



[AWS Black Belt Online Seminar] Amazon Redshift 運用管理

サービスカットシリーズ

Solutions Architect 平間 大輔
2021/1/27

AWS 公式 Webinar
<https://amzn.to/JPWebinar>



過去資料
<https://amzn.to/JPArchive>



AWS Black Belt Online Seminar とは

「サービス別」「ソリューション別」「業種別」のそれぞれのテーマに分かれて、アマゾンウェブ サービス ジャパン株式会社が主催するオンラインセミナーシリーズです。

質問を投げることができます！

- 書き込んだ質問は、主催者にしか見えません
- 今後のロードマップに関するご質問はお答えできませんのでご了承下さい

- ① 吹き出しをクリック
- ② 質問を入力
- ③ Sendをクリック



Twitter ハッシュタグは以下をご利用ください
#awsblackbelt

内容についての注意点

本資料では2021年1月27日現在のサービス内容および価格についてご説明しています。最新の情報はAWS公式ウェブサイト(<http://aws.amazon.com>)にてご確認ください。

資料作成には十分注意しておりますが、資料内の価格とAWS公式ウェブサイト記載の価格に相違があった場合、AWS公式ウェブサイトの価格を優先とさせていただきます。

価格は税抜表記となっております。日本居住者のお客様には別途消費税をご請求させていただきます。

AWS does not offer binding price quotes. AWS pricing is publicly available and is subject to change in accordance with the AWS Customer Agreement available at <http://aws.amazon.com/agreement/>. Any pricing information included in this document is provided only as an estimate of usage charges for AWS services based on certain information that you have provided. Monthly charges will be based on your actual use of AWS services, and may vary from the estimates provided.

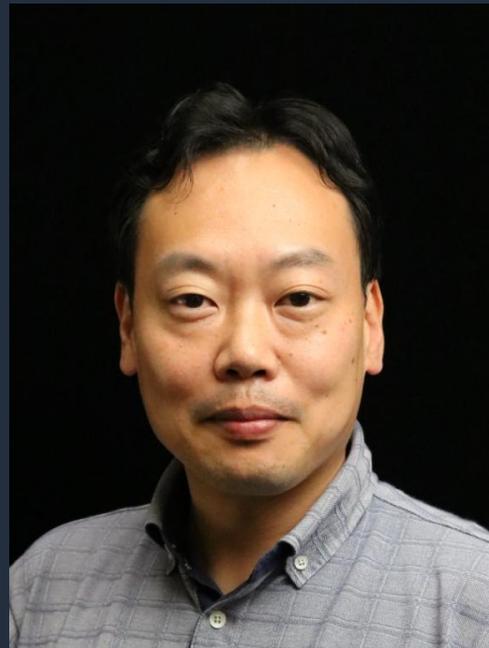
自己紹介

平間 大輔

アマゾン ウェブ サービス ジャパン
ソリューションアーキテクト
アナリティクス分野の技術支援を担当

好きなAWSサービス

- Amazon Redshift
- Amazon QuickSight
- AWS Glue



本日のアジェンダ

- Amazon Redshiftとは
- Amazon Redshiftを使ってみる
- 自動化された運用タスク
- モニタリングと性能改善
- 利用者の増加に対処する
- データ連携はどのように行うか

Amazon Redshift とは

AWS 公式 Webinar

<https://amzn.to/JPWebinar>

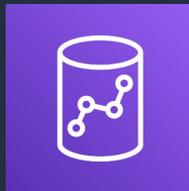
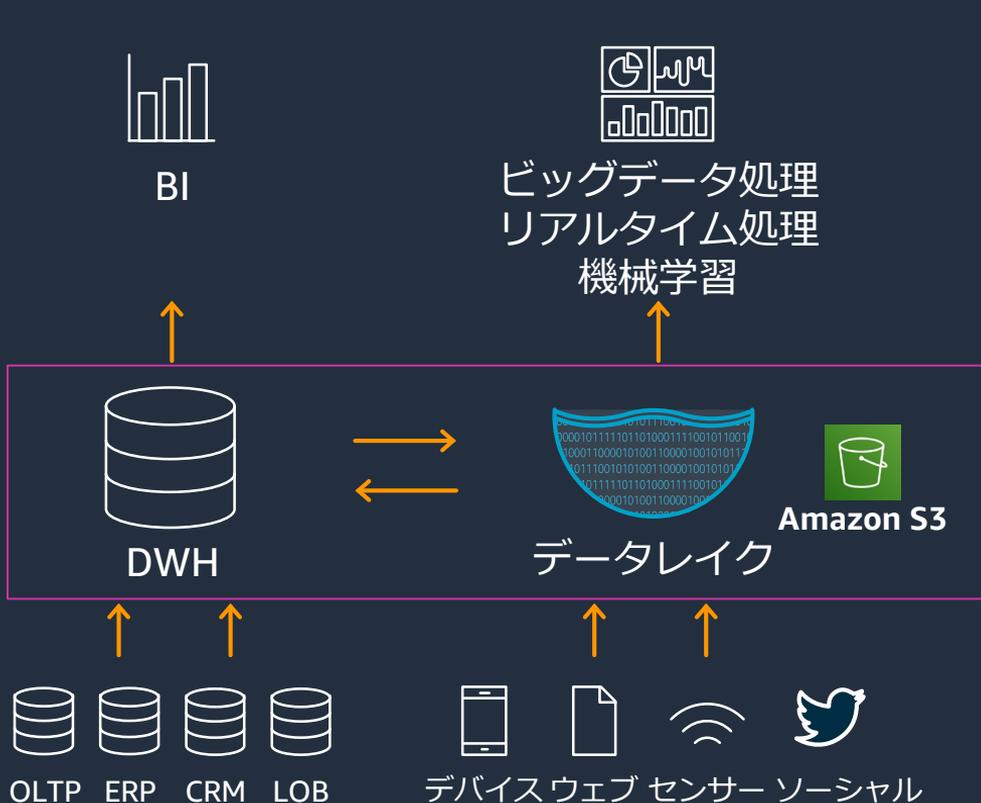


過去資料

<https://amzn.to/JPArchive>



Amazon Redshift とは



Amazon Redshift

高速、スケーラブルで
費用対効果の高い
データウェアハウス
およびデータレイク
分析マネージドサービス

Amazon Redshiftは 分析用クエリ実行に特化したRDBMS

分析ワークロードに特化

- 列指向ストレージ
- 並列分散処理
- PostgreSQL互換のSQL

柔軟なクラスタ構成

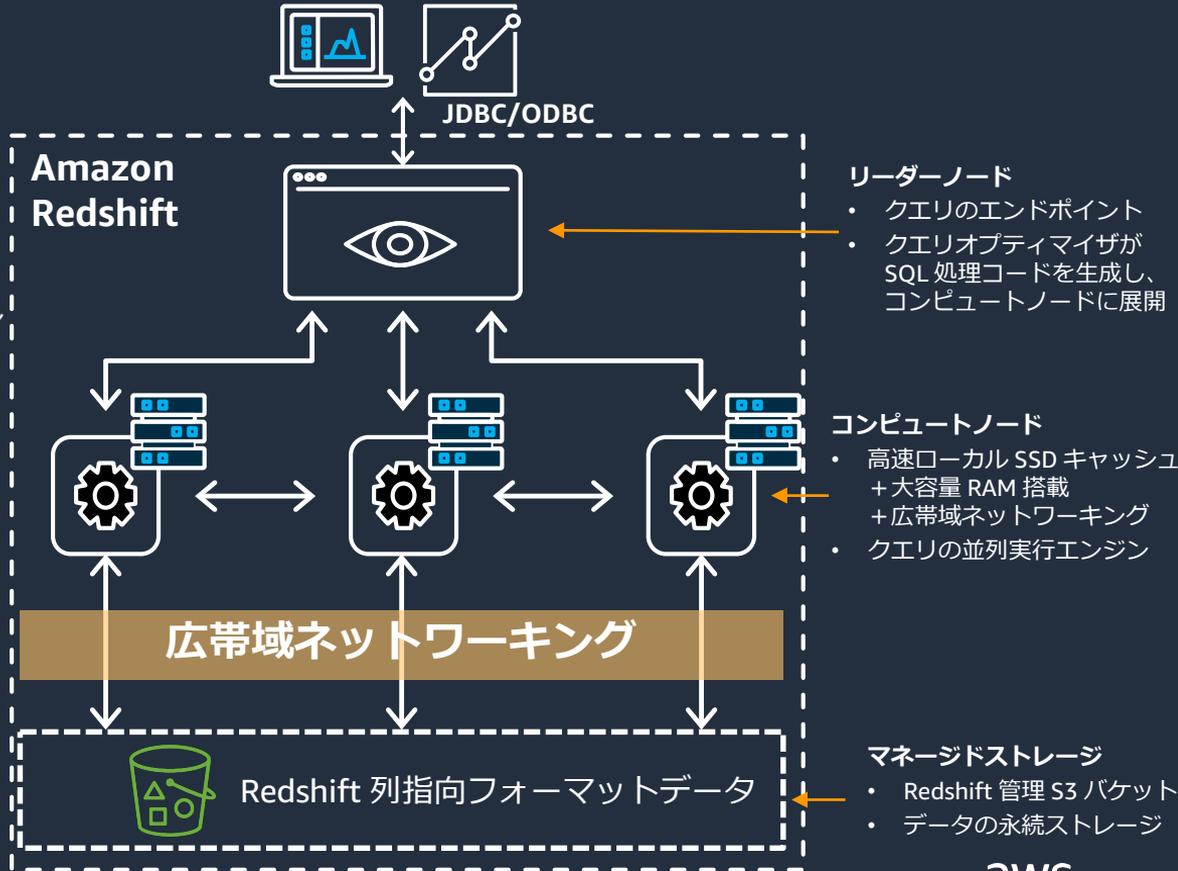
- コンピュートノードの追加で処理能力をスケール
- マネージドストレージにより、データ量増大をノード追加なく対処可能

自動的にワークロードを最適化

- テーブルメンテナンスの自動化
- 分散、ソートキーの自動設定
- クエリへのリソース割当を自動で最適化

追加の手動チューニングも可能

- 圧縮、分散、ソート、マテリアライズドビュー
- クエリの優先度設定
- チューニングのヒントは自動でアドバイス

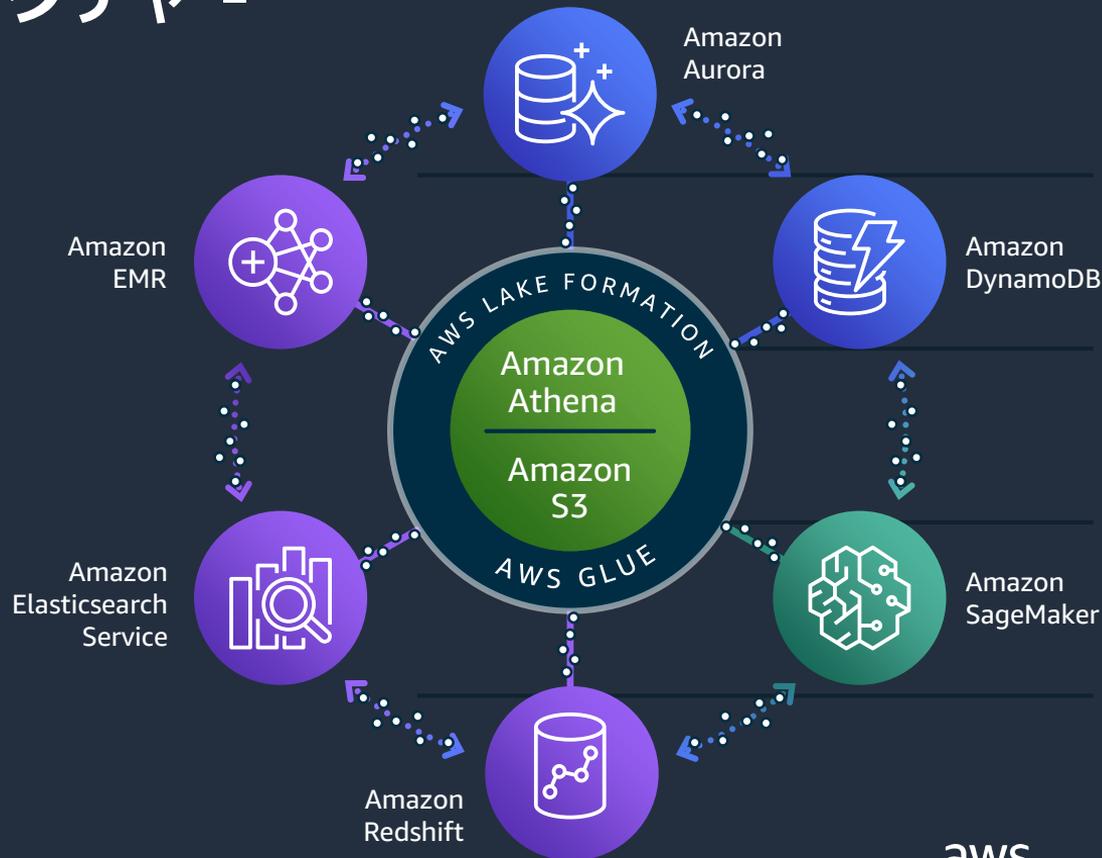


他の分析サービスとも手軽に連携 - レイクハウスアーキテクチャ -

Amazon S3でスケーラブルな
データレイクを構築することで、
AWSの他のサービスから生まれ
たデータを手軽に分析可能

Amazon Redshiftで分析した
データも、S3に保存することで
他のサービスから利用可能

Amazon Redshiftと他のサービ
スが直接連携する機能も充実



Amazon Redshift を使ってみる

AWS 公式 Webinar

<https://amzn.to/JPWebinar>



過去資料

<https://amzn.to/JPArchive>



数クリックで手軽にスタート

- 1画面の入力作業ですぐに起動
- ノード数やタイプは後から変更可能

クラスターを作成

クラスター設定

クラスター識別子
これは、クラスターを識別する一意のキーです。
redshift-cluster-1

識別子は 1-63 文字にする必要があります。有効な文字は a-z (小文字のみ) および - (ハイフン) です。

ノードの種類
CPU、RAM、ストレージ容量、およびドライブタイプの要件を満たすノードの種類を選択します。

推奨

ノードタイプ	ストレージ	価格
ra3.xlarge	マネージド型ストレージ: 最大 64 TB/ノード	\$3.836/ノード/時 \$0.026/GB/月
ra3.16xlarge	マネージド型ストレージ: 最大 64 TB/ノード	\$15.347/ノード/時 \$0.026/GB/月

レガシー高密度ストレージノードタイプを表示

ノード
必要なノードの数を入力します。
2

マスターユーザー名
DB インスタンスのマスターユーザーのログイン ID を入力します。
awsuser
名前は 1 - 128 文字の英数字にする必要があります。予約語にすることはできません。

マスターユーザーのパスワード

 パスワードを表示

- 値は 8-64 文字である必要があります。
- 値には、少なくとも 1 つの大文字が含まれている必要があります。
- 値には、少なくとも 1 つの小文字が含まれている必要があります。
- 値には、少なくとも 1 つの数字が含まれている必要があります。
- マスターパスワードに含めることができるのは、ASCII 文字 (ASCII コード 33-126) のみです。ただし、(一重引用符)、(二重引用符)、\、または @ は除きます。

▶ クラスターのアクセス許可 (オプション)

追加設定

これらの設定はオプションであり、クラスターの使用を開始するためにデフォルト設定が定義されています。これらの設定を今すぐ変更するには、[Use defaults] をオフにしてください。

設定	デフォルト
ネットワーク	デフォルト VPC (vpc) と デフォルトサブネットを使用
セキュリティ	default (sg-69f71b12) クラスターセキュリティグループを使用
バックアップ	自動スナップショットは 8 時間ごとに作成され、2 日間保持されます。
メンテナンス	現在のメンテナンストラックを使用

キャンセル クラスターを作成

クラスターの
ノード構成

クラスターの
詳細設定

どのノードタイプを選べば良い？

- Amazon Redshiftは、3つのノードファミリーそれぞれに2~3のサイズがあり、合計7タイプから選択可能
- ファミリーの違いは主にストレージの種類による
 - RA3 : マネージドストレージ & SSDキャッシュ
 - DC2 : SSD
 - DS2 : HDD

*1 2021年1月時点での東京リージョンのものです

	vCPU	メモリ	ストレージ	I/O	デフォルトスライス数	ノード数	コンピュータ料金 (*1)	ストレージ料金 (*1)
RA3 with Redshift Managed Storage(RMS)								
ra3.xlplus	4	32 GB	32TB RMS	650 MB/s	2	2~16 (*2)	\$1.278 /h	\$0.0261 /GB-Month
ra3.4xlarge	12	96 GB	128TB RMS	2.0 GB/s	4	2~32 (*2)	\$3.836 /h	
ra3.16xlarge	48	384 GB	128TB RMS	8.0 GB/s	16	2~128	\$15.347 /h	
DC2 - Dense Compute								
dc2.large	2	15 GB	0.16TB SSD	0.6 GB/s	2	1~32	\$0.314 /h	
dc2.8xlarge	32	244 GB	2.56TB SSD	7.5 GB/s	16	2~128	\$6.095 /h	
DS2 - Dense Storage								
ds2.xlarge	4	31 GB	2TB HDD	0.4 GB/s	2	1~32	\$1.190 /h	
ds2.8xlarge	36	244 GB	16TB HDD	3.3 GB/s	16	2~128	\$9.520 /h	

*2 クラスター作成後、Elastic Resizeによりra3.xlplusは32ノード、ra3.4xlargeは64ノードまで拡張可能です

ノードタイプ選定フロー

まずはRA3の利用を検討してみる

- 少数のノード数で大量のデータを格納可能
- データ量が急増してもノード追加なく対応可能
- RA3でだけ利用可能な機能がある
 - AQUA（クエリ高速化機能）
 - Data Sharing
 - クロスAZクラスターリカバリー



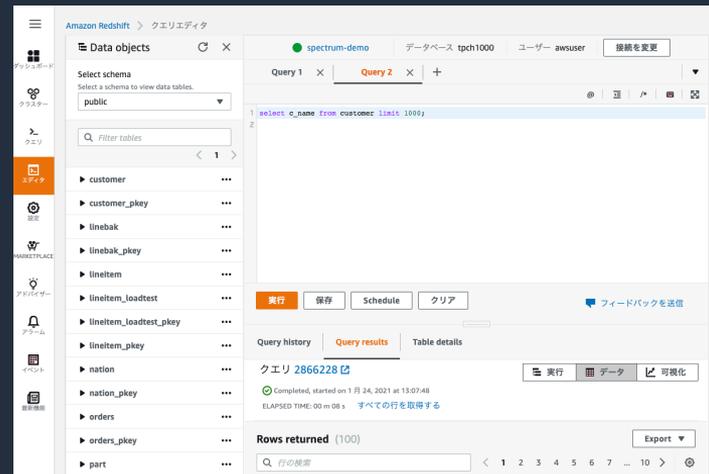
RA3では性能やコストが見合わない場合

RA3でだけ利用可能な機能を使わなくても良いのであれば...

- データはそれほど多くなく、とにかく性能が必要！
→DC2を検討
- 大量のデータを偏りなくアクセスするワークロードが多いため、RA3のSSDキャッシュが効きづらい
→DS2を検討

Amazon Redshiftにクエリしてみよう

- Amazon Redshiftへの主なアクセス手段
 - 管理コンソール内の「クエリエディタ」
 - Amazon Redshift ODBC/JDBCを利用したアプリケーション
 - Amazon Redshift Data API
 - PostgreSQLへのアクセスをサポートしたアプリケーション(※)
- データベースへのアクセスにはデータベースユーザーを使う
 - SQL文「CREATE USER」で作成
 - SAML2.0準拠のシングルサインオン(SSO)にも対応
 - 利用可能なプロバイダ：ADFS, Okta, PingFederate, Azure



※ PostgreSQLのみをサポートしているアプリケーションの場合、必ずしもAmazon Redshiftへの接続が保証されているわけではないことにご注意ください。

自動化された運用タスク

AWS 公式 Webinar
<https://amzn.to/JPWebinar>



過去資料
<https://amzn.to/JPArchive>



一般的な DWH の運用タスク

- バックアップ
- リストア
- 監視 (システム/ワークロード)
- アクセス監査
- バージョンアップグレード
- キャパシティ管理

など

対応には相応のコストと工数が必要

Amazon Redshift で変わる DWH 運用

- バックアップ
 - リストア
 - 監視 (システム/ワークロード)
 - アクセス監査
 - バージョンアップグレード
 - キャパシティ管理
- ➡ S3 への自動/手動スナップショット
 - ➡ スナップショットからの復元
 - ➡ コンソールや CLI 経由で状況を確認
 - ➡ 監査ログを S3 上に自動取得
 - ➡ 定期的な自動アップグレード
 - ➡ 厳密な管理は必ずしも必要ではない (マネージドストレージで自動スケール)

など

多くのタスクが自動化・簡易化される

テーブルの物理設計やメンテナンスタスクが 機械学習ベースで自動的に最適化

物理データ配置やその最適化を
自動化

データやワークロードの増加に
応じてピーク性能を最適化

機械学習を活用し、変化する
ワークロードに適応

パフォーマンスチューニングの
自動化



Automatic
vacuum delete



Automatic
distribution keys



Automatic
sort keys



Auto workload
manager



Automatic
table sort

Amazon Redshiftの高速化の工夫（1）

ゾーンマップとソートキー

ゾーンマップ

- Amazon Redshiftはカラムごとに「ブロック」単位でディスクにデータを格納。
1ブロック = 1 MB
- ブロック内の最小値と最大値をメモリに保存
- **不要なブロックを読み飛ばすことが可能**

10	10 13 14 26 ...
324	... 100 245 324
375	375 393 417...
623	... 512 549 623
637	637 712 809 ...
959	... 834 921 959

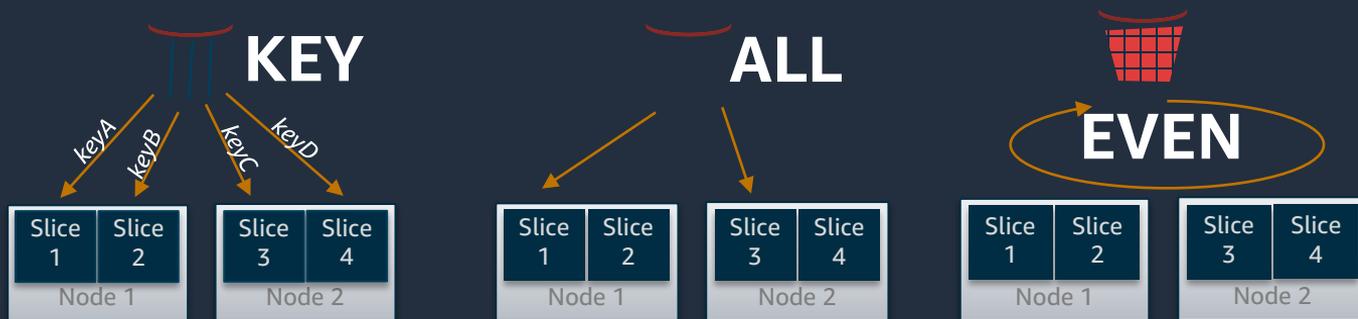
ソートキー

- カラムのデータをあらかじめソートしておけば、ゾーンマップによる読み込みブロックの絞り込みを効果的に行うことが可能
- クエリで頻繁に絞り込みを行う列をソートキーとして指定することで、データロードやメンテナンス時にデータをソートしておくことができる

Amazon Redshiftの高速化の工夫（２）

分散スタイル

- 通常は、全ノード・全スライス（並列処理の単位）にデータを均等に分散させることで、並列処理を効率的に行い、クエリを高速に実行することが可能
- ただし、テーブルをJOINする場合は、ノード間でネットワーク/I/Oが多発して速度が落ちる可能性がある
- JOINするレコード同士を同じノード内に置くことで、ネットワーク/I/Oを削減することが可能



同じキーは同じスライスへ

全てのデータを全ノードへ ラウンドロビンで均等分散

自動テーブル最適化

- 自動テーブル最適化機能では、Amazon Redshiftがクエリとテーブルの利用状況を継続的に監視し、ソートキーや分散キーがパフォーマンス向上に寄与すると判断すると、それらを自動設定する
- ソートキーや分散スタイルを指定せずに新規作成されたテーブルでは、自動テーブル最適化はデフォルトで有効
- 自動テーブル最適化が適用されていないテーブルでも、ALTER TABLE文であとから有効にすることが可能



Sort Keys



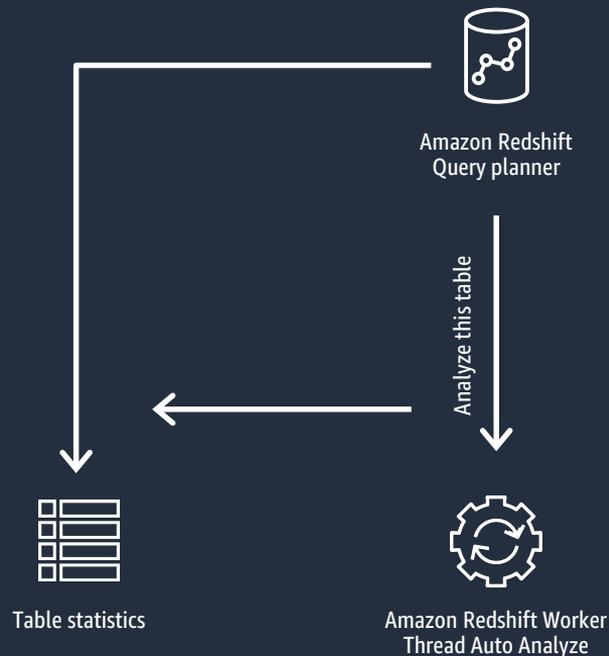
Distribution Style

```
ALTER TABLE table_name ALTER SORTKEY AUTO;  
ALTER TABLE table_name ALTER DISTSTYLE AUTO;
```

Analyze の自動化

Analyze は、最適なクエリ実行計画作成のために必要な、
テーブルの統計情報を更新する処理

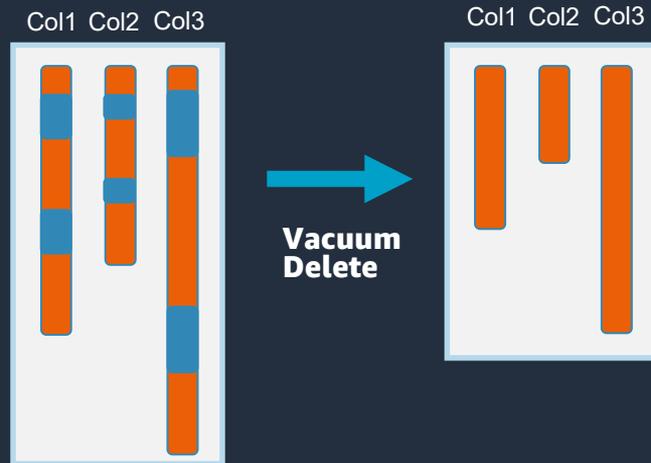
テーブルデータの変化と
クエリの負荷状況に基づいて、
適切なタイミングで**自動実行**される



Vacuum Delete の自動化

Vacuum Delete は Delete や Update 後の削除領域の解放を行う処理

テーブル内の削除済み行数とクエリの負荷状況に基づいて、適切なタイミングで**自動実行**される



テーブルソートの自動化

テーブルへのデータの追加・更新がされ続けると、テーブルの未ソート領域が次第に増えていくため、メンテナンスが必要となる

テーブル全体のソートは負荷が高いため、機械学習によりソートが必要な部分を判断し、ピンポイントでソートする。このため低負荷でソートを実行可能

適切なタイミングで**自動実行**される

パフォーマンスやアクセスに影響なし

Sorted by date

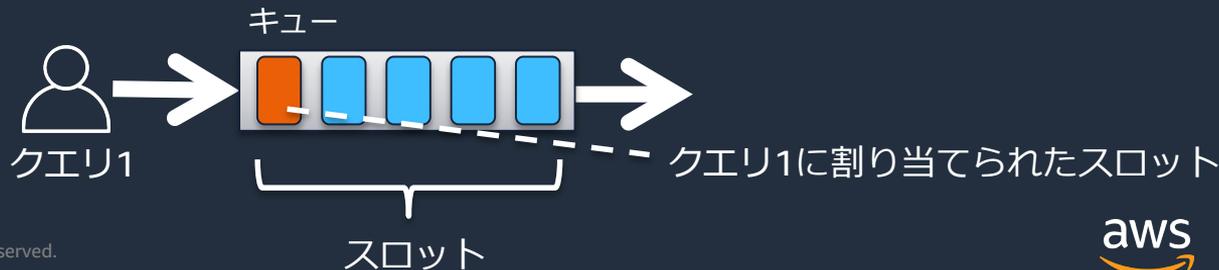


Most accessed partition

Amazon Redshiftの高速化の工夫（3）

ワークロード管理機能：WLM

- Redshift がクエリに対してどのようにリソース(メモリ/CPU/IO)を割り当てるかを決定づけるしくみ
- クエリが実行されると、必ず待ち行列(キュー)にアサインされる。キューはデフォルトで用意されているが、別途作成して増やすことも可能で、クエリの種類(ユーザーグループ、クエリグループ)に応じてアサイン先を振り分けることが可能
- クエリには、キューで利用可能なリソースセット(スロット)が割り当てられる。スロットが全て割り当てられたら、後続のクエリは実行待ちとなる

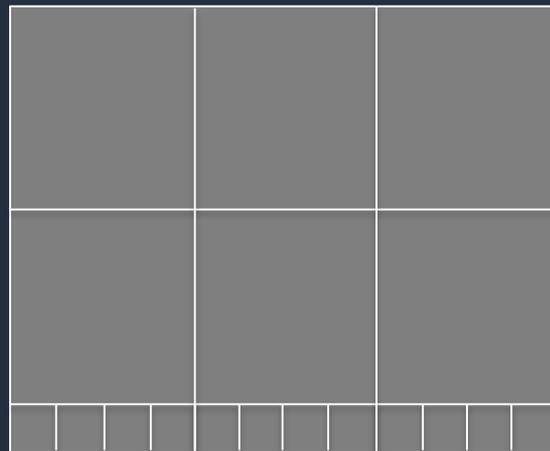


ワークロード管理の自動化 – Auto WLM

- WLMでの複雑なリソース割当を、Amazon Redshiftが自動的に行う仕組み
- クラスター全体で柔軟にリソースを使用
- クエリの内容に応じて、割り当てるメモリを適切に調整
- クエリ単体のパフォーマンスとクエリの同時実行数のバランスを自動的に最適化



クラスターの総メモリ : 40GB



WLMについてより詳しい技術情報を知りたい方は、こちらの過去のBlackBelt資料をご覧ください

https://d1.awsstatic.com/webinars/jp/pdf/services/20200729_AWS_BlackBelt_RedshiftAdvancedGuide.pdf

監視・パッチ適用の自動化

- モニタリング機能を内蔵
 - GUI (マネジメントコンソール)
 - API経由で操作も可能
- パッチ適用も自動的
 - メンテナンスウィンドウでパッチの時間帯を指定可能



▼ メンテナンス

メンテナンスウィンドウ
クラスターに保留中の通知またはメンテナンスを適用する毎週の時間範囲(UTC)の開始時刻を選択します。

Sunday 時刻 09:00 UTC+09:00

メンテナンストラック
メンテナンストラックは、メンテナンスウィンドウ中に適用されるクラスターバージョンを制御します。

① メンテナストラックへの変更は、今後のメンテナンスウィンドウで Amazon Redshift クラスターに適用されます。[クラスターステータス]の[保留中の修正値]に[メンテナンストラック]と表示されるまでは、リクエストをキャンセルし、元のトラックに戻ることができます。詳細はこちら

最新
最新の承認済みクラスターバージョンを使用します。

トレーリング
現在のバージョンの前のクラスターバージョンを使用します。

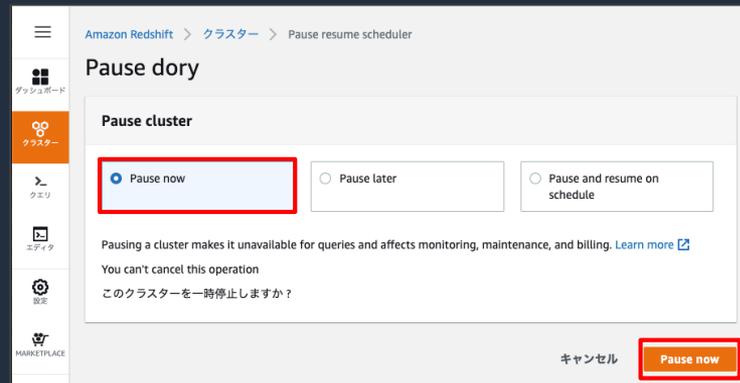
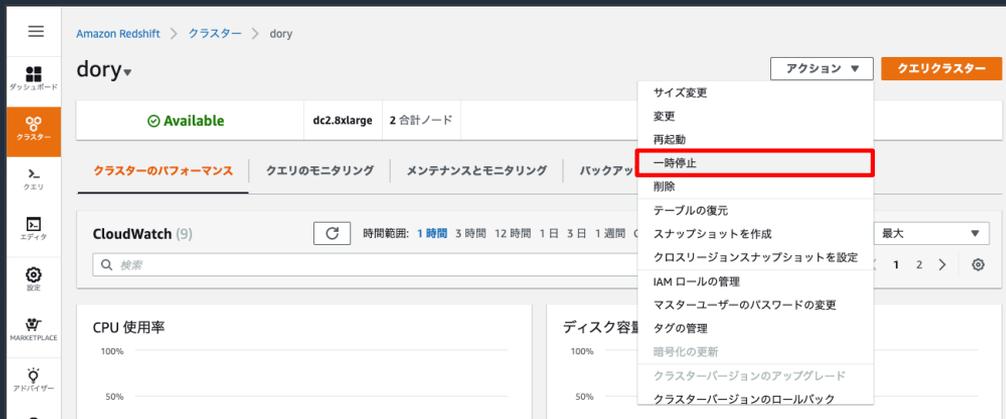
プレビュー
新しい機能のベータリリースでクラスターバージョンを使用します。

メンテナンスウィンドウを遅らせる
メンテナンスの延期ウィンドウは、クラスターのアクションメニュー、または[Cluster details properties]ページのメンテナンスウィンドウのプロパティの横にあります。ここでは、ここからメンテナンスを延期できます。

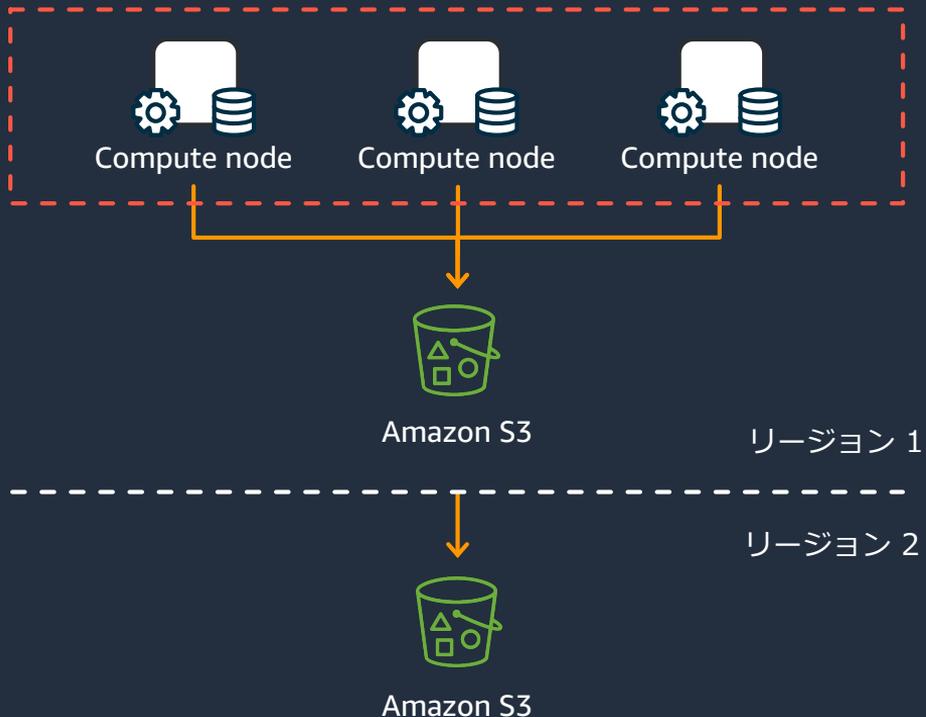
メンテナンスを延期

クラスターの一時停止と再開でコスト削減

- Redshift を使用しない間（週末等）はクラスターを一時停止（Pause）し、必要時にクラスターを再開（Resume）することでコスト発生を抑制可能
- スケジュール実行で自動的に一時停止・再開させることも可能



継続的な自動データバックアップ

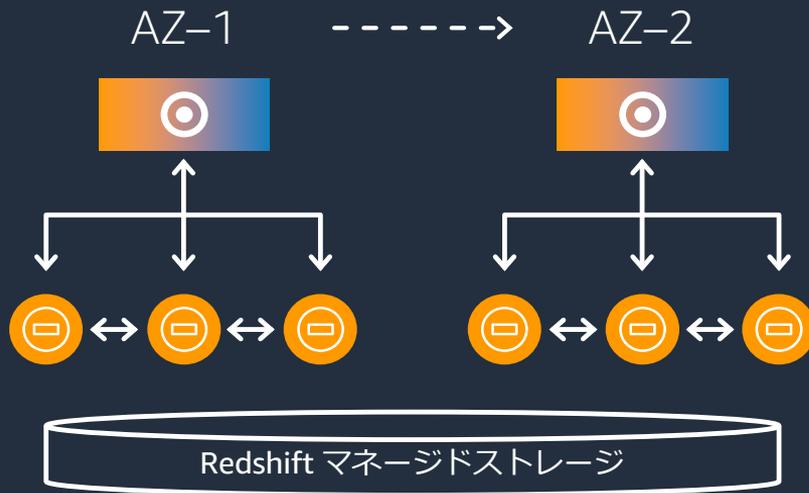


- Amazon S3に継続的な増分バックアップスナップショットを自動取得
- バックアップ&リストア中もSQLを実行可能
- リージョン間スナップショットコピーも可能
- ストリーミングリストアにも対応

AZ障害時はマネージドストレージを使って自動復旧

クロスAZクラスターリカバリー

- ✓ データロスなしにリカバリー (RPO = 0)
- ✓ スナップショットからのリストアが不要に
- ✓ オンデマンドフェールオーバー
- ✓ クラスタは別のAZにオンデマンドで作成されるため、スタンバイレプリカクラスター不要
- ✓ RA3 インスタンスでのサポート



モニタリングと性能改善

AWS 公式 Webinar
<https://amzn.to/JPWebinar>



過去資料
<https://amzn.to/JPArchive>



Amazon Redshiftの主なモニタリング項目

- クラスターのパフォーマンスメトリクス
 - Amazon CloudWatchによる監視メトリクスを提供
 - 管理コンソールからも確認可能
- クラスターのイベント
 - クラスターで発生したエラーや、クラスターのメンテナンス予告、パッチ適用予告などがイベントとして登録される
 - Amazon SNSを利用して通知することも可能
- システムテーブルとビュー
 - 個別クエリの実行統計や、テーブルの構成情報などのメタデータを確認可能

アドバイザー機能

Amazon Redshiftがワークロードを自動分析し、パフォーマンス向上やコスト削減につながる推奨事項を表示する機能。こちらにアドバイスが出ていないかを監視し、出ていれば優先して実行を検討

推奨事項の例：

- COPYコマンド実行時のファイル圧縮・分割
- 未使用クラスターの停止やダウンサイジング
- 設定すべきソートキーや分散キー（自動テーブル最適化を使っていない場合にはこちらを参照すると便利）

アドバイザーの推奨事項 (2)

並び替え基準 cluster 🔍 検索

▼ redshift-handson (2) 2 推奨事項 2 低い影響

▶ Improve Query Performance with Distribution Keys
Checks for appropriate distribution keys on tables.
Significantly improve query performance by using **ALTER TABLE** to redistribute the tables identified in this recommendation.

< 1 日前
2020年7月19日 20:44
低い影響

▼ Improve Query Performance with Sort Keys
Checks for appropriate sort keys on tables.
Significantly improve query performance by using **ALTER TABLE** to sort the tables identified in this recommendation.

< 1 日前
2020年7月20日 10:17
低い影響

確認した内容
An analysis of the cluster's workload between 2020-02-17 and 2020-07-20 (154 days), identified tables that will significantly benefit from being sorted on a SORTKEY.

できること
Use the following SQL statements to sort tables with the recommended SORTKEY column.

```
-- Database: "handson"  
ALTER TABLE /*skru-dbc28367-c244-45d5-b8b6-878878a83639-g8-lp/ "public"."customer" ALTER SORTKEY ("c_nattowkey");
```

Sorting a large table with **ALTER TABLE** consumes cluster resources and requires table locks at various times. It is best to implement each recommendation when the cluster's workload is light. More details on optimizing table sort key configurations can be found in the Amazon Redshift Engineering's Advanced Table Design Playbook: Compound and Interleaved Sort Keys.

Amazon Redshift sorts table rows according to the table sort key. The sorting of table rows is based on the SORTKEY column values.
Sorting a table on an appropriate SORTKEY could accelerate performance of queries, especially those with range-restricted predicates, by requiring fewer table blocks to be read from disk.

この投稿に立ちましたか? 🗨️

フィードバック 🇯🇵 日本語 © 2008 - 2020, Amazon Web Services, Inc. またはその関連会社。無断転用禁止。 プライバシーポリシー 利用規約

クエリーとクラスターの監視

- マネジメントコンソールの活用
- マネジメントコンソール → Redshift → クラスター → [クラスター名]
- 以下の情報を得ることができる

クラスターのパフォーマンス

CPU、ディスクI/O、ネットワークI/Oなど

クエリの履歴

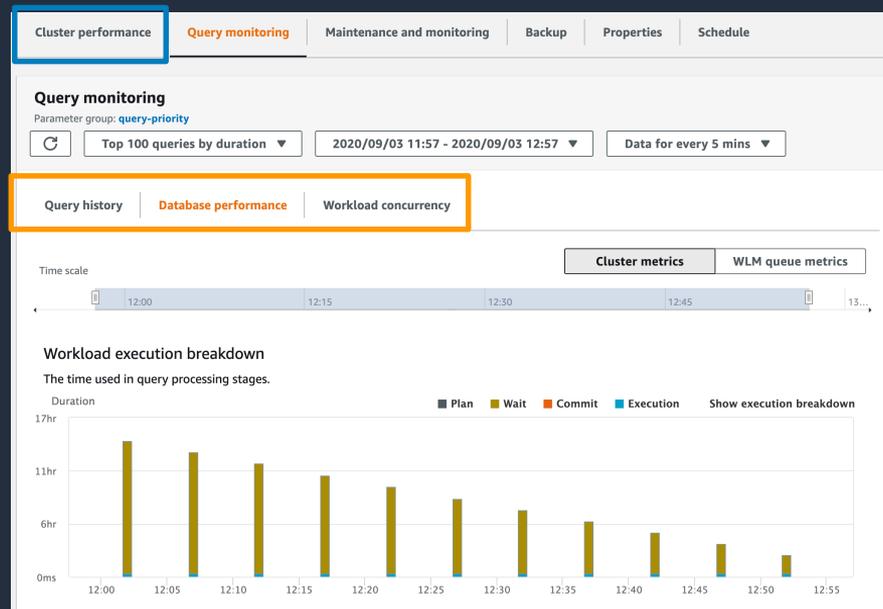
クエリやロードの実行時間やステータスなど

データベースパフォーマンス

スループット、レイテンシーなど

ワークロードコンカレンシー

クエリの同時実行状況 (キュー待ちや実行時間)



システムテーブルとビューによる性能分析

- Redshift は 4 種類のシステムテーブル/ビューを保持
 - 発生元や用途によって異なる
 - いずれも DB 領域外に保持されるためスナップショットには含まれない (一時停止/再開や、スナップショットからの復元では残存していない)

	STL	STV	SVL	SVV
タイプ	テーブル	仮想テーブル	ビュー	ビュー
生成方法	ディスク上のログから生成	オンメモリーデータから生成	STLへの参照	STVへの参照
主たる用途	過去の実行記録の参照	現在進行中の処理の参照	STL/STVデータを組み合わせて別軸で分析	

システムテーブルとビューによる性能分析

- 実行されたクエリには一意のクエリ ID が割り当てられる
- システムテーブル・ビューから情報を取得する際は、多くの場合クエリ ID をキーとする
- Tips
 - 同一セッションで情報を取得する場合は以下が便利
 1. クエリを実行
 2. `select pg_last_query_id() as q into temp table hoge;`
 3. `select * from stl_explain where query=(select q from hoge);`
 4. `select * from svl_query_summary where query=(select q from hoge);`
 5. :

Admin Views / Scripts

- 管理、モニタリングに有益なViewおよびスクリプト群
 - AWSにより開発・提供される
 - 無料で利用可能

<https://github.com/awslabs/amazon-redshift-utils>
- クラスターの状態確認、トラブルシューティングに利用可能
 - 例：ノードスライス間でのデータ分散状況の確認

クエリが性能要件を満たせない場合は

- クエリの実行計画・実行統計を見て非効率な動作を確認したら、テーブル設計の変更やSQLの修正など、パフォーマンスチューニングを実施
 - 圧縮、ソートキー、分散スタイルといったAmazon Redshift特有のテーブル物理設計の最適化は、現在は大部分自動化されている
- 複数のクエリがCPUやメモリなどのリソースを使い切ったうえで性能が出ない場合、クラスタをスケールアウト（またはスケールアップ）して、性能を增強する
- 夜間バッチ処理など、性能が必要な時間帯が決まっている場合は、その時間帯だけノード数を増やす

マテリアライズド・ビューの利用でクエリを高速化

頻繁に実行するクエリパターンを高速化

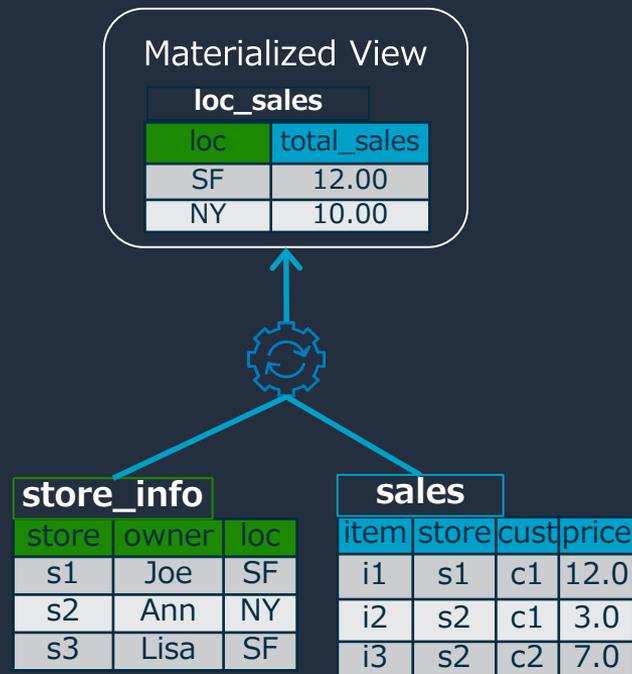
- 結合、フィルタ、集計、射影
- ベーステーブルとは異なる分散キーやソートキーを指定できる
- 外部表の参照も可能

ETL/BI パイプラインの簡素化

- データは自動でリフレッシュされる

クエリリライト

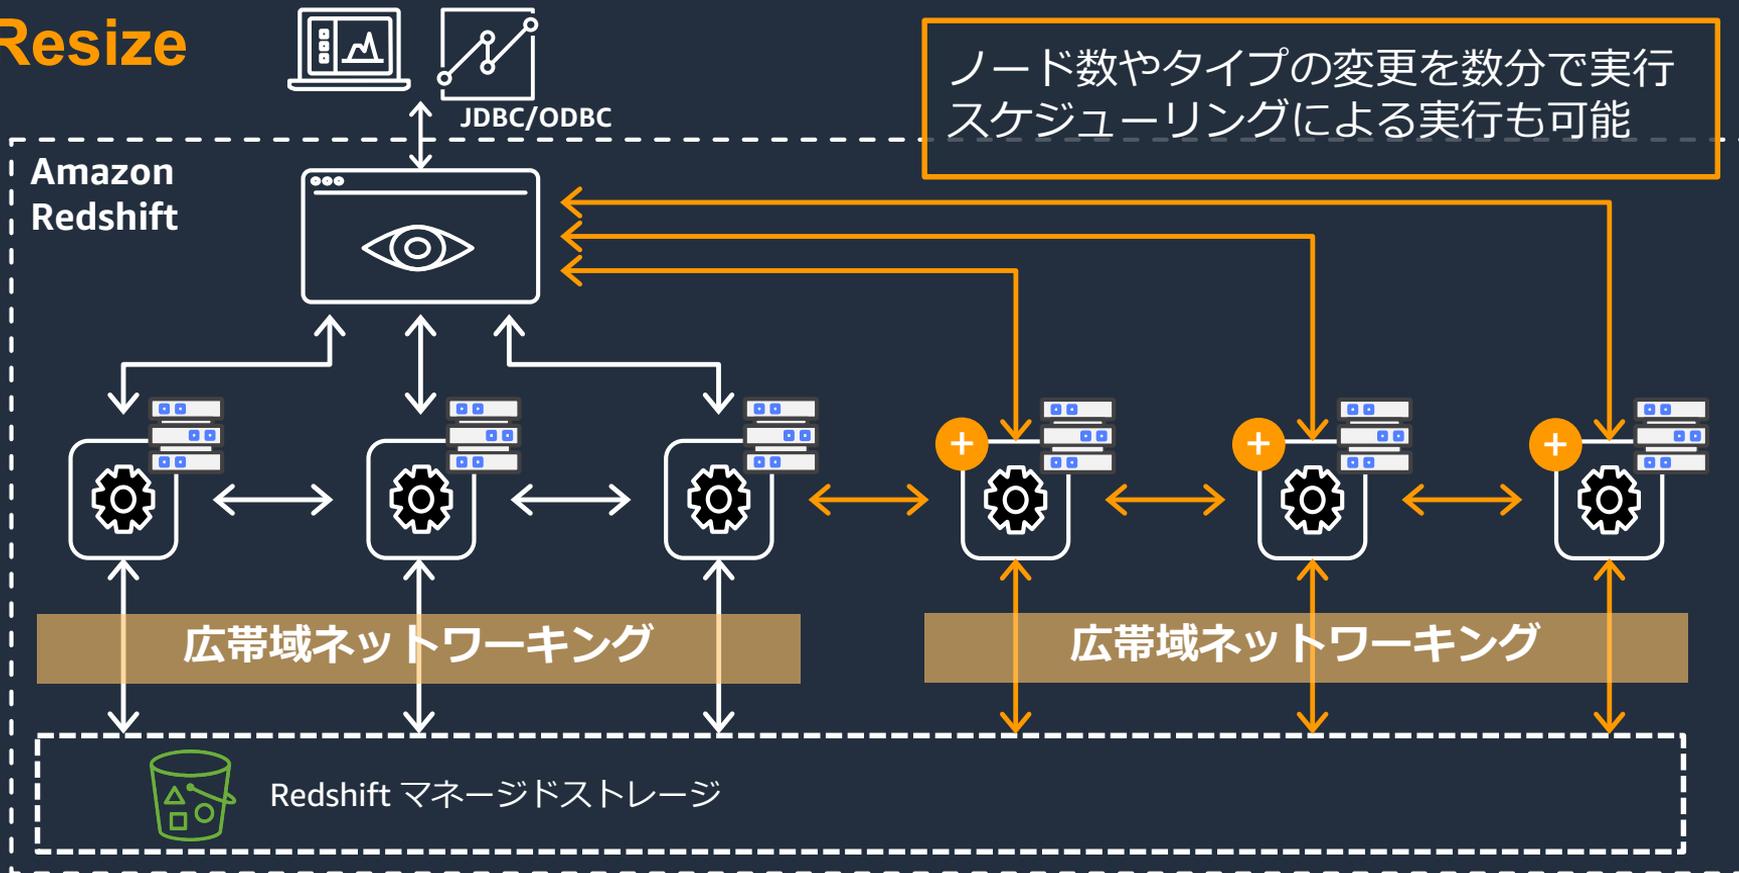
- アプリケーションからはテーブルに対してクエリするだけで必要に応じて実行計画を Rewrite し、マテリアライズドビューを参照



必要な性能に合わせてノード構成を変更する Elastic

Resize

ノード数やタイプの変更を数分で実行
スケジューリングによる実行も可能



利用者の増加に対処する

AWS 公式 Webinar
<https://amzn.to/JPWebinar>

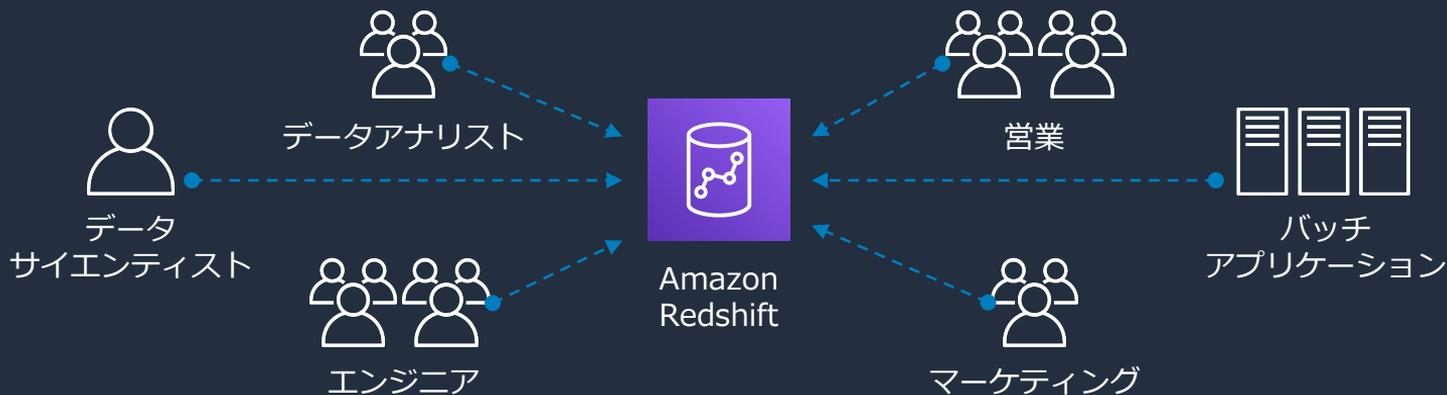


過去資料
<https://amzn.to/JPArchive>



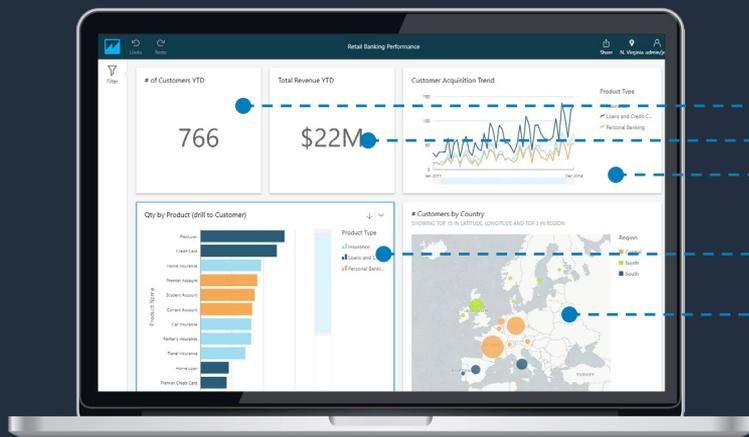
DWH ワークロードの特徴

- DWHには多様なユーザーが様々なツールを使って接続する可能性がある
- 評判のよいDWHは成長していく



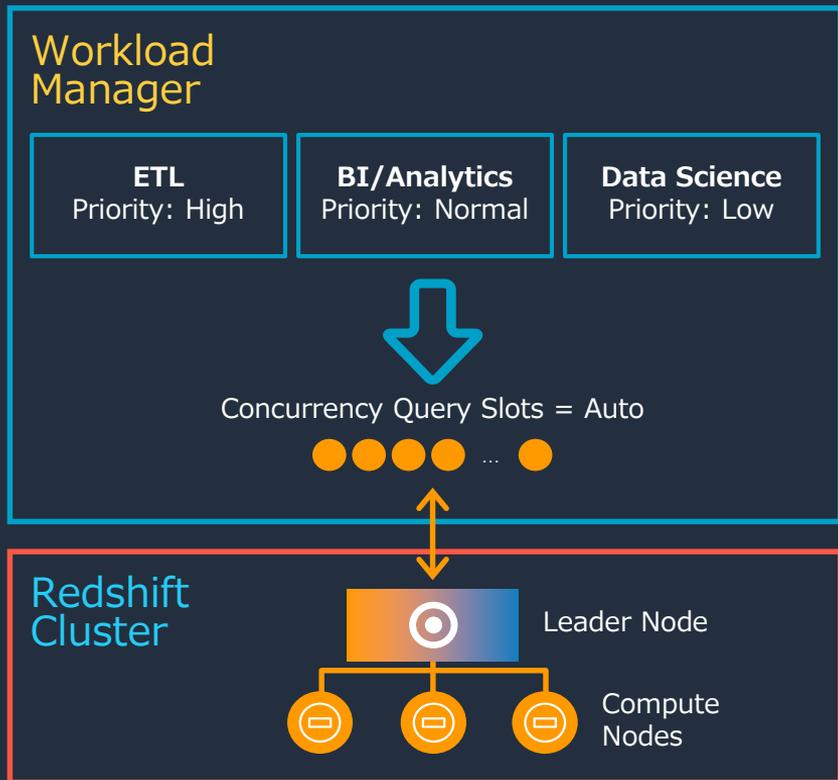
DWH ワークロードの特徴

- BI ダッシュボードからはバックグラウンドで複数のクエリが流れる
- DWH は接続ユーザー数以上のリクエストを受けられる可能性がある



Amazon
Redshift

重要なクエリを優先的に実行



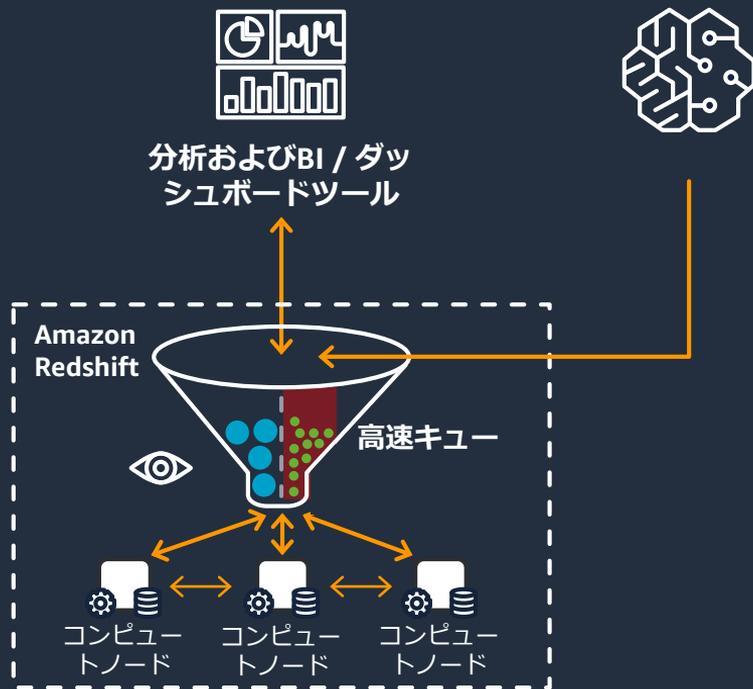
Auto WLMでは、ワークロード毎にキューを分け、相対的な優先度を設定することが可能

Amazon Redshift が、優先度の高いキューで実行された処理に自動的に多く CPU, IOリソースを割り当てる

優先度はコマンドなどで動的に変更が可能

ショートクエリアクセラレーション (SQA)

実行時間の短いクエリは、通常のキューとは別の領域で処理



SQAの機能

- 1 機械学習によってクエリの実行時間を予測する
- 2 ショートクエリと判断されたクエリは専用の高速キューにルーティングされる
- 3 リソースはショートクエリのために動的に確保される

機能はデフォルトで有効
(ユーザー側での設定は不要)

ピークタイムのワークロード

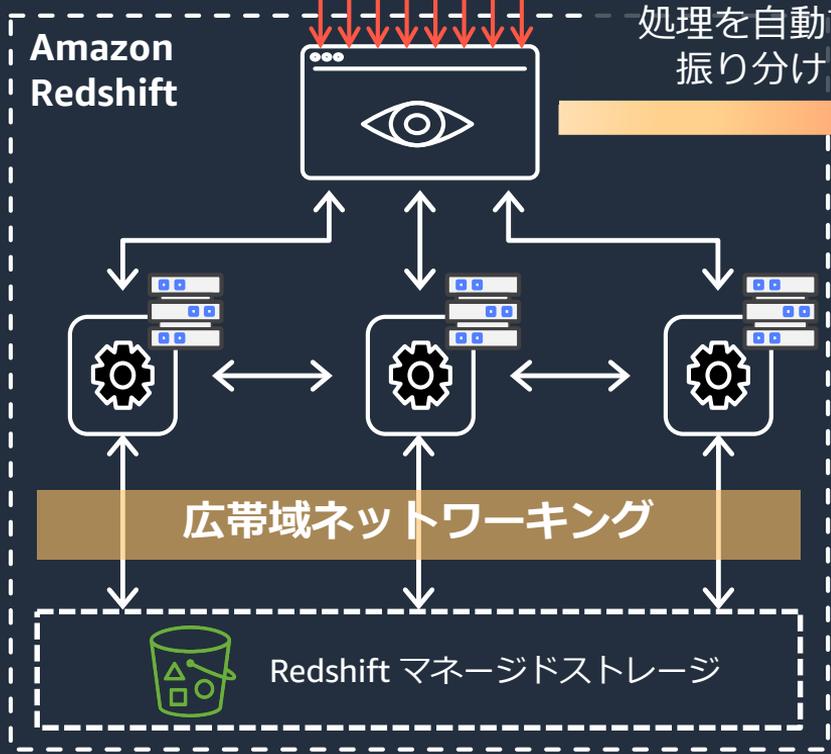
- アクセスの集中する時間帯では、システム全体のパフォーマンス低下を引き起こす可能性がある
- ピークタイムに合わせた DWH のリソースサイジングが必要になる



ピーク時にコンピュートを自動拡張する **Concurrency**

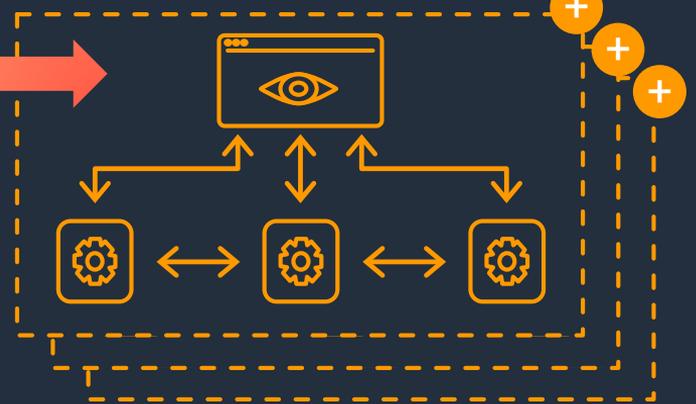
Scaling

メインクラスター



処理を自動で振り分け

追加クラスター(1~10)



メインクラスターでクエリのキュー待ちが発生すると、バックグラウンドで別の独立したクラスターを順次追加して並列処理

Concurrency Scaling を有効化するには

The screenshot shows the AWS IAM console interface. On the left, the '設定' (Settings) menu is open, with 'ワークロード管理' (Workload Management) highlighted. An arrow points from this menu to the 'concurrency-scaling-enable' parameter group configuration page. In this page, the 'ワークロード管理' (Workload Management) tab is active, and the 'ワークロードキュー' (Workload Queue) section is highlighted. Below this, the 'Default queue' configuration is shown, with the '同時実行スケーリングモード' (Concurrency Scaling Mode) dropdown menu open and '自動' (Automatic) selected. Other options include 'オフ' (Off) and '自動' (Automatic). The 'メモリ (%)' (Memory) and 'メインでの同時実行' (Concurrency in Main) are both set to '自動' (Automatic). The 'クエリモニタリングルール' (Query Monitoring Rules) section is empty, and the '再起動まで動的な変更を遅らせる' (Delay dynamic updates until restart) checkbox is unchecked.

クラスターに設定されているパラメータグループの WLM のキュー定義を編集し、「同時実行スケーリングモード」設定値を「自動」に設定

追加クラスターの最大数を指定

パラメータ

“max_concurrency_scaling_clusters”
にて、追加クラスターの最大数を
0-10 の範囲で指定 (デフォルト: 1)

Amazon Redshift > 設定 > ワークロード管理 > パラメータグループパラメータを変更

パラメータ concurrency-demo を変更します。

名前	値
auto_analyze boolean: true,false	true
datestyle string	ISO, MDY
enable_user_activity_logging boolean: true,false	false
extra_float_digits	0
max_concurrency_scaling_clusters integer: 0-10	5
max_cursor_result_set_size integer: 0-14400000	
query_group string	default
require_ssl boolean: true,false	false
search_path string	\$user, public
statement_timeout integer: 0,100-2147483647	0
use_fips_ssl boolean: true,false	false

Concurrency Scaling の料金

* 課金体系は 2021 年 1 月時点での東京リージョンのものです

- 各追加クラスターでクエリが実行された期間（秒）
- 1 日あたり 1 時間分の**無料クレジット**が付与（最大 30 時間）
- 日/週/月毎の単位で実行時間上限を設定しコストをコントロールすることも可能



追加クラスターへの課金

1クラスター分

2クラスター分

1

課金なし

1クラスター分

課金なし

データ連携はどのように行うか

AWS 公式 Webinar
<https://amzn.to/JPWebinar>

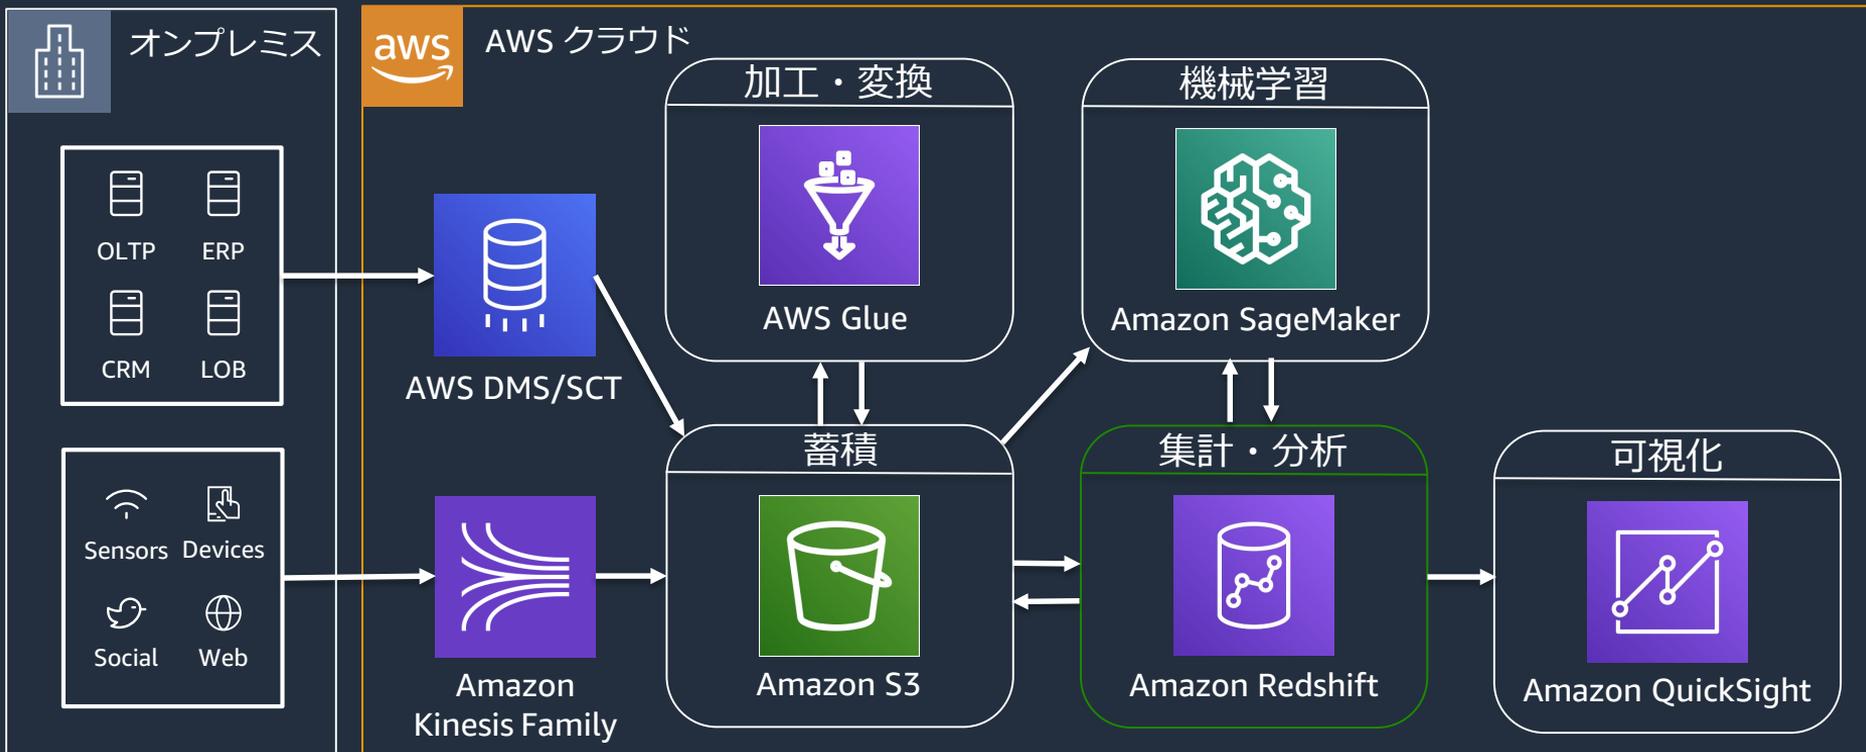


過去資料
<https://amzn.to/JPArchive>



様々なサービスと様々なデータを連携

Amazon Redshiftは、RDBMS以外にも様々なサービスとデータ連携をして分析を行うことができる
以下はデータ連携の一例だが、これ以外にも様々なデータ連携の形を取ることが可能



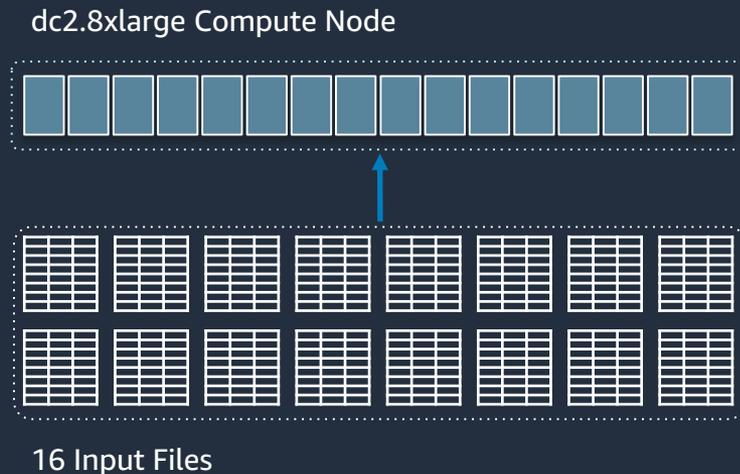
データロードと変換の基本

データロード

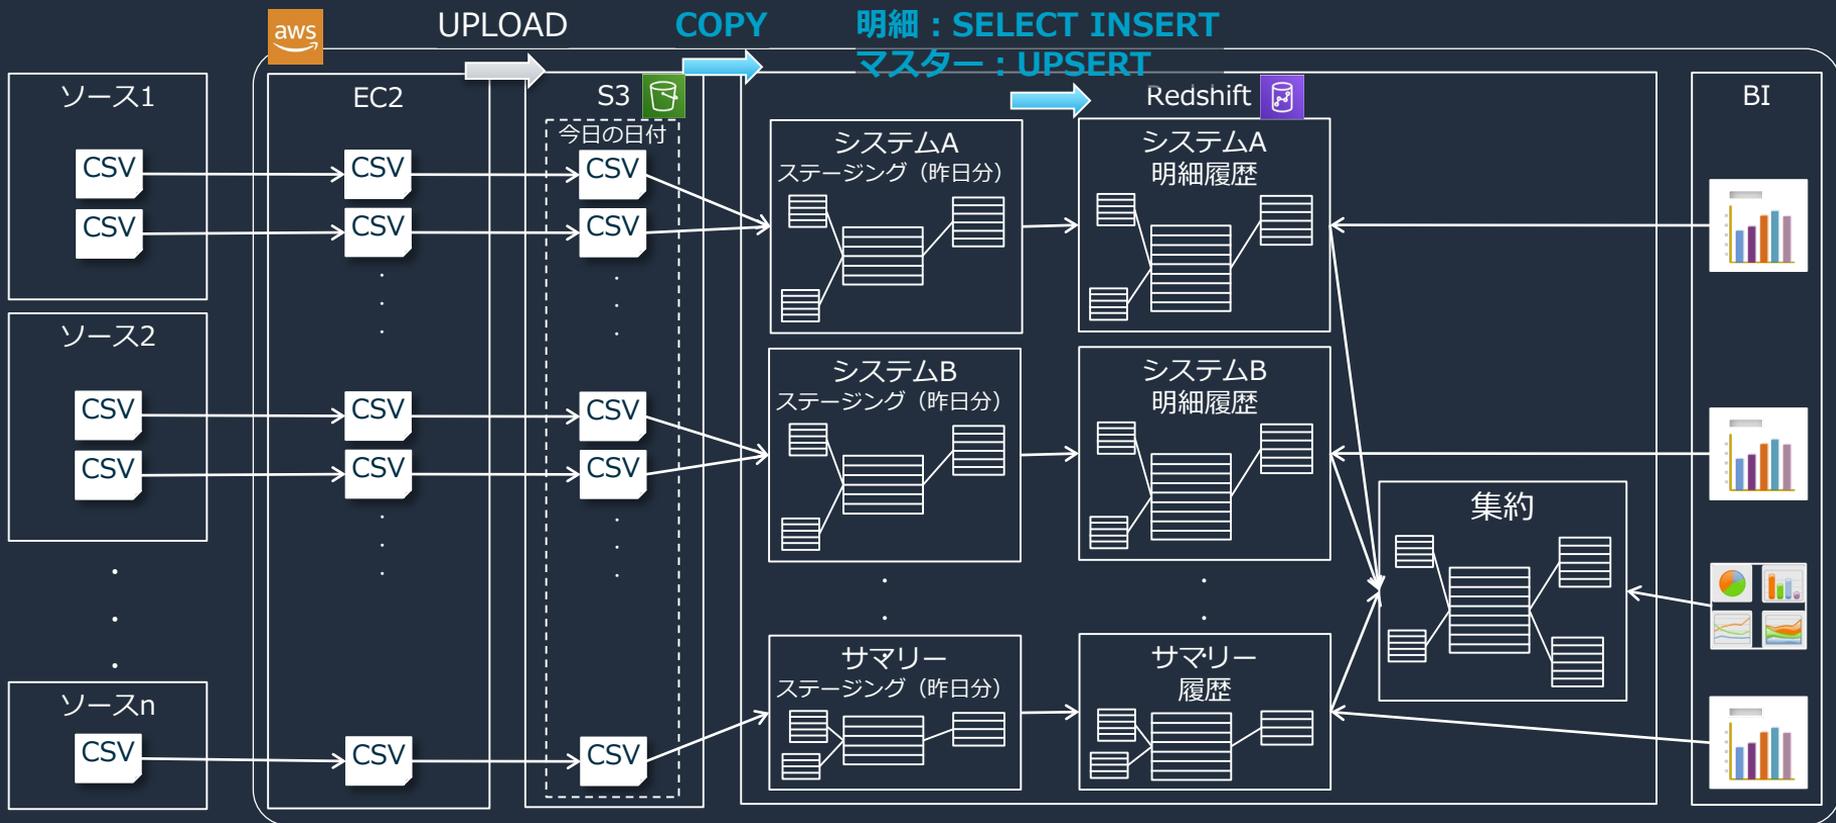
- S3にファイルを置いて、SQLのCOPYコマンドでロードを実行
- S3からのロードの際、あらかじめファイルを複数に分割しておくことで、各スライスが並列にロードを実行

データの変換 (Transform)

- 外部ETLツール、AWS Glue、Hadoop等で実行
- または、一旦Redshiftにデータをロードし、SQLで変換



データロード&変換の例



データレイクを介した他サービスとのデータ連携

Redshift Spectrum

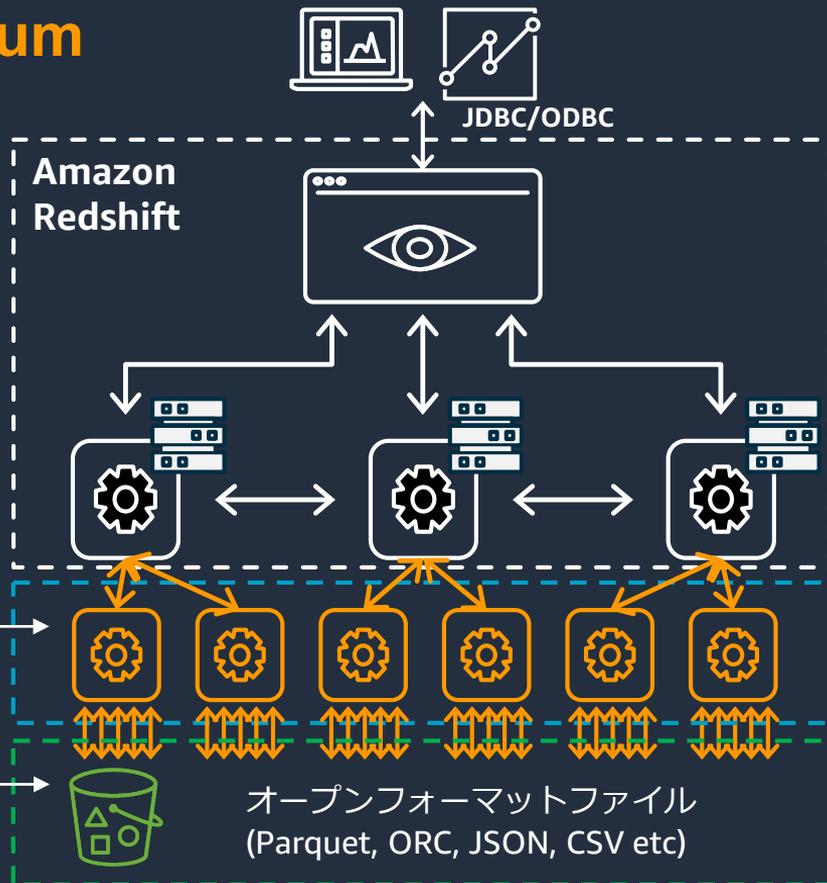
専用のクエリエンジンを用意することで、Amazon Redshift 本体にデータをロードしなくとも、S3にデータを置いたまま、高速なデータ分析や、分析結果のデータレイクへの書き出しが可能

Amazon Redshift Spectrum

- S3上のファイルに対する並列クエリ実行エンジン

データレイク

- ユーザー管理 S3 バケット



データカタログを共有することで、他のAmazon Redshiftクラスターや、Amazon Athenaなどの他のサービスと手軽にデータ連携が可能

AWS Glue

- データカタログ

Federated queryで、業務DBへ直接アクセス

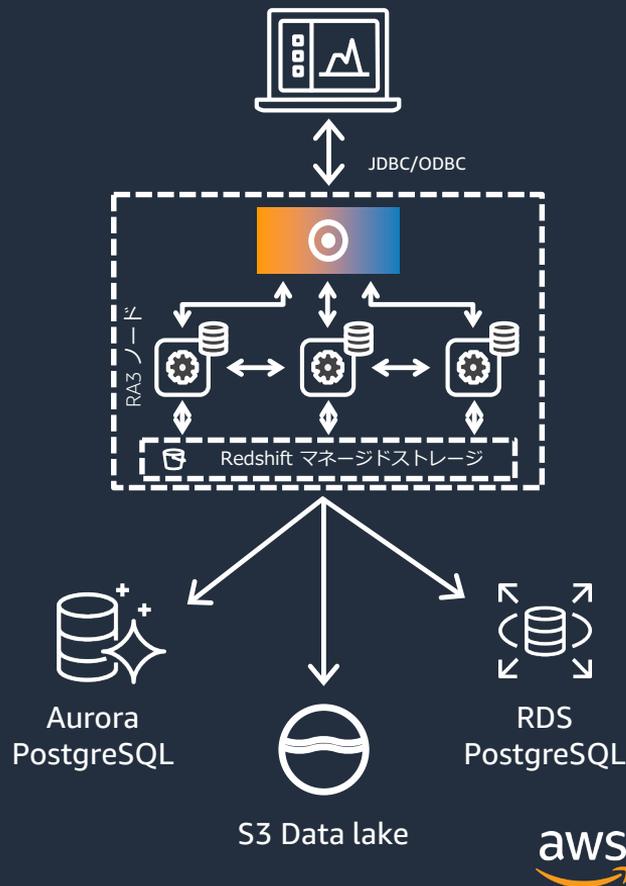
RDS/Aurora PostgreSQL に対して直接クエリ可能

データ移動なしにライブデータを分析

データウェアハウス、データレイク、
オペレーショナルデータベースのデータを
統合して分析

高い性能でセキュアにデータアクセス

RDS/Aurora MySQL をサポート (プレビュー)



Redshift SpectrumとFederated queryを利用した例

- Aurora PostgreSQLには最新のデータ (2019)
- Amazon Redshift には最近のデータ(2016-2018)
- Amazon S3にはアーカイブデータ (1992-1998)
- 全データを検索可能なUNION ALLビューを定義

```
CREATE VIEW lineitem_all AS
```

```
SELECT * FROM s3.lineitem_1t_part
```

コールドデータ

```
UNION ALL
```

```
SELECT * FROM public.lineitem
```

履歴データ

```
UNION ALL
```

```
SELECT * FROM apg.lineitem
```

最新データ

```
WITH NO SCHEMA BINDING
```

- 毎年1月の、発注量が1個の注文の数を集計
- 述語（検索条件）がプッシュダウンされる
- S3データはパーティションルーニングされる
- 集計がプッシュダウンされる
- とても直感的な構文で記載できる

```
SELECT EXTRACT(year FROM l_shipdate) AS year,  
       EXTRACT(month FROM l_shipdate) AS month,  
       COUNT(*) AS orders
```

```
FROM lineitem_all
```

```
WHERE extract(month FROM l_shipdate) = 1
```

```
AND l_quantity < 2
```

```
GROUP BY 1,2
```

```
ORDER BY 1,2;
```

Anazon Redshift Data Sharing

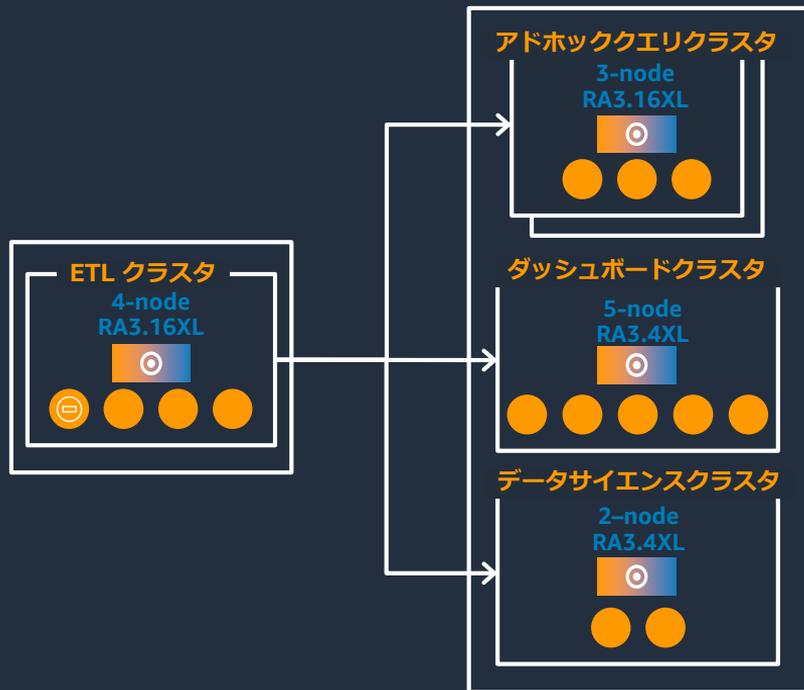
Redshift クラスター間でセキュアに簡単にデータを共有することが可能に



- プロデューサークラスターが書き込んだ共有データを、コンシューマークラスターがread onlyで共有することが可能
- データの移動がなく、アクセス権の管理と共有状況の監査により、セキュアなデータ共有を実現

Data sharing のユースケース (1)

様々なビジネスクリティカルなワークロードを、簡単でコストパフォーマンスよくサポート



新しい分析ワークロードを素早く利用可能に

パフォーマンス要件に応じて個々のクラスタの
サイズ・性能を最適化

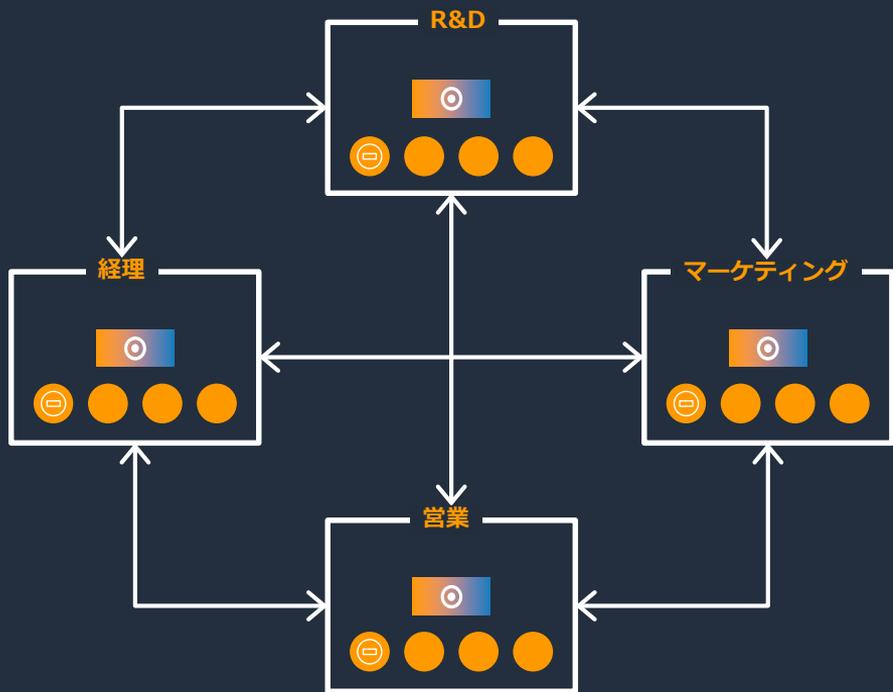
データセットを共有しながら、ワークロードを
分離

個々のワークロードごとに費用請求

コンシューマクラスタは必要に応じて停止/再開

Data sharing のユースケース (2)

部門間でのコラボレーション



より広範なデータ分析を実現するために部門間でシームレスにコラボレーションし、製品間での相互の影響を分析

データ移動に伴うコンプライアンス上の懸念をなくす

どのAmazon Redshiftクラスターも、プロデューサーにもコンシューマーにもなれる

まとめ

AWS 公式 Webinar
<https://amzn.to/JPWebinar>



過去資料
<https://amzn.to/JPArchive>



まとめ

- Amazon Redshift は、分析用クエリ実行に特化したRDBMS
- Amazon Redshiftの基本的な運用タスクは、大部分自動化されている
- 単体処理の性能が足りない場合は、必要な時間帯だけスケールアウト
- 一時的な利用ユーザーの増加には、クラスター追加を自動対応
- データ連携はデータロード、またはデータを動かさずに各サービスと連携

Q&A

お答えできなかったご質問については

AWS Japan Blog 「<https://aws.amazon.com/jp/blogs/news/>」にて

後日掲載します。

AWS の日本語資料の場所「AWS 資料」で検索



日本担当チームへお問い合わせ サポート 日本語 ▾ アカウント ▾

コンソールにサインイン

製品 ソリューション 料金 ドキュメント 学習 パートナー AWS Marketplace その他 🔍

AWS クラウドサービス活用資料集トップ

アマゾン ウェブ サービス (AWS) は安全なクラウドサービスプラットフォームで、ビジネスのスケールと成長をサポートする処理能力、データベースストレージ、およびその他多種多様な機能を提供します。お客様は必要なサービスを選択し、必要な分だけご利用いただけます。それらを活用するために役立つ日本語資料、動画コンテンツを多数ご提供しております。(本サイトは主に、AWS Webinar で使用した資料およびオンデマンドセミナー情報を掲載しています。)

[AWS Webinar お申込 »](#)

[AWS 初心者向け »](#)

[業種・ソリューション別資料 »](#)

[サービス別資料 »](#)

<https://amzn.to/JPArchive>



AWS Well-Architected 個別技術相談会

毎週“W-A個別技術相談会”を実施中

- AWSのソリューションアーキテクト(SA)に
対策などを相談することも可能

- 申込みはイベント告知サイトから

(<https://aws.amazon.com/jp/about-aws/events/>)

AWS イベント

で[検索]



ご視聴ありがとうございました

AWS 公式 Webinar
<https://amzn.to/JPWebinar>



過去資料
<https://amzn.to/JPArchive>

