-tags: 20
        openshift.io/images: 30
    - type: "PersistentVolumeClaim" ❾
      min:
        storage: "2Gi"
      max:
        storage: "50Gi"

```

- ❶ **LimitRange** オブジェクトの名前を指定します。
- ❷ Pod の制限を設定するには、必要に応じて CPU およびメモリーの最小および最大要求を指定します。
- ❸ コンテナの制限を設定するには、必要に応じて CPU およびメモリーの最小および最大要求を指定します。
- ❹ オプション: コンテナの場合、**Pod** 仕様で指定されていない場合、コンテナが使用できる CPU またはメモリーのデフォルト量を指定します。
- ❺ オプション: コンテナの場合、**Pod** 仕様で指定されていない場合、コンテナが要求できる CPU またはメモリーのデフォルト量を指定します。
- ❻ オプション: コンテナの場合、**Pod** 仕様で指定できる要求に対する制限の最大比率を指定します。

正しめろ。

- 7 Image オブジェクトに制限を設定するには、OpenShift イメージレジストリーにプッシュできるイメージの最大サイズを設定します。
- 8 イメージストリームの制限を設定するには、必要に応じて **ImageStream** オブジェクトファイルにあるイメージタグおよび参照の最大数を設定します。
- 9 永続ボリューム要求の制限を設定するには、要求できるストレージの最小および最大量を設定します。

2. オブジェクトを作成します。

```
$ oc create -f <limit_range_file> -n <project> 1
```

- 1 作成した YAML ファイルの名前と、制限を適用する必要があるプロジェクトを指定します。

8.3.3. 制限の表示

Web コンソールでプロジェクトの **Quota** ページに移動し、プロジェクトで定義される制限を表示できます。

CLI を使用して制限範囲の詳細を表示することもできます。

1. プロジェクトで定義される **LimitRange** オブジェクトのリストを取得します。たとえば、**demoproject** というプロジェクトの場合は以下ようになります。

```
$ oc get limits -n demoproject
```

```
NAME          CREATED AT
resource-limits 2020-07-15T17:14:23Z
```

2. 関連のある **LimitRange** オブジェクトを記述します。たとえば、**resource-limits** 制限範囲の場合は以下ようになります。

```
$ oc describe limits resource-limits -n demoproject
```

```
Name:          resource-limits
Namespace:      demoproject
Type           Resource      Min    Max    Default Request Default Limit  Max
Limit/Request Ratio
-----
Pod            cpu            200m   2      -      -      -
Pod            memory         6Mi    1Gi    -      -      -
Container      cpu            100m   2      200m   300m    10
Container      memory         4Mi    1Gi    100Mi   200Mi    -
openshift.io/Image      storage        -      1Gi    -      -      -
openshift.io/ImageStream openshift.io/image -      12     -      -      -
openshift.io/ImageStream openshift.io/image-tags -      10     -      -      -
PersistentVolumeClaim  storage        -      50Gi   -      -      -
```

8.3.4. 制限範囲の削除

プロジェクトで制限を実施しないように有効な **LimitRange** オブジェクト削除するには、以下を実行します。

- 以下のコマンドを実行します。

```
$ oc delete limits <limit_name>
```

8.4. コンテナメモリーとリスク要件を満たすためのクラスターメモリーの設定

クラスター管理者は、以下を実行し、クラスターがアプリケーションメモリーの管理を通じて効率的に動作するようにすることができます。

- コンテナ化されたアプリケーションコンポーネントのメモリーおよびリスク要件を判別し、それらの要件を満たすようコンテナメモリーパラメーターを設定する
- コンテナ化されたアプリケーションランタイム (OpenJDK など) を、設定されたコンテナメモリーパラメーターに基づいて最適に実行されるよう設定する
- コンテナでの実行に関連するメモリー関連のエラー状態を診断し、これを解決する

8.4.1. アプリケーションメモリーの管理について

まず OpenShift Container Platform によるコンピュートリソースの管理方法の概要をよく読んでから次の手順に進むことを推奨します。

各種のリソース (メモリー、CPU、ストレージ) に応じて、OpenShift Container Platform ではオプションの **要求** および **制限** の値を Pod の各コンテナに設定できます。

メモリー要求とメモリー制限について、以下の点に注意してください。

- **メモリー要求**
 - メモリー要求値は、指定される場合 OpenShift Container Platform スケジューラーに影響を与えます。スケジューラーは、コンテナのノードへのスケジュール時にメモリー要求を考慮し、コンテナの使用のために選択されたノードで要求されたメモリーをフェンスオフします。
 - ノードのメモリーが使い切られると、OpenShift Container Platform はメモリー使用がメモリー要求を最も超過しているコンテナのエビクションを優先します。メモリー消費の深刻な状況が生じる場合、ノードの OOM killer は同様のメトリックに基づいてコンテナでプロセスを選択し、これを強制終了する場合があります。
 - クラスター管理者は、メモリー要求値に対してクォータを割り当てるか、デフォルト値を割り当てることができます。
 - クラスター管理者は、クラスターのオーバーコミットを管理するために開発者が指定するメモリー要求の値を上書きできます。
- **メモリー制限**
 - メモリー制限値が指定されている場合、コンテナのすべてのプロセスに割り当て可能なメモリーにハード制限を指定します。

- コンテナのすべてのプロセスで割り当てられるメモリがメモリ制限を超過する場合、ノードの OOM (Out of Memory) killer はコンテナのプロセスをすぐに選択し、これを強制終了します。
- メモリ要求とメモリ制限の両方が指定される場合、メモリ制限の値はメモリ要求の値よりも大きい、これと等しくなければなりません。
- クラスター管理者は、メモリの制限値に対してクォータを割り当てるか、デフォルト値を割り当てることができます。
- 最小メモリ制限は 12 MB です。**Cannot allocate memory** Pod イベントのためにコンテナの起動に失敗すると、メモリ制限は低くなります。メモリ制限を引き上げるか、これを削除します。制限を削除すると、Pod は制限のないノードのリソースを消費できるようになります。

8.4.1.1. アプリケーションメモリーストラテジーの管理

OpenShift Container Platform でアプリケーションメモリーをサイジングする手順は以下の通りです。

1. 予想されるコンテナのメモリー使用の判別

必要時に予想される平均およびピーク時のコンテナのメモリー使用を判別します (例: 別の負荷テストを実行)。コンテナで並行して実行されている可能性のあるすべてのプロセスを必ず考慮に入れるようにしてください。たとえば、メインのアプリケーションは付属スクリプトを生成しているかどうかを確認します。

2. リスク選好 (risk appetite) の判別

退避のリスク選好を判別します。リスク選好のレベルが低い場合、コンテナは予想されるピーク時の使用量と安全マージンのパーセンテージに応じてメモリーを要求します。リスク選好が高くなる場合、予想される平均の使用量に応じてメモリーを要求することがより適切な場合があります。

3. コンテナのメモリー要求の設定

上記に基づいてコンテナのメモリー要求を設定します。要求がアプリケーションのメモリー使用をより正確に表示することが望ましいと言えます。要求が高すぎる場合には、クラスターおよびクォータの使用が非効率となります。要求が低すぎる場合、アプリケーションの退避の可能性が高まります。

4. コンテナのメモリー制限の設定 (必要な場合)

必要時にコンテナのメモリー制限を設定します。制限を設定すると、コンテナのすべてのプロセスのメモリー使用量の合計が制限を超える場合にコンテナのプロセスがすぐに強制終了されるため、いくつかの利点をもたらします。まずは予期しないメモリー使用の超過を早期に明確にする ("fail fast" (早く失敗する)) ことができ、次にプロセスをすぐに中止できます。

一部の OpenShift Container Platform クラスターでは制限値を設定する必要があります。制限に基づいて要求を上書きする場合があります。また、一部のアプリケーションイメージは、要求値よりも検出が簡単なことから設定される制限値に依存します。

メモリー制限が設定される場合、これは予想されるピーク時のコンテナのメモリー使用量と安全マージンのパーセンテージよりも低い値に設定することはできません。

5. アプリケーションが調整されていることの確認

適切な場合は、設定される要求および制限値に関連してアプリケーションが調整されていることを確認します。この手順は、JVM などのメモリーをプールするアプリケーションにおいてとくに当てはまります。残りの部分では、これを説明します。

- [コンピュートリソースとコンテナについて](#)

8.4.2. OpenShift Container Platform の OpenJDK 設定について

デフォルトの OpenJDK 設定はコンテナ化された環境では機能しません。そのため、コンテナで OpenJDK を実行する場合は常に追加の Java メモリー設定を指定する必要があります。

JVM のメモリーレイアウトは複雑で、バージョンに依存しており、この詳細はこのドキュメントでは説明しません。ただし、コンテナで OpenJDK を実行する際のスタートにあたって少なくとも以下の 3 つのメモリー関連のタスクが主なタスクになります。

1. JVM 最大ヒープサイズを上書きする。
2. JVM が未使用メモリーをオペレーティングシステムに解放するよう促す (適切な場合)。
3. コンテナ内のすべての JVM プロセスが適切に設定されていることを確認する。

コンテナでの実行に向けて JVM ワークロードを最適に調整する方法はこのドキュメントでは扱いませんが、これには複数の JVM オプションを追加で設定することが必要になる場合があります。

8.4.2.1. JVM の最大ヒープサイズを上書きする方法について

OpenJDK は、デフォルトで、使用可能なメモリーの最大 25% を "ヒープ" メモリーに使用します。その際、コンテナに設定されたメモリー制限も考慮されます。このデフォルト値は控えめな値であり、適切に設定されたコンテナ環境でこの値を使用すると、コンテナに割り当てられたメモリーの 75% がほとんど使用されないことになります。コンテナレベルでメモリー制限が課されるコンテナコンテキストでは、JVM がヒープメモリーに使用する割合を 80% などかなり高く設定する方が適しています。

ほとんどの Red Hat コンテナには、JVM の起動時に値を更新して OpenJDK のデフォルト設定を置き換える起動スクリプトが含まれています。

たとえば、Red Hat build of OpenJDK コンテナのデフォルト値は 80% です。この値は、**JAVA_MAX_RAM_RATIO** 環境変数を定義することで異なるパーセンテージに設定できます。

その他の OpenJDK デプロイメントの場合、次のコマンドを使用してデフォルト値の 25% を変更できます。

例

```
$ java -XX:MaxRAMPercentage=80.0
```

8.4.2.2. JVM で未使用メモリーをオペレーティングシステムに解放するよう促す方法について

デフォルトで、OpenJDK は未使用メモリーをオペレーティングシステムに積極的に返しません。これは多くのコンテナ化された Java ワークロードには適していますが、例外として、コンテナ内に JVM と共存する追加のアクティブなプロセスがあるワークロードの場合を考慮する必要があります。それらの追加のプロセスはネイティブのプロセスである場合や追加の JVM の場合、またはこれら 2 つの組み合わせである場合もあります。

Java ベースのエージェントは、次の JVM 引数を使用して、JVM が未使用のメモリーをオペレーティングシステムに解放するよう促すことができます。

```
-XX:+UseParallelGC
-XX:MinHeapFreeRatio=5 -XX:MaxHeapFreeRatio=10 -XX:GCTimeRatio=4
-XX:AdaptiveSizePolicyWeight=90
```

これらの引数は、割り当てられたメモリーが使用中のメモリー (**-XX:MaxHeapFreeRatio**) の 110% を超え、ガベージコレクター (**-XX:GCTimeRatio**) で CPU 時間の 20% を使用する場合は常にヒープメモリーをオペレーティングシステムに返すことが意図されています。アプリケーションのヒープ割り当てが初期のヒープ割り当て (**-XX:InitialHeapSize** / **-Xms** で上書きされる) を下回ることはありません。詳細は、[Tuning Java's footprint in OpenShift \(Part 1\)](#)、[Tuning Java's footprint in OpenShift \(Part 2\)](#)、および [OpenJDK and Containers](#) を参照してください。

8.4.2.3. コンテナ内のすべての JVM プロセスが適切に設定されていることを確認する方法について

複数の JVM が同じコンテナで実行される場合、それらすべてが適切に設定されていることを確認する必要があります。多くのワークロードでは、それぞれの JVM に memory budget のパーセンテージを付与する必要があります。これにより大きな安全マージンが残される場合があります。

多くの Java ツールは JVM を設定するために各種の異なる環境変数 (**JAVA_OPTS**、**GRADLE_OPTS** など) を使用します。適切な設定が適切な JVM に渡されていることを確認するのが容易でない場合があります。

JAVA_TOOL_OPTIONS 環境変数は OpenJDK によって常に考慮されます。**JAVA_TOOL_OPTIONS** で指定した値は、JVM コマンドラインで指定した他のオプションによってオーバーライドされます。デフォルトでは、Java ベースのエージェントイメージで実行されるすべての JVM ワークロードでこれらのオプションがデフォルトで使用されるように、OpenShift Container Platform Jenkins Maven エージェントイメージは次の変数を設定します。

```
JAVA_TOOL_OPTIONS="-Dsun.zip.disableMemoryMapping=true"
```

この設定は、追加オプションが要求されないことを保証する訳ではなく、有用な開始点になることを意図しています。

8.4.3. Pod 内でのメモリー要求および制限の検索

Pod 内からメモリー要求および制限を動的に検出するアプリケーションでは Downward API を使用する必要があります。

手順

1. **MEMORY_REQUEST** と **MEMORY_LIMIT** スタンザを追加するように Pod を設定します。

- a. 以下のような YAML ファイルを作成します。

```
apiVersion: v1
kind: Pod
metadata:
  name: test
spec:
  containers:
  - name: test
    image: fedora:latest
    command:
    - sleep
```

```
- "3600"
env:
- name: MEMORY_REQUEST ❶
  valueFrom:
    resourceFieldRef:
      containerName: test
      resource: requests.memory
- name: MEMORY_LIMIT ❷
  valueFrom:
    resourceFieldRef:
      containerName: test
      resource: limits.memory
resources:
  requests:
    memory: 384Mi
  limits:
    memory: 512Mi
```

- ❶ このスタンザを追加して、アプリケーションメモリーの要求値を見つけます。
- ❷ このスタンザを追加して、アプリケーションメモリーの制限値を見つけます。

b. 以下のコマンドを実行して Pod を作成します。

```
$ oc create -f <file-name>.yaml
```

検証

- リモートシェルを使用して Pod にアクセスします。

```
$ oc rsh test
```

- 要求された値が適用されていることを確認します。

```
$ env | grep MEMORY | sort
```

出力例

```
MEMORY_LIMIT=536870912
MEMORY_REQUEST=402653184
```



注記

メモリー制限値は、**/sys/fs/cgroup/memory/memory.limit_in_bytes** ファイルによってコンテナ内から読み取ることもできます。

8.4.4. OOM の強制終了ポリシーについて

OpenShift Container Platform は、コンテナのすべてのプロセスのメモリー使用量の合計がメモリー制限を超えるか、ノードのメモリーを使い切られるなどの深刻な状態が生じる場合にコンテナのプロセスを強制終了できます。

プロセスが OOM (Out of Memory) によって強制終了される場合、コンテナがすぐに終了する場合があります。コンテナの PID 1 プロセスが **SIGKILL** を受信する場合、コンテナはすぐに終了します。それ以外の場合、コンテナの動作は他のプロセスの動作に依存します。

たとえば、コンテナのプロセスは、SIGKILL シグナルを受信したことを示すコード 137 で終了します。

コンテナがすぐに終了しない場合、OOM による強制終了は以下のように検出できます。

1. リモートシェルを使用して Pod にアクセスします。

```
# oc rsh test
```

2. 以下のコマンドを実行して、**/sys/fs/cgroup/memory/memory.oom_control** で現在の OOM kill カウントを表示します。

```
$ grep '^oom_kill' /sys/fs/cgroup/memory/memory.oom_control
```

出力例

```
oom_kill 0
```

3. 以下のコマンドを実行して、Out Of Memory (OOM) による強制終了を促します。

```
$ sed -e " </dev/zero
```

出力例

```
Killed
```

4. 以下のコマンドを実行して、**sed** コマンドの終了ステータスを表示します。

```
$ echo $?
```

出力例

```
137
```

137 コードは、コンテナのプロセスが、SIGKILL シグナルを受信したことを示すコード 137 で終了していることを示唆します。

5. 以下のコマンドを実行して、**/sys/fs/cgroup/memory/memory.oom_control** の OOM kill カウンターの増分を表示します。

```
$ grep '^oom_kill' /sys/fs/cgroup/memory/memory.oom_control
```

出力例

```
oom_kill 1
```

Pod の 1 つ以上のプロセスが OOM で強制終了され、Pod がこれに続いて終了する場合 (即時で

あるかどうかは問わない)、フェーズは **Failed**、理由は **OOMKilled** になります。OOM で強制終了された Pod は **restartPolicy** の値によって再起動する場合があります。再起動されない場合は、レプリケーションコントローラーなどのコントローラーが Pod の失敗したステータスを認識し、古い Pod に置き換わる新規 Pod を作成します。

以下のコマンドを使用して Pod のステータスを取得します。

```
$ oc get pod test
```

出力例

```
NAME      READY   STATUS    RESTARTS   AGE
test      0/1     OOMKilled 0           1m
```

- Pod が再起動されていない場合は、以下のコマンドを実行して Pod を表示します。

```
$ oc get pod test -o yaml
```

出力例

```
...
status:
  containerStatuses:
  - name: test
    ready: false
    restartCount: 0
  state:
    terminated:
      exitCode: 137
      reason: OOMKilled
  phase: Failed
```

- 再起動した場合は、以下のコマンドを実行して Pod を表示します。

```
$ oc get pod test -o yaml
```

出力例

```
...
status:
  containerStatuses:
  - name: test
    ready: true
    restartCount: 1
  lastState:
    terminated:
      exitCode: 137
      reason: OOMKilled
  state:
    running:
  phase: Running
```

8.4.5. Pod エビクションについて

OpenShift Container Platform は、ノードのメモリーが使い切られると、そのノードから Pod を退避する場合があります。メモリー消費の度合いによって、エビクションは正常に行われる場合もあれば、そうでない場合もあります。グレースフルな退避とは、各コンテナのメインプロセス (PID 1) が SIGTERM シグナルを受信し、それでもプロセスがまだ終了していない場合に、しばらくしてから SIGKILL シグナルを受信することを意味します。グレースフルではない退避とは、各コンテナのメインプロセスが直ちに SIGKILL シグナルを受信することを意味します。

退避した Pod のフェーズは **Failed** になり、理由は **Evicted** になります。この場合、**restartPolicy** の値に関係なく再起動されません。ただし、レプリケーションコントローラーなどのコントローラーは Pod の失敗したステータスを認識し、古い Pod に置き換わる新規 Pod を作成します。

```
$ oc get pod test
```

出力例

```
NAME    READY   STATUS    RESTARTS   AGE
test    0/1     Evicted   0           1m
```

```
$ oc get pod test -o yaml
```

出力例

```
...
status:
  message: 'Pod The node was low on resource: [MemoryPressure].'
```

```
  phase: Failed
  reason: Evicted
```

8.5. オーバーコミットされたノード上に POD を配置するためのクラスターの設定

オーバーコミットとは、コンテナの計算リソース要求と制限の合計が、そのシステムで利用できるリソースを超えた状態のことです。オーバーコミットの使用は、容量に対して保証されたパフォーマンスのトレードオフが許容可能である開発環境において必要になる場合があります。

コンテナは、コンピュートリソース要求および制限を指定することができます。要求はコンテナのスケジューリングに使用され、最小限のサービス保証を提供します。制限は、ノード上で消費できるコンピュートリソースの量を制限します。

スケジューラーは、クラスター内のすべてのノードにおけるコンピュートリソース使用の最適化を試行します。これは Pod のコンピュートリソース要求とノードの利用可能な容量を考慮に入れて Pod を特定のノードに配置します。

OpenShift Container Platform 管理者は、[ClusterResourceOverride Operator](#) を使用して、オーバーコミットのレベルを制御し、開発者コンテナのコンテナ密度を管理できます。



注記

OpenShift Container Platform では、クラスターレベルのオーバーコミットを有効にする必要があります。ノードのオーバーコミットはデフォルトで有効にされています。[ノードのオーバーコミットの無効化](#) を参照してください。

8.5.1. リソース要求とオーバーコミット

各コンピュータリソースについて、コンテナはリソース要求および制限を指定できます。スケジューリングの決定は要求に基づいて行われ、ノードに要求される値を満たす十分な容量があることが確認されます。コンテナが制限を指定するものの、要求を省略する場合、要求はデフォルトで制限値に設定されます。コンテナは、ノードの指定される制限を超えることはできません。

制限の実施方法は、コンピュータリソースのタイプによって異なります。コンテナが要求または制限を指定しない場合、コンテナはリソース保証のない状態でノードにスケジュールされます。実際に、コンテナはローカルの最も低い優先順位で利用できる指定リソースを消費できます。リソースが不足する状態では、リソース要求を指定しないコンテナに最低レベルの quality of service が設定されます。

スケジューリングは要求されるリソースに基づいて行われる一方で、クォータおよびハード制限はリソース制限のことを指しており、これは要求されるリソースよりも高い値に設定できます。要求と制限の差によってオーバーコミットのレベルが決まります。たとえば、コンテナに 1 Gi のメモリー要求と 2 Gi のメモリー制限が指定されている場合、そのコンテナは、ノードで利用可能な 1 Gi の要求に基づいてスケジュールされますが、最大 2 Gi まで使用できます。そのため、この場合は 100% オーバーコミットされます。

8.5.2. Cluster Resource Override Operator を使用したクラスターレベルのオーバーコミット

Cluster Resource Override Operator は、クラスター内のすべてのノードでオーバーコミットのレベルを制御し、コンテナの密度を管理できる受付 Webhook です。Operator は、特定のプロジェクトのノードが定義されたメモリーおよび CPU 制限を超える場合に制御します。

Operator は、開発者コンテナに設定されている要求と制限の比率を変更します。制限とデフォルトを指定するプロジェクトごとの制限範囲と組み合わせることで、必要なレベルのオーバーコミットを実現できます。

次のセクションに示すように、OpenShift Container Platform コンソールまたは CLI を使用して、Cluster Resource Override Operator をインストールする必要があります。Cluster Resource Override Operator をデプロイすると、この Operator が特定の namespace 内のすべての新しい Pod を変更します。この Operator は、Operator をデプロイする前に存在していた Pod は編集しません。

インストール時に、以下の例のように、オーバーコミットのレベルを設定する **ClusterResourceOverride** カスタムリソース (CR) を作成します。

```
apiVersion: operator.autoscaling.openshift.io/v1
kind: ClusterResourceOverride
metadata:
  name: cluster 1
spec:
  podResourceOverride:
    spec:
      memoryRequestToLimitPercent: 50 2
      cpuRequestToLimitPercent: 25 3
      limitCPUMemoryPercent: 200 4
# ...
```

1 名前は **cluster** でなければなりません。

2 オプション: コンテナのメモリー制限が指定されているか、デフォルトに設定されている場合、メモリー要求は制限のパーセンテージ (1-100) に対して上書きされます。デフォルトは 50 です。

- 3 オプション: コンテナの CPU 制限が指定されているか、デフォルトに設定されている場合、CPU 要求は、1-100 までの制限のパーセンテージに対応して上書きされます。デフォルトは 25 で
- 4 オプション: コンテナのメモリー制限が指定されているか、デフォルトに設定されている場合、CPU 制限は、指定されている場合にメモリーのパーセンテージに対して上書きされます。1Gi の RAM の 100 パーセントでのスケールリングは、1 CPU コアに等しくなります。これは、CPU 要求を上書きする前に処理されます (設定されている場合)。デフォルトは 200 です。



注記

コンテナに制限が設定されていない場合、Cluster Resource Override Operator のオーバーライドは効果がありません。個別プロジェクトごとのデフォルト制限を使用して **LimitRange** オブジェクトを作成するか、**Pod** 仕様で制限を設定し、上書きが適用されるようにします。

設定したら、オーバーライドを適用する各プロジェクトの **Namespace** オブジェクトに次のラベルを適用することで、プロジェクトごとにオーバーライドを有効にできます。たとえば、インフラストラクチャコンポーネントがオーバーライドの対象にならないようにオーバーライドを設定できます。

```
apiVersion: v1
kind: Namespace
metadata:

# ...

labels:
  clusterresourceoverrides.admission.autoscaling.openshift.io/enabled: "true"

# ...
```

Operator は **ClusterResourceOverride** CR の有無を監視し、**ClusterResourceOverride** 受付 Webhook が Operator と同じ namespace にインストールされるようにします。

たとえば、Pod に次のリソース制限があるとします。

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
  namespace: my-namespace
# ...
spec:
  containers:
    - name: hello-openshift
      image: openshift/hello-openshift
      resources:
        limits:
          memory: "512Mi"
          cpu: "2000m"
# ...
```

Cluster Resource Override Operator は、元の Pod 要求をインターセプトし、**ClusterResourceOverride** オブジェクトに設定された設定に従ってリソースをオーバーライドします。

```
apiVersion: v1
kind: Pod
metadata:
  name: my-pod
  namespace: my-namespace
# ...
spec:
  containers:
  - image: openshift/hello-openshift
    name: hello-openshift
    resources:
      limits:
        cpu: "1" ❶
        memory: 512Mi
      requests:
        cpu: 250m ❷
        memory: 256Mi
# ...
```

- ❶ **ClusterResourceOverride** オブジェクトで **limitCPUToMemoryPercent** パラメーターが **200** に設定されているため、CPU 制限が **1** にオーバーライドされました。メモリー制限の 200% は 512 Mi であり、CPU で言えば 1 CPU コアです。
- ❷ **ClusterResourceOverride** オブジェクトで **cpuRequestToLimit** が **25** に設定されているため、CPU 要求は **250m** になります。1 CPU コアの 25% は 250m です。

8.5.2.1. Web コンソールを使用した Cluster Resource Override Operator のインストール

クラスターでオーバーコミットを制御できるように、OpenShift Container Platform Web コンソールを使用して Cluster Resource Override Operator をインストールできます。

前提条件

- 制限がコンテナに設定されていない場合、Cluster Resource Override Operator は影響を与えません。**LimitRange** オブジェクトを使用してプロジェクトのデフォルト制限を指定するか、**Pod** 仕様で制限を設定して上書きが適用されるようにする必要があります。

手順

OpenShift Container Platform Web コンソールを使用して Cluster Resource Override Operator をインストールするには、以下を実行します。

1. OpenShift Container Platform Web コンソールで、**Home** → **Projects** に移動します。
 - a. **Create Project** をクリックします。
 - b. **clusterresourceoverride-operator** をプロジェクトの名前として指定します。
 - c. **Create** をクリックします。
2. **Operators** → **OperatorHub** に移動します。

- a. 利用可能な Operator のリストから **ClusterResourceOverride Operator** を選択し、**Install** をクリックします。
 - b. **Install Operator** ページで、**A specific Namespace on the cluster**が **Installation Mode** に選択されていることを確認します。
 - c. **clusterresourceoverride-operator** が **Installed Namespace** に選択されていることを確認します。
 - d. **Update Channel** および **Approval Strategy** を選択します。
 - e. **Install** をクリックします。
3. **Installed Operators** ページで、**ClusterResourceOverride** をクリックします。
 - a. **ClusterResourceOverride Operator** 詳細ページで、**Create ClusterResourceOverride** をクリックします。
 - b. **Create ClusterResourceOverride** ページで、**YAML view** をクリックして、YAML テンプレートを編集し、必要に応じてオーバーコミット値を設定します。

```
apiVersion: operator.autoscaling.openshift.io/v1
kind: ClusterResourceOverride
metadata:
  name: cluster ❶
spec:
  podResourceOverride:
    spec:
      memoryRequestToLimitPercent: 50 ❷
      cpuRequestToLimitPercent: 25 ❸
      limitCPUToMemoryPercent: 200 ❹
# ...
```

- ❶ 名前は **cluster** でなければなりません。
 - ❷ オプション: コンテナメモリーの制限を上書きするためのパーセンテージが使用される場合は、これを 1-100 までの値で指定します。デフォルトは 50 です。
 - ❸ オプション: コンテナ CPU の制限を上書きするためのパーセンテージが使用される場合は、これを 1-100 までの値で指定します。デフォルトは 25 です。
 - ❹ オプション: コンテナメモリーの制限を上書きするためのパーセンテージが使用される場合は、これを指定します。1Gi の RAM の 100 パーセントでのスケーリングは、1 CPU コアに等しくなります。これは、CPU 要求を上書きする前に処理されます (設定されている場合)。デフォルトは 200 です。
- c. **Create** をクリックします。
4. クラスターカスタムリソースのステータスをチェックして、受付 Webhook の現在の状態を確認します。
 - a. **ClusterResourceOverride Operator** ページで、**cluster** をクリックします。
 - b. **ClusterResourceOverride Details** ページで、**YAML** をクリックします。Webhook の呼び出し時に、**mutatingWebhookConfigurationRef** セクションが表示されます。

■

```

apiVersion: operator.autoscaling.openshift.io/v1
kind: ClusterResourceOverride
metadata:
  annotations:
    kubectrl.kubernetes.io/last-applied-configuration: |

{"apiVersion":"operator.autoscaling.openshift.io/v1","kind":"ClusterResourceOverride","met
adata":{"annotations":{},"name":"cluster"},"spec":{"podResourceOverride":{"spec":
{"cpuRequestToLimitPercent":25,"limitCPUToMemoryPercent":200,"memoryRequestToLi
mitPercent":50}}}}
  creationTimestamp: "2019-12-18T22:35:02Z"
  generation: 1
  name: cluster
  resourceVersion: "127622"
  selfLink: /apis/operator.autoscaling.openshift.io/v1/clusterresourceoverrides/cluster
  uid: 978fc959-1717-4bd1-97d0-ae00ee111e8d
spec:
  podResourceOverride:
    spec:
      cpuRequestToLimitPercent: 25
      limitCPUToMemoryPercent: 200
      memoryRequestToLimitPercent: 50
status:

# ...

mutatingWebhookConfigurationRef: ❶
apiVersion: admissionregistration.k8s.io/v1
kind: MutatingWebhookConfiguration
name: clusterresourceoverrides.admission.autoscaling.openshift.io
resourceVersion: "127621"
uid: 98b3b8ae-d5ce-462b-8ab5-a729ea8f38f3

# ...

```

❶ **ClusterResourceOverride** 受付 Webhook への参照。

8.5.2.2. CLI を使用した Cluster Resource Override Operator のインストール

OpenShift Container Platform CLI を使用して Cluster Resource Override Operator をインストールし、クラスターでのオーバーコミットを制御できます。

前提条件

- 制限がコンテナに設定されていない場合、Cluster Resource Override Operator は影響を与えません。**LimitRange** オブジェクトを使用してプロジェクトのデフォルト制限を指定するか、**Pod** 仕様で制限を設定して上書きが適用されるようにする必要があります。

手順

CLI を使用して Cluster Resource Override Operator をインストールするには、以下を実行します。

1. Cluster Resource Override の namespace を作成します。

- a. Cluster Resource Override Operator の **Namespace** オブジェクト YAML ファイル (**cro-namespace.yaml** など) を作成します。

```
apiVersion: v1
kind: Namespace
metadata:
  name: clusterresourceoverride-operator
```

- b. namespace を作成します。

```
$ oc create -f <file-name>.yaml
```

以下に例を示します。

```
$ oc create -f cro-namespace.yaml
```

2. Operator グループを作成します。

- a. Cluster Resource Override Operator の **OperatorGroup** オブジェクトの YAML ファイル (cro-og.yaml など) を作成します。

```
apiVersion: operators.coreos.com/v1
kind: OperatorGroup
metadata:
  name: clusterresourceoverride-operator
  namespace: clusterresourceoverride-operator
spec:
  targetNamespaces:
    - clusterresourceoverride-operator
```

- b. Operator グループを作成します。

```
$ oc create -f <file-name>.yaml
```

以下に例を示します。

```
$ oc create -f cro-og.yaml
```

3. サブスクリプションを作成します。

- a. Cluster Resource Override Operator の **Subscription** オブジェクト YAML ファイル (cro-sub.yaml など) を作成します。

```
apiVersion: operators.coreos.com/v1alpha1
kind: Subscription
metadata:
  name: clusterresourceoverride
  namespace: clusterresourceoverride-operator
spec:
  channel: "stable"
  name: clusterresourceoverride
  source: redhat-operators
  sourceNamespace: openshift-marketplace
```

- b. サブスクリプションを作成します。

```
$ oc create -f <file-name>.yaml
```

以下に例を示します。

```
$ oc create -f cro-sub.yaml
```

4. **ClusterResourceOverride** カスタムリソース (CR) オブジェクトを **clusterresourceoverride-operator** namespace に作成します。

- a. **clusterresourceoverride-operator** namespace に切り替えます。

```
$ oc project clusterresourceoverride-operator
```

- b. Cluster Resource Override Operator の **ClusterResourceOverride** オブジェクト YAML ファイル (cro-cr.yaml など) を作成します。

```
apiVersion: operator.autoscaling.openshift.io/v1
kind: ClusterResourceOverride
metadata:
  name: cluster ❶
spec:
  podResourceOverride:
    spec:
      memoryRequestToLimitPercent: 50 ❷
      cpuRequestToLimitPercent: 25 ❸
      limitCPUToMemoryPercent: 200 ❹
```

- ❶ 名前は **cluster** でなければなりません。
- ❷ オプション: コンテナメモリーの制限を上書きするためのパーセンテージが使用される場合は、これを 1-100 までの値で指定します。デフォルトは 50 です。
- ❸ オプション: コンテナ CPU の制限を上書きするためのパーセンテージが使用される場合は、これを 1-100 までの値で指定します。デフォルトは 25 です。
- ❹ オプション: コンテナメモリーの制限を上書きするためのパーセンテージが使用される場合は、これを指定します。1Gi の RAM の 100 パーセントでのスケーリングは、1 CPU コアに等しくなります。これは、CPU 要求を上書きする前に処理されます (設定されている場合)。デフォルトは 200 です。

- c. **ClusterResourceOverride** オブジェクトを作成します。

```
$ oc create -f <file-name>.yaml
```

以下に例を示します。

```
$ oc create -f cro-cr.yaml
```

5. クラスターカスタムリソースのステータスをチェックして、受付 Webhook の現在の状態を確認します。

```
$ oc get clusterresourceoverride cluster -n clusterresourceoverride-operator -o yaml
```

Webhook の呼び出し時に、**mutatingWebhookConfigurationRef** セクションが表示されます。

出力例

```
apiVersion: operator.autoscaling.openshift.io/v1
kind: ClusterResourceOverride
metadata:
  annotations:
    kubectl.kubernetes.io/last-applied-configuration: |

{"apiVersion":"operator.autoscaling.openshift.io/v1","kind":"ClusterResourceOverride","metadata":{"annotations":{"name":"cluster"},"spec":{"podResourceOverride":{"spec":{"cpuRequestToLimitPercent":25,"limitCPUToMemoryPercent":200,"memoryRequestToLimitPercent":50}}}}
  creationTimestamp: "2019-12-18T22:35:02Z"
  generation: 1
  name: cluster
  resourceVersion: "127622"
  selfLink: /apis/operator.autoscaling.openshift.io/v1/clusterresourceoverrides/cluster
  uid: 978fc959-1717-4bd1-97d0-ae00ee111e8d
spec:
  podResourceOverride:
    spec:
      cpuRequestToLimitPercent: 25
      limitCPUToMemoryPercent: 200
      memoryRequestToLimitPercent: 50
status:

# ...

mutatingWebhookConfigurationRef: ❶
  apiVersion: admissionregistration.k8s.io/v1
  kind: MutatingWebhookConfiguration
  name: clusterresourceoverrides.admission.autoscaling.openshift.io
  resourceVersion: "127621"
  uid: 98b3b8ae-d5ce-462b-8ab5-a729ea8f38f3

# ...
```

❶ **ClusterResourceOverride** 受付 Webhook への参照。

8.5.2.3. クラスターレベルのオーバーコミットの設定

Cluster Resource Override Operator には、Operator がオーバーコミットを制御する必要のある各プロジェクトの **ClusterResourceOverride** カスタムリソース (CR) およびラベルが必要です。

前提条件

- 制限がコンテナに設定されていない場合、Cluster Resource Override Operator は影響を与えません。**LimitRange** オブジェクトを使用してプロジェクトのデフォルト制限を指定するか、**Pod** 仕様で制限を設定して上書きが適用されるようにする必要があります。

手順

クラスターレベルのオーバーコミットを変更するには、以下を実行します。

1. **ClusterResourceOverride** CR を編集します。

```
apiVersion: operator.autoscaling.openshift.io/v1
kind: ClusterResourceOverride
metadata:
  name: cluster
spec:
  podResourceOverride:
    spec:
      memoryRequestToLimitPercent: 50 ①
      cpuRequestToLimitPercent: 25 ②
      limitCPUToMemoryPercent: 200 ③
# ...
```

- ① オプション: コンテナメモリの制限を上書きするためのパーセンテージが使用される場合は、これを 1-100 までの値で指定します。デフォルトは 50 です。
- ② オプション: コンテナ CPU の制限を上書きするためのパーセンテージが使用される場合は、これを 1-100 までの値で指定します。デフォルトは 25 です。
- ③ オプション: コンテナメモリの制限を上書きするためのパーセンテージが使用される場合は、これを指定します。1Gi の RAM の 100 パーセントでのスケーリングは、1CPU コアに等しくなります。これは、CPU 要求を上書きする前に処理されます (設定されている場合)。デフォルトは 200 です。

2. 以下のラベルが Cluster Resource Override Operator がオーバーコミットを制御する必要のある各プロジェクトの namespace オブジェクトに追加されていることを確認します。

```
apiVersion: v1
kind: Namespace
metadata:
# ...

labels:
  clusterresourceoverrides.admission.autoscaling.openshift.io/enabled: "true" ①
# ...
```

- ① このラベルを各プロジェクトに追加します。

8.5.3. ノードレベルのオーバーコミット

quality of service (QoS) 保証、CPU 制限、またはリソースの予約など、特定ノードでオーバーコミットを制御するさまざまな方法を使用できます。特定のノードおよび特定のプロジェクトのオーバーコミットを無効にすることもできます。

8.5.3.1. コンピュートリソースとコンテナについて

コンピュートリソースに関するノードで実施される動作は、リソースタイプによって異なります。

8.5.3.1.1. コンテナの CPU 要求について

コンテナには要求する CPU の量が保証され、さらにコンテナで指定される任意の制限までノードで利用可能な CPU を消費できます。複数のコンテナが追加の CPU の使用を試行する場合、CPU 時間が各コンテナで要求される CPU の量に基づいて分配されます。

たとえば、あるコンテナが 500m の CPU 時間を要求し、別のコンテナが 250m の CPU 時間を要求した場合、ノードで利用可能な追加の CPU 時間は 2:1 の比率でコンテナ間で分配されます。コンテナが制限を指定している場合、指定した制限を超えて CPU を使用しないようにスロットリングされます。CPU 要求は、Linux カーネルの CFS 共有サポートを使用して適用されます。デフォルトで、CPU 制限は、Linux カーネルの CFS クォータサポートを使用して 100ms の測定間隔で適用されます。ただし、これは無効にすることができます。

8.5.3.1.2. コンテナのメモリー要求について

コンテナには要求するメモリー量が保証されます。コンテナは要求したよりも多くのメモリーを使用できますが、いったん要求した量を超えた場合には、ノードのメモリーが不足している状態では強制終了される可能性があります。コンテナが要求した量よりも少ないメモリーを使用する場合、システムタスクやデーモンがノードのリソース予約で確保されている分よりも多くのメモリーを必要としない限りそれが強制終了されることはありません。コンテナがメモリーの制限を指定する場合、その制限量を超えると即時に強制終了されます。

8.5.3.2. オーバーコミットメントと quality of service クラスについて

ノードは、要求を指定しない Pod がスケジュールされている場合やノードのすべての Pod での制限の合計が利用可能なマシンの容量を超える場合に **オーバーコミット** されます。

オーバーコミットされる環境では、ノード上の Pod がいずれかの時点で利用可能なコンピュートリソースよりも多くの量の使用を試行することができます。これが生じると、ノードはそれぞれの Pod に優先順位を指定する必要があります。この決定を行うために使用される機能は、Quality of Service (QoS) クラスと呼ばれます。

Pod は、優先度の高い順に 3 つの QoS クラスの 1 つとして指定されます。

表8.19 Quality of Service クラス

優先順位	クラス名	説明
1(最高)	Guaranteed	制限およびオプションの要求がすべてのリソースに設定されている場合 (0 と等しくない) でそれらの値が等しい場合、Pod は Guaranteed として分類されます。
2	Burstable	制限およびオプションの要求がすべてのリソースに設定されている場合 (0 と等しくない) でそれらの値が等しくない場合、Pod は Burstable として分類されます。

優先順位	クラス名	説明
3 (最低)	BestEffort	要求および制限がリソースのいずれにも設定されない場合、Pod は BestEffort として分類されます。

メモリーは圧縮できないリソースであるため、メモリー不足の状態では、最も優先順位の低いコンテナが最初に強制終了されます。

- **Guaranteed** コンテナは優先順位が最も高いコンテナとして見なされ、保証されます。強制終了されるのは、これらのコンテナで制限を超えるか、システムがメモリー不足の状態にあるものの、退避できる優先順位の低いコンテナが他にない場合のみです。
- システム不足の状態にある **Burstable** コンテナは、制限を超過し、**BestEffort** コンテナが他に存在しない場合に強制終了される可能性があります。
- **BestEffort** コンテナは優先順位の最も低いコンテナとして処理されます。これらのコンテナのプロセスは、システムがメモリー不足になると最初に強制終了されます。

8.5.3.2.1. Quality of Service (QoS) 層でのメモリーの予約方法について

qos-reserved パラメーターを使用して、特定の QoS レベルの Pod で予約されるメモリーのパーセンテージを指定することができます。この機能は、最も低い QoS クラスの Pod が高い QoS クラスの Pod で要求されるリソースを使用できないようにするために要求されたリソースの予約を試行します。

OpenShift Container Platform は、以下のように **qos-reserved** パラメーターを使用します。

- **qos-reserved=memory=100%** の値は、**Burstable** および **BestEffort** QoS クラスが、これらより高い QoS クラスで要求されたメモリーを消費するのを防ぎます。これにより、**Guaranteed** および **Burstable** ワークロードのメモリーリソースの保証レベルを上げることが優先され、**BestEffort** および **Burstable** ワークロードでの OOM が発生するリスクが高まります。
- **qos-reserved=memory=50%** の値は、**Burstable** および **BestEffort** QoS クラスがこれらより高い QoS クラスによって要求されるメモリーの半分を消費することを許可します。
- **qos-reserved=memory=0%** の値は、**Burstable** および **BestEffort** QoS クラスがノードの割り当て可能分を完全に消費することを許可しますが (利用可能な場合)、これにより、**Guaranteed** ワークロードが要求したメモリーにアクセスできなくなるリスクが高まります。この状況により、この機能は無効にされています。

8.5.3.3. swap メモリーと QOS について

Quality of Service (QOS) 保証を維持するため、swap はノード上でデフォルトで無効にすることができます。そうしない場合、ノードの物理リソースがオーバーサブスクライブし、Pod の配置時の Kubernetes スケジューラーによるリソース保証が影響を受ける可能性があります。

たとえば、2 つの **Guaranteed** Pod がメモリー制限に達した場合、それぞれのコンテナが swap メモリーを使用し始める可能性があります。十分な swap 領域がない場合には、pod のプロセスはシステムのオーバーサブスクライブのために終了する可能性があります。

swap を無効にしないと、ノードが **MemoryPressure** にあることを認識しなくなり、Pod がスケジューリング要求に対応するメモリーを受け取れなくなります。結果として、追加の Pod がノードに配置され、メモリー不足の状態が加速し、最終的にはシステムの Out Of Memory (OOM) イベントが発生するリスクが高まります。



重要

swap が有効にされている場合、利用可能なメモリに関するリソース不足の処理 (out-of-resource handling) のエビクションしきい値は予期どおりに機能しなくなります。メモリ不足の状態の場合に Pod をノードから退避し、Pod を不足状態にない別のノードで再スケジューリングできるようにリソース不足の処理 (out-of-resource handling) を利用できるようにします。

8.5.3.4. ノードのオーバーコミットについて

オーバーコミット環境では、最適なシステム動作を提供できるようにノードを適切に設定する必要があります。

ノードが起動すると、メモリ管理用のカーネルの調整可能なフラグが適切に設定されます。カーネルは、物理メモリが不足しない限り、メモリの割り当てに失敗することはありません。

この動作を確認するため、OpenShift Container Platform は、**vm.overcommit_memory** パラメーターを **1** に設定し、デフォルトのオペレーティングシステムの設定を上書きすることで、常にメモリをオーバーコミットするようにカーネルを設定します。

また、OpenShift Container Platform は **vm.panic_on_oom** パラメーターを **0** に設定することで、メモリが不足したときでもカーネルがパニックにならないようにします。0 の設定は、Out of Memory (OOM) 状態のときに oom_killer を呼び出すようカーネルに指示します。これにより、優先順位に基づいてプロセスを強制終了します。

現在の設定は、ノードに以下のコマンドを実行して表示できます。

```
$ sysctl -a |grep commit
```

出力例

```
#...
vm.overcommit_memory = 0
#...
```

```
$ sysctl -a |grep panic
```

出力例

```
#...
vm.panic_on_oom = 0
#...
```



注記

上記のフラグはノード上にすでに設定されているはずであるため、追加のアクションは不要です。

各ノードに対して以下の設定を実行することもできます。

- CPU CFS クォータを使用した CPU 制限の無効化または実行
- システムプロセスのリソース予約

- Quality of Service (QoS) 層でのメモリー予約

関連情報

- [CPU CFS クォータの使用による CPU 制限の無効化または実行](#)
- [システムリソースのリソース予約](#)
- [Quality of Service \(QoS\) 層でのメモリーの予約方法について](#)

8.5.3.5. CPU CFS クォータの使用による CPU 制限の無効化または実行

デフォルトで、ノードは Linux カーネルの Completely Fair Scheduler (CFS) クォータのサポートを使用して、指定された CPU 制限を実行します。

CPU 制限の適用を無効にする場合、それがノードに与える影響を理解しておくことが重要になります。

- コンテナに CPU 要求がある場合、これは Linux カーネルの CFS 共有によって引き続き適用されます。
- コンテナに CPU 要求がなく、CPU 制限がある場合は、CPU 要求はデフォルトで指定される CPU 制限に設定され、Linux カーネルの CFS 共有によって適用されます。
- コンテナに CPU 要求と制限の両方がある場合、CPU 要求は Linux カーネルの CFS 共有によって適用され、CPU 制限はノードに影響を与えません。

前提条件

- 次のコマンドを入力して、設定するノードタイプの静的な **MachineConfigPool** CRD に関連付けられたラベルを取得します。

```
$ oc edit machineconfigpool <name>
```

以下に例を示します。

```
$ oc edit machineconfigpool worker
```

出力例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfigPool
metadata:
  creationTimestamp: "2022-11-16T15:34:25Z"
  generation: 4
  labels:
    pools.operator.machineconfiguration.openshift.io/worker: "" ❶
  name: worker
```

- ❶ Labels の下にラベルが表示されます。

ヒント

ラベルが存在しない場合は、次のようなキー/値のペアを追加します。

```
$ oc label machineconfigpool worker custom-kubelet=small-pods
```

手順

1. 設定変更のためのカスタムリソース (CR) を作成します。

CPU 制限を無効化する設定例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
metadata:
  name: disable-cpu-units 1
spec:
  machineConfigPoolSelector:
    matchLabels:
      pools.operator.machineconfiguration.openshift.io/worker: "" 2
  kubeletConfig:
    cpuCfsQuota: false 3
```

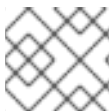
- 1** CR に名前を割り当てます。
- 2** マシン設定プールからラベルを指定します。
- 3** **cpuCfsQuota** パラメーターを **false** に設定します。

2. 以下のコマンドを実行して CR を作成します。

```
$ oc create -f <file_name>.yaml
```

8.5.3.6. システムリソースのリソース予約

より信頼できるスケジューリングを実現し、ノードリソースのオーバーコミットメントを最小化するために、各ノードでは、クラスターが機能できるようノードで実行する必要があるシステムデーモン用にそのリソースの一部を予約することができます。



注記

メモリーなどの圧縮できないリソースのリソースを予約することが推奨されます。

手順

Pod 以外のプロセスのリソースを明示的に予約するには、スケジューリングで利用可能なリソースを指定することにより、ノードリソースを割り当てます。詳細は、ノードのリソースの割り当てを参照してください。

関連情報

- [ノードのリソースの割り当て](#)

8.5.3.7. ノードのオーバーコミットの無効化

有効にされているオーバーコミットを、各ノードで無効にできます。

手順

ノード内のオーバーコミットを無効にするには、そのノード上で以下のコマンドを実行します。

```
$ sysctl -w vm.overcommit_memory=0
```

8.5.4. プロジェクトレベルの制限

オーバーコミットを制御するには、プロジェクトごとのリソース制限の範囲を設定し、オーバーコミットが超過できないプロジェクトのメモリーおよび CPU 制限およびデフォルト値を指定できます。

プロジェクトレベルのリソース制限の詳細は、関連情報を参照してください。

または、特定のプロジェクトのオーバーコミットを無効にすることもできます。

8.5.4.1. プロジェクトでのオーバーコミットメントの無効化

有効にされているオーバーコミットメントをプロジェクトごとに無効にすることができます。たとえば、インフラストラクチャーコンポーネントはオーバーコミットメントから独立して設定できます。

手順

プロジェクト内のオーバーコミットメントを無効にするには、以下の手順を実行します。

1. namespace オブジェクトを編集して、次のアノテーションを追加します。

```
apiVersion: v1
kind: Namespace
metadata:
  annotations:
    quota.openshift.io/cluster-resource-override-enabled: "false" 1
# ...
```

- 1 このアノテーションを **false** に設定すると、この namespace のオーバーコミットが無効になります。

8.5.5. 関連情報

- [デプロイメントリソースの設定](#)。

8.6. LINUX コントロールグループバージョン 2(CGROUP V2)の有効化

node.config オブジェクトを編集して、クラスターで [Linux コントロールグループバージョン 2](#) (cgroup v2)を有効にできます。OpenShift Container Platform で cgroup v2 を有効にすると、クラスター内のすべての cgroups バージョン 1 コントローラーおよび階層が無効になります。cgroup v1 はデフォルトで有効にされます。

cgroup v2 は、Linux cgroup API の現行バージョンです。cgroup v2 では、統一された階層、安全なサブツリー委譲、[Pressure Stall Information](#) 等の新機能、および強化されたリソース管理および分離など、cgroup v1 に対していくつかの改善が行われています。ただし、cgroup v2 には、cgroup v1 とは異

なる CPU、メモリー、および I/O 管理特性があります。したがって、一部のワークロードでは、cgroup v2 を実行するクラスター上のメモリーまたは CPU 使用率にわずかな違いが発生する可能性があります。

注記

- cgroup ファイルシステムに依存するサードパーティーの監視およびセキュリティーエージェントを実行している場合は、エージェントを cgroup v2 をサポートするバージョンに更新します。
- cgroup v2 を設定し、Pod とコンテナを監視するスタンドアロンデーモンセットとして cAdvisor を実行している場合は、cAdvisor を v0.43.0 以降に更新します。
- Java アプリケーションをデプロイする場合は、次のパッケージなど、cgroup v2 を完全にサポートするバージョンを使用してください。
 - OpenJDK/HotSpot: jdk8u372、11.0.16、15 以降
 - IBM Semeru ランタイム: jdk8u345-b01、11.0.16.0、17.0.4.0、18.0.2.0 以降
 - IBM SDK Java Technology Edition バージョン (IBM Java): 8.0.7.15 以降

重要

OpenShift Container Platform cgroups バージョン 2 のサポートはテクノロジープレビュー機能です。テクノロジープレビュー機能は、Red Hat 製品のサービスレベルアグリーメント (SLA) の対象外であり、機能的に完全ではないことがあります。Red Hat は、実稼働環境でこれらを使用することを推奨していません。テクノロジープレビュー機能は、最新の製品機能をいち早く提供して、開発段階で機能のテストを行い、フィードバックを提供していただくことを目的としています。

Red Hat のテクノロジープレビュー機能のサポート範囲に関する詳細は、[テクノロジープレビュー機能のサポート範囲](#) を参照してください。

8.6.1. Linux cgroup v2 の設定

`node.config` オブジェクトを編集して、cgroup v2 を有効にします。

注記

現在、CPU 負荷分散の無効化は cgroup v2 ではサポートされていません。その結果、cgroup v2 が有効になっている場合は、パフォーマンスプロファイルから望ましい動作が得られない可能性があります。パフォーマンスプロファイルを使用している場合は、cgroup v2 を有効にすることは推奨されません。

前提条件

- OpenShift Container Platform クラスター (バージョン 4.12 以降) が実行中。
- 管理者権限を持つユーザーとしてクラスターにログインしている。
- 機能ゲートを使用して、**TechPreviewNoUpgrade** 機能セットを有効にしている。

手順

1. ノードで cgroup v2 を有効にします。
 - a. **node.config** オブジェクトを編集します。

```
$ oc edit nodes.config/cluster
```

- b. **spec.cgroupMode: "v2"** を追加:

node.config オブジェクトの例

```
apiVersion: config.openshift.io/v1
kind: Node
metadata:
  annotations:
    include.release.openshift.io/ibm-cloud-managed: "true"
    include.release.openshift.io/self-managed-high-availability: "true"
    include.release.openshift.io/single-node-developer: "true"
    release.openshift.io/create-only: "true"
  creationTimestamp: "2022-07-08T16:02:51Z"
  generation: 1
  name: cluster
  ownerReferences:
  - apiVersion: config.openshift.io/v1
    kind: ClusterVersion
    name: version
    uid: 36282574-bf9f-409e-a6cd-3032939293eb
  resourceVersion: "1865"
  uid: 0c0f7a4c-4307-4187-b591-6155695ac85b
spec:
  cgroupMode: "v2" ❶
...
```

- ❶ cgroup v2 を有効にします。

検証

1. マシン設定をチェックして、新しいマシン設定が追加されたことを確認します。

```
$ oc get mc
```

出力例

NAME	GENERATEDBYCONTROLLER
IGNITIONVERSION AGE	
00-master 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0
00-worker 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0
01-master-container-runtime 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
01-master-kubelet 3.2.0 33m	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
01-worker-container-runtime	52dd3ba6a9a527fc3ab42afac8d12b693534c8c9

```

3.2.0      33m
01-worker-kubelet      52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
3.2.0      33m
97-master-generated-kubelet      52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
3.2.0      3m ❶
99-worker-generated-kubelet      52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
3.2.0      3m
99-master-generated-registries      52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
3.2.0      33m
99-master-ssh      3.2.0      40m
99-worker-generated-registries      52dd3ba6a9a527fc3ab42afac8d12b693534c8c9
3.2.0      33m
99-worker-ssh      3.2.0      40m
rendered-master-23e785de7587df95a4b517e0647e5ab7
52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0      33m
rendered-worker-5d596d9293ca3ea80c896a1191735bb1
52dd3ba6a9a527fc3ab42afac8d12b693534c8c9 3.2.0      33m
worker-enable-cgroups-v2      3.2.0      10s

```

❶ 予想どおり、新しいマシン設定が作成されます。

2. 新しい **kernelArguments** が新しいマシン設定に追加されたことを確認します。

```
$ oc describe mc <name>
```

出力例

```

apiVersion: machineconfiguration.openshift.io/v1
kind: MachineConfig
metadata:
  labels:
    machineconfiguration.openshift.io/role: worker
  name: 05-worker-kernelarg-selinuxpermissive
spec:
  kernelArguments:
    - systemd_unified_cgroup_hierarchy=1 ❶
    - cgroup_no_v1="all" ❷
    - psi=1 ❸

```

❶ systemd で cgroup v2 を有効にします。

❷ cgroups v1 を無効にします。

❸ Linux Pressure Stall Information (PSI) 機能を有効にします。

3. ノードをチェックして、ノードのスケジューリングが無効になっていることを確認します。これは、変更が適用されていることを示しています。

```
$ oc get nodes
```

出力例

NAME	STATUS	ROLES	AGE	VERSION
ci-ln-fm1qnwt-72292-99kt6-master-0	Ready		master 58m	v1.25.0
ci-ln-fm1qnwt-72292-99kt6-master-1	Ready		master 58m	v1.25.0
ci-ln-fm1qnwt-72292-99kt6-master-2	Ready		master 58m	v1.25.0
ci-ln-fm1qnwt-72292-99kt6-worker-a-h5gt4	Ready,SchedulingDisabled		worker 48m	v1.25.0
ci-ln-fm1qnwt-72292-99kt6-worker-b-7vtmd	Ready		worker 48m	v1.25.0
ci-ln-fm1qnwt-72292-99kt6-worker-c-rhzkv	Ready		worker 48m	v1.25.0

4. ノードが **Ready** 状態に戻ったら、そのノードのデバッグセッションを開始します。

```
$ oc debug node/<node_name>
```

5. **/host** をデバッグシェル内のルートディレクトリーとして設定します。

```
sh-4.4# chroot /host
```

6. **sys/fs/cgroup/cgroup2fs** ファイルがノードに存在することを確認します。このファイルは cgroup v2 によって作成されます。

```
$ stat -c %T -f /sys/fs/cgroup
```

出力例

```
cgroup2fs
```

関連情報

- [FeatureGate の使用による OpenShift Container Platform 機能の有効化](#)
- [OpenShift Container Platform インストールの概要](#)

8.7. フィーチャーゲートを使用した機能の有効化

管理者は、フィーチャーゲートを使用して、デフォルトの機能セットに含まれていない機能を有効にすることができます。

8.7.1. フィーチャーゲートについて

FeatureGate カスタムリソース (CR) を使用して、クラスター内の特定の機能セットを有効にすることができます。機能セットは、デフォルトで有効にされない OpenShift Container Platform 機能のコレクションです。

FeatureGate CR を使用して、以下の機能セットをアクティブにすることができます。

- **TechPreviewNoUpgrade:** この機能セットは、現在のテクノロジープレビュー機能のサブセットです。この機能セットを使用すると、テストクラスターでこれらのテクノロジープレビュー機能を有効にすることができます。そこでは、これらの機能を完全にテストできますが、運用クラスターでは機能を無効にしたままにできます。



警告

クラスターで **TechPreviewNoUpgrade** 機能セットを有効にすると、元に戻すことができず、マイナーバージョンの更新が妨げられます。本番クラスターでは、この機能セットを有効にしないでください。

この機能セットにより、以下のテクノロジープレビュー機能が有効になります。

- CSI の自動移行: サポートされているインツリーのボリュームプラグインを等価な Container Storage Interface (CSI) ドライバーに自動的に移行できます。サポート対象:
 - Azure File (**CSIMigrationAzureFile**)
 - VMware vSphere (**CSIMigrationvSphere**)
- OpenShift ビルドでの共有リソース CSI ドライバーおよびビルド CSI ボリューム。Container Storage Interface (CSI) を有効にします。(**CSIDriverSharedResource**)
- CSI ボリューム。OpenShift Container Platform ビルドシステムの CSI ボリュームサポートを有効にします。(**BuildCSIVolumes**)
- ノード上のスワップメモリー。ノードごとに OpenShift Container Platform ワークロードのスワップメモリーの使用を有効にします。(**NodeSwap**)
- cgroup v2。Linux cgroup API の次のバージョンである cgroup v2 を有効にします。(**CGroupsV2**)
- crun。crun コンテナランタイムを有効にします。(**Crun**)
- Insights Operator。OpenShift Container Platform 設定データを収集して Red Hat に送信する Insights Operator を有効にします。(**InsightsConfigAPI**)
- 外部クラウドプロバイダー。vSphere、AWS、Azure、GCP 上にあるクラスターの外部クラウドプロバイダーのサポートを有効にします。OpenStack のサポートは GA です。(**ExternalCloudProvider**)
- Pod トポロジー分散制約。Pod トポロジー制約の **matchLabelKeys** パラメーターを有効にします。パラメーターは、拡散が計算される Pod を選択するための Pod ラベルキーのリストです。(**MatchLabelKeysInPodTopologySpread**)
- Pod セキュリティーアドミッションの適用。Pod セキュリティーアドミッションの制限付き適用を有効にします。警告をログに記録するだけでなく、Pod のセキュリティ基準に違反している場合、Pod は拒否されます。(**OpenShiftPodSecurityAdmission**)



注記

Pod セキュリティー許可制限の適用は、OpenShift Container Platform クラスターのインストール後に **TechPreviewNoUpgrade** 機能セットを有効にした場合のみアクティブ化されます。クラスターのインストール中に **TechPreviewNoUpgrade** 機能セットを有効にした場合、これはアクティブになりません。

TechPreviewNoUpgrade フィーチャーゲートによってアクティブ化される機能の詳細は、次のトピックを参照してください。

- [CSI インラインの一時ボリューム](#)
- [CSI の自動移行](#)
- [Container Storage Interface \(CSI\) の使用](#)
- [Source-to-image \(S2I\) build volumes および Docker build volumes](#)
- [ノード上のスワップメモリー](#)
- [Cluster API によるマシンの管理](#)
- [Linux コントロールグループバージョン 2\(cgroup v2\)の有効化](#)
- [コンテナエンジンとコンテナランタイムについて](#)
- [Insights Operator の使用](#)
- [Pod トポロジー分散制約を使用した Pod 配置の制御](#)
- [Kubernetes ドキュメントの Pod セキュリティーアドミSSION および Pod セキュリティーアドミSSIONの理解と管理](#)

8.7.2. インストール時の機能セットの有効化

クラスターをデプロイする前に **install-config.yaml** ファイルを編集することで、クラスター内のすべてのノードの機能セットを有効にすることができます。

前提条件

- **install-config.yaml** ファイルがある。

手順

1. **featureSet** パラメーターを使用して、有効にする機能セットの名前 (**TechPreviewNoUpgrade** など) を指定します。



警告

クラスターで **TechPreviewNoUpgrade** 機能セットを有効にすると、元に戻すことができず、マイナーバージョンの更新が妨げられます。本番クラスターでは、この機能セットを有効にしないでください。

機能セットが有効になっている **install-config.yaml** ファイルのサンプル

```
compute:
  - hyperthreading: Enabled
```

```

name: worker
platform:
  aws:
    rootVolume:
      iops: 2000
      size: 500
      type: io1
    metadataService:
      authentication: Optional
    type: c5.4xlarge
    zones:
      - us-west-2c
  replicas: 3
featureSet: TechPreviewNoUpgrade

```

2. ファイルを保存し、インストールプログラムを使用してクラスターをデプロイメントするときに参照します。

検証

ノードが準備完了状態に戻った後、ノード上の **kubelet.conf** ファイルを確認することで、フィーチャゲートが有効になっていることを確認できます。

1. Web コンソールの **Administrator** パースペクティブで、**Compute** → **Nodes** に移動します。
2. ノードを選択します。
3. **Node details** ページで **Terminal** をクリックします。
4. ターミナルウィンドウで、root ディレクトリーを **/host** に切り替えます。

```
sh-4.2# chroot /host
```

5. **kubelet.conf** ファイルを表示します。

```
sh-4.2# cat /etc/kubernetes/kubelet.conf
```

出力例

```

# ...
featureGates:
  InsightsOperatorPullingSCA: true,
  LegacyNodeRoleBehavior: false
# ...

```

true として一覧表示されている機能は、クラスターで有効になっています。



注記

一覧表示される機能は、OpenShift Container Platform のバージョンによって異なります。

8.7.3. Web コンソールで機能セットの有効化

FeatureGate カスタムリソース (CR) を編集して、OpenShift Container Platform Web コンソールを使用してクラスター内のすべてのノードの機能セットを有効にすることができます。

手順

機能セットを有効にするには、以下を実行します。

1. OpenShift Container Platform Web コンソールで、**Administration** → **Custom Resource Definitions** ページに切り替えます。
2. **Custom Resource Definitions** ページで、**FeatureGate** をクリックします。
3. **Custom Resource Definition Details** ページで、**Instances** タブをクリックします。
4. **cluster** フィーチャゲートをクリックし、**YAML** タブをクリックします。
5. **cluster** インスタンスを編集して特定の機能セットを追加します。



警告

クラスターで **TechPreviewNoUpgrade** 機能セットを有効にすると、元に戻すことができず、マイナーバージョンの更新が妨げられます。本番クラスターでは、この機能セットを有効にしないでください。

フィーチャゲートカスタムリソースのサンプル

```
apiVersion: config.openshift.io/v1
kind: FeatureGate
metadata:
  name: cluster ❶
# ...
spec:
  featureSet: TechPreviewNoUpgrade ❷
```

❶ **FeatureGate** CR の名前は **cluster** である必要があります。

❷ 有効にする機能セットを追加します。

- **TechPreviewNoUpgrade** は、特定のテクノロジープレビュー機能を有効にします。

変更を保存すると、新規マシン設定が作成され、マシン設定プールが更新され、変更が適用されている間に各ノードのスケジューリングが無効になります。

検証

ノードが準備完了状態に戻った後、ノード上の **kubelet.conf** ファイルを確認することで、フィーチャゲートが有効になっていることを確認できます。

1. Web コンソールの **Administrator** パースペクティブで、**Compute** → **Nodes** に移動します。

2. ノードを選択します。
3. **Node details** ページで **Terminal** をクリックします。
4. ターミナルウィンドウで、root ディレクトリーを **/host** に切り替えます。

```
sh-4.2# chroot /host
```

5. **kubelet.conf** ファイルを表示します。

```
sh-4.2# cat /etc/kubernetes/kubelet.conf
```

出力例

```
# ...
featureGates:
  InsightsOperatorPullingSCA: true,
  LegacyNodeRoleBehavior: false
# ...
```

true として一覧表示されている機能は、クラスターで有効になっています。



注記

一覧表示される機能は、OpenShift Container Platform のバージョンによって異なります。

8.7.4. CLI を使用した機能セットの有効化

FeatureGate カスタムリソース (CR) を編集し、OpenShift CLI (**oc**) を使用してクラスター内のすべてのノードの機能セットを有効にすることができます。

前提条件

- OpenShift CLI (**oc**) がインストールされている。

手順

機能セットを有効にするには、以下を実行します。

1. **cluster** という名前の **FeatureGate** CR を編集します。

```
$ oc edit featuregate cluster
```



警告

クラスターで **TechPreviewNoUpgrade** 機能セットを有効にすると、元に戻すことができず、マイナーバージョンの更新が妨げられます。本番クラスターでは、この機能セットを有効にしないでください。

FeatureGate カスタムリソースのサンプル

```
apiVersion: config.openshift.io/v1
kind: FeatureGate
metadata:
  name: cluster ❶
# ...
spec:
  featureSet: TechPreviewNoUpgrade ❷
```

- ❶ **FeatureGate** CR の名前は **cluster** である必要があります。
- ❷ 有効にする機能セットを追加します。
 - **TechPreviewNoUpgrade** は、特定のテクノロジープレビュー機能を有効にします。

変更を保存すると、新規マシン設定が作成され、マシン設定プールが更新され、変更が適用されている間に各ノードのスケジューリングが無効になります。

検証

ノードが準備完了状態に戻った後、ノード上の **kubelet.conf** ファイルを確認することで、フィーチャゲートが有効になっていることを確認できます。

1. Web コンソールの **Administrator** パースペクティブで、**Compute → Nodes** に移動します。
2. ノードを選択します。
3. **Node details** ページで **Terminal** をクリックします。
4. ターミナルウィンドウで、root ディレクトリーを **/host** に切り替えます。

```
sh-4.2# chroot /host
```

5. **kubelet.conf** ファイルを表示します。

```
sh-4.2# cat /etc/kubernetes/kubelet.conf
```

出力例

```
# ...
featureGates:
  InsightsOperatorPullingSCA: true,
  LegacyNodeRoleBehavior: false
# ...
```

true として一覧表示されている機能は、クラスターで有効になっています。



注記

一覧表示される機能は、OpenShift Container Platform のバージョンによって異なります。

8.8. ワーカーレイテンシープロファイルを使用したレイテンシーの高い環境でのクラスターの安定性の向上

クラスター管理者が遅延テストを実行してプラットフォームを検証した際に、遅延が大きい場合でも安定性を確保するために、クラスターの動作を調整する必要性が判明することがあります。クラスター管理者が変更する必要があるのは、ファイルに記録されている1つのパラメーターだけです。このパラメーターは、監視プロセスがステータスを読み取り、クラスターの健全性を解釈する方法に影響を与える4つのパラメーターを制御するものです。1つのパラメーターのみを変更し、サポートしやすく簡単な方法でクラスターをチューニングできます。

Kubelet プロセスは、クラスターの健全性を監視する上での出発点です。**Kubelet** は、OpenShift Container Platform クラスター内のすべてのノードのステータス値を設定します。Kubernetes コントローラーマネージャー (**kube controller**) は、デフォルトで10秒ごとにステータス値を読み取ります。ノードのステータス値を読み取ることができない場合、設定期間が経過すると、**kube controller** とそのノードとの接続が失われます。デフォルトの動作は次のとおりです。

1. コントロールプレーン上のノードコントローラーが、ノードの健全性を **Unhealthy** に更新し、ノードの **Ready** 状態を `Unknown` とマークします。
2. この操作に応じて、スケジューラーはそのノードへの Pod のスケジューリングを停止します。
3. ノードライフサイクルコントローラーが、**NoExecute** effect を持つ **node.kubernetes.io/unreachable** taint をノードに追加し、デフォルトでノード上のすべての Pod を5分後に退避するようにスケジュールします。

この動作は、ネットワークが遅延の問題を起こしやすい場合、特にネットワークエッジにノードがある場合に問題が発生する可能性があります。場合によっては、ネットワークの遅延が原因で、Kubernetes コントローラーマネージャーが正常なノードから更新を受信できないことがあります。**Kubelet** は、ノードが正常であっても、ノードから Pod を削除します。

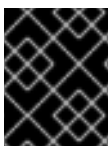
この問題を回避するには、**ワーカーレイテンシープロファイル** を使用して、**Kubelet** と Kubernetes コントローラーマネージャーがアクションを実行する前にステータスの更新を待機する頻度を調整できます。これらの調整により、コントロールプレーンとワーカーノード間のネットワーク遅延が最適でない場合に、クラスターが適切に動作するようになります。

これらのワーカーレイテンシープロファイルには、3つのパラメーターセットが含まれています。パラメーターは、遅延の増加に対するクラスターの反応を制御するように、慎重に調整された値で事前定義されています。試験により手作業で最良の値を見つける必要はありません。

クラスターのインストール時、またはクラスターネットワークのレイテンシーの増加に気付いたときはいつでも、ワーカーレイテンシープロファイルを設定できます。

8.8.1. ワーカーレイテンシープロファイルについて

ワーカーレイテンシープロファイルは、4つの異なるカテゴリからなる慎重に調整されたパラメーターです。これらの値を実装する4つのパラメーターは、**node-status-update-frequency**、**node-monitor-grace-period**、**default-not-ready-toleration-seconds**、および **default-unreachable-toleration-seconds** です。これらのパラメーターにより、遅延の問題に対するクラスターの反応を制御できる値を使用できます。手作業で最適な値を決定する必要はありません。



重要

これらのパラメーターの手動設定はサポートされていません。パラメーター設定が正しくないと、クラスターの安定性に悪影響が及びます。

すべてのワーカーレイテンシープロファイルは、次のパラメーターを設定します。

node-status-update-frequency

kubelet がノードのステータスを API サーバーにポストする頻度を指定します。

node-monitor-grace-period

Kubernetes コントローラマネージャーが、ノードを異常とマークし、**node.kubernetes.io/not-ready** または **node.kubernetes.io/unreachable** taint をノードに追加する前に、kubelet からの更新を待機する時間を秒単位で指定します。

default-not-ready-toleration-seconds

ノードを異常とマークした後、Kube API Server Operator がそのノードから Pod を削除するまでに待機する時間を秒単位で指定します。

default-unreachable-toleration-seconds

ノードを到達不能とマークした後、Kube API Server Operator がそのノードから Pod を削除するまでに待機する時間を秒単位で指定します。

次の Operator は、ワーカーレイテンシープロファイルの変更を監視し、それに応じて対応します。

- Machine Config Operator (MCO) は、ワーカーノードの **node-status-update-frequency** パラメーターを更新します。
- Kubernetes コントローラマネージャーは、コントロールプレーンノードの **node-monitor-grace-period** パラメーターを更新します。
- Kubernetes API Server Operator は、コントロールプレーンノードの **default-not-ready-toleration-seconds** および **default-unreachable-toleration-seconds** パラメーターを更新します。

ほとんどの場合、デフォルト設定が機能しますが、OpenShift Container Platform は、ネットワークで通常よりも高いレイテンシーが発生している状況に対して、他に 2 つのワーカーレイテンシープロファイルを提供します。次のセクションでは、3 つのワーカーレイテンシープロファイルについて説明します。

デフォルトのワーカーレイテンシープロファイル

Default プロファイルを使用すると、各 **Kubelet** が 10 秒ごとにステータスを更新します (**node-status-update-frequency**)。Kube Controller Manager は、Kubelet のステータスを 5 秒ごとにチェックします (**node-monitor-grace-period**)。

Kubernetes コントローラマネージャーは、Kubelet が異常であると判断するまでに、Kubelet からのステータス更新を 40 秒待機します。ステータスが提供されない場合、Kubernetes コントローラマネージャーは、ノードに **node.kubernetes.io/not-ready** または **node.kubernetes.io/unreachable** taint のマークを付け、そのノードの Pod を削除します。

そのノードの Pod に **NoExecute** taint がある場合、その Pod は **tolerationSeconds** に従って実行されます。Pod に taint がない場合、その Pod は 300 秒以内に削除されます (**Kube API Server** の **default-not-ready-toleration-seconds** および **default-unreachable-toleration-seconds** 設定)。

プロファイル	コンポーネント	パラメーター	値
デフォルト	kubelet	node-status-update-frequency	10s

プロファイル	コンポーネント	パラメーター	値
	Kubelet コントローラーマネージャー	node-monitor-grace-period	40s
	Kubernetes API Server Operator	default-not-ready-toleration-seconds	300s
	Kubernetes API Server Operator	default-unreachable-toleration-seconds	300s

中規模のワーカーレイテンシープロファイル

ネットワークレイテンシーが通常よりもわずかに高い場合は、**MediumUpdateAverageReaction** プロファイルを使用します。

MediumUpdateAverageReaction プロファイルは、kubelet の更新の頻度を 20 秒に減らし、Kubernetes コントローラーマネージャーがそれらの更新を待機する期間を 2 分に変更します。そのノード上の Pod の Pod 排除期間は 60 秒に短縮されます。Pod に **tolerationSeconds** パラメーターがある場合、エビクションはそのパラメーターで指定された期間待機します。

Kubernetes コントローラーマネージャーは、ノードが異常であると判断するまでに 2 分間待機します。別の 1 分間でエビクションプロセスが開始されます。

プロファイル	コンポーネント	パラメーター	値
MediumUpdateAverageReaction	kubelet	node-status-update-frequency	20s
	Kubelet コントローラーマネージャー	node-monitor-grace-period	2m
	Kubernetes API Server Operator	default-not-ready-toleration-seconds	60s
	Kubernetes API Server Operator	default-unreachable-toleration-seconds	60s

ワーカーの低レイテンシープロファイル

ネットワーク遅延が非常に高い場合は、**LowUpdateSlowReaction** プロファイルを使用します。

LowUpdateSlowReaction プロファイルは、kubelet の更新頻度を 1 分に減らし、Kubernetes コントローラーマネージャーがそれらの更新を待機する時間を 5 分に変更します。そのノード上の Pod

の Pod 排除期間は 60 秒に短縮されます。Pod に **tolerationSeconds** パラメーターがある場合、エビクションはそのパラメーターで指定された期間待機します。

Kubernetes コントローラマネージャーは、ノードが異常であると判断するまでに 5 分間待機します。別の 1 分間でエビクションプロセスが開始されます。

プロファイル	コンポーネント	パラメーター	値
LowUpdateSlowReaction	kubelet	node-status-update-frequency	1m
	Kubelet コントローラマネージャー	node-monitor-grace-period	5m
	Kubernetes API Server Operator	default-not-ready-toleration-seconds	60s
	Kubernetes API Server Operator	default-unreachable-toleration-seconds	60s



注記

レイテンシープロファイルは、カスタムのマシン設定プールをサポートしていません。デフォルトのワーカーマシン設定プールのみをサポートしています。

8.8.2. ワーカーレイテンシープロファイルの使用と変更

ネットワークの遅延に対処するためにワーカー遅延プロファイルを変更するには、**node.config** オブジェクトを編集してプロファイルの名前を追加します。遅延が増加または減少したときに、いつでもプロファイルを変更できます。

ワーカーレイテンシープロファイルは、一度に1つずつ移行する必要があります。たとえば、**Default** プロファイルから **LowUpdateSlowReaction** ワーカーレイテンシープロファイルに直接移行することはできません。まず **Default** ワーカーレイテンシープロファイルから **MediumUpdateAverageReaction** プロファイルに移行し、次に **LowUpdateSlowReaction** プロファイルに移行する必要があります。同様に、**Default** プロファイルに戻る場合は、まずロープロファイルからミディアムプロファイルに移行し、次に **Default** に移行する必要があります。



注記

OpenShift Container Platform クラスターのインストール時にワーカーレイテンシープロファイルを設定することもできます。

手順

デフォルトのワーカーレイテンシープロファイルから移動するには、以下を実行します。

1. 中規模のワーカーのレイテンシープロファイルに移動します。

- a. **node.config** オブジェクトを編集します。

```
$ oc edit nodes.config/cluster
```

- b. **spec.workerLatencyProfile: MediumUpdateAverageReaction** を追加します。

node.config オブジェクトの例

```
apiVersion: config.openshift.io/v1
kind: Node
metadata:
  annotations:
    include.release.openshift.io/ibm-cloud-managed: "true"
    include.release.openshift.io/self-managed-high-availability: "true"
    include.release.openshift.io/single-node-developer: "true"
    release.openshift.io/create-only: "true"
  creationTimestamp: "2022-07-08T16:02:51Z"
  generation: 1
  name: cluster
  ownerReferences:
    - apiVersion: config.openshift.io/v1
      kind: ClusterVersion
      name: version
      uid: 36282574-bf9f-409e-a6cd-3032939293eb
  resourceVersion: "1865"
  uid: 0c0f7a4c-4307-4187-b591-6155695ac85b
spec:
  workerLatencyProfile: MediumUpdateAverageReaction ❶
# ...
```

- ❶ 中規模のワーカーレイテンシーポリシーを指定します。

変更が適用されると、各ワーカーノードでのスケジューリングは無効になります。

2. 必要に応じて、ワーカーのレイテンシーが低いプロファイルに移動します。

- a. **node.config** オブジェクトを編集します。

```
$ oc edit nodes.config/cluster
```

- b. **spec.workerLatencyProfile** の値を **LowUpdateSlowReaction** に変更します。

node.config オブジェクトの例

```
apiVersion: config.openshift.io/v1
kind: Node
metadata:
  annotations:
    include.release.openshift.io/ibm-cloud-managed: "true"
    include.release.openshift.io/self-managed-high-availability: "true"
    include.release.openshift.io/single-node-developer: "true"
```

```

    release.openshift.io/create-only: "true"
    creationTimestamp: "2022-07-08T16:02:51Z"
    generation: 1
    name: cluster
    ownerReferences:
    - apiVersion: config.openshift.io/v1
      kind: ClusterVersion
      name: version
      uid: 36282574-bf9f-409e-a6cd-3032939293eb
    resourceVersion: "1865"
    uid: 0c0f7a4c-4307-4187-b591-6155695ac85b
  spec:
    workerLatencyProfile: LowUpdateSlowReaction ❶

# ...

```

- ❶ 低ワーカーレイテンシーポリシーの使用を指定します。

変更が適用されると、各ワーカーノードでのスケジューリングは無効になります。

検証

- 全ノードが **Ready** 状態に戻ると、以下のコマンドを使用して Kubernetes Controller Manager を確認し、これが適用されていることを確認できます。

```
$ oc get KubeControllerManager -o yaml | grep -i workerlatency -A 5 -B 5
```

出力例

```

# ...
- lastTransitionTime: "2022-07-11T19:47:10Z"
  reason: ProfileUpdated
  status: "False"
  type: WorkerLatencyProfileProgressing
- lastTransitionTime: "2022-07-11T19:47:10Z" ❶
  message: all static pod revision(s) have updated latency profile
  reason: ProfileUpdated
  status: "True"
  type: WorkerLatencyProfileComplete
- lastTransitionTime: "2022-07-11T19:20:11Z"
  reason: AsExpected
  status: "False"
  type: WorkerLatencyProfileDegraded
- lastTransitionTime: "2022-07-11T19:20:36Z"
  status: "False"

# ...

```

- ❶ プロファイルが適用され、アクティブであることを指定します。

ミディアムプロファイルからデフォルト、またはデフォルトからミディアムに変更する場合、**node.config** オブジェクトを編集し、**spec.workerLatencyProfile** パラメーターを適切な値に設定します。

第9章 ネットワークエッジ上にあるリモートワーカーノード

9.1. ネットワークエッジでのリモートワーカーノードの使用

ネットワークエッジにあるノードで OpenShift Container Platform クラスターを設定できます。このトピックでは、**リモートワーカーノード**と呼ばれます。リモートワーカーノードを含む通常のクラスターは、オンプレミスのマスターとワーカーノードを、クラスターに接続する他の場所にあるワーカーノードと統合します。このトピックは、リモートワーカーノードの使用のベストプラクティスに関するガイダンスを提供することを目的としており、特定の設定に関する詳細情報は含まれません。

リモートワーカーノードでのデプロイメントパターンの使用に関しては、さまざまな業界 (通信、小売、製造、政府など) で複数のユースケースがあります。たとえば、リモートワーカーノードを [Kubernetes ゾーン](#) に結合することで、プロジェクトとワークロードを分離して分離できます。

ただし、リモートワーカーノードを使用すると、高いレイテンシーの発生や、ネットワーク接続が断続的に失われるなどの問題が発生する可能性があります。リモートワーカーノードを含むクラスターの課題には、以下のようなものがあります。

- **ネットワーク分離:** OpenShift Container Platform コントロールプレーンとリモートワーカーノードは、相互に通信する必要があります。コントロールプレーンとリモートワーカーノードの間に距離があるため、ネットワークの問題が発生すると、この通信が妨げられる可能性があります。OpenShift Container Platform がネットワークの分離にどのように対応するか、およびクラスターへの影響を軽減する方法は、[リモートワーカーノードを使用したネットワークの分離](#) を参照してください。
- **停電:** コントロールプレーンとリモートワーカーノードは別々の場所にあるため、リモートの場所での停電、またはそれぞれの場所からの任意の場所での停電により、クラスターに悪影響を及ぼす可能性があります。ノードの電力損失に OpenShift Container Platform がどのように対応するか、およびクラスターへの影響を軽減する方法は、[リモートワーカーノードの電力損失](#) を参照してください。
- **急激な高レイテンシーまたは一時的なスループットの低下:** ネットワークの場合と同様に、クラスターとリモートワーカーノード間のネットワーク状態の変更は、クラスターに悪影響を及ぼす可能性があります。OpenShift Container Platform は、レイテンシーの問題に対するクラスターの反応を制御できる複数の **ワーカーレイテンシープロファイル** を提供します。

リモートワーカーノードを含むクラスターを計画する場合には、以下の制限に注意してください。

- OpenShift Container Platform は、オンプレミスクラスターが使用するクラウドプロバイダー以外のクラウドプロバイダーを使用するリモートワーカーノードをサポートしません。
- ワークロードを1つの Kubernetes ゾーンから別の Kubernetes ゾーンに移動すると、(特定のタイプのメモリーが異なるゾーンで利用できないなどの) システムや環境に関する課題により、問題が発生する可能性があります。
- プロキシおよびファイアウォールでは、このドキュメントでは扱われていない追加的制限が出てくる可能性があります。このような制限に対処する方法は、[ファイアウォールの設定](#) など、関連する OpenShift Container Platform ドキュメントを参照してください。
- コントロールプレーンとネットワークエッジノード間の L2/L3 レベルのネットワーク接続を設定および維持する必要があります。

9.1.1. リモートワーカーノードの追加

リモートワーカーノードをクラスターに追加するには、追加の考慮事項がいくつかあります。

- コントロールプレーンとすべてのリモートワーカーノードの間でトラフィックをルーティングするには、ルートまたはデフォルトゲートウェイが配置されていることを確認する必要があります。
- Ingress VIP をコントロールプレーンに配置する必要があります。
- user-provisioned infrastructure を使用してリモートワーカーノードを追加する方法は、他のワーカーノードを追加する方法と同じです。
- インストール時にインストーラーがプロビジョニングしたクラスターにリモートワーカーノードを追加するには、インストール前に **install-config.yaml** ファイルで各ワーカーノードのサブネットを指定します。DHCP サーバーに追加の設定は必要ありません。リモートワーカーノードはローカルプロビジョニングネットワークにアクセスできないため、仮想メディアを使用する必要があります。
- プロビジョニングネットワークでデプロイされたインストーラーでプロビジョニングされたクラスターにリモートワーカーノードを追加するには、仮想メディアを使用してノードを追加するように、**install-config.yaml** ファイルで **virtualMediaViaExternalNetwork** フラグが **true** に設定されていることを確認します。リモートワーカーノードは、ローカルプロビジョニングネットワークにアクセスできません。PXE ではなく、仮想メディアを使用してデプロイする必要があります。さらに、DHCP サーバー内のリモートワーカーノードの各グループとコントロールプレーンノードの各サブネットを指定します。

関連情報

- [サブネット間の通信の確立](#)
- [サブネット用のホストネットワークインターフェイスの設定](#)
- [コントロールプレーンで実行されるネットワークコンポーネントの設定](#)

9.1.2. リモートワーカーノードによるネットワーク分離

すべてのノードは、10 秒ごとに OpenShift Container Platform クラスターの Kubernetes Controller Manager Operator (kube コントローラー) にハートビートを送信します。クラスターがノードからハートビートを受信しない場合、OpenShift Container Platform は複数のデフォルトメカニズムを使用して応答します。

OpenShift Container Platform は、ネットワークパーティションやその他の中断に対して回復性を持たせるように設計されています。ソフトウェアのアップグレードの中断、ネットワーク分割、ルーティングの問題など、より一般的な中断の一部を軽減することができます。軽減策には、リモートワーカーノードの Pod が正しい CPU およびメモリーリソースの量を要求すること、適切なレプリケーションポリシーの設定、ゾーン間の冗長性の使用、ワークロードでの Pod の Disruption Budget の使用などが含まれます。

設定した期間後に kube コントローラーのノードとの接続が解除された場合、コントロールプレーンのノードコントローラーはノードの正常性を **Unhealthy** に更新し、ノードの **Ready** 状態を **Unknown** とマークします。この操作に応じて、スケジューラーはそのノードへの Pod のスケジューリングを停止します。オンプレミスノードコントローラーは、effect が **NoExecute** の **node.kubernetes.io/unreachable** taint をノードに追加し、デフォルトで 5 分後に、エビクション用にノード上で Pod をスケジュールします。

Deployment オブジェクト、または **StatefulSet** オブジェクトなどのワークロードコントローラーが、正常でないノードの Pod にトラフィックを転送し、他のノードがクラスターに到達できる場合、OpenShift Container Platform はトラフィックをノードの Pod から遠ざけます。クラスターに到達でき

ないノードは、新しいトラフィックルーティングでは更新されません。その結果、それらのノードのワークロードは、正常でないノードに到達しようとします。

以下の方法で接続損失の影響を軽減できます。

- デモンセットを使用した taint を容認する Pod の作成
- ノードがダウンした場合に自動的に再起動する静的 Pod の使用
- Kubernetes ゾーンを使用した Pod エビクシヨンの制御
- Pod のエビクシヨンを遅延または回避するための Pod toleration の設定
- ノードを正常でないとマークするタイミングを制御するように kubelet を設定します。

リモートワーカーノードを含むクラスターでこれらのオブジェクトを使用する方法の詳細は、[リモートワーカーノードの戦略について](#) を参照してください。

9.1.3. リモートワーカーノードの電源損失

リモートワーカーノードの電源がなくなったり、強制的な再起動を行う場合、OpenShift Container Platform は複数のデフォルトメカニズムを使用して応答します。

設定した期間後に Kubernetes Controller Manager Operator (kube コントローラー) のノードとの接続が解除された場合、コントロールプレーンはノードの正常性を **Unhealthy** に更新し、ノードの **Ready** 状態を **Unknown** とマークします。この操作に応じて、スケジューラーはそのノードへの Pod のスケジューリングを停止します。オンプレミスノードコントローラーは、effect が **NoExecute** の **node.kubernetes.io/unreachable** taint をノードに追加し、デフォルトで 5 分後に、エビクシヨン用にノード上で Pod をスケジュールします。

ノードでは、ノードが電源を回復し、コントロールプレーンに再接続する際に、Pod を再起動する必要があります。



注記

再起動時に Pod をすぐに再起動する必要がある場合は、静的 Pod を使用します。

ノードの再起動後に kubelet も再起動し、ノードにスケジュールされた Pod の再起動を試行します。コントロールプレーンへの接続にデフォルトの 5 分よりも長い時間がかかる場合、コントロールプレーンはノードの正常性を更新して **node.kubernetes.io/unreachable** taint を削除することができません。ノードで、kubelet は実行中の Pod をすべて終了します。これらの条件がクリアされると、スケジューラーはそのノードへの Pod のスケジューリングを開始できます。

以下の方法で、電源損失の影響を軽減できます。

- デモンセットを使用した taint を容認する Pod の作成
- ノードを使用して自動的に再起動する静的 Pod の使用
- Pod のエビクシヨンを遅延または回避するための Pod toleration の設定
- ノードコントローラーがノードを正常でないとマークするタイミングを制御するための kubelet の設定

リモートワーカーノードを含むクラスターでこれらのオブジェクトを使用する方法の詳細は、[リモートワーカーノードの戦略について](#) を参照してください。

9.1.4. リモートワーカーへのレイテンシーの急上昇またはスループットの一時的な低下

クラスター管理者が遅延テストを実行してプラットフォームを検証した際に、遅延が大きい場合でも安定性を確保するために、クラスターの動作を調整する必要性が判明することがあります。クラスター管理者が変更する必要があるのは、ファイルに記録されている1つのパラメーターだけです。このパラメーターは、監視プロセスがステータスを読み取り、クラスターの健全性を解釈する方法に影響を与える4つのパラメーターを制御するものです。1つのパラメーターのみを変更し、サポートしやすく簡単な方法でクラスターをチューニングできます。

Kubelet プロセスは、クラスターの健全性を監視する上での出発点です。**Kubelet** は、OpenShift Container Platform クラスター内のすべてのノードのステータス値を設定します。Kubernetes コントローラーマネージャー (**kube controller**) は、デフォルトで10秒ごとにステータス値を読み取ります。ノードのステータス値を読み取ることができない場合、設定期間が経過すると、**kube controller** とそのノードとの接続が失われます。デフォルトの動作は次のとおりです。

1. コントロールプレーン上のノードコントローラーが、ノードの健全性を **Unhealthy** に更新し、ノードの **Ready** 状態を `Unknown` とマークします。
2. この操作に応じて、スケジューラーはそのノードへの Pod のスケジューリングを停止します。
3. ノードライフサイクルコントローラーが、**NoExecute** effect を持つ **node.kubernetes.io/unreachable** taint をノードに追加し、デフォルトでノード上のすべての Pod を5分後に退避するようにスケジュールします。

この動作は、ネットワークが遅延の問題を起こしやすい場合、特にネットワークエッジにノードがある場合に問題が発生する可能性があります。場合によっては、ネットワークの遅延が原因で、Kubernetes コントローラーマネージャーが正常なノードから更新を受信できないことがあります。**Kubelet** は、ノードが正常であっても、ノードから Pod を削除します。

この問題を回避するには、**ワーカーレイテンシープロファイル** を使用して、**Kubelet** と Kubernetes コントローラーマネージャーがアクションを実行する前にステータスの更新を待機する頻度を調整できます。これらの調整により、コントロールプレーンとワーカーノード間のネットワーク遅延が最適でない場合に、クラスターが適切に動作するようになります。

これらのワーカーレイテンシープロファイルには、3つのパラメーターセットが含まれています。パラメーターは、遅延の増加に対するクラスターの反応を制御するように、慎重に調整された値で事前定義されています。試験により手作業で最良の値を見つける必要はありません。

クラスターのインストール時、またはクラスターネットワークのレイテンシーの増加に気付いたときはいつでも、ワーカーレイテンシープロファイルを設定できます。

関連情報

- [ワーカーレイテンシープロファイルを使用したレイテンシーの高い環境でのクラスターの安定性の向上](#)

9.1.5. リモートワーカーノードストラテジー

リモートワーカーノードを使用する場合は、アプリケーションを実行するために使用するオブジェクトを考慮してください。

ネットワークの問題や電源の損失時に必要とされる動作に基づいて、デーモンセットまたは静的 Pod を使用することが推奨されます。さらに、Kubernetes ゾーンおよび toleration を使用して、コントロールプレーンがリモートワーカーノードに到達できない場合に Pod エビクションを制御したり、回避したりできます。

デーモンセット

デーモンセットは、以下の理由により、リモートワーカーノードでの Pod の管理に最適な方法です。

- デーモンセットは通常、動作の再スケジュールを必要としません。ノードがクラスターから切断される場合、ノードの Pod は実行を継続できます。OpenShift Container Platform はデーモンセット Pod の状態を変更せず、Pod を最後に報告された状態のままにします。たとえば、デーモンセット Pod が **Running** 状態の際にノードが通信を停止する場合、Pod は実行し続けますが、これは OpenShift Container Platform によって実行されていることが想定されます。
- デーモンセット Pod はデフォルトで、**tolerationSeconds** 値のない **node.kubernetes.io/unreachable** taint および **node.kubernetes.io/not-ready** taint の **NoExecute** toleration で作成されます。これらのデフォルト値により、コントロールプレーンがノードに到達できなくても、デーモンセット Pod が退避されることはありません。以下に例を示します。

デフォルトでデーモンセット Pod に toleration を追加

```
tolerations:
- key: node.kubernetes.io/not-ready
  operator: Exists
  effect: NoExecute
- key: node.kubernetes.io/unreachable
  operator: Exists
  effect: NoExecute
- key: node.kubernetes.io/disk-pressure
  operator: Exists
  effect: NoSchedule
- key: node.kubernetes.io/memory-pressure
  operator: Exists
  effect: NoSchedule
- key: node.kubernetes.io/pid-pressure
  operator: Exists
  effect: NoSchedule
- key: node.kubernetes.io/unschedulable
  operator: Exists
  effect: NoSchedule
```

- デーモンセットは、ワークロードが一致するワーカーノードで実行されるように、ラベルを使用することができます。
- OpenShift Container Platform サービスエンドポイントを使用してデーモンセット Pod の負荷を分散できます。



注記

デーモンセットは、OpenShift Container Platform がノードに到達できない場合、ノードの再起動後に Pod をスケジュールしません。

静的 Pod

ノードの再起動時に Pod を再起動する必要がある場合 (電源が切れた場合など)、**静的な Pod** を考慮してください。ノードの kubelet は、ノードの再起動時に静的 Pod を自動的に再起動します。



注記

静的 Pod はシークレットおよび設定マップを使用できません。

Kubernetes ゾーン

Kubernetes ゾーン は、速度を落としたり、または場合によっては Pod エビクションを完全に停止したりすることができます。

コントロールプレーンがノードに到達できない場合、デフォルトでノードコントローラーは **node.kubernetes.io/unreachable** taint を適用し、1 秒あたり 0.1 ノードのレートで Pod を退避します。ただし、Kubernetes ゾーンを使用するクラスターでは、Pod エビクションの動作が変更されません。

ゾーンのすべてのノードに **False** または **Unknown** の **Ready** 状態が見られる、ゾーンが完全に中断された状態の場合、コントロールプレーンは **node.kubernetes.io/unreachable** taint をそのゾーンのノードに適用しません。

(ノードの 55% 超が **False** または **Unknown** 状態である) 部分的に中断されたゾーンの場合、Pod のエビクションレートは 1 秒あたり 0.01 ノードに低減されます。50 未満の小規模なクラスターにあるノードに taint は付けられません。これらの動作を有効にするには、クラスターに 4 つ以上のゾーンが必要です。

ノード仕様に **topology.kubernetes.io/region** ラベルを適用して、ノードを特定のゾーンに割り当てます。

Kubernetes ザーンのノードラベルの例

```
kind: Node
apiVersion: v1
metadata:
  labels:
    topology.kubernetes.io/region=east
```

KubeletConfig オブジェクト

kubelet が各ノードの状態をチェックする時間を調整することができます。

オンプレミスノードコントローラーがノードを **Unhealthy** または **Unreachable** 状態にマークするタイミングに影響を与える間隔を設定するには、**node-status-update-frequency** および **node-status-report-frequency** パラメーターが含まれる **KubeletConfig** オブジェクトを作成します。

各ノードの kubelet は **node-status-update-frequency** 設定で定義されたノードのステータスを判別し、**node-status-report-frequency** 設定に基づいてそのステータスをクラスターに報告します。デフォルトで、kubelet は 10 秒ごとに Pod のステータスを判別し、毎分ごとにステータスを報告します。ただし、ノードの状態が変更されると、kubelet は変更をクラスターに即時に報告します。OpenShift Container Platform は、Node Lease フィーチャーゲートが有効にされている場合にのみ、**node-status-report-frequency** 設定を使用します。これは OpenShift Container Platform クラスターのデフォルト状態です。Node Lease フィーチャーゲートが無効になっている場合、ノードは **node-status-update-frequency** 設定に基づいてノードのステータスを報告します。

kubelet 設定の例

```
apiVersion: machineconfiguration.openshift.io/v1
kind: KubeletConfig
```

```

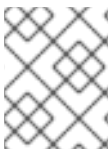
metadata:
  name: disable-cpu-units
spec:
  machineConfigPoolSelector:
    matchLabels:
      machineconfiguration.openshift.io/role: worker ❶
  kubeletConfig:
    node-status-update-frequency: ❷
      - "10s"
    node-status-report-frequency: ❸
      - "1m"

```

- ❶ **MachineConfig** オブジェクトのラベルを使用して、この **KubeletConfig** オブジェクトが適用されるノードタイプを指定します。
- ❷ kubelet がこの **MachineConfig** オブジェクトに関連付けられたノードのステータスをチェックする頻度を指定します。デフォルト値は **10s** です。このデフォルト値を変更すると、**node-status-report-frequency** の値は同じ値に変更されます。
- ❸ kubelet がこの **MachineConfig** オブジェクトに関連付けられたノードのステータスを報告する頻度を指定します。デフォルト値は **1m** です。

node-status-update-frequency パラメーターは **node-monitor-grace-period** および **pod-eviction-timeout** パラメーターと共に機能します。

- **node-monitor-grace-period** パラメーターは、コントローラーマネージャーがハートビートを受信しない場合に、この **MachineConfig** オブジェクトに関連付けられたノードが **Unhealthy** とマークされた後に、OpenShift Container Platform が待機する時間を指定します。この待機時間後も、ノード上のワークロードは引き続き実行されます。**node-monitor-grace-period** の期限が切れた後にリモートワーカーノードがクラスターに再度加わる場合、Pod は実行を継続します。新規 Pod をノードにスケジュールできます。**node-monitor-grace-period** の間隔は **40s** です。**node-status-update-frequency** の値は、**node-monitor-grace-period** の値よりも低い値である必要があります。
- **pod-eviction-timeout** パラメーターは、**MachineConfig** オブジェクトに関連付けられたノードを **Unreachable** としてマークした後、エビクション用に Pod のマークを開始するまでに OpenShift Container Platform が待機する時間を指定します。エビクトされた Pod は、他のノードで再スケジュールされます。**pod-eviction-timeout** の期限が切れた後にリモートワーカーノードがクラスターに再結合する場合、ノードコントローラーがオンプレミスで Pod をエビクトしたため、リモートワーカーノードで実行されている Pod は終了します。続いて、Pod をそのノードに再スケジュールできます。**pod-eviction-timeout** の期間は **5m0s** です。



注記

node-monitor-grace-period および **pod-eviction-timeout** パラメーターを変更することはサポートされていません。

容認

オンプレミスノードコントローラーが、effect が **NoExecute** の **node.kubernetes.io/unreachable** taint を到達できないノードに追加する場合、Pod toleration を使用して effect を軽減することができます。

effect が **NoExecute** の taint は、ノードですでに実行中の Pod に以下のような影響を及ぼします。

- taint を容認しない Pod は、エビクションのキューに置かれます。
- toleration の仕様に **tolerationSeconds** 値を指定せずに taint を容認する Pod は、永久にバインドされたままになります。
- 指定された **tolerationSeconds** 値で taint を容認する Pod は、指定された期間バインドされます。時間が経過すると、Pod はエビクションのキューに置かれます。

effect が **NoExecute** の **node.kubernetes.io/unreachable** テイントおよび **node.kubernetes.io/not-ready** テイントで Pod の容認を設定し、Pod のエビクションを遅延したり回避したりできます。

Pod 仕様での toleration の例

```
...
tolerations:
- key: "node.kubernetes.io/unreachable"
  operator: "Exists"
  effect: "NoExecute" ❶
- key: "node.kubernetes.io/not-ready"
  operator: "Exists"
  effect: "NoExecute" ❷
  tolerationSeconds: 600
...
```

❶ **tolerationSeconds** のない **NoExecute** effect により、コントロールプレーンがノードに到達する場合は Pod が永続的に残ります。

❷ **tolerationSeconds**: 600 の **NoExecute** effect により、コントロールプレーンがノードに **Unhealthy** のマークを付ける場合に Pod が 10 分間そのまま残ります。

OpenShift Container Platform は、**pod-eviction-timeout** 値の経過後、**tolerationSeconds** 値を使用します。

OpenShift Container Platform オブジェクトの他のタイプ

レプリカセット、デプロイメント、およびレプリケーションコントローラーを使用できます。スケジューラーは、ノードが 5 分間切断された後、これらの Pod を他のノードに再スケジュールできます。他のノードへの再スケジュールは、管理者が特定数の Pod を確実に実行し、アクセスできるようにする REST API などの一部のワークロードにとって有益です。



注記

リモートワーカーノードを使用する際に、リモートワーカーノードが特定の機能用に予約されることが意図されている場合、異なるノードでの Pod の再スケジュールは許容されない可能性があります。

ステートフルセット は、停止時に再起動されません。Pod は、コントロールプレーンが Pod の終了を認識できるまで、**terminating** 状態のままになります。

同じタイプの永続ストレージにアクセスできないノードにスケジュールしないようにするため、OpenShift Container Platform では、ネットワークの分離時に永続ボリュームを必要とする Pod を他のゾーンに移行することはできません。

関連情報

- Daemonsets の詳細は、[DaemonSets](#) を参照してください。
- taint と toleration の詳細は、[ノード taint を使用した Pod の配置の制御](#) を参照してください。
- **KubeletConfig** オブジェクトの設定の詳細は、[KubeletConfig CRD の作成](#) を参照してください。
- レプリカセットの詳細は、[ReplicaSets](#) を参照してください。
- デプロイメントの詳細は、[デプロイメント](#) を参照してください。
- レプリケーションコントローラーの詳細は、[レプリケーションコントローラー](#) を参照してください。
- コントローラーマネージャーの詳細は、[Kubernetes Controller Manager Operator](#) を参照してください。

第10章 シングルノード OPENSHIFT クラスター用のワーカーノード

10.1. 単一ノードの OPENSHIFT クラスターへのワーカーノードの追加

単一ノードの OpenShift クラスターは、単一ホストへのデプロイメントのホスト前提条件を減らします。これは、制約のある環境またはネットワークエッジでのデプロイメントに役立ちます。ただし、通信やネットワークエッジのシナリオなどでは、クラスターに容量を追加する必要がある場合があります。これらのシナリオでは、ワーカーノードを単一ノードクラスターに追加できます。

単一ノードクラスターにワーカーノードを追加するには、いくつかの方法があります。[Red Hat OpenShift Cluster Manager](#) を使用するか、Assisted Installer REST API を直接使用して、クラスターにワーカーノードを手動で追加できます。



重要

ワーカーノードを追加してもクラスターコントロールプレーンは拡張されず、クラスターに高可用性は提供されません。単一ノードの OpenShift クラスターの場合、高可用性は別のサイトにフェイルオーバーすることによって処理されます。多数のワーカーノードを単一ノードクラスターに追加することは推奨しません。



注記

マルチノードクラスターとは異なり、ワーカーノードを追加した後でも、デフォルトではすべての ingress トラフィックが単一のコントロールプレーンノードにルーティングされます。

10.1.1. 単一ノードの OpenShift ワーカーノードをインストールするための要件

単一ノードの OpenShift ワーカーノードをインストールするには、次の要件に対応する必要があります。

- **管理ホスト:** ISO を準備し、インストールを監視するためのコンピューターが必要です。
- **実稼働環境グレードサーバー:** 単一ノードの OpenShift ワーカーノードをインストールするには、OpenShift Container Platform サービスと実稼働環境ワークロードを実行するのに十分なリソースを備えたサーバーが必要です。

表10.1 最小リソース要件

プロファイル	仮想 CPU	メモリー	ストレージ
最低限	2 vCPU コア	8GB の RAM	100GB



注記

1vCPU は、同時マルチスレッド (SMT) またはハイパースレッディングが有効にされていない場合に1つの物理コアと同等です。有効にした場合には、次の式を使用して対応する比率を計算します。

(コアあたりのスレッド数 x コア数) x ソケット数 = 仮想 CPU 数

仮想メディアを使用して起動する場合は、サーバーには Baseboard Management Controller (BMC) が必要です。

- **ネットワーク:** ワーカーノードサーバーは、ルーティング可能なネットワークに接続されていない場合、インターネットまたはローカルレジストリーにアクセスする必要があります。ワーカーノードサーバーには、DHCP 予約または静的 IP アドレスが必要であり、単一ノードの OpenShift クラスター Kubernetes API、ingress ルート、およびクラスターノードのドメイン名にアクセスする必要があります。単一ノードの OpenShift クラスターの次の完全修飾ドメイン名 (FQDN) のそれぞれに IP アドレスを解決するように DNS を設定する必要があります。

表10.2 必要な DNS レコード

使用法	FQDN	説明
Kubernetes API	api.<cluster_name>.<base_domain>	DNS A/AAAA または CNAME レコードを追加します。このレコードは、クラスター外のクライアントで解決する必要があります。
内部 API	api-int.<cluster_name>.<base_domain>	ISO を手動で作成する場合は、DNS A/AAAA または CNAME レコードを追加します。このレコードは、クラスター内のノードにより解決可能である必要があります。
Ingress ルート	*.apps.<cluster_name>.<base_domain>	ノードをターゲットにするワイルドカード DNS A/AAAA または CNAME レコードを追加します。このレコードは、クラスター外のクライアントで解決する必要があります。

永続的な IP アドレスがない場合、**apiserver** と **etcd** の間の通信で失敗する可能性があります。

関連情報

- [クラスターインストールの最小リソース要件](#)
- [クラスターのスケーリングに関する推奨プラクティス](#)
- [ユーザーによってプロビジョニングされる DNS 要件](#)
- [Creating a bootable ISO image on a USB drive](#)
- [Bootimg from an ISO image served over HTTP using the Redfish API](#)
- [クラスターからのノードの削除](#)

10.1.2. Assisted Installer および OpenShift Cluster Manager を使用したワーカーノードの追加

[Assisted Installer](#) を使用して、[Red Hat OpenShift Cluster Manager](#) で作成された単一ノードの OpenShift クラスターにワーカーノードを追加できます。



重要

単一ノードの OpenShift クラスターへのワーカーノードの追加は、OpenShift Container Platform バージョン 4.11 以降を実行しているクラスターに対してのみサポートされます。

前提条件

- [Assisted Installer](#) を使用してインストールされた単一ノードの OpenShift クラスターにアクセスできる。
- OpenShift CLI (**oc**) がインストールされている。
- **cluster-admin** 権限を持つユーザーとしてログインしている。
- ワーカーノードを追加するクラスターに必要なすべての DNS レコードが存在することを確認してください。

手順

1. [OpenShift Cluster Manager](#) にログインし、ワーカーノードを追加する単一ノードクラスターをクリックします。
2. **Add hosts** をクリックし、新しいワーカーノードの検出 ISO をダウンロードして、必要に応じて SSH 公開キーを追加し、クラスター全体のプロキシ設定を設定します。
3. 検出 ISO を使用してターゲットホストを起動し、ホストがコンソールで検出されるまで待ちます。ホストが検出されたら、インストールを開始します。
4. インストールが進行するにつれて、インストールはワーカーノードの保留中の証明書署名要求 (CSR) を生成します。プロンプトが表示されたら、保留中の CSR を承認してインストールを完了します。
ワーカーノードが正常にインストールされると、クラスター Web コンソールにワーカーノードとして一覧表示されます。



重要

新しいワーカーノードは、元のクラスターと同じ方法を使用して暗号化されます。

関連情報

- [ユーザーによってプロビジョニングされる DNS 要件](#)
- [マシンの証明書署名要求の承認](#)

10.1.3. Assisted Installer API を使用したワーカーノードの追加

Assisted Installer REST API を使用して、単一ノードの OpenShift クラスターにワーカーノードを追加できます。ワーカーノードを追加する前に、[OpenShift Cluster Manager](#) にログインし、API に対して認証する必要があります。

10.1.3.1. Assisted Installer REST API に対する認証

Assisted Installer REST API を使用する前に、生成した JSON Web トークン (JWT) を使用して API に対して認証する必要があります。

前提条件

- クラスター作成権限を持つユーザーで [OpenShift Cluster Manager](#) にログインする。
- **jq** をインストールします。

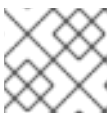
手順

1. [OpenShift Cluster Manager](#) にログインし、API トークンをコピーします。
2. 次のコマンドを実行して、コピーした API トークンを使用して **\$OFFLINE_TOKEN** 変数を設定します。

```
$ export OFFLINE_TOKEN=<copied_api_token>
```

3. 以前に設定した **\$OFFLINE_TOKEN** 変数を使用して、**\$JWT_TOKEN** 変数を設定します。

```
$ export JWT_TOKEN=$(
  curl \
    --silent \
    --header "Accept: application/json" \
    --header "Content-Type: application/x-www-form-urlencoded" \
    --data-urlencode "grant_type=refresh_token" \
    --data-urlencode "client_id=cloud-services" \
    --data-urlencode "refresh_token=${OFFLINE_TOKEN}" \
    "https://sso.redhat.com/auth/realms/redhat-external/protocol/openid-connect/token" \
    | jq --raw-output ".access_token"
)
```



注記

JWT トークンは 15 分間のみ有効です。

検証

- オプション: 次のコマンドを実行して、API にアクセスできることを確認します。

```
$ curl -s https://api.openshift.com/api/assisted-install/v2/component-versions -H
"Authorization: Bearer ${JWT_TOKEN}" | jq
```

出力例

```
{
  "release_tag": "v2.5.1",
  "versions":
  {
    "assisted-installer": "registry.redhat.io/rhai-tech-preview/assisted-installer-rhel8:v1.0.0-175",
    "assisted-installer-controller": "registry.redhat.io/rhai-tech-preview/assisted-installer-
```

```
reporter-rhel8:v1.0.0-223",
  "assisted-installer-service": "quay.io/app-sre/assisted-service:ac87f93",
  "discovery-agent": "registry.redhat.io/rhai-tech-preview/assisted-installer-agent-
rhel8:v1.0.0-156"
}
}
```

10.1.3.2. Assisted Installer REST API を使用したワーカーノードの追加

Assisted Installer REST API を使用して、クラスターにワーカーノードを追加できます。

前提条件

- OpenShift Cluster Manager CLI (**ocm**) をインストールしている。
- クラスター作成権限を持つユーザーで [OpenShift Cluster Manager](#) にログインする。
- **jq** をインストールします。
- ワーカーノードを追加するクラスターに必要なすべての DNS レコードが存在することを確認してください。

手順

1. Assisted Installer REST API に対して認証し、セッションの JSON Web トークン (JWT) を生成します。生成された JWT トークンは 15 分間のみ有効です。
2. 次のコマンドを実行して、**\$API_URL** 変数を設定します。

```
$ export API_URL=<api_url> ❶
```

- ❶ **<api_url>** を Assisted Installer API の URL に置き換えます (例: <https://api.openshift.com>)。

3. 次のコマンドを実行して、単一ノードの OpenShift クラスターをインポートします。
 - a. **\$OPENSHIFT_CLUSTER_ID** 変数を設定します。クラスターにログインし、次のコマンドを実行します。

```
$ export OPENSHIFT_CLUSTER_ID=$(oc get clusterversion -o
jsonpath='{.items[].spec.clusterID}')
```

- b. クラスターのインポートに使用される **\$CLUSTER_REQUEST** 変数を設定します。

```
$ export CLUSTER_REQUEST=$(jq --null-input --arg openshift_cluster_id
"$OPENSHIFT_CLUSTER_ID" '{
  "api_vip_dnsname": "<api_vip>", ❶
  "openshift_cluster_id": $openshift_cluster_id,
  "name": "<openshift_cluster_name>" ❷
}')
```

- 1 **<api_vip>** をクラスターの API サーバーのホスト名に置き換えます。これは、API サーバーの DNS ドメイン、またはワーカーノードが到達できる単一ノードの IP アドレス
- 2 **<openshift_cluster_name>** をクラスターのプレーンテキスト名に置き換えます。クラスター名は、Day 1 クラスターのインストール中に設定されたクラスター名と一致する必要があります。

- c. クラスターをインポートし、**\$CLUSTER_ID** 変数を設定します。以下のコマンドを実行します。

```
$ CLUSTER_ID=$(curl "$API_URL/api/assisted-install/v2/clusters/import" -H
"Authorization: Bearer ${JWT_TOKEN}" -H 'accept: application/json' -H 'Content-Type:
application/json' \
-d "$CLUSTER_REQUEST" | tee /dev/stderr | jq -r '.id')
```

4. 次のコマンドを実行して、クラスターの **InfraEnv** リソースを生成し、**\$INFRA_ENV_ID** 変数を設定します。

- a. console.redhat.com の Red Hat OpenShift Cluster Manager からプルシークレットファイルをダウンロードします。

- b. **\$INFRA_ENV_REQUEST** 変数を設定します。

```
export INFRA_ENV_REQUEST=$(jq --null-input \
--slurpfile pull_secret <path_to_pull_secret_file> \ 1
--arg ssh_pub_key "$(cat <path_to_ssh_pub_key>)" \ 2
--arg cluster_id "$CLUSTER_ID" '{
"name": "<infraenv_name>", 3
"pull_secret": $pull_secret[0] | tojson,
"cluster_id": $cluster_id,
"ssh_authorized_key": $ssh_pub_key,
"image_type": "<iso_image_type>" 4
}')
```

- 1 **<path_to_pull_secret_file>** を、console.redhat.com の Red Hat OpenShift Cluster Manager からダウンロードしたプルシークレットを含むローカルファイルへのパスに置き換えます。

- 2 **<path_to_ssh_pub_key>** を、ホストへのアクセスに必要な公開 SSH キーへのパスに置き換えます。この値を設定しないと、検出モードでホストにアクセスできません。

- 3 **<infraenv_name>** を **InfraEnv** リソースのプレーンテキスト名に置き換えます。

- 4 **<iso_image_type>** を **full-iso** または **minimal-iso** のいずれかの ISO イメージタイプに置き換えます。

- c. **\$INFRA_ENV_REQUEST** を **/v2/infra-envs** API に送信し、**\$INFRA_ENV_ID** 変数を設定します。

```
$ INFRA_ENV_ID=$(curl "$API_URL/api/assisted-install/v2/infra-envs" -H "Authorization:
Bearer ${JWT_TOKEN}" -H 'accept: application/json' -H 'Content-Type: application/json'
-d "$INFRA_ENV_REQUEST" | tee /dev/stderr | jq -r '.id')
```

5. 次のコマンドを実行して、クラスターワーカーノードの検出 ISO の URL を取得します。

```
$ curl -s "$API_URL/api/assisted-install/v2/infra-envs/$INFRA_ENV_ID" -H "Authorization: Bearer ${JWT_TOKEN}" | jq -r '.download_url'
```

出力例

```
https://api.openshift.com/api/assisted-images/images/41b91e72-c33e-42ee-b80f-b5c5bbf6431a?arch=x86_64&image_token=eyJhbGciOiJIUzI1NiIsInR5cCI6IkpXVCJ9.eyJleHAiOiJlE2NTYwMjYzNzEsInN1YiI6IjQxYjYkZTcyLWMzM2UtNDJlZS1iODBmLWI1YzViYmY2NDMxYSJ9.1EX_VGaMNejMhrAvVRBS7PDPIQtOOc8LtG8OukE1a4&type=minimal-iso&version=4.12
```

6. ISO をダウンロードします。

```
$ curl -L -s '<iso_url>' --output rhcos-live-minimal.iso ❶
```

- ❶ **<iso_url>** を前の手順の ISO の URL に置き換えます。

7. ダウンロードした **rhcos-live-minimal.iso** から新しいワーカーホストを起動します。

8. インストールされていない クラスター内のホストのリストを取得します。新しいホストが表示されるまで、次のコマンドを実行し続けます。

```
$ curl -s "$API_URL/api/assisted-install/v2/clusters/$CLUSTER_ID" -H "Authorization: Bearer ${JWT_TOKEN}" | jq -r '.hosts[] | select(.status != "installed").id'
```

出力例

```
2294ba03-c264-4f11-ac08-2f1bb2f8c296
```

9. 新しいワーカーノードの **\$HOST_ID** 変数を設定します。次に例を示します。

```
$ HOST_ID=<host_id> ❶
```

- ❶ **<host_id>** を前の手順のホスト ID に置き換えます。

10. 以下のコマンドを実行して、ホストがインストールできる状態であることを確認します。



注記

完全な **jq** 式を含むコマンド全体をコピーしてください。

```
$ curl -s $API_URL/api/assisted-install/v2/clusters/$CLUSTER_ID -H "Authorization: Bearer ${JWT_TOKEN}" | jq 'def host_name($host): if (.suggested_hostname // "") == "" then if (.inventory // "") == "" then "Unknown hostname, please wait" else
```

```

        .inventory | fromjson | .hostname
    end
else
    .suggested_hostname
end;

def is_notable($validation):
    ["failure", "pending", "error"] | any(. == $validation.status);

def notable_validations($validations_info):
    [
        $validations_info // "{}"
        | fromjson
        | to_entries[].value[]
        | select(is_notable(.))
    ];

{
    "Hosts validations": {
        "Hosts": [
            .hosts[]
            | select(.status != "installed")
            | {
                "id": .id,
                "name": host_name(.),
                "status": .status,
                "notable_validations": notable_validations(.validations_info)
            }
        ]
    },
    "Cluster validations info": {
        "notable_validations": notable_validations(.validations_info)
    }
}
'-r

```

出力例

```

{
  "Hosts validations": {
    "Hosts": [
      {
        "id": "97ec378c-3568-460c-bc22-df54534ff08f",
        "name": "localhost.localdomain",
        "status": "insufficient",
        "notable_validations": [
          {
            "id": "ntp-synced",
            "status": "failure",
            "message": "Host couldn't synchronize with any NTP server"
          },
          {
            "id": "api-domain-name-resolved-correctly",
            "status": "error",
            "message": "Parse error for domain name resolutions result"
          }
        ]
      }
    ]
  }
}

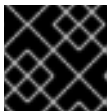
```

```
{
  "id": "api-int-domain-name-resolved-correctly",
  "status": "error",
  "message": "Parse error for domain name resolutions result"
},
{
  "id": "apps-domain-name-resolved-correctly",
  "status": "error",
  "message": "Parse error for domain name resolutions result"
}
]
},
"Cluster validations info": {
  "notable_validations": []
}
}
```

11. 前のコマンドでホストの準備ができていることが示されたら、次のコマンドを実行し、[/v2/infra-envs/{infra_env_id}/hosts/{host_id}/actions/install](#) API を使用してインストールを開始します。

```
$ curl -X POST -s "$API_URL/api/assisted-install/v2/infra-envs/$INFRA_ENV_ID/hosts/$HOST_ID/actions/install" -H "Authorization: Bearer ${JWT_TOKEN}"
```

12. インストールが進行するにつれて、インストールはワーカーノードの保留中の証明書署名要求 (CSR) を生成します。



重要

インストールを完了するには、CSR を承認する必要があります。

次の API 呼び出しを実行し続けて、クラスターのインストールを監視します。

```
$ curl -s "$API_URL/api/assisted-install/v2/clusters/$CLUSTER_ID" -H "Authorization: Bearer ${JWT_TOKEN}" | jq '{
  "Cluster day-2 hosts":
    [
      .hosts[]
      | select(.status != "installed")
      | {id, requested_hostname, status, status_info, progress, status_updated_at,
        updated_at, infra_env_id, cluster_id, created_at}
    ]
}'
```

出力例

```
{
  "Cluster day-2 hosts": [
    {
      "id": "a1c52dde-3432-4f59-b2ae-0a530c851480",
      "requested_hostname": "control-plane-1",
```

```

    "status": "added-to-existing-cluster",
    "status_info": "Host has rebooted and no further updates will be posted. Please check
console for progress and to possibly approve pending CSRs",
    "progress": {
      "current_stage": "Done",
      "installation_percentage": 100,
      "stage_started_at": "2022-07-08T10:56:20.476Z",
      "stage_updated_at": "2022-07-08T10:56:20.476Z"
    },
    "status_updated_at": "2022-07-08T10:56:20.476Z",
    "updated_at": "2022-07-08T10:57:15.306369Z",
    "infra_env_id": "b74ec0c3-d5b5-4717-a866-5b6854791bd3",
    "cluster_id": "8f721322-419d-4eed-aa5b-61b50ea586ae",
    "created_at": "2022-07-06T22:54:57.161614Z"
  }
]
}

```

13. オプション: 次のコマンドを実行して、クラスターのすべてのイベントを表示します。

```

$ curl -s "$API_URL/api/assisted-install/v2/events?cluster_id=$CLUSTER_ID" -H
"Authorization: Bearer ${JWT_TOKEN}" | jq -c '.[] | {severity, message, event_time, host_id}'

```

出力例

```

{"severity":"info","message":"Host compute-0: updated status from insufficient to known (Host
is ready to be installed)","event_time":"2022-07-08T11:21:46.346Z","host_id":"9d7b3b44-
1125-4ad0-9b14-76550087b445"}
{"severity":"info","message":"Host compute-0: updated status from known to installing
(Installation is in progress)","event_time":"2022-07-08T11:28:28.647Z","host_id":"9d7b3b44-
1125-4ad0-9b14-76550087b445"}
{"severity":"info","message":"Host compute-0: updated status from installing to installing-in-
progress (Starting installation)","event_time":"2022-07-
08T11:28:52.068Z","host_id":"9d7b3b44-1125-4ad0-9b14-76550087b445"}
{"severity":"info","message":"Uploaded logs for host compute-0 cluster 8f721322-419d-4eed-
aa5b-61b50ea586ae","event_time":"2022-07-08T11:29:47.802Z","host_id":"9d7b3b44-1125-
4ad0-9b14-76550087b445"}
{"severity":"info","message":"Host compute-0: updated status from installing-in-progress to
added-to-existing-cluster (Host has rebooted and no further updates will be posted. Please
check console for progress and to possibly approve pending CSRs)","event_time":"2022-07-
08T11:29:48.259Z","host_id":"9d7b3b44-1125-4ad0-9b14-76550087b445"}
{"severity":"info","message":"Host: compute-0, reached installation stage
Rebooting","event_time":"2022-07-08T11:29:48.261Z","host_id":"9d7b3b44-1125-4ad0-9b14-
76550087b445"}

```

14. クラスターにログインし、保留中の CSR を承認してインストールを完了します。

検証

- 新しいワーカーノードが **Ready** のステータスで、クラスターに正常に追加されたことを確認します。

```

$ oc get nodes

```

出力例

NAME	STATUS	ROLES	AGE	VERSION
control-plane-1.example.com	Ready	master,worker	56m	v1.25.0
compute-1.example.com	Ready	worker	11m	v1.25.0

関連情報

- [ユーザーによってプロビジョニングされる DNS 要件](#)
- [マシンの証明書署名要求の承認](#)

10.1.4. 単一ノードの OpenShift クラスターへのワーカーノードの手動での追加

Red Hat Enterprise Linux CoreOS (RHCOS) ISO からワーカーノードを起動し、クラスターの **worker.ign** ファイルを使用して新しいワーカーノードをクラスターに参加させることにより、単一ノードの OpenShift クラスターにワーカーノードを手動で追加できます。

前提条件

- ベアメタルに単一ノードの OpenShift クラスターをインストールします。
- OpenShift CLI (**oc**) がインストールされている。
- **cluster-admin** 権限を持つユーザーとしてログインしている。
- ワーカーノードを追加するクラスターに必要なすべての DNS レコードが存在することを確認してください。

手順

1. OpenShift Container Platform バージョンを設定します。

```
$ OCP_VERSION=<ocp_version> ❶
```

- ❶ **<ocp_version>** を現在のバージョン (**latest-4.12** など) に置き換えます。

2. ホストアーキテクチャーを設定します。

```
$ ARCH=<architecture> ❶
```

- ❶ **<architecture>** をターゲットホストアーキテクチャー (**aarch64** や **x86_64** など) に置き換えます。

3. 次のコマンドを実行して、実行中の単一ノードクラスターから **worker.ign** データを取得します。

```
$ oc extract -n openshift-machine-api secret/worker-user-data-managed --keys=userData --to=- > worker.ign
```

4. ネットワークからアクセスできる Web サーバーで **worker.ign** ファイルをホストします。

5. OpenShift Container Platform インストーラーをダウンロードし、以下のコマンドを入力して使用できるようにします。

```
$ curl -k https://mirror.openshift.com/pub/openshift-
v4/clients/ocp/$OCP_VERSION/openshift-install-linux.tar.gz > openshift-install-linux.tar.gz
```

```
$ tar zxvf openshift-install-linux.tar.gz
```

```
$ chmod +x openshift-install
```

6. RHCOS ISO URL を取得します。

```
$ ISO_URL=$(./openshift-install coreos print-stream-json | grep location | grep $ARCH | grep
iso | cut -d\" -f4)
```

7. RHCOS ISO をダウンロードします。

```
$ curl -L $ISO_URL -o rhcos-live.iso
```

8. RHCOS ISO とホストされている **worker.ign** ファイルを使用して、ワーカーノードをインストールします。

- a. RHCOS ISO と任意のインストール方法を使用して、ターゲットホストを起動します。
- b. ターゲットホストが RHCOS ISO から起動したら、ターゲットホストでコンソールを開きます。
- c. ローカルネットワークで DHCP が有効になっていない場合は、RHCOS インストールを実行する前に、新しいホスト名で Ignition ファイルを作成し、ワーカーノードの静的 IP アドレスを設定する必要があります。以下の手順を実行します。

- i. 静的 IP を使用してワーカーホストネットワーク接続を設定します。ターゲットホストコンソールで次のコマンドを実行します。

```
$ nmcli con mod <network_interface> ipv4.method manual /
ipv4.addresses <static_ip> ipv4.gateway <network_gateway> ipv4.dns <dns_server>
/
802-3-ethernet.mtu 9000
```

ここでは、以下のようになります。

<static_ip>

ホストの静的 IP アドレスと CIDR です (例: **10.1.101.50/24**)。

<network_gateway>

ネットワークゲートウェイです (例: **10.1.101.1**)。

- ii. 変更したネットワークインターフェイスを有効にします。

```
$ nmcli con up <network_interface>
```

- iii. 新しい Ignition ファイル **new-worker.ign** を作成します。このファイルには、元の **worker.ign** への参照と、**coreos-installer** プログラムが新しいワーカーホストの

/etc/hostname ファイルに入力するために使用する追加の命令を含めます。以下に例を示します。

```
{
  "ignition":{
    "version":"3.2.0",
    "config":{
      "merge":[
        {
          "source":"<hosted_worker_ign_file>" ❶
        }
      ]
    }
  },
  "storage":{
    "files":[
      {
        "path":"/etc/hostname",
        "contents":{
          "source":"data:,<new_fqdn>" ❷
        },
        "mode":420,
        "overwrite":true,
        "path":"/etc/hostname"
      }
    ]
  }
}
```

- ❶ **<hosted_worker_ign_file>** は、元の **worker.ign** ファイルのローカルでアクセス可能な URL です。たとえば、<http://webserver.example.com/worker.ign> です。
- ❷ **<new_fqdn>** は、ワーカーノードに設定した新しい FQDN です。たとえば、**new-worker.example.com** です。

- iv. ネットワークからアクセスできる Web サーバーで **new-worker.ign** ファイルをホストします。
- v. 次の **coreos-installer** コマンドを実行して、**ignition-url** とハードディスクの詳細を渡します。

```
$ sudo coreos-installer install --copy-network /
--ignition-url=<new_worker_ign_file> <hard_disk> --insecure-ignition
```

ここでは、以下ようになります。

<new_worker_ign_file>

ホストされている **new-worker.ign** ファイルのローカルでアクセス可能な URL です (例: <http://webserver.example.com/new-worker.ign>)。

<hard_disk>

RHCOS をインストールするハードディスクです (例: **/dev/sda**)。

- d. DHCP が有効になっているネットワークでは、静的 IP を設定する必要はありません。ターゲットホストコンソールから次の **coreos-installer** コマンドを実行して、システムをインストールします。

```
$ coreos-installer install --ignition-url=<hosted_worker_ign_file> <hard_disk>
```

- e. DHCP を手動で有効にするには、次の **NMStateConfig** CR を単一ノードの OpenShift クラスターに適用します。

```
apiVersion: agent-install.openshift.io/v1
kind: NMStateConfig
metadata:
  name: nmstateconfig-dhcp
  namespace: example-sno
  labels:
    nmstate_config_cluster_name: <nmstate_config_cluster_label>
spec:
  config:
    interfaces:
      - name: eth0
        type: ethernet
        state: up
        ipv4:
          enabled: true
          dhcp: true
        ipv6:
          enabled: false
    interfaces:
      - name: "eth0"
        macAddress: "AA:BB:CC:DD:EE:11"
```

重要

単一ノードの OpenShift が静的 IP アドレスでデプロイされた場合に、静的 IP アドレスを使用してワーカーノードを正常にデプロイし、動的 IP アドレスを使用してワーカーノードを追加するには、**NMStateConfig** CR が必要です。クラスターネットワーク DHCP は、これらのネットワーク設定を新しいワーカーノードに自動的に設定しません。

9. インストールが進行するにつれて、インストールはワーカーノードの保留中の証明書署名要求 (CSR) を生成します。プロンプトが表示されたら、保留中の CSR を承認してインストールを完了します。
10. インストールが完了したら、ホストを再起動します。ホストは、新しいワーカーノードとしてクラスターに参加します。

検証

- 新しいワーカーノードが **Ready** のステータスで、クラスターに正常に追加されたことを確認します。

```
$ oc get nodes
```

出力例

NAME	STATUS	ROLES	AGE	VERSION
control-plane-1.example.com	Ready	master	56m	v1.25.0
compute-1.example.com	Ready	worker	11m	v1.25.0

関連情報

- [ユーザーによってプロビジョニングされる DNS 要件](#)
- [マシンの証明書署名要求の承認](#)

10.1.5. マシンの証明書署名要求の承認

マシンをクラスターに追加する際に、追加したそれぞれのマシンに対して 2 つの保留状態の証明書署名要求 (CSR) が生成されます。これらの CSR が承認されていることを確認するか、必要な場合はそれらを承認してください。最初にクライアント要求を承認し、次にサーバー要求を承認する必要があります。

前提条件

- マシンがクラスターに追加されています。

手順

1. クラスターがマシンを認識していることを確認します。

```
$ oc get nodes
```

出力例

NAME	STATUS	ROLES	AGE	VERSION
master-0	Ready	master	63m	v1.25.0
master-1	Ready	master	63m	v1.25.0
master-2	Ready	master	64m	v1.25.0

出力には作成したすべてのマシンがリスト表示されます。



注記

上記の出力には、一部の CSR が承認されるまで、ワーカーノード (ワーカーノードとも呼ばれる) が含まれない場合があります。

2. 保留中の証明書署名要求 (CSR) を確認し、クラスターに追加したそれぞれのマシンのクライアントおよびサーバー要求に **Pending** または **Approved** ステータスが表示されていることを確認します。

```
$ oc get csr
```

出力例

NAME	AGE	REQUESTOR	CONDITION
csr-8b2br	15m	system:serviceaccount:openshift-machine-config-operator:node-bootstrap	Pending

```
csr-8vnps 15m system:serviceaccount:openshift-machine-config-operator:node-
bootstrapper Pending
...
```

この例では、2つのマシンがクラスターに参加しています。このリストにはさらに多くの承認された CSR が表示される可能性があります。

- 追加したマシンの保留中の CSR すべてが **Pending** ステータスになった後に CSR が承認されない場合には、クラスターマシンの CSR を承認します。

注記

CSR のローテーションは自動的に実行されるため、クラスターにマシンを追加後1時間以内に CSR を承認してください。1時間以内に承認しない場合には、証明書のローテーションが行われ、各ノードに3つ以上の証明書が存在するようになります。これらの証明書すべてを承認する必要があります。クライアントの CSR が承認された後に、Kubelet は提供証明書のセカンダリー CSR を作成します。これには、手動の承認が必要になります。次に、後続の提供証明書の更新要求は、Kubelet が同じパラメーターを持つ新規証明書を要求する場合に **machine-approver** によって自動的に承認されます。

注記

ベアメタルおよび他の user-provisioned infrastructure などのマシン API ではないプラットフォームで実行されているクラスターの場合、kubelet 提供証明書要求 (CSR) を自動的に承認する方法を実装する必要があります。要求が承認されない場合、API サーバーが kubelet に接続する際に提供証明書が必須であるため、**oc exec**、**oc rsh**、および **oc logs** コマンドは正常に実行できません。Kubelet エンドポイントにアクセスする操作には、この証明書の承認が必要です。この方法は新規 CSR の有無を監視し、CSR が **system:node** または **system:admin** グループの **node-bootstrapper** サービスアカウントによって提出されていることを確認し、ノードの ID を確認します。

- それらを個別に承認するには、それぞれの有効な CSR に以下のコマンドを実行します。

```
$ oc adm certificate approve <csr_name> ❶
```

- ❶ **<csr_name>** は、現行の CSR のリストからの CSR の名前です。

- すべての保留中の CSR を承認するには、以下のコマンドを実行します。

```
$ oc get csr -o go-template='{{range .items}}{{if not .status}}{{.metadata.name}}{{"\n"}}{{end}}{{end}}' | xargs --no-run-if-empty oc adm certificate approve
```

注記

一部の Operator は、一部の CSR が承認されるまで利用できない可能性があります。

- クライアント要求が承認されたら、クラスターに追加した各マシンのサーバー要求を確認する必要があります。

```
$ oc get csr
```

出力例

```
NAME      AGE   REQUESTOR                                     CONDITION
csr-bfd72 5m26s system:node:ip-10-0-50-126.us-east-2.compute.internal
Pending
csr-c57lv 5m26s system:node:ip-10-0-95-157.us-east-2.compute.internal
Pending
...
```

- 残りの CSR が承認されず、それらが **Pending** ステータスにある場合、クラスターマシンの CSR を承認します。

- それらを個別に承認するには、それぞれの有効な CSR に以下のコマンドを実行します。

```
$ oc adm certificate approve <csr_name> 1
```

- 1** **<csr_name>** は、現行の CSR のリストからの CSR の名前です。

- すべての保留中の CSR を承認するには、以下のコマンドを実行します。

```
$ oc get csr -o go-template='{{range .items}}{{if not .status}}{{.metadata.name}}{{"\n"}}{{end}}{{end}}' | xargs oc adm certificate approve
```

- すべてのクライアントおよびサーバーの CSR が承認された後に、マシンのステータスが **Ready** になります。以下のコマンドを実行して、これを確認します。

```
$ oc get nodes
```

出力例

```
NAME      STATUS   ROLES    AGE   VERSION
master-0  Ready    master   73m   v1.25.0
master-1  Ready    master   73m   v1.25.0
master-2  Ready    master   74m   v1.25.0
worker-0  Ready    worker   11m   v1.25.0
worker-1  Ready    worker   11m   v1.25.0
```



注記

サーバー CSR の承認後にマシンが **Ready** ステータスに移行するまでに数分の時間がかかる場合があります。

関連情報

- CSR の詳細は、[Certificate Signing Requests](#) を参照してください。

