Red Hat Ceph Storage 3

ストレージストラテジーガイド

Red Hat Ceph Storage クラスターのストレージストラテジーの作成

Last Updated: 2023-02-22

Red Hat Ceph Storage 3 ストレージストラテジーガイド

Red Hat Ceph Storage クラスターのストレージストラテジーの作成

Enter your first name here. Enter your surname here.
Enter your organisation's name here. Enter your organisational division here.
Enter your email address here.

法律上の通知

概要

本書では、CRUSH 階層の作成、配置グループの数の見積り、作成するストレージプールのタイプの決定、プールの管理など、ストレージストラテジーの作成方法を説明します。

目次

第1章 概要

Ceph クライアントの視点から、Ceph ストレージクラスターとの対話は非常に簡単なものになります。

1. クラスターへの接続
2. プール I/O コンテキストの作成

この非常にシンプルなインターフェースは、Ceph クライアントが定義するストレージストラテジーのいずれかを選択する方法と同じです。ストレージストラテジーはすべて、ストレージ容量およびパフォーマンスにおいて Ceph クライアントを認識しません。

1.1. ストレージストラテジーの概要

ストレージストラテジーは、特定のユースケースに対応するデータを保存するための方法です。たとえば、OpenStack のようなクラウドプラットフォーム用のボリュームおよびイメージを格納する必要がある場合は、SSD ベースのジャーナルで、妥当なパフォーマンスの SAS ドライブにデータを保存することを選択できます。これとは対照に、S3 または Swift 準拠のゲートウェイのオブジェクトデータを保存する必要がある場合は、従来の SATA ドライブなどの、より経済的なオプションを選択できます。Ceph は、同じ Ceph クラスターで両方のシナリオに対応することができますが、プラットフォーム (OpenStack では SAS/SSD ストレージストラテジーなど) を提供し、オブジェクトストアに SATA ストレージを提供する手段が必要です。

ストレージストラテジーには、ストレージメディア (ハードドライブ、SSD など)、ストレージメディア、配置グループの数、およびプールインターフェースのパフォーマンスおよび失敗ドメインを設定する CRUSH マップが含まれます。Ceph では、複数のストレージストラテジーがサポートされます。ユースケース、コスト/分散によるパフォーマンスに関するトレードオフおよびデータの持続性は、ストレージ戦略を駆動する主な考慮事項です。

1. **ユースケース:** Ceph は大容量のストレージを提供し、多くのユースケースをサポートします。たとえば、Ceph Block Device クライアントは、OpenStack などのクラウドプラットフォームの主要なストレージバックエンドです。OpenStack の場合、コピーオンライトのクローン作成などの高パフォーマンスな機能と共にボリュームおよびイメージの制限のないストレージを提供。これとは対照的に、Ceph Object Gateway クライアントは、音声、ビットマップ、ビデオなどのオブジェクト向けの RESTful S3 準拠のオブジェクトおよび Swift 準拠のオブジェクトストレージを提供するクラウドプラットフォームの主要なストレージバックエンドです。

2. **パフォーマンスのコスト/利点:** 高速さはより優れています。大きい方が優れています。持続性が高くなりました。ただし、ベスト的の質ごとに、対応するコストや利益のトレードオフに価格があります。パフォーマンスの観点からでは、以下のユースケースを考慮してください。SSD は、比較的小規模なデータおよびジャーナリングのために非常に高速ストレージを提供できます。データベースやオブジェクトインデックスを格納すると、非常に高速な SSD のプールから利点がある場合もありますが、他のデータにとっては非常に高価な高価です。SSD ジャーナリングを使用した SAS ドライブは、ボリュームおよびイメージへの経済的な価格で高速なパフォーマンスを提供します。SSD ジャーナリングなしで SATA ドライブを使用すると、パフォーマンスが全体的に低下します。OSD の CRUSH 階層を作成する場合は、ユースケースと許容コスト/パフォーマンスのトレードオフを考慮する必要があります。

3. **耐久性:** 大規模なクラスターでは、ハードウェア障害は予想され、例外ではありません。ただし、データの損失やサービスの中断は、受け入れられなかったままになります。このため、データの持続性は非常に重要です。Ceph は、オブジェクトの複数のディープコピー、またはイレイジャーコーディングおよび複数のコーディングのチャンクでデータの持続性に対応します。複数のコピーまたはコロケーションチャンクが、さらにコストや適切なトレードオフを示します。このトレードオフは、コピーが少なくなる、またはチャンクが少なくなるのが困難です。ただし、動作が低下した状態でサービスの書き込み要求の原因になる可能性があります。

通常、2 つの追加のコピー (つまり **size = 3**) または 2 つのコーディングチャンクを持つオブジェクトを使用すると、クラスターが復旧する間に、クラスターが動作が低下した状態での書き込みを行うことができます。CRUSH アルゴリズムは、Ceph が、クラスター内の異なる場所に追加のコピーまたはコーディングしたチャンクを保存することでこのプロセスを禁止します。これにより、1 つのストレージデバイスまたはノードに障害が発生しても、データ損失の妨げに必要なコピーやコードチャンクがすべて失われないようにします。

ストレージストラテジーでパフォーマンスのトレードオフやデータの耐性を確保し、それをストレージプールとして Ceph クライアントに提示することができます。

重要

Ceph のオブジェクトのコピーやブロックのチャンクにより RAID が廃止されます。Ceph はすでにデータの持続性を処理して、低下した RAID のパフォーマンスに悪影響を与えるため、RAID を使用したデータの復元は、ディープコピーまたはイレイジャーコーディングのチャンクを使用するよりも大幅に遅くなります。

1.2. ストレージストラテジーの開発

ストレージストラテジーの設定は、Ceph OSD を CRUSH 階層に割り当て、プールの配置グループの数を定義し、プールを作成します。一般的な手順は以下のとおりです。

1. **ストレージストラテジーの定義:** ストレージストラテジーでは、ユースケース、コスト/利点のパフォーマンストレードオフおよびデータ永続性を分析する必要があります。次に、そのユースケースに適した OSD を作成します。たとえば、パフォーマンスの高いプール用に SSD 対応 OSD を作成できます。高パフォーマンスのブロックデバイスボリュームおよびイメージ用には SAS ドライブ/SSD のジャーナル OSD、低コストストレージ用の SATA 対応 OSD を作成できます。理想としては、ユースケース向けの各 OSD には同じハードウェア構成を持つ必要があり、これによりパフォーマンスプロファイルの一貫性が保たれます。

2. **CRUSH 階層の定義:** Ceph ルールは、CRUSH 階層にあるノード (通常は **ルート**) を選択し、配置グループおよびそれに含まれるオブジェクトを保存するための適切な OSD を特定します。ストレージストラテジーの CRUSH 階層および CRUSH ルールを作成する必要があります。CRUSH ルール設定では、CRUSH の階層はプールに直接割り当てられます。

3. **配置グループの計算:** Ceph はプールを配置グループにシャード化します。プールに適した配置グループ数を設定し、同じ CRUSH ルールに複数のプールを割り当てるイベントで、正常な配置グループの最大数を留まる必要があります。

4. **プールの作成:** 最終的にプールを作成し、複製されたストレージまたはイレイジャーコーディングされたストレージを使用するかどうかを判別する必要があります。プールの配置グループの数、プールのルール、永続性 (サイズまたは **K+M** コーディングチャンク) を設定する必要があります。

プールはストレージクラスターに対する Ceph クライアントのインターフェースですが、ストレージストラテジーは Ceph クライアントに対しては完全に透過的です (容量とパフォーマンスを除く)。

第2章 CRUSH 管理

CRUSH (Controlled Replication Under Scalable Hashing) アルゴリズムは、コンピューティングデータストレージの場所によるデータの格納および取得方法を決定します。

	十分な高度な技術は、マジックなものと主導しているものと言えます。	
		-- Arthur C. Clarke

2.1. CRUSH の概要

ストレージクラスターの CRUSH マップは、CRUSH 階層内のデバイスの場所と、Ceph がデータをどのように保管するかを決定する各階層のルールを記述します。

CRUSH マップには、最低でもノードの階層が 1 つ含まれ、残されます。Ceph の「buckets」という階層のノードは、その種別で定義されるストレージの場所の集約です。たとえば、行、ラック、シャーシ、ホスト、およびデバイスなどがあります。階層の各リーフは、ストレージデバイスの一覧におけるストレージデバイスの 1 つを基本的に構成します。リーフは常に 1 つのノードまたは「bucket」に含まれます。 CRUSH マップには、CRUSH ストアとデータの取得方法を決定するルールの一覧もあります。

注記

OSD をクラスターに追加する際に、ストレージデバイスが CRUSH マップに追加されます。

CRUSH アルゴリズムは、デバイスごとの加重値に従ってストレージデバイス間でデータオブジェクトを分散します。これは、統一された確率分を分散します。CRUSH は、管理者が定義する階層のクラスターに応じて、オブジェクトとそのレプリカ、または消去したチャンクを分散します。CRUSH マップは、利用可能なストレージデバイスと、ルールにそれらを含む論理バケット、およびルールを使用する各プールで、それぞれを表します。

障害ドメインまたはパフォーマンスドメイン全体で OSD に配置グループをマップするために、CRUSH マップはバケットタイプの階層的な一覧を定義します。これは、生成された CRUSH マップの **types** の下にあります。バケット階層を作成する目的は、リーフノードを障害ドメインまたはパフォーマンスドメインか、またはその両方で分離することです。障害ドメインには、ホスト、シャーシ、ラック、電源分散ユニット、Pod、行、部屋、およびデータセンターが含まれます。パフォーマンスドメインには、特定の設定の障害ドメインおよび OSD が含まれます。たとえば、SSD ジャーナル、SATA ドライブなどを使用した SSD、SAS ドライブなどです。RHCS 3 では、デバイスは **hdd**、**ssd**、**nvme** などの **class** の概念を持ち、デバイスのクラスを使用して CRUSH 階層をより迅速にビルドします。

OSD を表すリーフノードを除き、階層の残りの部分は任意となり、デフォルトタイプが要求に適さない場合、独自のニーズに応じて定義することができます。CRUSH のマップのバケットタイプを組織のハードウェアの命名規則に適合し、物理ハードウェア名を反映するインスタンス名を使用することが推奨されます。命名プラクティスを使用すると、OSD または他のハードウェアの誤作動時に、クラスターの管理と問題のトラブルシューティングを容易にし、管理者がホストまたは他のハードウェアへのリモートアクセスまたは物理的なアクセスが必要な場合に役立ちます。

以下の例では、バケット階層には 4 つのリーフバケット (**osd 1-4**)、ノードバケット (**host 1-2**)、および 1 つのラックノード (**rack 1**) があります。

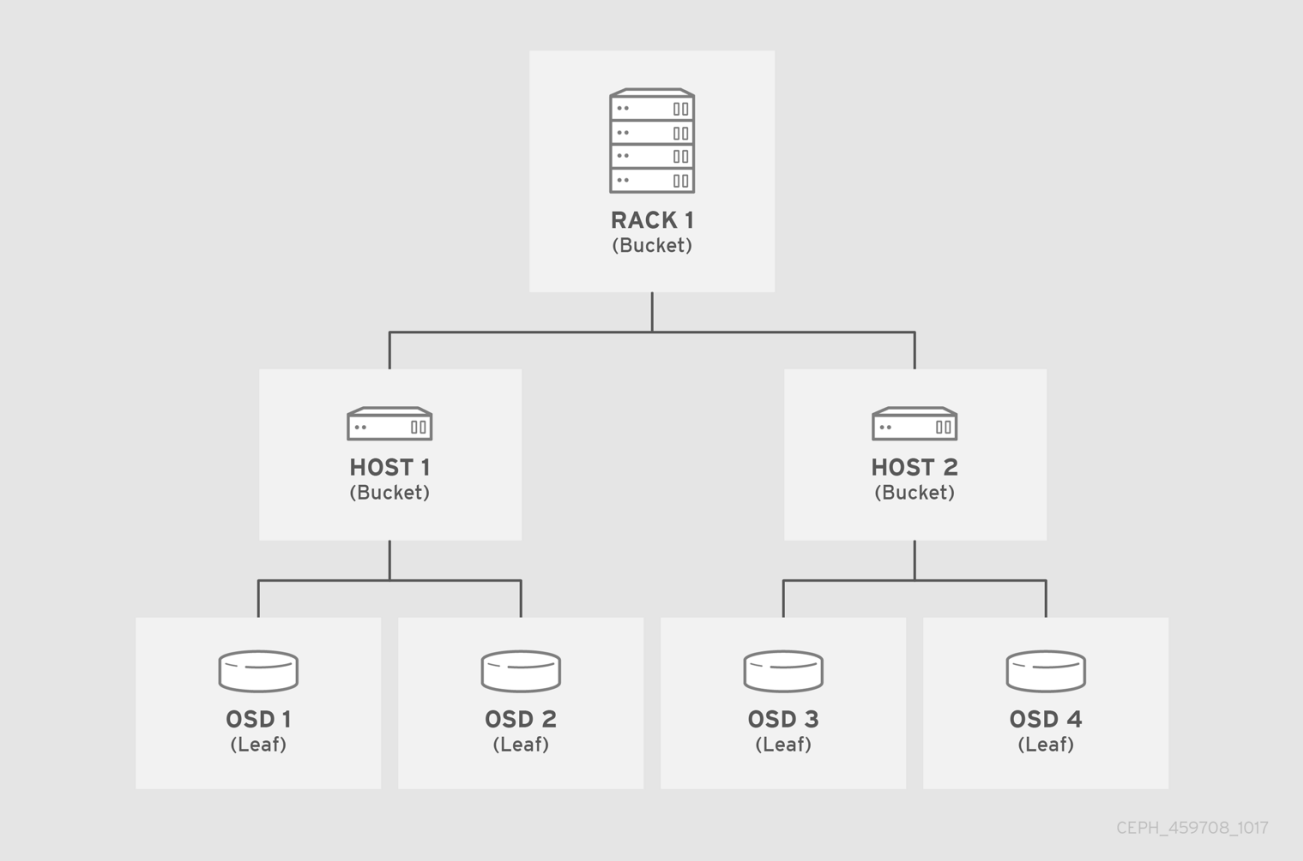

リーフノードは、CRUSH マップの開始時に **devices** 一覧に宣言されたストレージデバイスを反映するため、それらをバケットインスタンスとして宣言する必要はありません。階層内の 2 番目のバケットタイプは、通常デバイスを集約し、通常はストレージメディアが含まれるコンピューターで、管理者が好む "node"、"computer"、"server"、"host"、"machine"、"machine" などの用語を使用します。高密度の高い環境では、カードごとおよびシャーシごとに複数のホスト/ノードを確認することが一般的です。カードおよびシャーシの不具合も考慮に入れるようにしてください。たとえば、ノードに障害が発生した場合に、カードやシャーシを引き抜かなければならないようなことになると、非常に多くのホスト/ノードと OSD がダウンすることがあります。

バケットインスタンスを宣言する場合は、その型を指定し、一意の名前を文字列として指定し、負の整数として表現される任意の一意の ID を割り当て、アイテムの合計容量または機能に対する重みを指定し、**straw** などのバケットアルゴリズムを指定します。また、通常はハッシュアルゴリズム **rjenkins1** を反映した **0** となるハッシュを指定します。バケットには 1 つ以上の項目を指定できます。この項目は、ノードバケットで構成されるか、そのままになります。項目は、項目の相対的な重みを反映する重みを指定できます。

2.1.1. データの動的配置

Ceph クライアントおよび Ceph OSD はどちらも CRUSH マップと CRUSH アルゴリズムを使用します。

- **Ceph Clients:** CRUSH マップを Ceph クライアントに配布することにより、CRUSH は Ceph クライアントが OSD に直接通信できるようにします。つまり、Ceph クライアントは、単一障害点、パフォーマンスのボトルネック、集中ルックアップサーバーにおける接続制限、ストレージクラスターのスケーラビリティーへの物理的な制限などの集中オブジェクトルックアップテーブルを回避します。

- **Ceph OSD:** CRUSH マップを Ceph OSD に分散することにより、Ceph は OSD を変換してレプリケーション、バックフィル、およびリカバリーを処理します。つまり、Ceph OSD は Ceph クライアントの代わりにオブジェクトレプリカ (または共存するチャンク) のストレージを処理

することを意味します。また、Ceph OSD はクラスター (バックフィル) をクラスターを再分散し、障害から動的に回復するのに十分なクラスターについて把握できることを意味します。

2.1.2. 障害ドメインの確立

複数のオブジェクトレプリカまたは **M** イレイジャーコーディングチャンクを使用するとデータの損失を防ぐことができますが、高可用性に対応するには十分ではありません。Ceph Storage クラスターの基礎となる物理組織を反映することで、CRUSH は、関連するデバイスの障害についてのアドレス指定元的なソースをモデル化できます。クラスターのトポロジーをクラスターマップにエンコードすることで、CRUSH 配置ポリシーは別々の障害ドメインにわたって、オブジェクトレプリカまたはイレイジャーコーディングチャンクを別々に使用できます。また、必要な疑似ランダム分散も依然として維持できます。たとえば、同時障害の可能性に対応するには、異なるシェルフ、ラック、電源、コントローラーまたは物理的な場所を使用するデバイス上または消去するチャンクがデバイスにあることが望ましい場合があります。これは、データ損失を回避し、クラスターが動作が低下した状態で動作できるようにします。

2.1.3. パフォーマンスドメインの確立

CRUSH マップは複数の階層をサポートし、ハードウェアパフォーマンスプロファイルのタイプを別のタイプから分離できます。たとえば、CRUSH はハードディスクドライブと SSD に別の階層を 1 つ作成できます。パフォーマンスドメイン: ベースとなるハードウェアのパフォーマンスプロファイルを把握する階層は、さまざまなパフォーマンス特性をサポートする必要があるため、注目されています。運用上、それらは複数の **root** タイプバケットを持つ CRUSH マップです。ユースケースの例を以下に示します。

- **仮想マシン:** OpenStack、CloudStack、ProxMox、OpenNebula などのクラウドプラットフォームのバックエンドとして機能する Ceph ホストは、ジャーナリング用に高性能 SSD がパーティション化されている SAS ドライブ上の XFS など、最も安定したファイルシステムを使用する傾向があります。XFS はジャーナルと書き込みを同時に行わないためです。一貫したパフォーマンスプロファイルを維持するために、このようなユースケースでは、同じハードウェアを CRUSH 階層に集約する必要があります。

- **Object Storage:** S3 および Swift インターフェースのオブジェクトストレージバックエンドとして機能する Ceph ホストは、仮想マシンに適さない SATA ドライブなど、より安価なストレージメディアを利用する場合があります。また、オブジェクトストレージのギガバイトあたりのコストを軽減しつつ、クラウドプラットフォームでボリュームやイメージを保管するより高性能なストレージホストとより安価なストレージホストを分離することができます。HTTP はオブジェクトストレージシステムでボトルネックとなる傾向があります。

- **コールドストレージ:** コールドストレージ用に設計されたシステム (アクセス頻度が低いデータや、パフォーマンス要件が緩和されたデータの取得) では、より安価なストレージメディアやイレイジャーコーディングを利用できます。ただし、イレイジャーコーディングには、追加の RAM および CPU が必要になることがあり、そのため、オブジェクトストレージまたは仮想マシンに使用されるホストからの RAM および CPU 要件とは異なります。

- **SSD でバックアップされるプール:** SSD は高価ですが、ハードドライブよりも大きな利点があります。SSD にはシーク時間がなく、合計スループットが提供されます。ジャーナリングに SSD を使用することに加え、クラスターは、SSD のバックエンドプールをサポートできます。一般的なユースケースには、高パフォーマンス SSD プールが含まれます。たとえば、Ceph Object Gateway の **.rgw.buckets.index** プールを SATA ドライブではなく SSD にマッピングすることができます。

RHCS 3 以降のリリースでは、CRUSH マップはデバイス **class** の概念をサポートします。Ceph はストレージデバイスの要素を検出し、自動的に **hdd**、**ssd**、**nvme** などのクラスを割り当てることができます。ただし、CRUSH はこれらのデフォルトに限定されません。たとえば、CRUSH の階層を使用して、異なるタイプのワークロードを区切られることもできます。たとえば、SSD は、ジャーナルまたは

ログ先行書き込み、バケットインデックス、または raw オブジェクトストレージに使用される場合があります。CRUSH は **ssd-bucket-index**、**ssd-object-storage** などの異なるデバイスクラスをサポートできるため、Ceph は異なるワークロードに同じストレージメディアを使用しないようにします。これによりパフォーマンスは予測可能で一貫性が高くなります。

2.1.3.1. RHCS 2 以降での Different Device Classes の使用

RHCS 2 以前には、デバイスクラスの概念はありません。SSD や SATA ドライブなど、RHCS 2 以前で異なるストレージクラスを使用するには、SSD ドライブおよび SATA ドライブを参照するプールを作成します。これらのプールに送信されるデータは、SSD ドライブおよび SATA ドライブにそれぞれ個別のルート階層を作成して分離する必要があります。CRUSH マップは SSD に 1 つの階層と SATA ドライブに 1 つの階層を定義する必要があります。SSD ドライブと SATA ドライブは同じホストまたは別のホストに存在する場合があります。

2 つの CRUSH 階層が存在したら、SSD および SATA 階層に個別のルールを作成し、適切なルールセットを使用するように対応するプールを設定します。

注記

Red Hat は、RHCS 3.0 以降のリリースでの **ruleset** の概念はサポートしていません。CRUSH ルールセットの詳細は、RHCS 2 のドキュメントを参照してください。

これを行うには、CRUSH マップを変更します (変更するには CRUSH マップを逆コンパイルします。詳細は「CRUSH マップのでコンパイル」セクションを参照してください)。CRUSH アルゴリズムがオブジェクトを保存する 2 つの異なるルートポイントまたはエントリーポイントを作成します。SSD ディスクには 1 つのルートと SATA ディスク用のルートが 1 つあります。以下の例には、各ホストに 2 つの SATA ディスクと 2 つの SSD ディスク、および合計 3 つのホストがあります。これにより、CRUSH は 2 つの異なるプラットフォームがあると判断します。

CRUSH マップの例：

```
##
# OSD SATA DECLARATION
##
host ceph-osd2-sata {
  id -2   # do not change unnecessarily
  # weight 2.000
  alg straw
  hash 0  # rjenkins1
  item osd.0 weight 1.000
  item osd.3 weight 1.000
}
host ceph-osd1-sata {
  id -3   # do not change unnecessarily
  # weight 2.000
  alg straw
  hash 0  # rjenkins1
  item osd.2 weight 1.000
  item osd.5 weight 1.000
}
host ceph-osd0-sata {
  id -4   # do not change unnecessarily
  # weight 2.000
  alg straw
  hash 0  # rjenkins1
  item osd.1 weight 1.000
```

```
  item osd.4 weight 1.000
}

##
# OSD SSD DECLARATION
##

host ceph-osd2-ssd {
  id -22    # do not change unnecessarily
  # weight 2.000
  alg straw
  hash 0  # rjenkins1
  item osd.6 weight 1.000
  item osd.9 weight 1.000
}
host ceph-osd1-ssd {
  id -23    # do not change unnecessarily
  # weight 2.000
  alg straw
  hash 0  # rjenkins1
  item osd.8 weight 1.000
  item osd.11 weight 1.000
}
host ceph-osd0-ssd {
  id -24    # do not change unnecessarily
  # weight 2.000
  alg straw
  hash 0  # rjenkins1
  item osd.7 weight 1.000
  item osd.10 weight 1.000
}
```

1. OSD を含む 2 つのルートを作成します。

```
##
# SATA ROOT DECLARATION
##

root sata {
  id -1   # do not change unnecessarily
  # weight 6.000
  alg straw
  hash 0  # rjenkins1
  item ceph-osd2-sata weight 2.000
  item ceph-osd1-sata weight 2.000
  item ceph-osd0-sata weight 2.000
}

##
# SATA ROOT DECLARATION
##

root ssd {
  id -21    # do not change unnecessarily
  # weight 6.000
  alg straw
```

```
  hash 0  # rjenkins1
  item ceph-osd2-ssd weight 2.000
  item ceph-osd1-ssd weight 2.000
  item ceph-osd0-ssd weight 2.000
}
```

2. SSD 用に新しいルールを 2 つ作成します。

```
##
# SSD RULE DECLARATION
##

# rules
rule ssd {
 ruleset 0
 type replicated
 min_size 1
 max_size 10
 step take ssd
 step chooseleaf firstn 0 type host
 step emit
}

##
# SATA RULE DECLARATION
##

rule sata {
 ruleset 1
 type replicated
 min_size 1
 max_size 10
 step take sata
 step chooseleaf firstn 0 type host
 step emit
}
```

3. 新しいマップをコンパイルし、注入します。

```
$ crushtool -c lamap.txt -o lamap.coloc
$ sudo ceph osd setcrushmap -i lamap.coloc
```

4. 結果を確認します。

```
$ sudo ceph osd tree
# id  weight  type name up/down reweight
-21 12  root ssd
-22 2       host ceph-osd2-ssd
6 1           osd.6 up  1
9 1           osd.9 up  1
-23 2       host ceph-osd1-ssd
8 1           osd.8 up  1
11  1          osd.11  up  1
-24 2       host ceph-osd0-ssd
7 1           osd.7 up  1
```

```
10  1          osd.10  up  1
-1  12  root sata
-2  2       host ceph-osd2-sata
0 1            osd.0 up  1
3 1            osd.3 up  1
-3  2       host ceph-osd1-sata
2 1            osd.2 up  1
5 1            osd.5 up  1
-4  2       host ceph-osd0-sata
1 1            osd.1 up  1
4 1            osd.4 up  1
```

プールで動作するようになりました。

1. プールを作成します。
   プールの **ssd**:

   ```
   root@ceph-mon0:~# ceph osd pool create ssd 128 128
   ```

   プールの **sata**:

   ```
   root@ceph-mon0:~# ceph osd pool create sata 128 128
   ```

2. ルールをプールに割り当てます。
   プール 8 crush_ruleset を 0 に設定します。

   ```
   root@ceph-mon0:~# ceph osd pool set ssd crush_ruleset 0
   ```

   プール 9 crush_ruleset を 1 に設定します。

   ```
   root@ceph-mon0:~# ceph osd pool set sata crush_ruleset 1
   ```

3. **ceph osd dump** の結果:

   ```
   pool 8 'ssd' replicated size 2 min_size 1 crush_ruleset 0 object_hash rjenkins
   pg_num 128 pgp_num 128 last_change 116 flags hashpspool stripe_width 0
   pool 9 'sata' replicated size 2 min_size 1 crush_ruleset 1 object_hash rjenkins
   pg_num 128 pgp_num 128 last_change 117 flags hashpspool stripe_width 0
   ```

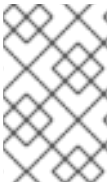

注記

サービスの再起動時に OSD がデフォルトの CRUSH の場所に戻されないようにするには、**osd crush update on start = false** を使用して、デーモンの開始時に CRUSH マップの更新を無効にします。

2.1.3.2. RHCS 3 以降での Different Device Classes の使用

RHCS 3 でパフォーマンスドメインを作成するには、デバイスクラスと単一の CRUSH 階層を使用します。CLI を使用して RHCS 2 と同様に、OSD を CRUSH 階層に追加するだけです。次に、以下を実行します。

1. 各デバイスにクラスを追加します。以下に例を示します。

```
# ceph osd crush set-device-class <class> <osdId> [<osdId>]
# ceph osd crush set-device-class hdd osd.0 osd.1 osd.4 osd.5
# ceph osd crush set-device-class ssd osd.2 osd.3 osd.6 osd.7
```

2. 次に、デバイスを使用するルールを作成します。

```
# ceph osd crush rule create-replicated <rule-name> <root> <failure-domain-type> <class>
# ceph osd crush rule create-replicated cold default host hdd
# ceph osd crush rule create-replicated hot default host ssd
```

3. 最後に、ルールを使用するようにプールを設定します。

```
ceph osd pool set <poolname> crush_rule <rule-name>
ceph osd pool set cold_tier crush_rule cold
ceph osd pool set hot_tier crush_rule hot
```

RHCS 3 以降では、CRUSH マップを手動で編集する必要はありません。

2.2. CRUSH 階層

CRUSH マップは転送されたグラフであるため、複数の階層に対応することができます (例: パフォーマンスドメイン)。CRUSH 階層を作成し、変更する方法は Ceph CLI で行いますが、CRUSH マップのコンパイル、編集、再コンパイル、およびアクティブ化することもできます。

Ceph CLI でバケットインスタンスを宣言する場合には、そのタイプを指定して一意の名前 (文字列) を指定する必要があります。Ceph はバケット ID を自動的に割り当て、アルゴリズムを **straw** に設定し**rjenkins1** を反映してハッシュを **0** に設定し、重みを設定します。コンパイルされていない CRUSH マップを変更する場合は、バケットに負の整数 (任意) として表現される一意の ID を割り当て、アイテムの合計容量/機能に対する重みを指定し、バケットアルゴリズム (通常は **straw**)、およびハッシュ (通常はハッシュアルゴリズム **rjenkins1** を反映させ **0**)。

バケットには 1 つ以上の項目を指定できます。項目は、ノードバケット (ラック、行、ホストなど)、またはリーフ (OSD ディスクなど) で構成されます。項目は、項目の相対的な重みを反映する重みを指定できます。

コンパイルした CRUSH マップを変更する場合、以下の構文でノードバケットを宣言できます。

```
[bucket-type] [bucket-name] {
    id [a unique negative numeric ID]
    weight [the relative capacity/capability of the item(s)]
    alg [the bucket type: uniform | list | tree | straw ]
    hash [the hash type: 0 by default]
    item [item-name] weight [weight]
}
```

たとえば、上図を使用すると、ホストバケットと 1 つのラックバケットを 2 つ定義します。OSD は、ホストバケット内の項目として宣言されます。

```
host node1 {
    id -1
    alg straw
    hash 0
    item osd.0 weight 1.00
    item osd.1 weight 1.00
```

```
}

host node2 {
    id -2
    alg straw
    hash 0
    item osd.2 weight 1.00
    item osd.3 weight 1.00
}

rack rack1 {
    id -3
    alg straw
    hash 0
    item node1 weight 2.00
    item node2 weight 2.00
}
```

注記

前の例では、ラックバケットに OSD が含まれていないことに注意してください。低レベルホストバケットが含まれ、項目エントリーでの重みの合計が含まれます。

2.2.1. CRUSH の場所

CRUSH の場所は、CRUSH マップの階層に関して OSD の場所です。コマンドラインインターフェースで CRUSH の場所を表すと、CRUSH の場所指定子は、OSD の場所を説明する名前/値のペアの一覧を取得します。たとえば、OSD が特定の行、ラック、シャーシ、およびホストにあり、**default** の CRUSH ツリーの一部である場合、そのクラッシュの場所は以下のように記述できます。

```
root=default row=a rack=a2 chassis=a2a host=a2a1
```

注記:

1. キーの順序は問題にはなりません。
2. キー名 (**=** の左) は有効な CRUSH **type** である必要があります。デフォルトでは、これには、**root**、**datacenter**、**room**、**row**、**pod**、**pdu**、**rack**、**chassis**、および **host** が含まれます。CRUSH マップを編集して、ニーズに合わせてタイプを変更できます。
3. すべての buckets/keys を指定する必要はありません。たとえば、デフォルトでは Ceph は **ceph-osd** デーモンの場所を **root=default host={HOSTNAME}** に自動的に設定します (**hostname -s** からの出力に基づいています)。

2.2.1.1. デフォルトの ceph-crush-location フック

起動時に、Ceph は、デフォルトで **ceph-crush-location** ツールを使用して各デーモンの CRUSH の場所を取得します。**ceph-crush-location** ユーティリティーは、指定のデーモンの CRUSH の場所を返します。その CLI の使用は以下で構成されます。

```
ceph-crush-location --cluster {cluster-name} --id {ID} --type {daemon-type}
```

たとえば、以下のコマンドは **OSD.0** の場所を返します。

```
ceph-crush-location --cluster ceph --id 0 --type osd
```

デフォルトでは、**ceph-crush-location** ユーティリティーは、指定のデーモンの CRUSH の場所文字列を返します。優先順位順に返される場所は以下に基づきます。

1. Ceph 設定ファイルの **{TYPE}_crush_location** オプションたとえば、OSD デーモンの場合、**{TYPE}** は **osd** のようになり、設定は **osd_crush_location** となります。
2. Ceph 設定ファイル内の特定のデーモン用の **crush_location** オプション。
3. **root=default host=HOSTNAME** のデフォルト。ホスト名が **hostname -s** コマンドで返されます。

典型的なデプロイメントシナリオでは、プロビジョニングソフトウェア (またはシステム管理者) は単にホストの Ceph 設定ファイルの **crush_location** フィールドを設定して、データセンターまたはクラスター内でのマシンの場所を記述できます。これにより、Ceph デーモンおよびクライアントに対して以下のような場所を認識できます。

2.2.1.2. カスタムロケーションフック

カスタムの場所フックは、階層内の OSD デーモン配置の汎用フックの代わりに使用できます。（起動時に、各 OSD の位置が正しいことを確認します）。

```
osd_crush_location_hook = /path/to/script
```

このフックは複数の引数が渡され (以下)、CRUSH の場所の説明で単一行を **stdout** (標準出力) に出力する必要があります。

```
ceph-crush-location --cluster {cluster-name} --id {ID} --type {daemon-type}
```

--cluster 名前は通常「ceph」で、**--id** はデーモン識別子 (OSD 番号) に、デーモン **--type** は通常 **osd** です。

2.2.2. バケットの追加

CRUSH 階層にバケットインスタンスを追加するには、バケット名とそのタイプを指定します。バケット名は CRUSH マップで一意である必要があります。

```
ceph osd crush add-bucket {name} {type}
```

たとえば、異なるハードウェアパフォーマンスプロファイルなど、複数の階層を使用する場合 (ハードウェアパフォーマンスプロファイルなど)、ハードウェアのタイプまたはユースケースに基づいてバケットの命名を検討してください。

たとえば、ソリッドステートドライブ (**ssd**) の階層、SSD ジャーナルのある SAS ディスクの階層 (**hdd-journal**)、および SATA ドライブ (**hdd**) に別の階層を作成できます。

```
ceph osd crush add-bucket ssd-root root
ceph osd crush add-bucket hdd-journal-root root
ceph osd crush add-bucket hdd-root root
```

Ceph CLI を出力します。

```
added bucket ssd-root type root to crush map
added bucket hdd-journal-root type root to crush map
added bucket hdd-root type root to crush map
```

重要

バケット名におけるコロン(:)の使用はサポートされません。

階層に必要な各バケットタイプのインスタンスを追加します。以下の例は、SSD ホストのラックがある行のバケットと、オブジェクトストレージのホストのラックの追加を示しています。

```
ceph osd crush add-bucket ssd-row1 row
ceph osd crush add-bucket ssd-row1-rack1 rack
ceph osd crush add-bucket ssd-row1-rack1-host1 host
ceph osd crush add-bucket ssd-row1-rack1-host2 host
ceph osd crush add-bucket hdd-row1 row
ceph osd crush add-bucket hdd-row1-rack2 rack
ceph osd crush add-bucket hdd-row1-rack1-host1 host
ceph osd crush add-bucket hdd-row1-rack1-host2 host
ceph osd crush add-bucket hdd-row1-rack1-host3 host
ceph osd crush add-bucket hdd-row1-rack1-host4 host
```

注記

Ansible 自動化アプリケーションまたは別のツールを使用して OSD をクラスターに追加する場合、ホストノードは CRUSH マップにすでにある可能性があります。

これらの手順を完了したら、ツリーを表示します。

```
ceph osd tree
```

階層はフラットのままである点に注意してください。CRUSH マップに追加した後に、バケットを階層の位置に移動する必要があります。

2.2.3. バケットの移動

初期クラスターの作成時に、Ceph には **default** という名前のルートバケットのあるの CRUSH マップがあり、初期 OSD ホストは **default** のバケットに表示されます。CRUSH マップにバケットインスタンスを追加する場合、これは CRUSH 階層に表示されますが、必ずしも特定のバケットに表示されるわけではありません。

CRUSH 階層の特定の場所にバケットインスタンスを移動するには、バケット名とそのタイプを指定します。以下に例を示します。

```
ceph osd crush move ssd-row1 root=ssd-root
ceph osd crush move ssd-row1-rack1 row=ssd-row1
ceph osd crush move ssd-row1-rack1-host1 rack=ssd-row1-rack1
ceph osd crush move ssd-row1-rack1-host2 rack=ssd-row1-rack1
```

これらの手順を完了したら、ツリーを表示できます。

```
ceph osd tree
```

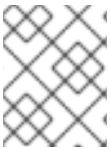

注記

ceph osd crush create-or-move を使用して、OSD の移動中に場所を作成することもできます。

2.2.4. バケットの削除

CRUSH 階層からバケットインスタンスを削除するには、バケット名を指定します。以下に例を示します。

```
ceph osd crush remove {bucket-name}
```

または、以下を実行します。

```
ceph osd crush rm {bucket-name}
```

注記

これを削除するには、バケットを空にする必要があります。

高レベルのバケット (例: **default**などのルート) を削除する場合は、プールがそのバケットを選択する CRUSH ルールを使用するかどうかを確認します。その場合は、CRUSH ルールを変更する必要があります。指定しない場合は、ピアリングに失敗します。

2.2.5. バケットアルゴリズム

Ceph CLI を使用してバケットを作成する場合、Ceph はデフォルトでアルゴリズムを **straw** に設定します。Ceph は 4 つのバケットアルゴリズムをサポートします。各アルゴリズムは、パフォーマンスと組織の効率間のトレードオフを示しています。使用するバケットタイプが不明な場合は、**straw** バケットを使用することが推奨されます。バケットアルゴリズムは次のとおりです。

1. **Uniform:** Uniform バケットは、**完全に** 同一の重みを持つデバイスを集約します。たとえば、ハードウェアが送信または廃止されたハードウェアの場合、通常は、同じ物理構成 (一括購入など) を持つ多数のマシンを使用します。ストレージデバイスの重みが完全に一致する場合は、**uniform** されたバケットタイプを使用できます。これにより、CRUSH が一定の時間内にレプリカを統一されたバケットにマップできます。一方向以外の重みでは、別のバケットアルゴリズムを使用する必要があります。

2. **List**: List バケットは、コンテンツをリンクリストとして集約します。RUSH (スケーラブルハッシュでのレプリケーション) $_P$アルゴリズムに基づいて、リストは**拡張クラスター**の自然で直感的な選択です。オブジェクトは適切な確率で最新のデバイスに再配置されるか、以前のように古いデバイスに残ります。アイテムがバケットに追加されると、結果は最適なデータ移行になります。ただし、一覧の途中または末尾から削除された項目は、大量の不要な移動が大量に実行され、リストバケットが **縮小されない (またはほとんどない)** 状況に最適です。

3. **Tree**: Tree バケットはバイナリー検索ツリーを使用します。バケットのより大きな項目のセットが含まれる場合、バケットを一覧表示する方が効率的です。RUSH (スケーラブルハッシュでのレプリケーション) $_R$アルゴリズムに基づいて、ツリーバケットは配置時間を O(log $_n$) に短縮し、はるかに大きなデバイスのセットまたはネストされたバケットの管理に適したものにします。

4. **Straw (デフォルト):** List および Tree バケットは、特定の項目に優先順位を指定するか (たとえば、リストの最初の項目を優先するなど)、または項目のサブツリー全体を考慮する必要をなく

す方法で分割統治ストラテジーを使用します。レプリカ配置プロセスのパフォーマンスを向上しますが、項目の追加、削除、または再度の重み計算によりバケットの内容が変更される場合に、準最適な再調整的な動作が発生することもあります。straw バケットタイプにより、わらのくじを引くような仕方で、すべての項目はレプリカの配置について相互に対してほぼ「完了」した状態になります。

2.3. CRUSH の CEPH OSD

OSD の CRUSH 階層を作成したら、OSD を CRUSH 階層に追加します。既存の階層から OSD を移動または削除することもできます。Ceph CLI の使用には、以下の値が使用できます。

id

説明

OSD の数値 ID。

タイプ

整数

必須

Yes

例

0

name

説明

OSD のフルネーム。

タイプ

文字列

必須

Yes

例

osd.0

weight

説明

OSD の CRUSH 加重。

タイプ

double

必須

Yes

例

2.0

root

説明

OSD が存在する階層またはツリーのルートバケットの名前。

タイプ

キーと値のペア。

必須

Yes

例

root=default、root=replicated_rule など

bucket-type

説明

1 つ以上の name-value ペア。ここで、名前はバケットタイプで、値はバケットの名前になります。CRUSH 階層で OSD の CRUSH の場所を指定できます。

タイプ

キーと値のペア。

必須

No

例

datacenter=dc1 room=room1 row=foo rack=bar host=foo-bar-1

2.3.1. CRUSH での OSD の表示

ceph osd crush tree コマンドは、CRUSH バケットと項目をツリービューで出力します。このコマンドを使用して、特定のバケット内の OSD の一覧を確認します。**ceph osd tree** のような出力が表示されます。

詳細情報を返すには、以下のコマンドを実行します。

```
# ceph osd crush tree -f json-pretty
```

このコマンドは、以下のような出力を返します。

```
[
   {
      "id": -2,
      "name": "ssd",
      "type": "root",
      "type_id": 10,
      "items": [
         {
            "id": -6,
            "name": "dell-per630-11-ssd",
            "type": "host",
            "type_id": 1,
            "items": [
               {
                  "id": 6,
                  "name": "osd.6",
                  "type": "osd",
                  "type_id": 0,
                  "crush_weight": 0.099991,
                  "depth": 2
               }
```

```
            ]
        },
        {
            "id": -7,
            "name": "dell-per630-12-ssd",
            "type": "host",
            "type_id": 1,
            "items": [
                {
                    "id": 7,
                    "name": "osd.7",
                    "type": "osd",
                    "type_id": 0,
                    "crush_weight": 0.099991,
                    "depth": 2
                }
            ]
        },
        {
            "id": -8,
            "name": "dell-per630-13-ssd",
            "type": "host",
            "type_id": 1,
            "items": [
                {
                    "id": 8,
                    "name": "osd.8",
                    "type": "osd",
                    "type_id": 0,
                    "crush_weight": 0.099991,
                    "depth": 2
                }
            ]
        }
    ]
},
{
    "id": -1,
    "name": "default",
    "type": "root",
    "type_id": 10,
    "items": [
        {
            "id": -3,
            "name": "dell-per630-11",
            "type": "host",
            "type_id": 1,
            "items": [
                {
                    "id": 0,
                    "name": "osd.0",
                    "type": "osd",
                    "type_id": 0,
                    "crush_weight": 0.449997,
                    "depth": 2
                },
```

```
            {
                "id": 3,
                "name": "osd.3",
                "type": "osd",
                "type_id": 0,
                "crush_weight": 0.289993,
                "depth": 2
            }
        ]
    },
    {
        "id": -4,
        "name": "dell-per630-12",
        "type": "host",
        "type_id": 1,
        "items": [
            {
                "id": 1,
                "name": "osd.1",
                "type": "osd",
                "type_id": 0,
                "crush_weight": 0.449997,
                "depth": 2
            },
            {
                "id": 4,
                "name": "osd.4",
                "type": "osd",
                "type_id": 0,
                "crush_weight": 0.289993,
                "depth": 2
            }
        ]
    },
    {
        "id": -5,
        "name": "dell-per630-13",
        "type": "host",
        "type_id": 1,
        "items": [
            {
                "id": 2,
                "name": "osd.2",
                "type": "osd",
                "type_id": 0,
                "crush_weight": 0.449997,
                "depth": 2
            },
            {
                "id": 5,
                "name": "osd.5",
                "type": "osd",
                "type_id": 0,
                "crush_weight": 0.289993,
                "depth": 2
            }
```

```
            ]
        }
    ]
  }
]
```

注記

RHCS 3 以降では、OSD オブジェクトには **device_class** 属性も含まれます。

2.3.2. OSD の CRUSH への追加

OSD を CRUSH 階層に追加することは、OSD を起動する前の最後のステップ (**up** および **in** を編集する) であり、Ceph は配置グループを OSD に割り当てます。

注記

RHCS 3 では、デバイスクラスも追加できます。

OSD を準備してから、CRUSH 階層を追加する必要があります。Ansible 自動化アプリケーションなどのデプロイメントユーティリティーで、このステップを実行します。詳細は、「OSD の追加/削除」を参照してください。

CRUSH 階層は概念であるため、**ceph osd crush add** コマンドを使用すると、希望する場所の CRUSH 階層に OSD を追加できます。指定する場所は、実際の場所を反映している **はず** です。少なくとも 1 つのバケットを指定すると、コマンドにより OSD を指定する最も具体的なバケットに配置され、**かつ** そのバケットは指定した他のバケットの下に移動します。

OSD を CRUSH 階層に追加するには、以下を実行します。

```
ceph osd crush add {id-or-name} {weight}  [{bucket-type}={bucket-name} ...]
```

重要

root バケットのみを指定した場合、このコマンドは OSD を直接ルートに割り当てます。ただし、CRUSH ルールは OSD がホストまたはシャーシの内部にあり、ホストまたはシャーシはクラスタートポロジーを反映する他のバケットの内部にある **必要** があります。

以下の例では、**osd.0** を階層に追加します。

```
ceph osd crush add osd.0 1.0 root=default datacenter=dc1 room=room1 row=foo rack=bar host=foo-bar-1
```

注記

ceph osd crush set または **ceph osd crush create-or-move** を使用して、OSD を CRUSH 階層に追加することもできます。

2.3.3. CRUSH 階層内での OSD の移動

Ansible 自動化アプリケーションなど、デプロイメントユーティリティーで OSD が準最適な CRUSH ロケーションで CRUSH マップに追加された場合や、クラスタートポロジーが変更された場合は、CRUSH 階層内の OSD を移動して実際の場所を反映させることができます。

重要

CRUSH 階層で OSD を移動すると、Ceph は OSD に割り当てられる配置グループを再計算することを意味します。これにより、データが大幅に再分配される可能性があります。

CRUSH 階層内の OSD を移動するには、以下を実行します。

```
ceph osd crush set {id-or-name} {weight} root={pool-name}  [{bucket-type}={bucket-name} ...]
```

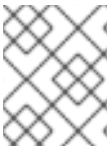

注記

ceph osd crush create-or-move を使用して、CRUSH 階層内で OSD を移動することもできます。

2.3.4. CRUSH 階層からの OSD の削除

CRUSH 階層からの OSD 削除は、クラスターから OSD を削除する場合の最初の手順となります。CRUSH マップから OSD を削除すると、CRUSH は配置グループおよびデータリバランスを取得する OSD が再計算されます。詳細は、「OSD の追加/削除」を参照してください。

実行中のクラスターの CRUSH マップから OSD を削除するには、以下を実行します。

```
ceph osd crush remove {name}
```

2.4. デバイスクラス

Ceph の CRUSH マップは、データの配置を制御するのに余分な柔軟性を提供します。これは、Ceph の最も大きなメリットの 1 つです。初期の Ceph のデプロイメントでは、ハードディスクドライブをほぼ排他的に使用していました。現在、Ceph クラスターは複数のタイプのストレージデバイスで頻繁にビルドされます (HDD、SSD、NVMe、またはさまざまなクラス)。たとえば、クライアントが低速な HDD 上にデータを格納するためのストレージポリシーや、高速 SSD にデータを保存するその他のストレージポリシーを持つように、Ceph Object Gateway デプロイメントにおいて一般的に使用されます。Ceph Object Gateway デプロイメントでは、バケットインデックスの高速 SSD によるプールをサポートする可能性があります。また、OSD ノードにも、CRUSH マップには表示されないジャーナルまたは書き込みログに SSD のみが使用されます。これらの複雑なハードウェアシナリオでは、CRUSH マップを手動で編集する必要がありました。これには、多くの時間と労力が必要となることがありました。RHCS 3 では、Red Hat は新しい「デバイスクラス」を追加しました。これにより、CRUSH 階層の作成が大幅に簡素化されています。その場合、RHCS 3 以上では、異なるストレージデバイスの異なる CRUSH 階層を持つ必要はありません。

CRUSH ルールは、CRUSH 階層の用語で機能します。ただし、同じホスト内に異なるストレージデバイスのクラスが存在する場合、このプロセスはより複雑になり、デバイスの各クラスに複数の CRUSH 階層を作成し、CRUSH 階層管理の多くを自動化する **osd crush update on start** オプションを無効にします。デバイスクラスは、使用するデバイスのクラスに対して CRUSH ルールに指示することで、この適合性を排除します。これにより、CRUSH 管理タスクを単純化します。

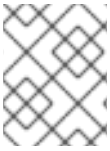

注記

RHCS 3 以降では、**ceph osd tree** コマンドに、デバイスクラスを反映した列があります。

以下のセクションでは、デバイスクラスの使用について詳しく説明します。その他の例については、「RHCS 3 以降におけるさまざまなデバイスクラスの使用」および「CRUSH ストレージ戦略の例」を参照してください。

2.4.1. デバイスクラスの設定

OSD にデバイスクラスを設定するには、次のコマンドを実行します。

```
# ceph osd crush set-device-class <class> <osdId> [<osdId>...]
```

以下に例を示します。

```
# ceph osd crush set-device-class hdd osd.0 osd.1
# ceph osd crush set-device-class ssd osd.2 osd.3
# ceph osd crush set-device-class bucket-index osd.4
```

注記

Ceph はクラスをデバイスに自動的に割り当てる場合があります。ただし、クラス名は単に任意の文字列です。**hdd**、**ssd**、**nvme** に準拠する必要はありません。前述の例では、**bucket-index** という名前のデバイスクラスが、Ceph Object Gatway プールが排他的バケットインデックスワークロードを使用する SSD デバイスを示す場合があります。すでに設定されているデバイスクラスを変更するには、最初に **ceph osd crush rm-device-class** を使用します。

2.4.2. デバイスクラスの削除

OSD のデバイスクラスを削除するには、以下を実行します。

```
# ceph osd crush rm-device-class <class> <osdId> [<osdId>...]
```

以下に例を示します。

```
# ceph osd crush rm-device-class hdd osd.0 osd.1
# ceph osd crush rm-device-class ssd osd.2 osd.3
# ceph osd crush rm-device-class bucket-index osd.4
```

2.4.3. デバイスクラスの名前変更

そのクラスを使用するすべての OSD のデバイスクラスの名前を変更するには、以下のコマンドを実行します。

```
# ceph osd crush class rename <oldName> <newName>
```

以下に例を示します。

```
# ceph osd crush class rename hdd sas15k
```

2.4.4. デバイスクラスの一覧表示

CRUSH マップのデバイスクラスを一覧表示するには、以下を実行します。

```
# ceph osd crush class ls
```

出力は以下のようになります。

```
[
    "hdd",
    "ssd",
    "bucket-index"
]
```

2.4.5. デバイスクラスの OSD の一覧表示

特定のクラスに属するすべての OSD を一覧表示するには、以下のコマンドを実行します。

```
# ceph osd crush class ls-osd <class>
```

以下に例を示します。

```
# ceph osd crush class ls-osd hdd
```

出力は、OSD 番号のリストです。以下に例を示します。

```
0
1
2
3
4
5
6
```

2.4.6. クラス別の CRUSH ルールの一覧表示

同じクラスを参照する crush ルールを一覧表示するには、以下のコマンドを実行します。

```
# ceph osd crush rule ls-by-class <class>
```

以下に例を示します。

```
# ceph osd crush rule ls-by-class hdd
```

2.5. CRUSH WEIGHTS

CRUSH アルゴリズムは、新しいデータオブジェクトを PG に、PG を OSD に割り当てる書き込み要求のための一貫した確率分散で、OSD ごとにテラバイトで重み値を割り当てます (規則により)。このため、ベストプラクティスとして、同じタイプおよびサイズのデバイスとともに CRUSH の階層を作成

し、同じ重みを割り当てることが推奨されます。また、パフォーマンス特性がデータの分散に影響を及ぼさなくても、CRUSH 階層にパフォーマンス特性が統一されるように、同じ I/O およびスループット特性でデバイスを使用することが推奨されます。

統一されたハードウェアを使用することは常に実用的な設定ではないため、異なるサイズの OSD デバイスを取り入れ、Ceph が大規模なデバイスにより多くのデータを配信し、小さいデバイスにさらに多くのデータが配信するようにできます。

2.5.1. テラバイトでの OSD の重みの設定

CRUSH マップ内の Terabytes で OSD CRUSH 重みを設定するには、以下のコマンドを実行します。

```
ceph osd crush reweight {name} {weight}
```

詳細は以下のようになります。

name

説明

OSD のフルネーム。

タイプ

文字列

必須

Yes

例

osd.0

weight

説明

OSD の CRUSH 加重。これはテラバイト単位で OSD のサイズになります。**1.0** は 1 テラバイトです。

型

double

必須

Yes

例

2.0

この設定は、OSD を作成するか、OSD の追加直後に CRUSH 重みを調整する際に使用されます。通常、OSD のライフサイクルは変更されません。

2.5.2. バケットの OSD 重みの設定

ceph osd crush reweight を使用すると、時間がかかる可能性があります。以下を実行して、すべての Ceph OSD 加重をバケット (行、ラック、ノードなど) の下で設定できます。

```
osd crush reweight-subtree <name>
```

詳細は以下のようになります。

name は CRUSH バケットの名前です。

2.5.3. OSD の in 重みの設定

ceph osd in および **ceph osd out** の目的上、OSD はクラスター内 (**in**) か、またはクラスター外 (**out**) のいずれかにあります。これは、モニターする OSD のステータスを記録します。ただし、OSD はクラスター内 (**in**) となりますが、修正されるまでは依存したくない機能 (ストレージドライブの置き換え、コントローラーの変更など) 生する可能性があります。

以下を実行して (つまり、テラバイト単位でその重みを変更せずに)、以下のコマンドを実行して、特定の OSD の **in** 重みを増減できます。

```
ceph osd reweight {id} {weight}
```

詳細は以下のようになります。

- **id** は OSD の番号です。
- **weight** は 0.0 ~ 1.0 の範囲です。 **0** はクラスター内 (**in**) には含まれません (つまり、PG がクラスターに割り当てられていません)。1.0 はクラスター内 (**in**) です (つまり、OSD は他の OSD と同じ数の PG を受信します)。

2.5.4. 使用状況による OSD の重みの設定

CRUSH は、新しいデータオブジェクトの PG と PG を OSD に割り当てる書き込み要求のための一貫した確率分散を概観するために設計されています。ただし、クラスターは任意に負荷分散される可能性があります。これは、さまざまな理由で発生する可能性があります。以下に例を示します。

- **複数のプール:** CRUSH 階層に複数のプールを割り当てることができますが、プールには異なる配置グループの数、サイズ (保存するレプリカ数)、およびオブジェクトサイズの特性を持たせることができます。
- **カスタムクライアント:** クライアントからのブロックデバイス、オブジェクトゲートウェイ、ファイルシステムシャードデータなどの Ceph クライアント。統一されたサイズの小さい RADOS オブジェクトとして、データをクラスター全体でオブジェクトとしてストライプ化します。したがって、フォレッシングシナリオを除き、CRUSH は通常、その目的を達成します。ただし、クラスターに不安定な状態が生じるもう 1 つのケースがあります。つまり、**librados** を使用してオブジェクトのサイズを正規化せずにデータを保存することです。このシナリオでは、クラスターがアンバランスになります (例: 100 1MB と 10 4MB のオブジェクトを格納すると、他よりも多くのデータを持つ OSD が少なくなります)。
- **可能性:** 統一されたディストリビューションでは、PG が多い OSD と少ない OSD が発生します。OSD が多数あるクラスターの場合、統計外メモリーはさらに省略されます。

以下を実行することで、使用率に従って OSD を再度有効にできます。

```
ceph osd reweight-by-utilization [threshold]  [weight_change_amount] [number_of_OSDs] [--no-increasing]
```

以下に例を示します。

```
ceph osd test-reweight-by-utilization 110 .5 4 --no-increasing
```

詳細は以下のようになります。

- **threshold** は、OSD がデータストレージ負荷を高くする使用率が低くなり、割り当てられた PG の数が減ります。デフォルト値は **120** で、120 % を反映しています。 **100** 以降の値はすべて有効なしきい値です。任意です。

- **weight_change_amount** は重みを変更する量です。有効な値は **0.0 - 1.0** より大きいです。デフォルト値は **0.05** です。任意です。

- **number_of_OSDs** は、リライトする OSD の最大数です。大規模なクラスターの場合、OSD の数を reweight に制限すると、影響の大きいリバランスが妨げられます。任意です。

- **no-increasing** は、デフォルトで **off** になっています。**reweight-by-utilization** コマンドまたは **test-reweight-by-utilization** コマンドを使用すると、osd 重みを増やすことができます。このオプションを使用すると、OSD の使用率が低くなっている場合でも、OSD の重みが増加しないようにします。任意です。

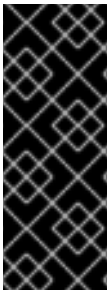

重要

大規模なクラスターに **reweight-by-utilization** を実行することが推奨されます。使用率レートは時間の経過と共に変化する場合があります。また、クラスターのサイズやハードウェアの変化により、使用率の変更を反映するために重み付けを更新しなければならない場合があります。使用率の再行を選択した場合には、使用率、ハードウェア、またはクラスターのサイズの変更としてこのコマンドを再実行する必要がある場合があります。

重みを割り当てる上記またはその他の重みのコマンドを実行すると、このコマンドによって割り当てられる重みが上書きされます (例: **osd reweight-by-utilization**、**osd crush weight**、**osd weight**、**in**、または **out**)。

2.5.5. PG Distribution による OSD の重みの設定

少数の OSD を持つ CRUSH 階層では、一部の OSD が他の OSD よりも長い PG を取得できるため、負荷が高くなることがあります。以下のコマンドを実行して、この状況に対処するために PG ディストリビューションで OSD を再非推奨にすることができます。

```
osd reweight-by-pg <poolname>
```

詳細は以下のようになります。

- **poolname** はプールの名前です。Ceph は、プールの PG を OSD に割り当ててから、このプールの PG ディストリビューションに従って OSD をどのように割り当てるかを検証します。複数のプールを同じ CRUSH 階層に割り当てることができることに注意してください。1 つのプールのディストリビューションに従って OSD を再実行すると、同じ CRUSH 階層に割り当てられた他のプールには、同じサイズ (レプリカの数) と PG が割り当てられていない場合に、意図しない影響が出る可能性があります。

2.5.6. CRUSH ツリーの重みを再計算

CRUSH ツリーバケットは、リーフの重みの合計である必要があります。CRUSH マップの重みを手動で編集する場合は、以下を実行し、CRUSH バケットツリーがバケット内のリーフ OSD の合計を正確に反映するようにする必要があります。

```
osd crush reweight-all
```

2.6. プライマリーアフィニティー

Ceph クライアントがデータの読み取りまたは書き込み時に、適切なセット内のプライマリー OSD を常に問い合わせます。**[2, 3, 4]** セットの場合には、**osd.2** がプライマリーになります。OSD が他の OSD と比較して適していない場合があります (例: ディスクや低速なコントローラーなど)。ハードウェアの使用率を最大限にするために (読み込み操作上) パフォーマンスのボトルネックを防ぐために、CRUSH が OSD を機能セット内のプライマリーセットとして使用することの可能性が低くなるように Ceph OSD のプライマリーアフィニティーを設定できます。

```
ceph osd primary-affinity <osd-id> <weight>
```

プライマリーアフィニティーはデフォルトで **1** です (**つまり**、OSD がプライマリーとして機能する可能性があります)。OSD のプライマリー範囲を **0-1** に設定できます。ここで、**0** は OSD をプライマリーとして **使用しない** ことを意味します。**1** は、OSD がプライマリーとして使用される可能性があることを意味します。重みが **<1** の場合は、CRUSH が、プライマリーとして機能する Ceph OSD デーモンを選択する可能性は低くなります。

2.7. CRUSH ルール

CRUSH ルールは、Ceph クライアントがバケットとそれら内の OSD を選択する方法を定義し、プライマリー OSD がバケットとセカンダリー OSD を選択してレプリカやコーディングのチャンクを保存する方法を定義します。たとえば、2 つのオブジェクトレプリカ用に SSD がサポートするターゲット OSD と、3 つのレプリカ用に SAS ドライブがサポートする 3 つのターゲット OSD を選択するルールを作成できます。

ルールは以下の形式を取ります。

```
rule <rulename> {

    ruleset <ruleset>
    type [ replicated | raid4 ]
    min_size <min-size>
    max_size <max-size>
    step take <bucket-type> [class <class-name>]
    step [choose|chooseleaf] [firstn|indep] <N> <bucket-type>
    step emit
}
```

ルールセット

説明

(非推奨) ルールを一連のルールに属するように分類する手段。プールにルールセットを設定してアクティベートされます。RHCS 2 以前のリリースでサポートされます。RHCS 3 以降のリリースでは、ルールセットはサポートされません。

目的

ルールマスクのコンポーネント。

タイプ

整数

必須

Yes

デフォルト

0

type

説明

では、ストレージドライブ (複製) または RAID のいずれかのルールを説明します。

目的

ルールマスクのコンポーネント。

タイプ

文字列

必須

Yes

デフォルト

replicated

有効な値

現在は **replicated** のみ

min_size

説明

プールがこの数よりも小さいレプリカを使用する場合、CRUSH はこのルールを選択しません。

タイプ

整数

目的

ルールマスクのコンポーネント。

必須

Yes

デフォルト

1

max_size

説明

プールがこの数を超えるレプリカを行うと、CRUSH はこのルールを選択しません。

タイプ

整数

目的

ルールマスクのコンポーネント。

必須

Yes

デフォルト

10

step take <bucket-name> [class <class-name>]

説明

バケット名を取り、ツリーを下ってのイテレートを開始します。RHCS 3 以降では、デバイスクラス名を取る可能性があります。

目的

ルールのコンポーネント。

必須

Yes

例

step take data step take data class ssd

step choose firstn <num> type <bucket-type>

説明

特定タイプのバケット数を選択します。通常、この数はプール内のレプリカ数です (プールサイズ)。

- **<num> == 0** の場合は、**pool-num-replicas** バケット (利用可能なすべて) を選択します。
- **<num> > 0 && < pool-num-replicas** の場合は、多くのバケットを選択します。
- **<num> < 0** の場合、これは **pool-num-replicas - {num}** を意味します。

目的

ルールのコンポーネント。

前提条件

step take または **step choose** の後に行います。

例

step choose firstn 1 type row

step chooseleaf firstn <num> type <bucket-type>

詳細

{bucket-type} のバケットのセットを選択し、バケットのセットの各バケットのサブツリーからリーフノードを選択します。セットのバケット数は、通常プール内のレプリカ数です (プールサイズ)。

- **<num> == 0** の場合は、**pool-num-replicas** バケット (利用可能なすべて) を選択します。
- **<num> > 0 && < pool-num-replicas** の場合は、多くのバケットを選択します。
- **<num> < 0** の場合、これは **pool-num-replicas - <num>** を意味します。

目的

ルールのコンポーネント。使い方は、2 つの手順を使用してデバイスを選択する必要がなくなります。

前提条件

step take または **step choose** の後に行います。

例

step chooseleaf firstn 0 type row

step emit

説明

現在の値を出力します。また、スタックを除算します。通常、ルールの最後に使用されますが、同じルール内の異なるツリーを選択する際に使用することもできます。

目的

ルールのコンポーネント。

前提条件

step choose の後に行います。

例

step emit

firstn versus indep

説明

CRUSH マップで OSD がダウンする場合に使用する代替ストラテジーを制御します。このルールをレプリケートされたプールで使用する場合はこれを **firstn** にする必要があります。イレイジャーコーディングされたプールの場合は、**indep** にする必要があります。

例

OSD 1、2、3、4、5 に PG が保存されており、3 が落ちています。最初のシナリオでは、**firstn** モードの場合、CRUSH は、計算を調整して 1 および 2 を選択し、次に 3 を選択しますがそれがダウンしていることを検出したため、再試行して 4 と 5 を選択し、新しい OSD 6 を選択します。最終的な CRUSH マッピングの変更は **1、2、3、4、5** から **1、2、4、5、6** になります。2 つ目のシナリオでは、イレイジャーコーディングされたプールに **indep** モードが設定されていると、CRUSH は失敗した OSD 3 の選択を試行し、**1、2、3、4、5** から **1、2、6、4、5**) の最終変換に 6 を選択します。

重要

指定した CRUSH ルールは複数のプールに割り当てることができますが、単一プールで複数の CRUSH ルールを割り当てることはできません。

2.7.1. ルールの一覧表示

コマンドラインから CRUSH ルールを一覧表示するには、以下を実行します。

```
ceph osd crush rule list
ceph osd crush rule ls
```

2.7.2. ルールのダンプ

特定の CRUSH ルールの内容をダンプするには、以下を実行します。

```
ceph osd crush rule dump {name}
```

2.7.3. 簡単なルールの追加

CRUSH ルールを追加するには、使用する階層のルートノード、複数の複製するバケットタイプ (例: 'rack'、'row' など)、バケットを選択するモードを指定する必要があります。

```
ceph osd crush rule create-simple {rulename} {root} {bucket-type} {firstn|indep}
```

Ceph は、**chooseleaf** と、指定したタイプのバケットを 1 つ使用してルールを作成します。

以下に例を示します。

```
ceph osd crush rule create-simple deleteme default host firstn
```

以下のルールを作成します。

```
{ "rule_id": 1,
  "rule_name": "deleteme",
  "ruleset": 1,
  "type": 1,
  "min_size": 1,
  "max_size": 10,
  "steps": [
        { "op": "take",
          "item": -1,
          "item_name": "default"},
        { "op": "chooseleaf_firstn",
          "num": 0,
          "type": "host"},
        { "op": "emit"}]}
```

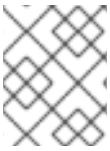

注記

RHCS 3 以降のリリースでは、**ruleset** はサポートされません。RHCS 2 およびそれ以前の Ceph リリースにおける後方互換性にのみ存在します。

2.7.4. レプリケートされたルールの追加

レプリケートされたプールに CRUSH ルールを作成するには、以下を実行します。

```
# ceph osd crush rule create-replicated <name> <root> <failure-domain> <class>
```

詳細は以下のようになります。

- **<name>**: 仮想マシンの名前。
- **<root>**: CRUSH 階層のルート。
- **<failure-domain>**: 障害ドメイン。たとえば、**host** または **rack** です。
- **<class>**: ストレージデバイスクラス。たとえば、**hdd** または **ssd** です。RHCS 3 以降のみ。

以下に例を示します。

```
# ceph osd crush rule create-replicated fast default host ssd
```

2.7.5. 実験的コードルールの追加

イレイジャーコードプールで使用する CRUSH ルールを追加するには、ルール名とイレイジャーコードプロファイルを指定できます。

```
ceph osd crush rule create-erasure {rulename} {profilename}
```

2.7.6. ルールの削除

ルールを削除するには、以下を実行し、CRUSH ルール名を指定します。

```
ceph osd crush rule rm {name}
```

2.8. CRUSH の調整可能パラメーター

Ceph プロジェクトでは、多くの変更と新機能が指数関数的に拡張されました。Ceph の最初の商用サポート対象メジャーリリース v0.48 (Argonaut) から始め、Ceph は CRUSH アルゴリズムの特定パラメーターを調整する機能を提供します。つまり、設定はソースコードでフリーズしません。

考慮すべき重要な点を以下に示します。

- CRUSH の値を調整すると、ストレージノード間で一部の PG の変化が発生することがあります。Ceph クラスターが多数のデータを保存する場合には、移動するデータの一部を準備する必要があります。
- **ceph-osd** デーモンおよび **ceph-mon** デーモンは、更新されたマップを受け取るとすぐに、新しい接続の機能ビットを要求するようになります。ただし、すでに接続済みのクライアントはすでに取得され、新機能をサポートしない場合は誤作動します。Ceph クライアントも更新する Ceph Storage Cluster デーモンをアップグレードする場合を確認してください。
- CRUSH の調整可能パラメーターがレガシー以外の値に設定され、後でレガシー値に戻された場合は、その機能をサポートするのに **ceph-osd** デーモンは必要ありません。ただし、OSD ピアリングプロセスでは、古いマップを調べ、理解する必要があります。したがって、クラスターが以前に非レガシー CRUSH 値を使用していた場合は、マップの最新バージョンがレガシーデフォルトの使用に戻されたとしても、古いバージョンの **ceph-osd** デーモンを実行しないでください。

2.8.1. CRUSH の調整可能パラメーターの進化

バージョン 0.48 より前の Ceph クライアントおよびデーモンは、調整可能を検出せず、バージョン 0.48 以降と互換性がありません。アップグレードする必要があります。調整可能パラメーター CRUSH の値も、主要な Ceph リリースと共に進化しました。

レガシー値

CRUSH Tunables のある新規クラスターにデプロイされたレガシー値は、誤作動する可能性があります。問題には、以下が含まれます。

- リーフバケット内の少数のデバイスを持つ階層では、PG の一部マップは、必要なレプリカ数より少なく済みます。これは通常、それぞれ 1 つのうちの OSD をネスト化した数 (1-3) のノードに「ホスト」ノードで階層が起こります。
- 大規模なクラスターの場合、必要な数の OSD よりも小さいために PG マップの割合 (パーセント) です。これは、階層のレイヤーが複数ある場合に広く使われます。たとえば、行、ラック、ホスト、osd などです。
- OSD の一部にマークが付けられると、階層全体がではなく、OSD に再配布される傾向があります。

重要

Red Hat では、CRUSH の調整可能パラメーターを利用するために、Ceph クライアントと Ceph デーモンの両方を主要なサポートされるリリースにアップグレードすることを強く推奨します。Red Hat は、すべてのクラスターデーモンおよびクライアントが同じリリースバージョンを使用することを推奨しています。

Argonaut (レガシー)

これは、Ceph の最初にサポートされる最初のリリースです。

- バージョン要件
  - Ceph 0.48、0.49 以降
  - RBD カーネルクライアントを含む Linux カーネル 3.6 以降
- サポートされている、CRUSH の調整可能パラメーター:
  - **choose_local_tries**: ローカル再試行の数。レガシー値は 2 で、最適な値は 0 です。
  - **choose_local_fallback_tries**: レガシー値は 5 で、最適値は 0 です。
  - **choose_total_tries**: アイテムの選択試行回数の合計。レガシー値は 19 であり、後続のテストは通常のクラスターに対して 50 の値がより適していることを示します。非常に大きなクラスターの場合、大きな値が必要になる場合があります。

Bobtail

- バージョン要件
  - Ceph 0.55、0.56.x 以降
  - RBD カーネルクライアントを含む Linux カーネル 3.9 以降
- サポートされている、CRUSH の調整可能パラメーター:
  - **chooseleaf_descend_once**: 再帰的な chooseleaf の試行で再試行するか、1 回だけ試行して、元の配置の再試行を許可するか。レガシーのデフォルト値は 0 で、最適な値は 1 です。

firefly

これは、Red Hat がサポートする最初の Ceph バージョンです。

- バージョン要件
  - Red Hat Ceph Storage 1.2.3 以降
  - RBD カーネルクライアントを含む Linux カーネル 7.1 以降
- サポートされている、CRUSH の調整可能パラメーター:
  - **chooseleaf_vary_r**: 親がすでに行った試行回数に基づいて、再帰的な chooseleaf 試行がゼロ以外の値の r で開始するかどうか。レガシーデフォルト値は 0 ですが、この値 CRUSH は時折マッピングを見つけられません。計算費や正確性の面での最適な値は 1 です。ただ

し、既存データが多数あるレガシークラスターの場合、0 から 1 に変更すると、多くのデータが移動します。4 または 5 の値により、CRUSH が有効なマッピングを検索できますが、データの移動は少なくなります。

- **straw_calc_version**: ストローバケットの CRUSH マップで計算および保存される内部重みにいくつかの問題がありました。具体的には、CRUSH の重み 0 が指定された項目がある場合、または重みと重複した CRUSH の両方がデータを不適切に分散している場合、これは重みに比例していません。0 の値は以前の内部加重計算を保持します。1 の値は動作を修正します。**straw_calc_version** を 1 に設定し、アイテムの追加、削除、再重み付けを行うか、reweight-all コマンドを使用して straw バケットを調整すると、クラスターが問題のある状態のいずれかに到達した場合は、データ移動の量を軽減するよう小規模にトリガーできます。この調整可能なオプションは、クライアント側で必要なカーネルバージョンに全く影響を及ぼさないため、特別なものです。

hammer

hammer 調整可能なプロファイルは、調整可能なプロファイルを変更するだけで、既存の CRUSH マップのマッピングには影響しませんが、新規のバケットタイプ **straw2** がサポートされるようになりました。

- バージョン要件
  - Red Hat Ceph Storage 1.3 以降
  - RBD カーネルクライアントを含む Linux カーネル 7.1 以降
- 新しいバケットタイプ:
  - 新しい **straw2** バケットタイプは、元の straw バケットのいくつかの制限を修正します。具体的には、古い straw バケットは重みの調整時に変更する必要のある一部のマッピングを変更し、straw2 バケットは重みが変更されたバケット項目に対して、またはここからのマッピングのみを変更するという元の目的を達成します。**straw2** バケットは、新規に作成されたすべてのバケットのデフォルトです。バケットタイプの straw から straw2 への変更により、どの程度バケット項目の重みが相互に異なるかに応じてデータの移動が小さくなります。加重がすべて同じデータで移動しない場合、アイテムの加重が大きく異なる場合は、より多くの移動が必要になります。

Jewel

Red Hat Ceph Storage 2 は Red Hat Enterprise Linux 7.2 以降でサポートされていますが、**jewel** 調整可能なプロファイルは Red Hat Enterprise Linux 7.3 以降でのみサポートされます。**jewel** 調整可能なプロファイルは、CRUSH の全体的な動作を改善します。これにより、OSD のマークが付けられる際にマッピングの変更が大幅に削減されます。

- バージョン要件
  - Red Hat Ceph Storage 2 以降
  - RBD カーネルクライアントおよび CephFS カーネルクライアントを含む Red Hat Enterprise Linux 7.3 以降
- サポートされている、CRUSH の調整可能パラメーター:
  - **chooseleaf_stable**: 再帰的な chooseleaf の試行で、OSD がマークアウトされたときのマッピング変更の数を大幅に減らす内部ループにより良い値を使用するかどうか。レガシー値は 0 で、新しい値は 1 で新しいアプローチを使用します。既存クラスターのこの値を変更すると、ほとんどの場合で PG マッピングが変更される可能性が高いため、データの移動が非常に高くなります。

2.8.2. CRUSH のチューニング

CRUSH を調整する前に、すべての Ceph クライアントおよびすべての Ceph デーモンが同じバージョンを使用するようにする必要があります。最近アップグレードした場合は、デーモンを再起動して、クライアントを再接続していることを確認します。

CRUSH パラメーターを調整する最も簡単な方法は、既知のプロファイルに変更します。以下のとおりです。

- **legacy**: v0.47 (pre-Argonaut) 以前のバージョンのレガシー動作。
- **argonaut**: v0.48 (Argonaut) リリースがサポートするレガシーの値。
- **bobtail**: v0.56 (Bobtail) リリースでサポートされる値。
- **firefly**: 0.80 (Firefly) リリースでサポートされる値。
- **hammer**: v0.94 (Hammer) リリースでサポートされる値。
- **jewel**: v10.0.2 (Jewel) リリースでサポートされる値。
- **optimal**: 現在の最適値
- **default**: 新規クラスターの現在のデフォルト値。

実行中のクラスターでプロファイルを選択するには、以下のコマンドを実行します。

```
# ceph osd crush tunables <profile>
```

注記

これにより、データの移動が生じる場合があります。

通常、アップグレード後に CRUSH パラメーターを設定するか、または警告が表示されるようにする必要があります。バージョン v0.74 以降では、CRUSH パラメーターが最適な値に設定されていない場合に、Ceph は健全性についての警告を発行します。最適な値は v0.73 のデフォルトになります。この警告を外すには、2 つのオプションがあります。

1. 既存クラスターの調整可能パラメーターを調整します。この結果、データの移動 (10% の可能性) が生じます。これは優先されるルートですが、データの移動がパフォーマンスに影響する可能性があります。以下を使用して、最適なチューニング可能なパラメーターを有効にできます。

   ```
   # ceph osd crush tunables optimal
   ```

   パフォーマンスの低下が悪い場合 (たとえば、負荷が非常に多い) か、非常に進捗が行われたか、またはクライアントの互換性の問題 (カーネルの cephfs または rbd クライアント、または pre-bobtail librados クライアント) がある場合には、以前のプロファイルに戻すことができます。

   ```
   # ceph osd crush tunables <profile>
   ```

   たとえば、pre-v0.48 (Argonaut) 値を復元するには、以下のコマンドを実行します。

   ```
   # ceph osd crush tunables legacy
   ```

2. 以下のオプションを、**ceph.conf** ファイルの **[mon]** セクションに追加すると、CRUSH に変更を加えずに警告を離れることができます。

```
mon warn on legacy crush tunables = false
```

変更を有効にするには、モニターを再起動するか、オプションを適用してモニターを実行します。

```
# ceph tell mon.\* injectargs --no-mon-warn-on-legacy-crush-tunables
```

2.8.3. CRUSH のチューニング (難しい方法)

すべてのクライアントが最新のコードを実行していることを確認できる場合は、CRUSH マップを抽出して値を変更し、これをクラスターへ再ミラーリングすることで、調整可能パラメーターを調整できます。

- 最新の CRUSH マップを抽出します。

```
ceph osd getcrushmap -o /tmp/crush
```

- 調整可能パラメーターの調整を行います。これらの値は、テストした大規模なクラスターと小規模なクラスターの両方に最適な動作を提供するように見えます。このコマンドが機能するには、**crushtool** に **--enable-unsafe-tunables** 引数も指定する必要があります。このオプションは細心の注意:

```
crushtool -i /tmp/crush --set-choose-local-tries 0 --set-choose-local-fallback-tries 0 --set-choose-total-tries 50 -o /tmp/crush.new
```

- 変更したマップの再インジェクト:

```
ceph osd setcrushmap -i /tmp/crush.new
```

2.8.4. レガシー値

詳細は、CRUSH 調整可能パラメーターのレガシー値を設定できます。

```
crushtool -i /tmp/crush --set-choose-local-tries 2 --set-choose-local-fallback-tries 5 --set-choose-total-tries 19 --set-chooseleaf-descend-once 0 --set-chooseleaf-vary-r 0 -o /tmp/crush.legacy
```

ここでも、特別な **--enable-unsafe-tunables** オプションが必要になります。さらに、上記のように、機能ビットが完全に適用されていないため、レガシー値に戻した後、古いバージョンの **ceph-osd** デーモンを実行する場合は注意が必要です。

2.9. CRUSH マップの設定

通常、Ceph CLI を使用してランタイム時に CRUSH マップを変更すると、CRUSH マップを手動で編集する場合よりも便利です。ただし、デフォルトのバケットタイプの変更や **straw** 以外のバケットアルゴリズムの使用など、編集を選択できます。

既存の CRUSH マップを編集するには、以下を実行します。

1. CRUSH マップを取得します。
2. CRUSH マップを 逆コンパイル します。
3. 1 つ以上のデバイスおよびバケットおよびルールを編集します。
4. CRUSH マップを 再コンパイル します。
5. CRUSH マップを設定します。

特定のプールの CRUSH マップルールを有効にするには、共通ルール番号を特定し、プールの作成時にそのプールのルール番号を指定します。

2.9.1. CRUSH マップの取得

クラスターの CRUSH マップを取得するには、以下を実行します。

```
ceph osd getcrushmap -o {compiled-crushmap-filename}
```

Ceph は、コンパイルされた CRUSH マップを指定したファイル名に出力 (-o) します。CRUSH マップはコンパイルフォームにあるため、これを編集する前に先にコンパイルする必要があります。

2.9.2. CRUSH マップのデコンパイル

CRUSH マップをコンパイルするには、以下を実行します。

```
crushtool -d {compiled-crushmap-filename} -o {decompiled-crushmap-filename}
```

Ceph は、コンパイルされた CRUSH マップと出力 (-o) を指定したファイル名にコンパイル (-d) します。

2.9.3. CRUSH マップのコンパイル

CRUSH マップをコンパイルするには、以下を実行します。

```
crushtool -c {decompiled-crush-map-filename} -o {compiled-crush-map-filename}
```

Ceph は、コンパイルされた CRUSH マップを指定したファイル名に保存します。

2.9.4. CRUSH マップの設定

クラスターに CRUSH マップを設定するには、以下を実行します。

```
ceph osd setcrushmap -i  {compiled-crushmap-filename}
```

Ceph は、クラスターの CRUSH マップとして指定したファイル名のコンパイルされた CRUSH マップを入力します。

2.10. CRUSH ストレージストラテジーの例

大規模なハードドライブがサポートするほとんどのプールを OSD に指定するとします。ただし、高速ソリッドステートドライブ (SSD) がサポートする OSD にマッピングされているプールもあります。CRUSH は、これらのシナリオを容易に処理できます。

RHCS 2 およびそれ以前

RHCS 2 以前では、同じ CRUSH マップ内に複数の独立した CRUSH 階層を持つことで、異なるパフォーマンスドメインを反映させることができます。ハードディスク (例: "root platter" など) と SSD 用 ("root ssd" など) の 2 つの異なるルートノードを持つ階層を 2 つ定義します。以下に例を示します。

```
device 0 osd.0
device 1 osd.1
device 2 osd.2
device 3 osd.3
device 4 osd.4
device 5 osd.5
device 6 osd.6
device 7 osd.7

 host ceph-osd-ssd-server-1 {
    id -1
    alg straw
    hash 0
    item osd.0 weight 1.00
    item osd.1 weight 1.00
 }

 host ceph-osd-ssd-server-2 {
    id -2
    alg straw
    hash 0
    item osd.2 weight 1.00
    item osd.3 weight 1.00
 }

 host ceph-osd-platter-server-1 {
    id -3
    alg straw
    hash 0
    item osd.4 weight 1.00
    item osd.5 weight 1.00
 }

 host ceph-osd-platter-server-2 {
    id -4
    alg straw
    hash 0
    item osd.6 weight 1.00
    item osd.7 weight 1.00
 }

 root platter {
    id -5
    alg straw
    hash 0
    item ceph-osd-platter-server-1 weight 2.00
    item ceph-osd-platter-server-2 weight 2.00
 }

 root ssd {
```

```
    id -6
    alg straw
    hash 0
    item ceph-osd-ssd-server-1 weight 2.00
    item ceph-osd-ssd-server-2 weight 2.00
}

rule data {
    ruleset 0
    type replicated
    min_size 2
    max_size 2
    step take platter
    step chooseleaf firstn 0 type host
    step emit
}

rule metadata {
    ruleset 1
    type replicated
    min_size 0
    max_size 10
    step take platter
    step chooseleaf firstn 0 type host
    step emit
}

rule rbd {
    ruleset 2
    type replicated
    min_size 0
    max_size 10
    step take platter
    step chooseleaf firstn 0 type host
    step emit
}

rule platter {
    ruleset 3
    type replicated
    min_size 0
    max_size 10
    step take platter
    step chooseleaf firstn 0 type host
    step emit
}

rule ssd {
    ruleset 4
    type replicated
    min_size 0
    max_size 4
    step take ssd
    step chooseleaf firstn 0 type host
    step emit
}
```

```
rule ssd-primary {
    ruleset 5
    type replicated
    min_size 5
    max_size 10
    step take ssd
    step chooseleaf firstn 1 type host
    step emit
    step take platter
    step chooseleaf firstn -1 type host
    step emit
}
```

続いて、以下のコマンドを実行して、SSD ルールを使用するようにプールを設定できます。

```
ceph osd pool set <poolname> crush_ruleset 4
```

注記

Red Hat は、RHCS 3 以降のリリースの **ruleset** 設定および **crush_ruleset** 設定をサポートしません。

SSD プールは、高速ストレージプールとして機能することができます。同様に、**ssd-primary** ルールを使用して、プール内の各配置グループを、プライマリーとして SSD を使用し、レプリカとしてプラッターを使用して配置することができます。

RHCS 3 以降

RHCS 3 以降では、デバイスクラスを使用します。このプロセスは、各デバイスにクラスを追加するのがはるかに簡単です。以下に例を示します。

```
# ceph osd crush set-device-class <class> <osdId> [<osdId>]
# ceph osd crush set-device-class hdd osd.0 osd.1 osd.4 osd.5
# ceph osd crush set-device-class ssd osd.2 osd.3 osd.6 osd.7
```

次に、デバイスを使用するルールを作成します。

```
# ceph osd crush rule create-replicated <rule-name> <root> <failure-domain-type> <device-class>:
# ceph osd crush rule create-replicated cold default host hdd
# ceph osd crush rule create-replicated hot default host ssd
```

最後に、ルールを使用するようにプールを設定します。

```
ceph osd pool set <poolname> crush_rule <rule-name>
ceph osd pool set cold crush_rule hdd
ceph osd pool set hot crush_rule ssd
```

1 つの階層が複数のデバイスのクラスに対応できるため、CRUSH マップを手動で編集する必要はありません。RHCS 2 の例と比較すると、デバイスクラスを使用する場合、CRUSH マップは RHCS 3 でもはるかに簡単です。

```
device 0 osd.0 class hdd
device 1 osd.1 class hdd
device 2 osd.2 class ssd
```

```
device 3 osd.3 class ssd
device 4 osd.4 class hdd
device 5 osd.5 class hdd
device 6 osd.6 class ssd
device 7 osd.7 class ssd

 host ceph-osd-server-1 {
    id -1
    alg straw
    hash 0
    item osd.0 weight 1.00
    item osd.1 weight 1.00
    item osd.2 weight 1.00
    item osd.3 weight 1.00
 }

 host ceph-osd-server-2 {
    id -2
    alg straw
    hash 0
    item osd.4 weight 1.00
    item osd.5 weight 1.00
    item osd.6 weight 1.00
    item osd.7 weight 1.00
 }

 root default {
    id -3
    alg straw
    hash 0
    item ceph-osd-server-1 weight 4.00
    item ceph-osd-server-2 weight 4.00
 }


 rule cold {
    ruleset 0
    type replicated
    min_size 2
    max_size 11
    step take default class hdd
    step chooseleaf firstn 0 type host
    step emit
 }


 rule hot {
    ruleset 1
    type replicated
    min_size 2
    max_size 11
    step take default class ssd
    step chooseleaf firstn 0 type host
    step emit
 }
```

第3章 配置グループ (PG)

配置グループ (PG) は Ceph クライアントには表示されませんが、Ceph Storage クラスターの重要な役割を果たします。

Ceph Storage Cluster では、ストレージ容量に数万もの OSD が必要になる可能性があります。Ceph クライアントは、オブジェクトをプールに保存します。プールには、クラスターの論理サブセットです。プールに保存されているオブジェクトの数は、数百万以上のものでも簡単に実行できます。オブジェクト数またはそれ以上のシステムが、オブジェクトごとの配置を現実的に追跡できず、適切に実行することができません。Ceph はオブジェクトを配置グループに割り当て、配置グループを OSD に割り当て、動的かつ効率的に分散できるようにします。

	コンピューターのすべての問題は、間接化が過剰に発生する問題を除き、別のレベルの間接方法で解決できます。	
		-- David Wheeler

3.1. 配置グループについて

プール内のオブジェクト毎のオブジェクトの配置を追跡することは、スケーリング時に計算が高くなります。スケーリング時に高パフォーマンスを容易にするために、Ceph はプールを配置グループに分割し、各個別のオブジェクトを配置グループに割り当て、配置グループを **プライマリー** OSD に割り当てます。OSD の失敗やクラスターのリバランスを行う場合、Ceph は配置グループ全体を移動するか、または複製できます。たとえば、配置グループのすべてのオブジェクトを個別に対応する必要はありません。これにより、Ceph クラスターは効率的にリバランスまたはリカバリーを実行できるようになります。

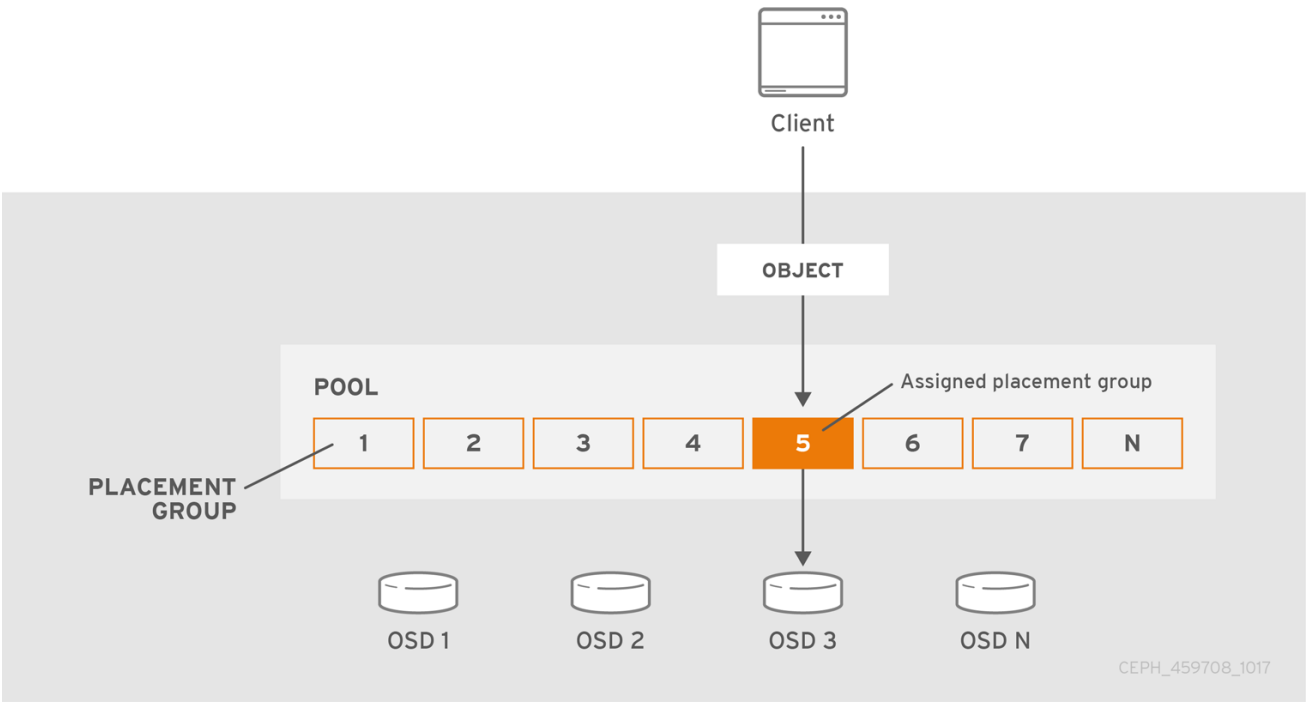

CRUSH が配置グループを OSD に割り当てると、最初の主要な OSD の一連の OSD を計算します。レプリケートされたプールの場合は **osd_pool_default_size** 設定から **1** を引いた、イレイジャーコーディングされたプール用のコーディングチャンク **M** の数が、データを永続的に失わない配置グループを保存できる OSD の数を決定します。プライマリー OSD は CRUSH を使用してセカンダリー OSD を特定し、配置グループのコンテンツをセカンダリー OSD にコピーします。たとえば、CRUSH がオブジェクトを配置グループに割り当て、配置グループがプライマリー OSD として OSD 5 に割り当てられ

る場合、CRUSH が OSD 1 および OSD 8 がセカンダリー OSD を計算すると、プライマリー OSD 5 はデータを OSD 1 および 8 にコピーします。クライアントの代わりにデータをコピーすると、Ceph はクライアントのインターフェースを単純化し、クライアントのワークロードを減らします。同じプロセスにより、Ceph クラスターは動的リカバリーおよびリバランスが可能です。

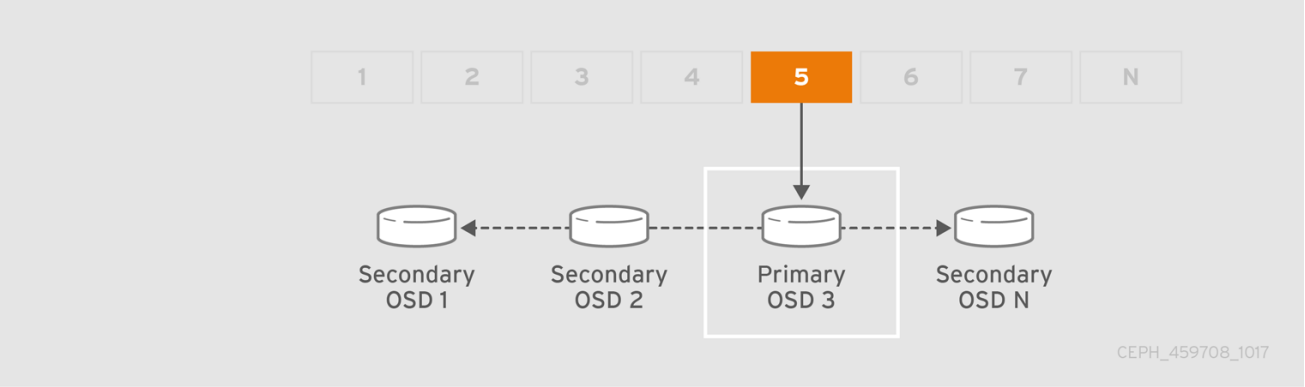

プライマリー OSD が失敗し、クラスターの印が付けられた場合、CRUSH は配置グループを別の OSD に割り当てます。これにより、配置グループ内のオブジェクトのコピーを受け取ります。**Up Set** 内の別の OSD は、プライマリー OSD ロールを想定します。

オブジェクトレプリカ数を増やすか、または共存する場合、CRUSH は各配置グループを必要に応じて追加の OSD に割り当てます。

注記

PG は OSD を所有しません。CRUSH は、多くの配置グループを各 OSD 擬似リソースに割り当て、データをクラスター全体で均等に分散できるようにします。

3.2. 配置グループの制限

より多くの配置グループに対するすべての OSD 呼び出し間のデータの持続性とデータの分散性以外にも、CPU とメモリーリソースを節約するための最大パフォーマンスを最大化するために最低限必要な数を減らす必要があります。

3.2.1. データの永続性

Ceph はデータの永続的な損失を防ぐように努めます。ただし、OSD が失敗すると、含まれるデータが完全に回復するまで、永続的なデータの損失のリスクが高まります。まれに、永続的なデータ損失を使用することは可能です。以下のシナリオとして、Ceph が 1 つの配置グループのデータを永続的に失った方法が、3 つのデータのコピーで永久に失われるシナリオを説明します。

- OSD が失敗し、これに含まれるオブジェクトのすべてのコピーが失われます。OSD に保管されている配置グループ内のすべてのオブジェクトについて、レプリカ数を 3 から 2 に破棄します。
- Ceph は、新規 OSD を選択して、各配置グループの全オブジェクトの 3 つ目のコピーを再作成して、失敗した OSD に保管されている各配置グループのリカバリーを開始します。
- 新しい OSD が完全にコピー 3 つになるまで、同じ配置グループのコピーを含む 2 つ目の OSD は失敗します。一部のオブジェクトには、コピーが 1 つだけ含まれます。
- Ceph はまだ別の OSD を選択し、オブジェクトをコピーして必要なコピー数を復元します。

- リカバリーが完了するまで、同じ配置グループのコピーを含む 3 つ目の OSD は失敗します。この OSD にオブジェクトの残りのコピーのみが含まれる場合、オブジェクトは永続的に失われます。

ハードウェア障害は例外ではありませんが、予想されます。前述のシナリオを防止するには、リカバリープロセスを最速に行いておく必要があります。クラスターのサイズ、ハードウェア構成、および配置グループの数は、復旧時間の合計における重要な役割を果たします。

小規模なクラスターはすぐにリカバリーしません。

3 つのレプリカプールに 512 の配置グループと共に 10 OSD が含まれるクラスターでは、CRUSH ごとに配置グループ 3 つが提供されます。各 OSD は、ホスト **(512 * 3)** / **10 = ~150** の配置グループになります。最初の OSD が失敗すると、クラスターは 150 のすべての配置グループのリカバリーを同時に開始します。

Ceph は、9 つの残りの OSD にわたり、残りの 150 の配置グループをランダムに保存している可能性があります。したがって、残りの OSD は、現在割り当てられている 150 個の配置グループの一部を担当することになるため、残りの各 OSD は、他のすべての OSD にオブジェクトのコピーを送信する可能性が高く、また、いくつかの新しいオブジェクトを受け取る可能性があります。

リカバリー合計時間は、プールをサポートするハードウェアによって異なります。たとえば、10 OSD クラスターにおいて、ホストに 1TB SSD を持つ OSD が 1 つあり、10GB/s スイッチが 10 個の各ホストを接続すると、復旧に **M** 分かかります。一方、ホストに 2 つの SATA OSD が含まれ、1GB/s スイッチが 5 台に接続すると、復元が大幅に長くなります。同様に、このサイズのクラスターで、配置グループの数に直面的には、データの持続性に影響を与えることはありません。配置グループ数は 128 または 8192 で、復元速度は遅くなったり、速くなったりしません。

ただし、同じ Ceph クラスターを 10 OSD ではなく 20 個の OSD に拡張すると、復元を迅速化するため、データの持続性が大幅に向上します。なぜですか？各 OSD は 150 ではなく、75 の配置グループしか参加しません。20 個の OSD クラスターでは、回復するために同じコピー操作を実行するには、残り 19 個すべての OSD が必要になります。10 OSD クラスターでは、各 OSD は約 100 GB をコピーする必要がありました。各 OSD はそれぞれ 20 個の OSD クラスターでは、それぞれ 50 GB のみをコピーする必要があります。ネットワークがボトルネックである場合、リカバリーは高速になります。つまり、OSD の数が増えると、復旧時間が短縮されます。

大規模なクラスターでは、PG 数は重要です。

exemplary クラスターが 40 OSD に拡大すると、各 OSD は 35 の配置グループのみをホストします。OSD が停止した場合、別のボトルネック解決しないと、復旧時間が減少します。ただし、このクラスターが 200 個の OSD を拡張する場合、各 OSD は約 7 の配置グループのみをホストします。OSD が停止した場合、これらの配置グループにある最大 21 **(7 * 3)** OSD の間に復元が行われます。**復元には、40 の OSD があった場合よりも時間がかかります。つまり、配置グループの数を増やす必要があります。**

重要

リカバリー時間は短い方法に関係ありません。復元中、他の OSD が配置グループの保存時に失敗する可能性があります。

上記の 10 OSD クラスターでは、いずれかの OSD に障害が発生した場合は、約 8 個の配置グループ (つまり、**75 pgs** / **9 osds** が復元されます) には、残りのコピーが 1 つしかありません。残りの 8 つの OSD のいずれかが失敗すると、1 つの配置グループの最後のオブジェクトが失われる可能性があります (つまり、残りの 1 つのコピーのみが復元される **8 pgs** / **8 osds** など）。このため、大規模なクラスターから始まります (例: 50 OSD)。

クラスターのサイズが 20 個の OSD に増加する場合、3 つの OSD ドロップによって破損した配置グループの数が増えます。2 つ目に失われた OSD は、8 ではなく約 2 (つまり **35 pgs** / **19 osds** が復元) に低下し、3番目に失われた OSD は、残りのコピーを含む 2 つの OSD の 1 つである場合にのみデータ

を失います。つまり、回復時間枠内で 1 つの OSD が失われる確率が **0.0001%** の場合は、10 OSD のクラスターの**8 * 0.0001%** から 20 OSD のクラスターの **2 * 0.0001%** になります。データの耐性が懸念されるため、50 OSD 未満のクラスターで 512 または 4096 の配置グループがほぼ同等になります。

ヒント

つまり、OSD が多いほどリカバリーが速くなり、カスケーディングが配置グループとそのオブジェクトの永続的な損失が発生するリスクが低くなります。

OSD をクラスターに追加する場合、新しい OSD に配置グループおよびオブジェクトが追加されるまでに長い時間がかかる可能性があります。ただし、オブジェクトの低下はなく、OSD を追加するとデータの持続性は影響を受けません。

3.2.2. データディストリビューション

Ceph はホットスポットを避けるようにします。一部の OSD は、その他の OSD よりも多くのトラフィックを受信します。理想的には、CRUSH は配置グループにオブジェクトを均等に割り当て、配置グループが OSD (またはランダムに擬似) に割り当てられる場合でも、プライマリー OSD は、クラスター全体に均等に分散され、ホットスポットやネットワークオーバーサブスクリプションの問題が発生しないようにオブジェクトをストアします。

CRUSH は各オブジェクトの配置グループを計算するが、実際にはこの配置グループ内の各 OSD に保管されるデータの量を認識しないため、**配置グループの数と OSD の数の比率が、データの分散に大きく影響する可能性があります**。

たとえば、3 つのレプリカプールに OSD が 10 個しかない配置グループが 1 つしかない場合、Ceph は CRUSH には他の選択がないために 3 つの OSD だけを使用します。より多くの配置グループを利用できる場合、CRUSH はオブジェクトを OSD 全体に均等に分散させる可能性が高くなります。また、CRUSH は配置グループを OSD に均等に割り当てます。

OSD よりも多くの配置グループの順序が 1 つまたは 2 つまたは 2 つある限り、ディストリビューションも OSD よりも多くの配置グループで構成される必要があります。たとえば、OSD 3 つは 300 の配置グループ、10 個は OSD 用 1000 の配置グループなどとなります。

OSD と配置グループの割合は、通常、オブジェクトストライピングのような高度な機能を実装する Ceph クライアントのデータ分散の問題を解決します。たとえば、4TB ブロックデバイスでは、4MB オブジェクトになる可能性があります。

CRUSH はオブジェクトサイズを考慮しないため、OSD と配置グループ間の比率は、他のケースで不均等なデータ分散に対応しません。librados インターフェースを使用して、いくつかの比較的小さなオブジェクトといくつかの非常に大きなオブジェクトを格納すると、データの分散が不均一になる可能性があります。たとえば、10 個の OSD 上に 1,000 個の配置グループの中に、合計 100 万個の 4K オブジェクト (合計で 4GB) が均等に配置されています。OSD ごとに **4GB / 10 = 400MB** を使用します。プールに 400MB オブジェクト 1 つが追加されると、オブジェクトの配置先の配置グループをサポートする 3 つの OSD で **400MB + 400MB = 800MB** が使用され、残りの 7 つの OSD は 400MB のみで占有されます。

3.2.3. リソース使用状況

各配置グループ、OSD および Ceph モニターにはメモリー、ネットワーク、および CPU を常時必要とし、復旧中にさらに必要です。配置グループ内のクラスタリングオブジェクトによるこのオーバーヘッドの共有は、主な配置グループのいずれかです。

配置グループの数を最小限にすると、リソースの量が大きくなります。

3.3. PG 数

プール内の配置グループ数では、クラスターのピアがデータおよびリバランスの分散方法などの重要な役割を果たします。小規模なクラスターでは、配置グループの数を増やすことで、大規模なクラスターと比較してパフォーマンスが向上されません。ただし、同じ OSD に多数のプールを持つクラスターは、Ceph OSD がリソースを効率的に使用するように PG 数を考慮しないといけない場合があります。

ヒント

Red Hat は、OSD あたり 100 から 200 PG を推奨します。

3.3.1. PG Calculator

PG の計算ツールを使用して、特定のユースケースに対応する配置グループの数を計算しています。PG の計算ツールは、通常同じルール (CRUSH 階層) を使用して Ceph Object Gateway などの Ceph クライアントを使用する場合に特に役立ちます。引き続き、小規模クラスターの PG 数 および PG 数の計算 に関するガイドラインを使用して手動で PG を手動で計算することもできます。ただし、PG の計算方法は、PG を計算するのに推奨される方法です。

詳細は、Red Hat カスタマーポータル の「Ceph Placement Groups (PGs) per Pool Calculator」 を参照してください。

3.3.2. デフォルトの PG 数の設定

プールの作成時に、プールに配置グループの数も作成します。配置グループの数を指定しない場合、Ceph はデフォルト値 **8** を使用します。これは許容範囲を超えるほど低い値です。プールの配置グループ数を増やすことはできますが、Ceph 設定ファイルで妥当なデフォルト値を設定することを推奨します。

```
osd pool default pg num = 100
osd pool default pgp num = 100
```

配置グループ (合計) 数と、オブジェクトに使用される配置グループの数 (PG 設定で使用) の両方を設定する必要があります。これらは等しい必要があります。

3.3.3. Small クラスターの PG 数

小規模なクラスターでは、多くの配置グループには利点はありません。OSD の数が増えると、**pg_num** および **pgp_num** が正しい値を選択することが重要になります。これは、クラスターの動作に大きな影響を与えるだけでなく、異常が発生した時のデータの耐久性 (致命的なイベントによってデータ損失が発生する可能性) があるためです。小規模なクラスターで PG 計算ツール を使用することが重要です。

3.3.4. PG 数の計算

OSD が 50 を超える場合は、リソース使用状況、データ耐性、分散のバランスを取るために、OSD ごとに約 50 - 100 個の配置グループを推奨します。OSD が 50 未満の場合は、Small クラスターの PG 数などを選択することが理想的です。オブジェクトのプール 1 つに対して、以下の式を使用してベースラインを取得できます。

```
              (OSDs * 100)
Total PGs =  ------------
               pool size
```

プールサイズ は、(**ceph osd erasure-code-profile get** によって返される) レプリケートされたプールのレプリカ数、または異例ジャーコードされたプールの **K+M** 合計になります。

次に、データの永続性を最大化し、データ分散を最大化し、リソースの使用を最小限に抑えるために、Ceph クラスターが設計した内容が適切かどうかを確認する必要があります。

結果は、**最も近い 2 の累乗に切り上げられる必要があります**。数の丸めはオプションですが、CRUSH では配置グループ間でオブジェクト数を均等に分散させることが推奨されます。

OSD が 200 でプールサイズ 3 つのレプリカのクラスターの場合、以下のように PG 数を見積もります。

```
(200 * 100)
----------- = 6667. Nearest power of 2: 8192
     3
```

8192 個の配置グループを 200 個の OSD に分散することで、OSD ごとに約 41 の配置グループを評価します。また、クラスターで使用される可能性のあるプールの数も考慮する必要があります。これは、各プールで配置グループが作成されるので、クラスターで使用される可能性も検討する必要があります。妥当な 最大 PG 数 があることを確認します。

3.3.5. 最大 PG 数

オブジェクト格納に複数のデータプールを使用する場合は、プールごとの配置グループの数と、OSD ごとの配置グループの合計数が妥当な数になるように、配置グループの合計数のバランスを取る必要があります。この目的は、システムリソースに負荷をかけたり、ピアリングプロセスを遅らせずに、OSD ごとのさまざまな負荷を達成することにあります。

たとえば、10 個の OSD 上の 512 の配置グループを持つ、10 個のプールで構成される Ceph Storage クラスターでは、10 個を超える OSD に広がる 5120 の配置グループや、OSD ごとに 512 の配置グループがあります。ハードウェアの設定によっては、リソースが多すぎる可能性があります。これとは対照的に、512 個の配置グループをそれぞれに持つ 1,000 プールを作成する場合、OSD はそれぞれの配置グループ 50,000 までを処理し、より多くのリソースが必要になります。OSD ごとの配置グループが多すぎると、特にリバランスまたは復旧時にパフォーマンスが大幅に低下します。

Ceph Storage Cluster には、OSD ごとに最大 300 の配置グループの最大値があります。Ceph 設定ファイルに異なる最大値を設定することができます。

```
mon pg warn max per osd
```

ヒント

Ceph Object Gateway は 10-15 プールでデプロイするので、妥当な最大数に達するにあたり OSD ごとに 100 未満の PG 未満を使用してください。

3.4. PG コマンドラインリファレンス

ceph CLI では、プールの配置グループ数の設定および取得、PG マップの表示、PG の統計の取得を行うことができます。

3.4.1. PG の数の設定

プール内の配置グループの数を設定するには、プールの作成時に配置グループの数を指定する必要があります。詳細は、「プールの作成」を参照してください。プールに配置グループを設定したら、配置グ

ループの数を増やすことができます (ただし、配置グループの数を減らすことはできません)。配置グループの数を増やすには、以下のコマンドを実行します。

```
ceph osd pool set {pool-name} pg_num {pg_num}
```

配置グループの数を増やしたら、クラスターがリバランスする前に、配置 (**pgp_num**) の配置グループの数も増やす必要があります。**pgp_num** は **pg_num** と同じである必要があります。配置の配置グループの数を増やすには、以下のコマンドを実行します。

```
ceph osd pool set {pool-name} pgp_num {pgp_num}
```

3.4.2. PG の数の取得

プール内の配置グループの数を取得するには、以下のコマンドを実行します。

```
ceph osd pool get {pool-name} pg_num
```

3.4.3. クラスター PG の統計の取得

クラスター内の配置グループの統計を取得するには、以下を実行します。

```
ceph pg dump [--format {format}]
```

有効な形式は **plain** (デフォルト) および **json** です。

3.4.4. 詰まった PG の統計を取得

指定された状態で固まったすべての配置グループを取得するには、以下を実行します。

```
ceph pg dump_stuck {inactive|unclean|stale|undersized|degraded
[inactive|unclean|stale|undersized|degraded...]} {<int>}
```

Inactive 配置グループは、最新のデータを持つ OSD が up で in になることを待っているため、読み取りや書き込みを処理できません。

Unclean 配置グループには、希望する回数を複製しないオブジェクトが含まれます。これらは回復中である必要があります。

Stale 配置グループは不明な状態にあります それをホストする OSDは、しばらくモニタークラスターに対して報告されていない OSD です (**mon_osd_report_timeout** で設定されます)。

有効な形式は **plain** (デフォルト) および **json** です。このしきい値は、返される統計に含める前に、配置グループがス詰まった最小秒数を定義します (デフォルトは 300 秒)。

3.4.5. PG マップの取得

特定の配置グループの配置グループマップを取得するには、以下のコマンドを実行します。

```
ceph pg map {pg-id}
```

以下に例を示します。

```
ceph pg map 1.6c
```

Ceph は配置グループマップ、配置グループ、および OSD のステータスを返します。

```
osdmap e13 pg 1.6c (1.6c) -> up [1,0] acting [1,0]
```

3.4.6. PG の統計の取得

特定の配置グループの統計を取得するには、以下のコマンドを実行します。

```
ceph pg {pg-id} query
```

3.4.7. 配置グループへのスクラブ

配置グループをスクラブするには、以下のコマンドを実行します。

```
ceph pg scrub {pg-id}
```

Ceph はプライマリーノードとレプリカノードを確認し、配置グループ内の全オブジェクトのカタログを生成し、オブジェクトが見つからないか、一致しないか、その内容の一貫性を保つようにします。レプリカがすべて一致したことを想定すると、最終的なセマンティックスイープにより、すべてのスナップショット関連のオブジェクトメタデータの一貫性が確保されます。エラーはログにより報告されます。

3.4.8. 失われたオブジェクトの回復

クラスターが 1 つ以上のオブジェクトが失われ、失われたデータの検索を破棄した場合、失われたオブジェクトを **lost** とマークする必要があります。

可能なロケーションがすべてクエリーされ、オブジェクトが依然として失われている場合は、失われたオブジェクトは諦めるしかありません。この障害には、書き込み自体が復旧する前に実行された書き込みについて、クラスターが認識できるようにする、障害上の組み合わせが発生したことが考えられます。

現時点で、サポートされる唯一のオプションは「revert」です。これはオブジェクトの以前のバージョンにロールバックするか、または (新しいオブジェクトの場合は) 完全にロールバックします。「unfound」オブジェクトを「lost」とマークするには、以下を実行します。

```
ceph pg {pg-id} mark_unfound_lost revert|delete
```

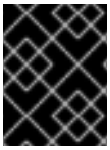

重要

オブジェクトが存在すると想定されるアプリケーションが同じ場合があるため、この機能は注意して使用してください。

第4章 プール

Ceph クライアントは、データをプールに保存します。プールの作成時に、クライアントがデータを保存するための I/O インターフェースを作成します。Ceph クライアントの視点 (例: ブロックデバイス、ゲートウェイなど) からは、Ceph ストレージクラスターと対話することが非常にシンプルです。たとえば、クラスターを処理し、クラスターに接続して、オブジェクトを読み取りおよび書き込みするための I/O コンテキストを作成します。

クラスターハンドルの作成およびクラスターへの接続

Ceph Storage クラスターに接続するには、Ceph クライアントにはクラスター名 (通常は **ceph**) と初期モニターアドレスが必要です。通常、Ceph クライアントは Ceph 設定ファイルのデフォルトパスを使用してパラメーターを取得し、ファイルからファイルを読み取りますが、コマンドラインでパラメーターを指定することもできます。Ceph クライアントは、ユーザー名および秘密鍵も提供します (デフォルトでは認証は **on** です)。次に、クライアントは Ceph monitor クラスターに接続し、モニター、OSD、およびプールを含むクラスターマップの最新コピーを取得します。

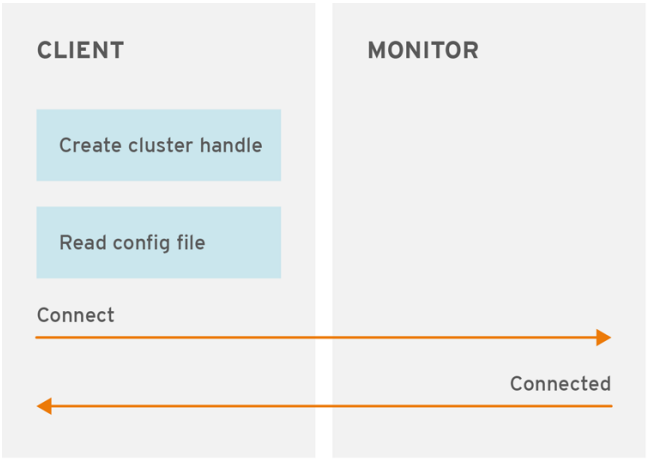

プール I/O コンテキストの作成

データの読み取りと書き込みには、Ceph クライアントは Ceph ストレージクラスター内の特定のプールに i/o コンテキストを作成します。指定したユーザーにプールのパーミッションがある場合は、Ceph クライアントは指定されたプールから読み取り/書き込みを行うことができます。

Ceph のアーキテクチャーを使用することで、ストレージクラスターは、プール名を指定して簡単に定義し、I/O コンテキストの作成で簡単に定義するストレージストラテジーのいずれかをクライアントが選択できるように、ストレージクラスターを Ceph クライアントに提供することができます。ストレー

ジストラテジーはすべて、容量およびパフォーマンスにおいて Ceph クライアントを認識しません。同様に、Ceph クライアントの複雑性 (ブロックデバイス表現へのオブジェクトのマッピング、S3/Swift RESTful サービスの提供) は Ceph ストレージクラスターに見えません。

以下のようにプールを提供します。

- **耐障害性**: データを損失せずに失敗した OSD の数を設定できます。複製されたプールの場合、これはオブジェクトのコピー/レプリカの数です。通常の設定では、オブジェクトと 1 つの追加コピー (例: **size = 2**) が保存されますが、コピー/レプリカの数は決定できます。イレイジャーコードプールの場合は、コーディングしたチャンクの数です (例: **イレイジャーコードプロファイル**の **m=2**)。

- **配置グループ**: プールの配置グループの数を設定できます。典型的な設定では、OSD ごとに約 50-100 の配置グループを使用して、最高のコンピューティングリソースを使用せずに最適なバランスを提供します。複数のプールを設定する場合は、全体としてプールとクラスターの両方に妥当な配置グループ数を設定するように注意してください。

- **CRUSH ルール**: プールにデータをプールに保存すると、CRUSH ルールがプールにマッピングされた CRUSH ルールにより、CRUSH が各オブジェクトとそのレプリカ (またはイレイジャーコード化されたプールのチャンク) の配置のルールを特定できます。プールにカスタム CRUSH ルールを作成できます。

- Snapshots: **ceph osd pool mksnap** を使用してスナップショットを作成すると、特定のプールのスナップショットが効果的に作成されます。

- Quotas:**ceph osd pool set-quota** を使用してプールにクォータを設定する場合は、オブジェクトの最大数または指定されたプールに格納される最大バイト数を制限できます。

4.1. プールとストレージストラテジー

プールを管理するために、プールの一覧を表示、作成、および削除できます。各プールの使用状況の統計を表示することもできます。

4.2. プールの一覧を表示します。

クラスターのプールを一覧表示するには、以下を実行します。

```
ceph osd lspools
```

4.3. プールの作成

プールを作成する前に、Red Hat Ceph Storage 3 の『**設定 ガイド**』の「**プール、PG、および CRUSH 設定 リファレンス**」の章を参照してください。

注記

Red Hat Ceph Storage 3 以降では、システム管理者は、Ceph クライアントから I/O 操作を受信するプールを表現的に有効にする必要があります。詳細は、「アプリケーションの有効化」を参照してください。プールを有効にしないと、**HEALTH_WARN** のステータスになります。

デフォルト値がニーズに適していないため、Ceph 設定ファイル内の配置グループ数のデフォルト値を調整してください。以下に例を示します。

```
osd pool default pg num = 100
osd pool default pgp num = 100
```

複製されたプールを作成するには、次のコマンドを実行します。

```
ceph osd pool create <pool-name> <pg-num> <pgp-num> [replicated] \
     [crush-rule-name] [expected-num-objects]
```

イレイジャーコーディングされたプールを作成するには、以下のコマンドを実行します。

```
ceph osd pool create <pool-name> <pg-num> <pgp-num> erasure \
     [erasure-code-profile] [crush-rule-name] [expected-num-objects]
```

詳細は以下のようになります。

pool-name

説明

プールの名前。一意でなければなりません。

タイプ

文字列

必須

Yes指定されていない場合は、Ceph 設定ファイルまたはデフォルト値にリストされた値に設定されます。

デフォルト

ceph

pg-num

説明

プールの現在の配置グループ数。適切な数を計算する方法は、「配置グループ」セクションおよびおよび 「Ceph Placement Groups (PGs) per Pool Calculator」 を参照してください。デフォルト値 **8** は、ほとんどのシステムには適していません。

型

整数

必須

Yes

デフォルト

8

pgp-num

説明

配置目的の配置グループの合計数。この値は、配置グループ分割シナリオを除き、配置グループの合計数と同じでなければなりません。

タイプ

整数

必須

Yes指定されていない場合は、Ceph 設定ファイルまたはデフォルト値にリストされた値に設定されます。

デフォルト

8

レプリケートまたはイレイジャー

詳細

オブジェクトまたは **erasure** を複数維持することで失われた OSD から復旧するために **複製** することのできるプールタイプは、一般的な RAID5 機能を取得します。複製されたプールにはより多くの raw ストレージが必要であり、すべての Ceph 操作が実装されます。消去コード化されたプールにより必要な raw ストレージは少なくなりますが、この場合利用可能な操作のサブセットのみが実装されます。

タイプ

文字列

必須

いいえ

デフォルト

replicated

crush-rule-name

説明

プールの crush ルールの名前。このルールが存在する **必要があります**。レプリケートされたプールの場合、名前は **osd_pool_default_crush_rule** 設定で指定されたルールになります。イレイジャーコーディングされたプールの場合は、デフォルトのイレイジャーコードプロファイルまたは **{pool-name}** を指定すると、名前が **erasure-code** になります。Ceph では、ルールが存在しない場合に、指定した名前でこのルールが暗黙的に作成されます。

タイプ

文字列

必須

いいえ

デフォルト

イレイジャーコーディングされたプールに **erasure-code** を使用します。複製されたプールの場合は、Ceph 設定からの **osd_pool_default_crush_rule** 変数の値を使用します。

expected-num-objects

説明

プールに必要なオブジェクト数この値を、負の **filestore_merge_threshold** 変数と共に設定すると、Ceph は配置グループをプールの作成時に分割し、ランタイムディレクトリー分割によるレイテンシーの影響を回避します。

型

整数

必須

いいえ

デフォルト

0 (プールの作成時に分割されない)

erasure-code-profile

説明

イレイジャーコーディングされたプールのみの場合。イレイジャーコードプロファイルを使用します。これは、Ceph 設定ファイルの **osd erasure-code-profile set** 変数で定義されている既存のプロファイルでなければなりません。詳細は「コードプロファイルの消去」セクションを参照してください。

タイプ

文字列

必須

いいえ

プールの作成時に、配置グループの数を妥当な値に設定します (例: **100**)。OSD ごとの配置グループの合計数も検討してください。配置グループは計算的に負荷がかかるため、多くの配置グループを持つプールが大量にある場合 (たとえば、100 個の配置グループにそれぞれ 50 プールある場合) は、パフォーマンスが低下します。終了点は、OSD ホストのパワーによって異なります。

プールの適切な配置グループ数を計算する方法は、「配置グループ」セクションおよび「Ceph Placement Groups (PGs) per Pool Calculator」を参照してください。

4.4. プールクォータの設定

プールクォータは、最大バイト数またはプールごとのオブジェクトの最大数、またはその両方に設定できます。

```
ceph osd pool set-quota <pool-name> [max_objects <obj-count>] [max_bytes <bytes>]
```

以下に例を示します。

```
ceph osd pool set-quota data max_objects 10000
```

クォータを削除するには、その値を **0** に設定します。

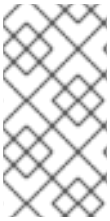

注記

インフライト書き込み操作は、Ceph がプールの使用をクラスター全体の伝播するまで、短時間にプールクォータを過剰に実行する可能性があります。これは通常の動作です。インフライト書き込み操作でプールクォータを適用すると、パフォーマンスが大幅に低下します。

4.5. プールの削除

プールを削除するには、次のコマンドを実行します。

```
ceph osd pool delete <pool-name> [<pool-name> --yes-i-really-really-mean-it]
```

重要

RHCS 3 以降のリリースでは、データを保護するために、管理者はデフォルトでプールを削除することはできません。プールを削除する前に **mon_allow_pool_delete** 設定オプションを設定します。

プールに独自のルールがある場合は、プールの削除後に削除することを検討してください。プールにユーザー自体の使用を厳密に使用する場合は、プールの削除後にそれらのユーザーを削除することを検討してください。

4.6. プールの名前変更

プールの名前を変更するには、次のコマンドを実行します。

```
ceph osd pool rename <current-pool-name> <new-pool-name>
```

プールの名前を変更し、認証されたユーザーのプールごとの機能がある場合は、新しいプール名でユーザー機能 (容量など) を更新する必要があります。

4.7. プールの統計表示

プールの使用状況の統計を表示するには、以下を実行します。

```
rados df
```

4.8. プールのスナップショットを作成

プールのスナップショットを作成するには、次のコマンドを実行します。

```
ceph osd pool mksnap <pool-name> <snap-name>
```

警告

プールスナップショットを作成する場合、プール内で RBD イメージスナップショットを作成できなくなり、これを元に戻せません。

4.9. プールのスナップショットの削除

プールのスナップショットを削除するには、次のコマンドを実行します。

```
ceph osd pool rmsnap <pool-name> <snap-name>
```

4.10. プール値

プールに値を設定するには、次のコマンドを実行します。

```
ceph osd pool set <pool-name> <key> <value>
```

Pool Values セクションでは、設定可能なキーと値のペアをすべて表示します。

4.11. プール値

プールから値を取得するには、以下のコマンドを実行します。

```
ceph osd pool get <pool-name> <key>
```

Pool Values セクションでは、取得可能なキーと値のペアをすべて表示します。

4.12. アプリケーションの有効化

RHCS 3 以降のリリースでは、未承認タイプのクライアントがプールにデータを書き込むことを防ぐために、プールに対する保護を強化します。つまり、システム管理者は、プールが Ceph Block Device、Ceph Object Gateway、Ceph Filesystem、またはカスタムアプリケーションから I/O 操作を受信するように指定する必要があります。

クライアントアプリケーションがプールで I/O 操作を実行できるようにするには、以下を実行します。

```
[root@host ~]# ceph osd pool application enable <poolname> <app> {--yes-i-really-mean-it}
```

<app> は次のとおりです。

- Ceph Filesystem 用の **cephfs**。
- Ceph ブロックデバイス用の **rbd**
- Ceph Object Gateway 用の **rgw**

注記

カスタムアプリケーションに別の **<app>** 値を指定します。

重要

有効ではないプールは、**HEALTH_WARN** ステータスを生成します。このシナリオでは、**ceph health detail -f json-pretty** の出力により、以下が出力されます。

```
{
    "checks": {
        "POOL_APP_NOT_ENABLED": {
            "severity": "HEALTH_WARN",
            "summary": {
                "message": "application not enabled on 1 pool(s)"
            },
            "detail": [
                {
                    "message": "application not enabled on pool '<pool-name>'"
                },
                {
                    "message": "use 'ceph osd pool application enable <pool-name> <app-name>', where
<app-name> is 'cephfs', 'rbd', 'rgw', or freeform for custom applications."
                }
            ]
        }
    },
    "status": "HEALTH_WARN",
```

```
    "overall_status": "HEALTH_WARN",
    "detail": [
        "'ceph health' JSON format has changed in luminous. If you see this your monitoring system is scraping the wrong fields. Disable this with 'mon health preluminous compat warning = false'"
    ]
}
```

注記

rbd pool init <pool-name> を使用して、Ceph ブロックデバイスのプールを初期化します。

4.13. アプリケーションの無効化

プールで I/O 操作を実行するクライアントアプリケーションを無効にするには、以下を実行します。

```
[root@host ~]# ceph osd pool application disable <poolname> <app> {--yes-i-really-mean-it}
```

<app> は次のとおりです。

- Ceph Filesystem 用の **cephfs**。
- Ceph ブロックデバイス用の **rbd**
- Ceph Object Gateway 用の **rgw**

注記

カスタムアプリケーションに別の **<app>** 値を指定します。

4.14. アプリケーションメタデータの設定

RHCS 3 以降のリリースでは、クライアントアプリケーションの属性を説明するキーと値のペアを設定する機能を提供します。

プールでクライアントアプリケーションのメタデータを設定するには、以下を実行します。

```
[root@host ~]# ceph osd pool application set <poolname> <app> <key> <value>
```

<app> は次のとおりです。

- Ceph Filesystem 用の **cephfs**。
- Ceph ブロックデバイス用の **rbd**
- Ceph Object Gateway 用の **rgw**

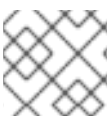

注記

カスタムアプリケーションに別の **<app>** 値を指定します。

4.15. アプリケーションメタデータの削除

プール上のクライアントアプリケーションのメタデータを削除するには、以下を実行します。

```
[root@host ~]# ceph osd pool application set <poolname> <app> <key>
```

<app> は次のとおりです。

- Ceph Filesystem 用の **cephfs**。
- Ceph ブロックデバイス用の **rbd**
- Ceph Object Gateway 用の **rgw**

注記

カスタムアプリケーションに別の **<app>** 値を指定します。

4.16. OBJECT REPLICAS の数の設定

複製されたプールにオブジェクトレプリカ数を設定するには、次のコマンドを実行します。

```
ceph osd pool set <poolname> size <num-replicas>
```

重要

<num-replicas> パラメーターにはオブジェクト自体が含まれます。オブジェクトの合計 3 つのインスタンスについて、オブジェクトとオブジェクトの 2 つのコピーを含める場合は、**3** を指定します。

以下に例を示します。

```
ceph osd pool set data size 3
```

各プールに対してこのコマンドを実行することができます。

注記

オブジェクトは、**pool size** 設定での指定よりも少ないレプリカを持つ低下モードで I/O 操作を受け入れることができます。I/O に必要なレプリカの最小数を設定するには、**min_size** 設定を使用します。以下に例を示します。

```
ceph osd pool set data min_size 2
```

これにより、データプール内のオブジェクトは、**min_size** 設定で指定されたよりも少ないレプリカを持つ I/O を受信しないようになります。

4.17. OBJECT REPLICAS の数を取得します。

オブジェクトレプリカ数を取得するには、以下のコマンドを実行します。

```
ceph osd dump | grep 'replicated size'
```

Ceph はプールを一覧表示し、**replicated size** 属性を強調表示します。デフォルトでは、Ceph はオブジェクトのレプリカを 2 つ (つまり合計 3 つ、またはサイズ **3**) 作成します。

4.18. プール値

以下の一覧には、設定または取得可能なキーと値のペアが含まれます。詳細は、「プール値の設定」および「プール値の取得」を参照してください。

size

説明

プール内のオブジェクトのレプリカ数を指定します。詳細は「オブジェクトレプリカ数の設定」セクションを参照してください。レプリケートされたプールにのみ適用可能です。

タイプ

整数

min_size

説明

I/O に必要なレプリカの最小数を指定します。詳細は「オブジェクトレプリカ数の設定」セクションを参照してください。レプリケートされたプールにのみ適用可能です。

タイプ

整数

crash_replay_interval

説明

クライアントが確認応答を再生できますが、コミットされていないリクエストを再実行できる秒数を指定します。

タイプ

整数

pg-num

説明

プールの現在の配置グループ数。適切な数を計算する方法は 、『Red Hat Ceph Storage 3 設定ガイド』の「プール、PG、および CRUSH 設定リファレンス」セクションを参照してください。デフォルト値 **8** は、ほとんどのシステムには適していません。

型

整数

必須

Yes

デフォルト

8

pgp-num

説明

配置目的の配置グループの合計数。これは、配置グループ分割シナリオを除き、**配置グループの合計数と同じでなければなりません。**

タイプ

整数

必須

Yes指定されていない場合は、デフォルトの Ceph 設定値を選択します。

デフォルト

8

有効な範囲

pg_num 変数で指定された値以下。

crush_rule

説明

クラスター内のオブジェクトの配置にマッピングするために使用するルール。

タイプ

文字列

hashpspool

詳細

指定プールの **HASHPSPOOL** フラグを有効または無効にします。このオプションを有効にすると、プールのハッシュおよび配置グループのマッピングが変更され、プールと配置グループの重複が改善されます。

タイプ

整数

有効な範囲

1 はフラグを有効にし、**0** はフラグを無効にします。

重要

多数の OSD およびデータを持つクラスターの実稼働プールでは、このオプションを有効にしないでください。プール内のすべての配置グループを再マッピングする必要があります。これにより、データの移動が大幅に低下します。

fast_read

説明

イレイジャーコーディングを使用するプールでは、このフラグが有効にされている場合、読み取り要求がすべてのシャードに対して読み取り要求を発行し、クライアントを提供するために十分なシャードを受信するまで待機します。**jerasure** プラグインおよび **isa erasure** プラグインの場合は、最初の K 応答が返されると、クライアントのリクエストは応答からデコードされたデータを即座に使用します。これにより、パフォーマンスを向上させるためにリソースを確保するのに役立ちます。現在、このフラグはイレイジャーコーディングプールにのみサポートされています。

タイプ

ブール値

デフォルト

0

allow_ec_overwrites

説明

イレイジャーコードのプールへの書き込みがオブジェクトの一部を更新できるかどうかで、Ceph ファイルシステムおよび Ceph ブロックデバイスがこれを使用できるようにします。

タイプ

ブール値

バージョン

RHCS 3 以降のみ。

compression_algorithm

説明

BlueStore ストレージバックエンドで使用するインライン圧縮アルゴリズムを設定します。この設定は、**bluestore_compression_algorithm** 設定を上書きします。

型

文字列

有効の設定

lz4、**snappy**、**zlib**、**zstd**

compression_mode

説明

BlueStore ストレージバックエンドのインライン圧縮アルゴリズムのポリシーを設定します。この設定は、**bluestore_compression_mode** 設定を上書きします。

型

文字列

有効の設定

none、**passive**、**aggressive**、**force**

compression_min_blob_size

説明

BlueStore は、このサイズよりも小さいチャンクを圧縮しません。この設定は、**bluestore_compression_min_blob_size** 設定を上書きします。

型

未署名の整数

compression_max_blob_size

詳細

BlueStore は、データを圧縮する前に、このサイズより大きいチャンクを **compression_max_blob_size** の小さなブロブに分割します。

型

未署名の整数

nodelete

詳細

指定されたプールで **NODELETE** フラグを設定または解除します。

型

整数

有効な範囲

1 はフラグを設定します。**0** はフラグの設定を解除します。

nopgchange

詳細

指定したプールに **NOPGCHANGE** フラグを設定または設定解除します。

型

整数

有効な範囲

1 はフラグを設定します。**0** フラグの設定を解除します。

nosizechange

詳細

指定したプールに **NOSIZECHANGE** フラグを設定または設定解除します。

型

整数

有効な範囲

1 はフラグを設定します。**0** フラグの設定を解除します。

write_fadvise_dontneed

詳細

特定のプールの **WRITE_FADVISE_DONTNEED** フラグを設定または解除します。

型

整数

有効な範囲

1 はフラグを設定します。**0** フラグの設定を解除します。

noscrub

詳細

指定したプールに **NOSCRUB** フラグを設定または設定解除します。

型

整数

有効な範囲

1 はフラグを設定します。**0** フラグの設定を解除します。

nodeep-scrub

詳細

指定したプールに **NODEEP_SCRUB** フラグを設定または設定解除します。

型

整数

有効な範囲

1 はフラグを設定します。**0** フラグの設定を解除します。

scrub_min_interval

説明

負荷が低い際のプールスクラビングの最小間隔 (秒単位)。**0** の場合、Ceph は **osd_scrub_min_interval** の設定を使用します。

型

double

デフォルト

0

scrub_max_interval

説明

クラスター負荷のプールスクラビングが最大の間隔 (秒単位)。**0** の場合、Ceph は **osd_scrub_max_interval** の設定を使用します。

型

double

デフォルト

0

deep_scrub_interval

説明

プール 'deep' スクラビングの間隔 (秒単位)。**0** の場合、Ceph は **osd_deep_scrub_interval** の設定を使用します。

型

double

デフォルト

0

第5章 イレイジャーコードプール

Ceph ストレージストラテジーには、データの持続性要件を定義します。データの持続性とは、データが失われることなく、1 つまたは複数の OSD の損失を持続させることができることを意味します。

Ceph は、データをプールに保存します。プールには 2 種類のプールがあります。

- **replicated**
- **erasure-coded**

Ceph はデフォルトで複製されたプールを使用します。これにより、Ceph はすべてのオブジェクトをプライマリー OSD ノードから 1 つ以上のセカンダリー OSD にコピーします。

イレイジャーコーディングされたプールは、データの持続性を確保するのに必要なディスク容量を減らしますが、レプリケーションよりもコストが高くなります。

イレイジャーコーディングは、Ceph ストレージクラスターにオブジェクトを大幅に格納する方法であり、イレイジャーコードアルゴリズムによりオブジェクトがデータチャンク (**k**)、およびコーディングチャンク (**m**) に分割され、これらのチャンクを異なる OSD に保存します。

OSD に障害が発生すると、Ceph は他の OSD から残りのデータ (**k**) およびコーディング (**m**) チャンクを取得し、イレイジャーコードアルゴリズムはこれらのチャンクからオブジェクトを復元します。

注記

Red Hat では、書き込みやデータの損失を防ぐために、イレイジャーコーディングされたプールの **min_size** を **K+2** 以上にすることが推奨します。

イレイジャーコーディングは、レプリケーションよりもストレージ容量をより効率的に使用します。n 個のレプリケーションアプローチは、オブジェクトの **n** 個のコピーを維持するのに対し (Ceph のデフォルトは 3x)、イレイジャーコーディングは **k** + **m** チャンクのみを保持します。たとえば、3 データと 2 つのブロックのチャンクは、元のオブジェクトの 1.5x のストレージ領域を使用します。

イレイジャーコーディングはレプリケーションと比べてストレージのオーバーヘッドが少なく、イレイジャーコードアルゴリズムは、オブジェクトへのアクセスや復旧時に、レプリケーションよりも多くの RAM および CPU を使用します。イレイジャーコーディングは、データストレージが永続的であり、耐障害性になければならないものの、高速な読み取り (たとえば、コールドマイグレーションストレージ、履歴レコードなど) を必要としない場合に役立ちます。

Ceph でのイレイジャーコード **がどのように機能するかの詳細は、Red Hat Ceph Storage 3 の『アーキテクチャーガイド』 の「イレイジャーコード I/O**」セクションを参照してください。

k=2 および **m=1** を使用してクラスターを初期化する際に、Ceph は **デフォルト** のイレイジャーコードプロファイルを作成します。つまり、Ceph は 3 つの OSD (**k+m == 3**) にオブジェクトデータを分散し、Ceph がこれらの OSD のいずれかを、データを失うことなく失う可能性があることを意味します。イレイジャーコードのプロファイリングの詳細は、「イレイジャーコードのプロファイル」を参照してください。

重要

.rgw.buckets プールのみをイレイジャーコーディング済みとして設定し、その他のすべての Ceph Object Gateway プールをレプリケート済みとして設定すると、新しいバケットを作成しようとすると以下のエラーで失敗します。

```
set_req_state_err err_no=95 resorting to 500
```

このため、イレイジャーコーディングされたプールは **omap** 操作をサポートしません。特定の Ceph Object Gateway メタデータプールには **omap** サポートが必要です。

5.1. サンプルでコーディングされたプールの作成

最も簡単なイレイジャーコードプールは RAID5 と同等で、少なくとも 3 台のホストが必要です。

```
$ ceph osd pool create ecpool 50 50 erasure
pool 'ecpool' created
$ echo ABCDEFGHI | rados --pool ecpool put NYAN -
$ rados --pool ecpool get NYAN -
ABCDEFGHI
```

注記

pool create の 50 は配置グループの数を表します。

5.2. イレイジャーコードプロファイル

Ceph は、**プロファイル** でイレイジャーコーディングされたプールを定義します。Ceph は、イレイジャーコーディングされたプールおよび関連する CRUSH ルールを作成する際にプロファイルを使用します。

Ceph は、クラスターを初期化する時にデフォルトのイレイジャーコードプロファイルを作成し、レプリケートされたプール内の 2 つのコピーと同じレベルの冗長性を提供します。ただし、25% 未満のストレージ容量を使用します。デフォルトのプロファイルは **k=2** および **m=1** を定義します。Ceph はオブジェクトデータを 3 つの OSD (**k+m=3**) に分散し、Ceph はデータを損失することなくこれらの OSD のいずれかを失う可能性があります。

デフォルトの元号付けコードプロファイルでは、1 つの OSD の損失を回避できます。これは 2 サイズが 2 つある複製されたプールと同等ですが、データ 1 TB を保存するには 1.5 TB ではなく 1.5 TB が必要になります。デフォルトのプロファイルを表示するには、以下のコマンドを使用します。

```
$ ceph osd erasure-code-profile get default
directory=.libs
k=2
m=1
plugin=jerasure
crush-failure-domain=host
technique=reed_sol_van
```

Raw ストレージ要件を増加させずに冗長性を強化するために、新規プロファイルを作成できます。たとえば、**k=8** と **m=4** のプロファイルでは、12 個の (**k+m=12**) OSD オブジェクトを配布することで、4 個の (**m=4**) OSD が失われないようにすることができます。Ceph はオブジェクトを **8** つのチャンクに分割し、リカバリー用に **4** つのコーディングチャンクを計算します。たとえば、オブジェクトサイズが 8

MB の場合、各データチャンクが 1 MB で、各データチャンクのサイズは 1 MB であり、各データチャンクのサイズは 1 MB でも同じサイズになります。4 つの OSD が同時に失敗した場合でも、このオブジェクトは失われません。

プロファイルで最も重要なパラメーターは、ストレージのオーバーヘッドとデータの永続性を定義するため、**k**、**m**、および **crush-failure-domain** です。

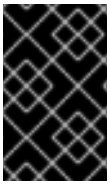

重要

プールの作成後にプロファイルを変更できないため、正しいプロファイルの選択は重要です。プロファイルを変更するには、別のプロファイルで新しいプールを作成し、オブジェクトを古いプールから新しいプールに移行する必要があります。

たとえば、目的のアーキテクチャーがストレージオーバーヘッドの 40% オーバーヘッドの 2 つのラックが失われなければならない場合、以下のプロファイルを定義することができます。

```
$ ceph osd erasure-code-profile set myprofile \
   k=4 \
   m=2 \
   crush-failure-domain=rack
$ ceph osd pool create ecpool 12 12 erasure *myprofile*
$ echo ABCDEFGHIJKL | rados --pool ecpool put NYAN -
$ rados --pool ecpool get NYAN -
ABCDEFGHIJKL
```

プライマリー OSD は、**NYAN** オブジェクト を 4 つ (**k=4**) のデータチャンクに分割し、2 つの追加のチャンク (**m=2**) を作成します。**m** の値は、データを失うことなく同時に失われた OSD の数を定義します。**crush-failure-domain=rack** は、2 つのチャンクが同じラックに保存されないように CRUSH ルールを作成します。

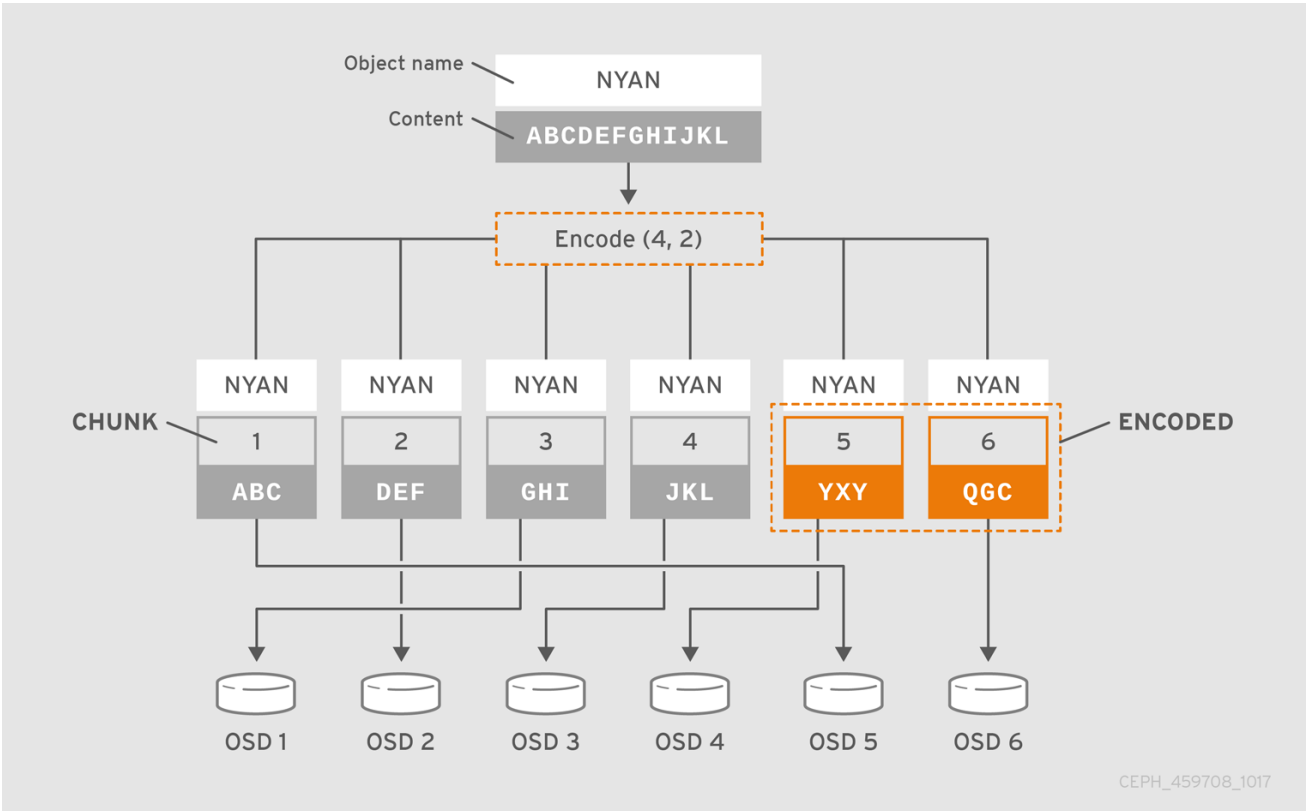

重要

Red Hat は、**k** および **m** に以下の jerasure コーディング値をサポートしています。

- k=8 m=3
- k=8 m=4
- k=4 m=2

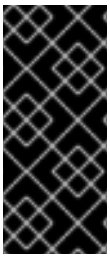

重要

失われた OSD の数がコーディングチャンクの数 (**m**) と同等である場合、イレイジャーコーディングプールの一部の配置グループは不完全な状態になります。失われた OSD の数が **m** 未満の場合、配置グループは不完全な状態になりません。いずれの場合も、データの損失は発生しません。配置グループが不完全な状態の場合は、イレイジャーコード化されたプールの **min_size** を一時的に縮小することで復元が可能になります。

5.2.1. OSD erasure-code-profile Set

新しい元号のコードプロファイルを作成するには、以下の手順を実施します。

```
ceph osd erasure-code-profile set <name> \
     [<directory=directory>] \
     [<plugin=plugin>] \
     [<stripe_unit=stripe_unit>] \
     [<crush-device-class>]\
     [<crush-failure-domain>]\
     [<key=value> ...] \
     [--force]
```

詳細は以下のようになります。

directory

説明

イレイジャーコードプラグインが読み込まれた **ディレクトリー** 名を設定します。

タイプ

文字列

必須

いいえ

デフォルト

/usr/lib/ceph/erasure-code

プラグイン

説明

イレイジャーコードプラグインを使用して、コーディングしたチャンクを計算して、欠落しているチャンクを回復します。詳細は「イレイジャーコードのプラグイン」セクションを参照してください。

タイプ

文字列

必須

いいえ

デフォルト

jerasure

stripe_unit

説明

ストライプごとにデータチャンクのデータの量。たとえば、2 つのデータチャンクと **stripe_unit=4K** のプロファイルでは、範囲 0 ~ 4,000 がチャンク 0 に設定され、4,000 ~ 8,000 がチャンク 1 に、8,000 ~ 12,000 がチャンク 0 に再び設定されます。最高のパフォーマンスを得るためには、4K の倍数である必要があります。デフォルト値は、プールの作成時に監視設定オプション **osd_pool_erasure_code_stripe_unit** から取得されます。このプロファイルを使用するプールの stripe_width は、この **stripe_unit** で乗算したデータチャンクの数になります。

型

文字列

必須

いいえ

デフォルト

4K

crush-device-class

詳細

hdd、**ssd** などのデバイスクラス。RHCS 3 以降でのみ利用可能です。

タイプ

文字列

必須

いいえ

デフォルト

none (CRUSH がクラスに関係なくすべてのデバイスを使用することを意味します)。

crush-failure-domain

詳細

host、**rack** などの障害ドメイン。

型

文字列

必須

いいえ

デフォルト

host

key

説明

残りのキーと値のペアのセマンティックは、イレイジャーコードプラグインによって定義されます。

タイプ

文字列

必須

No

--force

説明

同じ名前で既存のプロファイルを上書きします。

タイプ

文字列

必須

いいえ

5.2.2. OSD erasure-code-profile Remove

イレイジャーコードプロファイルを削除するには、以下のコマンドを実行します。

```
ceph osd erasure-code-profile rm <name>
```

プロファイルがプールで参照される場合、削除は失敗します。

5.2.3. OSD erasure-code-profile Get

イレイジャーコードプロファイルを表示するには、以下のコマンドを実行します。

```
ceph osd erasure-code-profile get <name>
```

5.2.4. OSD erasure-code-profile List

イレイジャーコードプロファイルの名前を一覧表示するには、以下のコマンドを実行します。

```
ceph osd erasure-code-profile ls
```

5.3. 上書きによるイレイジャーコーディング（テクノロジープレビュー）

デフォルトでは、イレイジャーコーディングのプールは Ceph Object Gateway でのみ機能します。これにより、全オブジェクト書き込みを実行し、追記します。Red Hat Ceph Storage 3 では、イレイジャーコード化されたプールの部分的な書き込みをプールごとに有効にできます。

上書きによるイレイジャーコードプールを使用すると、Ceph のブロックデバイスと CephFS は、イレイジャーコードプールにデータを保存できます。

構文

```
ceph osd pool set <erasure_coded_pool_name> allow_ec_overwrites true
```

例

```
$ ceph osd pool set ec_pool allow_ec_overwrites true
```

上書きによるイレイジャーコードプールを有効にすることで、BlueStore OSD を使用するプールにしか存在できません。BlueStore のチェックサムは、ディレップスクラブ中にビットロットやその他の破損を検出するために使用されます。イレイジャーコードによる FileStore の使用は安全でないため、BlueStore と比較してパフォーマンスが低下します。

イレイジャーコードプールは omap をサポートしません。Ceph Block Devices および CephFS で元号のコードプールを使用するには、イレイジャーコードプールにデータを、複製プールにメタデータを保存します。

Ceph ブロックデバイスの場合は、イメージの作成時に **--data-pool** オプションを使用します。

構文

```
rbd create --size <image_size>M|G|T --data-pool <erasure_coded_pool_name>
<replicated_pool_name>/<image_name>
```

例

```
$ rbd create --size 1G --data-pool ec_pool rep_pool/image01
```

CephFS にイレイジャーコードプールを使用している場合には、ファイルレイアウトで上書きを設定する必要があります。

5.4. イレイジコードプラグイン

Ceph では、プラグインアーキテクチャーとのイレイジャーコーディングがサポートされます。つまり、さまざまなタイプのアルゴリズムを使用して、イレイジャーコードプールを作成できます。Ceph では、以下がサポートされています。

- Jerasure (デフォルト)
- ローカルに修復可能
- ISA (Intel のみ)

以下のセクションでは、これらのプラグインの詳細を説明します。

5.4.1. Jerasure Erasure コードプラグイン

jerasure プラグインは、最も汎用的で柔軟性のあるプラグインです。Ceph Erasure コードプールのデフォルトでもあります。

jerasure プラグインは JerasureH ライブラリーをカプセル化します。パラメーターの詳細は、**jerasure** のドキュメントを参照してください。

jerasure プラグインを使用して新しいイレイジャーコードプロファイルを作成するには、以下のコマンドを実行します。

```
ceph osd erasure-code-profile set <name> \
    plugin=jerasure \
    k=<data-chunks> \
    m=<coding-chunks> \
```

```
    technique=
<reed_sol_van|reed_sol_r6_op|cauchy_orig|cauchy_good|liberation|blaum_roth|liber8tion> \
    [crush-root=<root>] \
    [crush-failure-domain=<bucket-type>] \
    [directory=<directory>] \
    [--force]
```

詳細は以下のようになります。

k

説明

各オブジェクトは **data-chunks** の部分で分割され、それぞれが異なる OSD に保管されます。

タイプ

整数

必須

Yes

例

4

m

説明

各オブジェクトの **コーディングチャンク** を計算し、それらを異なる OSD に保存します。コーディングのチャンクの数は、データが失われることなくダウンできる OSD 数でもあります。

タイプ

整数

必須

Yes

例

2

テクニック

説明

より柔軟な技術は **reed_sol_van** で、**k** と **m** を設定するだけで十分です。**cauchy_good** 技術は速くなりますが、慎重に **packetsize** を選択する必要があります。**reed_sol_r6_op**、**liberation**、**blaum_roth**、**liber8tion** はすべて、**m=2** でしか設定できない意味で **RAID6** と同等です。

タイプ

文字列

必須

No

有効なセット

reed_sol_van reed_sol_r6_op cauchy_orig cauchy_good liberation blaum_roth liber8tion

デフォルト

reed_sol_van

packetsize

説明

エンコーディングは、**バイト** サイズのパケットで一度に行われます。適切なパケットサイズの選択は困難です。**jerasure** ドキュメントには、このトピックに関する詳細な情報が記載されています。

タイプ

整数

必須

いいえ

デフォルト

2048

crush-root

説明

ルールの最初のステップに使用される CRUSH バケットの名前。たとえば、**step take default** となります。

タイプ

文字列

必須

いいえ

デフォルト

default

crush-failure-domain

説明

同じ障害ドメインを持つバケットに 2 つのチャンクがないことを確認します。たとえば、障害ドメインが **ホスト** の場合、2 つのチャンクは同じホストに保存されません。これは、**step chooseleaf host** などのルールステップを作成するのに使用します。

タイプ

文字列

必須

いいえ

デフォルト

host

directory

説明

イレイジャーコードプラグインが読み込まれた **ディレクトリー** 名を設定します。

タイプ

文字列

必須

いいえ

デフォルト

/usr/lib/ceph/erasure-code

--force

説明

同じ名前で既存のプロファイルを上書きします。

タイプ

文字列

必須

No

5.4.2. ローカルに修復可能な Erasure Code (LRC) プラグイン

jerasure プラグインでは、Ceph が複数の OSD にイレイジャーコーディングされたオブジェクトを保存する際に、1 つの OSD が失われた場合からの復元には、他のすべての OSD からの読み取りが必要です。たとえば、**k=8** および **m=4** で **jerasure** を設定する場合は、OSD の 1 つの OSD が失われると、修復のために他の 11 個から読み取る必要があります。

lrc イレイジャーコードプラグインは、少ない OSD を使用して復元できるようにローカルパリティーチャンクを作成します。たとえば、**k=8**、**m=4**、および **l=4** で **lrc** を設定する場合は、4 つの OSD ごとに追加のパリティーチャンクが作成されます。Ceph が単一の OSD を失うと、そのオブジェクトデータを eleven ではなく 4 つの OSD のみで復旧できます。

すべてのホストが同じスイッチに接続されている場合はおそらく関心のあるユースケースではありませんが、**lrc** イレイジャーコードプラグインを使用する際に、ラック間の帯域幅使用量の使用量を低減することができます。

```
$ ceph osd erasure-code-profile set LRCprofile \
    plugin=lrc \
    k=4 m=2 l=3 \
    crush-failure-domain=host
$ ceph osd pool create lrcpool 12 12 erasure LRCprofile
```

1.2 バージョンでは、プライマリー OSD が失われたチャンクと同じラックにある場合に限り、帯域幅を低下させることができます。

```
$ ceph osd erasure-code-profile set LRCprofile \
    plugin=lrc \
    k=4 m=2 l=3 \
    crush-locality=rack \
    crush-failure-domain=host
$ ceph osd pool create lrcpool 12 12 erasure LRCprofile
```

5.4.2.1. LRC プロファイルの作成

新しい LRC Erasure コードプロファイルを作成するには、以下のコマンドを実行します。

```
ceph osd erasure-code-profile set <name> \
    plugin=lrc \
    k=<data-chunks> \
    m=<coding-chunks> \
    l=<locality> \
    [crush-root=<root>] \
    [crush-locality=<bucket-type>] \
```

```
[crush-failure-domain=<bucket-type>] \
[directory=<directory>] \
[--force]
```

詳細は以下のようになります。

k

説明

各オブジェクトは **data-chunks** の部分で分割され、それぞれが異なる OSD に保管されます。

タイプ

整数

必須

Yes

例

4

m

説明

各オブジェクトの **コーディングチャンク** を計算し、それらを異なる OSD に保存します。コーディングのチャンクの数は、データが失われることなくダウンできる OSD 数でもあります。

タイプ

整数

必須

Yes

例

2

l

説明

コーディングとデータチャンクをサイズの **局所性** のセットにグループ化します。たとえば、**k=4** および **m=2** で **locality=3** の場合は、3 つのグループが 2 つ作成されます。各セットは、別のセットからチャンクを読み込まなくても、復旧できます。

タイプ

整数

必須

Yes

例

3

crush-root

説明

ルールの最初のステップに使用される crush バケットの名前。たとえば、**step take default** となります。

タイプ

文字列

必須

いいえ

デフォルト

default

CRUSH-locality

説明

l で定義される各チャンクのセットの crush バケットのタイプが保存されます。たとえば、 **rack** に設定すると、l チャンクの各グループは異なるラックに配置されます。これは、**step choose rack** などのルールステップを作成するために使用されます。設定されていない場合、そのようなグループ化は行われません。

タイプ

文字列

必須

No

crush-failure-domain

説明

同じ障害ドメインを持つバケットに 2 つのチャンクがないことを確認します。たとえば、障害ドメインが **ホスト** の場合、2 つのチャンクは同じホストに保存されません。これは、**step chooseleaf host** などのルールステップを作成するのに使用します。

タイプ

文字列

必須

いいえ

デフォルト

host

directory

説明

イレイジャーコードプラグインが読み込まれた **ディレクトリー** 名を設定します。

タイプ

文字列

必須

いいえ

デフォルト

/usr/lib/ceph/erasure-code

--force

説明

同じ名前で既存のプロファイルを上書きします。

タイプ

文字列

必須

No

5.4.2.2. 低レベル LRC プロファイルの作成

k および **m** の合計は、**l** パラメーターの倍数でなければなりません。低レベル設定パラメーターはこのような制限を課さないため、特定の目的で使用する方が便利です。たとえば、4 つのチャンクがあるグループと、3 つのチャンクを持つ 2 つのグループを定義できます。また、インスタンスデータセンターやラックなど、局所性セットをデータセンターに再帰的で定義することもできます。**k/m/l** は、低レベルの設定を生成することで実装されます。

lrc イレイジャーコードプラグインは、イレイジャーコード技術を再帰的に適用し、一部のチャンクの失われた状態を回復するには、ほとんどの場合は、利用可能なチャンクのサブセットのみが必要になります。

たとえば、3 つのコーディングのステップを以下に説明します。

```
chunk nr    01234567
step 1      _cDD_cDD
step 2      cDDD____
step 3      ____cDDD
```

c がデータチャンク **D** から計算したチャンクをコーディングする場合、チャンク **7** の損失は、最後の 4 つのチャンクを使用して復元できます。chun **2** チャンクが失われると、最初の 4 つのチャンクを使用して復元できます。

最小のテストシナリオは、デフォルトの erasure-code プロファイルの使用を厳密に同等です。**DD** は **K=2** を意味し、**c** は **M=1** を意味し、デフォルトで **jerasure** プラグインを使用します。

```
$ ceph osd erasure-code-profile set LRCprofile \
    plugin=lrc \
    mapping=DD_ \
    layers='[ [ "DDc", "" ] ]'
$ ceph osd pool create lrcpool 12 12 erasure LRCprofile
```

lrc プラグインは、ラック間の帯域幅の使用量を減らすのに特に便利です。すべてのホストが同じスイッチに接続されている場合に、ユースケースが考慮されないかもしれませんが、帯域幅の使用量は実際に確認される可能性があります。チャンクのレイアウトは異なりますが、**k=4**、**m=2**、および **l=3** と同等です。

```
$ ceph osd erasure-code-profile set LRCprofile \
    plugin=lrc \
    mapping=__DD__DD \
    layers='[
            [ "_cDD_cDD", "" ],
            [ "cDDD____", "" ],
            [ "____cDDD", "" ],
          ]'
$ ceph osd pool create lrcpool 12 12 erasure LRCprofile
```

Firefly では、プライマリー OSD が失われたチャンクと同じラックにある場合にのみ、帯域幅が減少します。

```
$ ceph osd erasure-code-profile set LRCprofile \
    plugin=lrc \
```

```
    mapping=__DD__DD \
    layers='[
            [ "_cDD_cDD", "" ],
            [ "cDDD____", "" ],
            [ "____cDDD", "" ],
          ]' \
    crush-steps='[
                  [ "choose", "rack", 2 ],
                  [ "chooseleaf", "host", 4 ],
                 ]'
$ ceph osd pool create lrcpool 12 12 erasure LRCprofile
```

LRC は、デフォルトの EC バックエンドとして **jerasure** を使用するようになりました。低レベル設定を使用して、レイヤーごとに EC バックエンドおよびアルゴリズムを指定することができます。layers='[["DDc", ""]]' の 2 つ目の引数は、実際にこのレベルに使用するイレイジャーのコードプロファイルです。以下の例は、lrcpool で使用する Cauchy 手法を含む ISA バックエンドを示しています。

```
$ ceph osd erasure-code-profile set LRCprofile \
    plugin=lrc \
    mapping=DD_ \
    layers='[ [ "DDc", "plugin=isa technique=cauchy" ] ]'
$ ceph osd pool create lrcpool 12 12 erasure LRCprofile
```

レイヤーごとに異なるイレイジャーコードプロファイルを使用することもできます。

```
$ ceph osd erasure-code-profile set LRCprofile \
    plugin=lrc \
    mapping=__DD__DD \
    layers='[
            [ "_cDD_cDD", "plugin=isa technique=cauchy" ],
            [ "cDDD____", "plugin=isa" ],
            [ "____cDDD", "plugin=jerasure" ],
          ]'
$ ceph osd pool create lrcpool 12 12 erasure LRCprofile
```

5.4.3. CRUSH 配置の制御

デフォルトの CRUSH ルールは、異なるホストにある OSD を提供します。たとえば、以下のようになります。

```
chunk nr    01234567

step 1      _cDD_cDD
step 2      cDDD____
step 3      ____cDDD
```

各チャンクに 1 つずつ、正確に **8** つの OSD が必要です。ホストが 2 つ隣り合ったラックにある場合は、最初の 4 つのチャンクを最初のラックに配置し、残りを 2 番目のラックに配置できます。1 つの OSD の失われた状態からのリカバリーには、2 つのラック間で帯域幅を使用する必要はありません。

たとえば、以下のようになります。

```
crush-steps='[ [ "choose", "rack", 2 ], [ "chooseleaf", "host", 4 ] ]'
```

rack タイプのクラッシュバケットを 2 つ選択し、それぞれに 4 つの OSD (タイプ **host** の異なるバケットに配置) を選択するルールを作成します。

また、細かい制御のためにルールを手動で作成することもできます。

5.5. ISA イレイジャーコードプラグイン

isa プラグインは ISA ライブラリーをカプセル化します。Intel プロセッサーでのみ実行されます。

isa プラグインを使用して新しいイレイジャーコードプロファイルを作成するには、以下のコマンドを実行します。

```
ceph osd erasure-code-profile set <name> \
    plugin=isa \
    technique=<reed_sol_van|cauchy> \
    [k=<data-chunks>] \
    [m=<coding-chunks>] \
    [crush-root=<root>] \
    [crush-failure-domain=<bucket-type>] \
    [directory=<directory>] \
    [--force]
```

詳細は以下のようになります。

テクニック

説明

ISA プラグインは、Reed Solomon フォームの 2 つとなります。**reed_sol_van** を設定すると、Vandermonde になります。**cauchy** を設定すると、Cauchy になります。

タイプ

文字列

必須

No

有効の設定

reed_sol_van cauchy

デフォルト

reed_sol_van

k

説明

各オブジェクトは **data-chunks** の部分で分割され、それぞれが異なる OSD に保管されます。

タイプ

整数

必須

いいえ

デフォルト

7

m

説明

各オブジェクトの **コーディングチャンク** を計算し、それらを異なる OSD に保存します。コーディングのチャンクの数は、データが失われることなくダウンできる OSD 数でもあります。

タイプ

整数

必須

いいえ

デフォルト

3

crush-root

説明

ルールの最初のステップに使用される crush バケットの名前。たとえば、**step take default** となります。

タイプ

文字列

必須

いいえ

デフォルト

default

crush-failure-domain

説明

同じ障害ドメインを持つバケットに 2 つのチャンクがないことを確認します。たとえば、障害ドメインが **ホスト** の場合、2 つのチャンクは同じホストに保存されません。これは、**step chooseleaf host** などのルールステップを作成するのに使用します。

タイプ

文字列

必須

いいえ

デフォルト

host

directory

説明

イレイジャーコードプラグインが読み込まれた **ディレクトリー** 名を設定します。

タイプ

文字列

必須

いいえ

デフォルト

/usr/lib/ceph/erasure-code

--force

説明

同じ名前で既存のプロファイルを上書きします。

タイプ

文字列

必須

No

5.6. PYRAMID イレイジャーコード

Pyramid イレイジャーコードは、データのアクセスとリカバリーを向上させるために、元のイレイジャーコードアルゴリズムに基づいて、非常に改善されたアルゴリズムになりました。これは単に、任意の (n, k) に対して **Reed-Solomon** のような既存の MDS (Maximum Curve Separable) コードを判別するだけです。ここで、**k** はデータチャンクの元の数で、**n** はコーディングプロセス後のデータチャンクの合計数です。Pyramid コードは標準の MDS コードをベースとしているため、エンコーディング/デコードアプローチと同じです。pyramid コーディングされたデータプールには、同じ書き込みオーバーヘッドがあり、通常のイレッジャーコードプールなどの任意の障害などのリカバリーが可能です。pyramid コードの利点は、通常のイレイジャーコードと比べると、オーバーヘッドを大幅に削減することです。

(11、8) イレイジャーコードプールの例を考えて、pyramid コードアプローチをこれに適用します。イレッチャーコード (11, 8) の元号を、(12, 8) の Pyramid コードプールに変換します。イレイジャーコード化されたプールには **8** 個のデータチャンク、**11 - 8 = 3** の冗長チャンクがあります。Pyramid コードは、8 データチャンクを 2 つのサイズグループ (例: P1 = {a1, a2, a3, a4} および P2 = {a5, a6, a7, a8}. に分割します。イレイジャーコードから冗長なチャンクが 2 つ変更されない (b2 と b3) の 2 つを維持します。これら 2 つのチャンクは、すべての 8 データチャンクに対応するため、グローバルな冗長チャンクと呼ばれます。次に、グループ P1 に対して新たな冗長チャンクが計算されます。これはグループ (またはローカル) の冗長チャンク b1,1 として示されます。この計算は、P2 にあるすべてのデータチャンクを 0 に設定する場合を除き、元のイレイジャーコードで b1 の計算用として行われます。同様に、グループ冗長チャンク b1,2 は P2 用に計算されます。グループ冗長チャンクは、対応するグループのデータチャンクにのみ影響し、他のグループには影響を及ぼしません。グループ冗長チャンクは、イレイジャーコード内の元の冗長チャンクのプロジェクト地点として解釈できます。つまり、b1,1 + b1,2 = b1 です。したがって、この方法では、1 つのデータチャンクが失敗した場合は、通常のイレイジャーコードプール用に 8 ではなく、4 の読み取りオーバーヘッドを使用して復旧できます。たとえば、**P1** の **a3** に障害が発生し、**a1** がスクラビングの代表的な OSD である場合は **P2** からの読み取りではなく、**a1**、**a2**、**a4**、および **b1,1** を使用して **a3** を回復できます。すべてのチャンクを読み取ることは、同じグループに複数のチャンクが欠落している場合にのみ必要になります。

この Pyramid コードには、元のイレイジャーコードと同じ書き込みのオーバーヘッドがあります。データチャンクが更新されるたびに、Pyramid コードには 3 つの冗長チャンク (b2、b3、そして b1,1 または b1,2 のいずれか) を更新する必要がありますが、イレイジャーコードが 3 つの冗長なチャンク (b1、b2、および b3) を更新します。また、通常のイレイジャーコードと同じ 3 つの元号を回復することもできます。上述の利点は、1 つの冗長チャンクを使用するコストがかかるため、オーバーヘッドが少なくなります。したがって、Pyramid コードは、アクセス効率に対するストレージ領域をトレードオフします。

以下の図は、構築された pyramid コードを示しています。

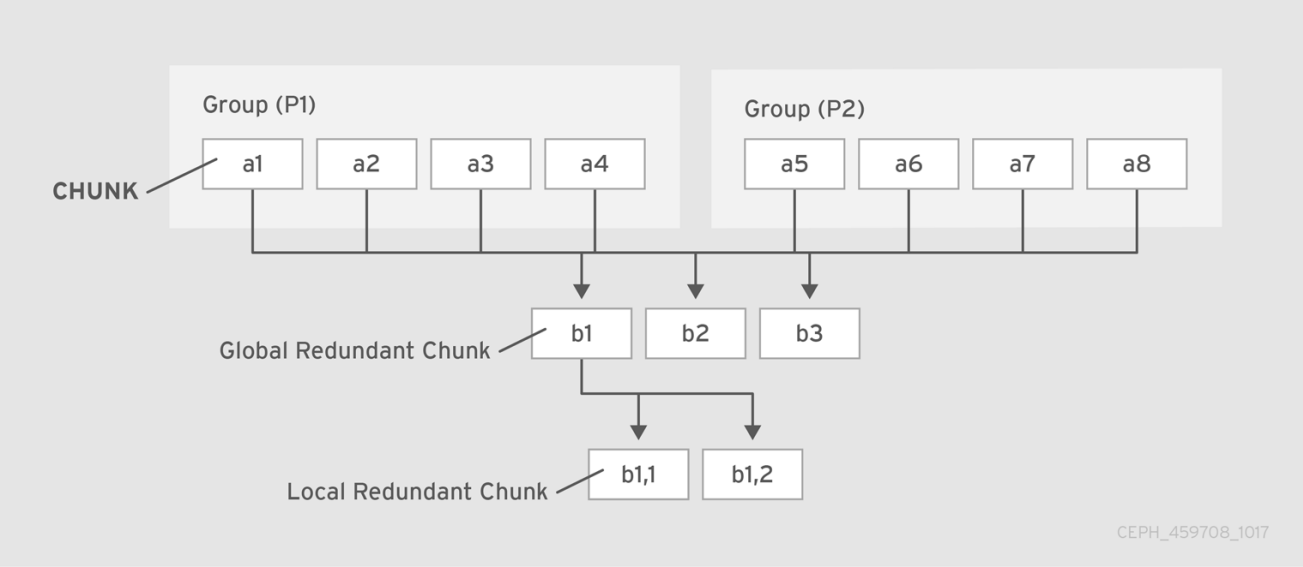
Group (P1)
Group (P2)
CHUNK
a1
a2
a3
a4
a5
a6
a7
a8
Global Redundant Chunk
b1
b2
b3
Local Redundant Chunk
b1,1
b1,2
CEPH_459708_1017