Google Cloud

日経の DX を支える BigQuery を中心とした分析基盤の運用

小室貴之

日本経済新聞社

スピーカー自己紹介

- 名前: 小室 貴之 (Takayuki Komuro)
- 所属
  - 2013 - 2017: 株式会社ドワンゴ
  - 2017 - 2018: 株式会社マンバ
  - 2018-: 日本経済新聞社
- やっていること:
  - データ分析基盤上のアプリケーションと
    インフラの開発・運用

今日話すこと

- 日経におけるデータ分析基盤の課題
- BigQuery の活用方法
- Data Catalog によるドキュメンテーション
- Cloud Composer によるジョブ管理

日本経済新聞社におけるデータ分析

日経電子版とは

- 日経の記事を Web で配信
- 有料ユーザー 80 万人以上
- 無料ユーザー 450 万人以上

日経におけるデータ分析

- データ量
  - ユーザーイベントのみで 1 日約 1.5 億レコード
- 利用人数
  - 間接的な利用を含めるとほぼ全社員 (約 3000 人)
- クエリ実行数
  - アドホック: 約 2000 件 / 日
  - バッチ: 約 1 万件 / 日

日経におけるデータ活用例

- 編集部向けリアルタイム ダッシュボード
- 記事推奨
- マーケティング施策分析
- リアルタイム マーケティング オートメーション
- ...etc

編集向けダッシュボード

BigQuery を採用した背景

課題 1 : スケールの難しさ

- 日々増大していくクエリの実行やデータ量に対して
  従来利用していたデータウェアハウスでは
  スケールするのが難しくなっていた
  - ストレージの追加が追いつかず、古いデータをDWH
    の外部に退避させていた
  - 夜間などの大量のバッチが実行される時間帯に
    一時的にコンピューティング リソースが
    足りなくなる現象が発生していた

課題 2 : 運用が追いつかない

- 利用者からの依頼でテーブル作成やカラム変更、
  DWH へのアクセス権の付与等をデータエンジニアが行っ
  ていたが、依頼が増えるに連れてその作業に
  割かれる時間が増えていった

スケーラビリティの解決

BigQuery とは

“
ビジネスのアジリティに対応して設計された、サーバーレスでスケーラビリティと
費用対効果に優れたマルチクラウド データ
ウェアハウスです。”

出典: https://cloud.google.com/bigquery?hl=ja

データ分析基盤のアーキテクチャ

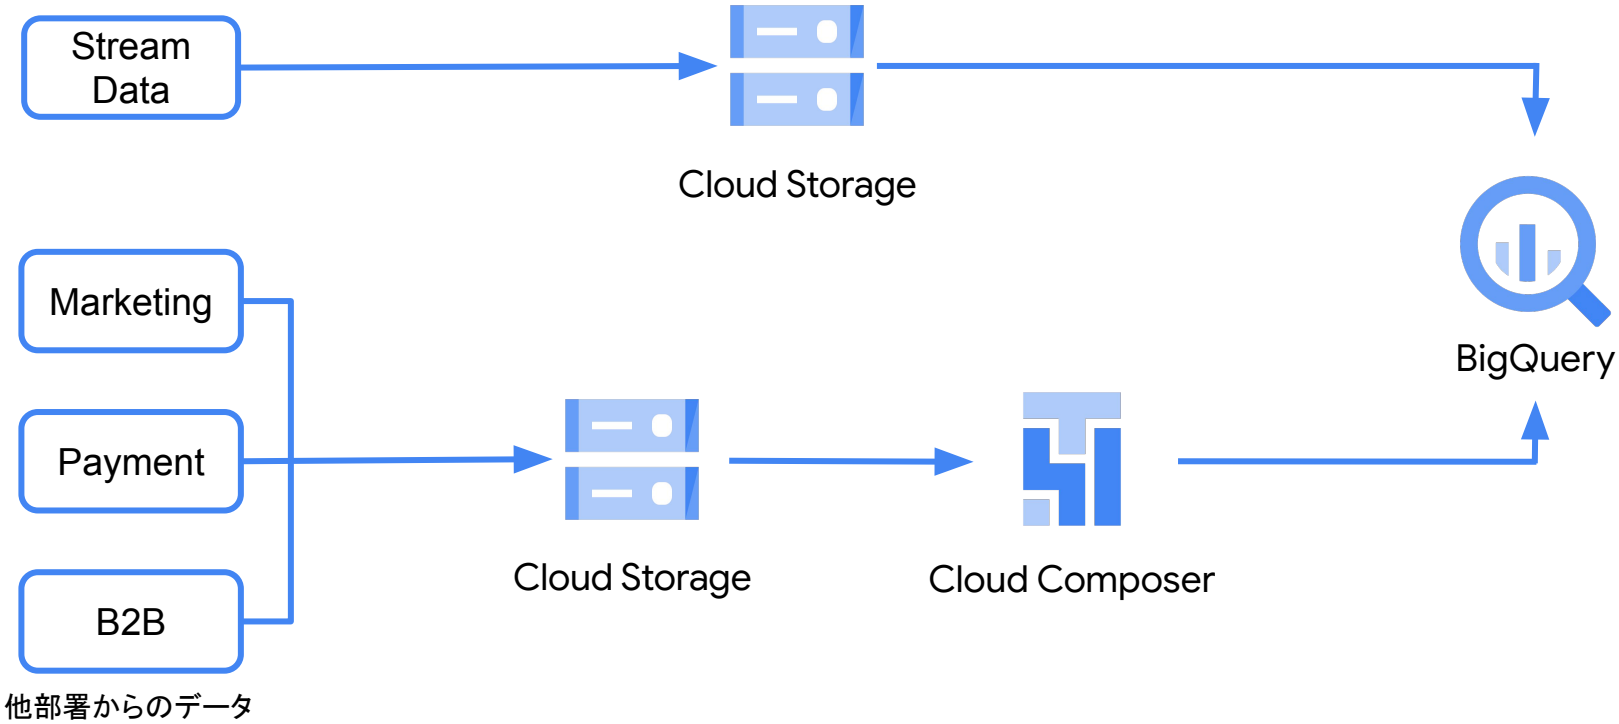

データ分析基盤のアーキテクチャ

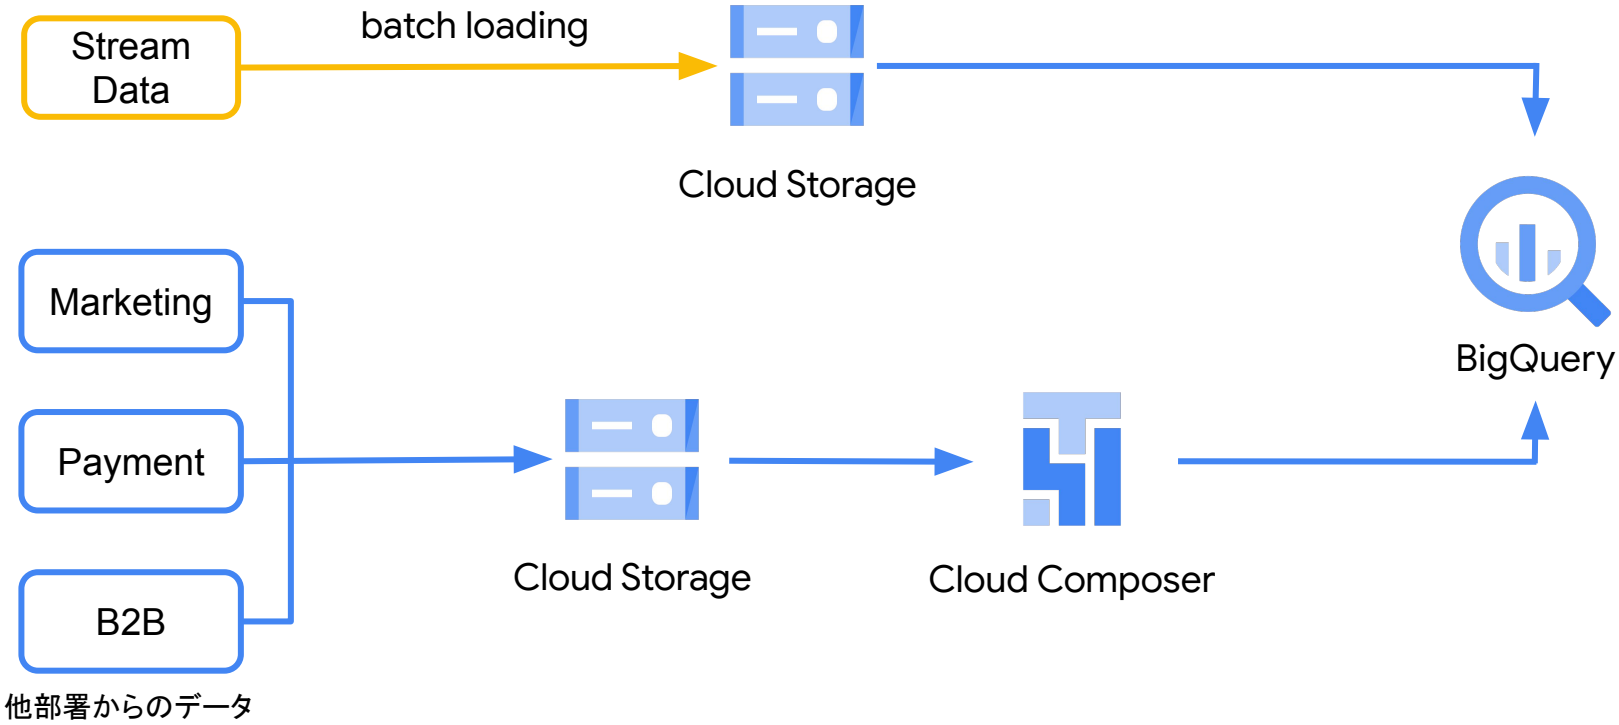

データ分析基盤のアーキテクチャ

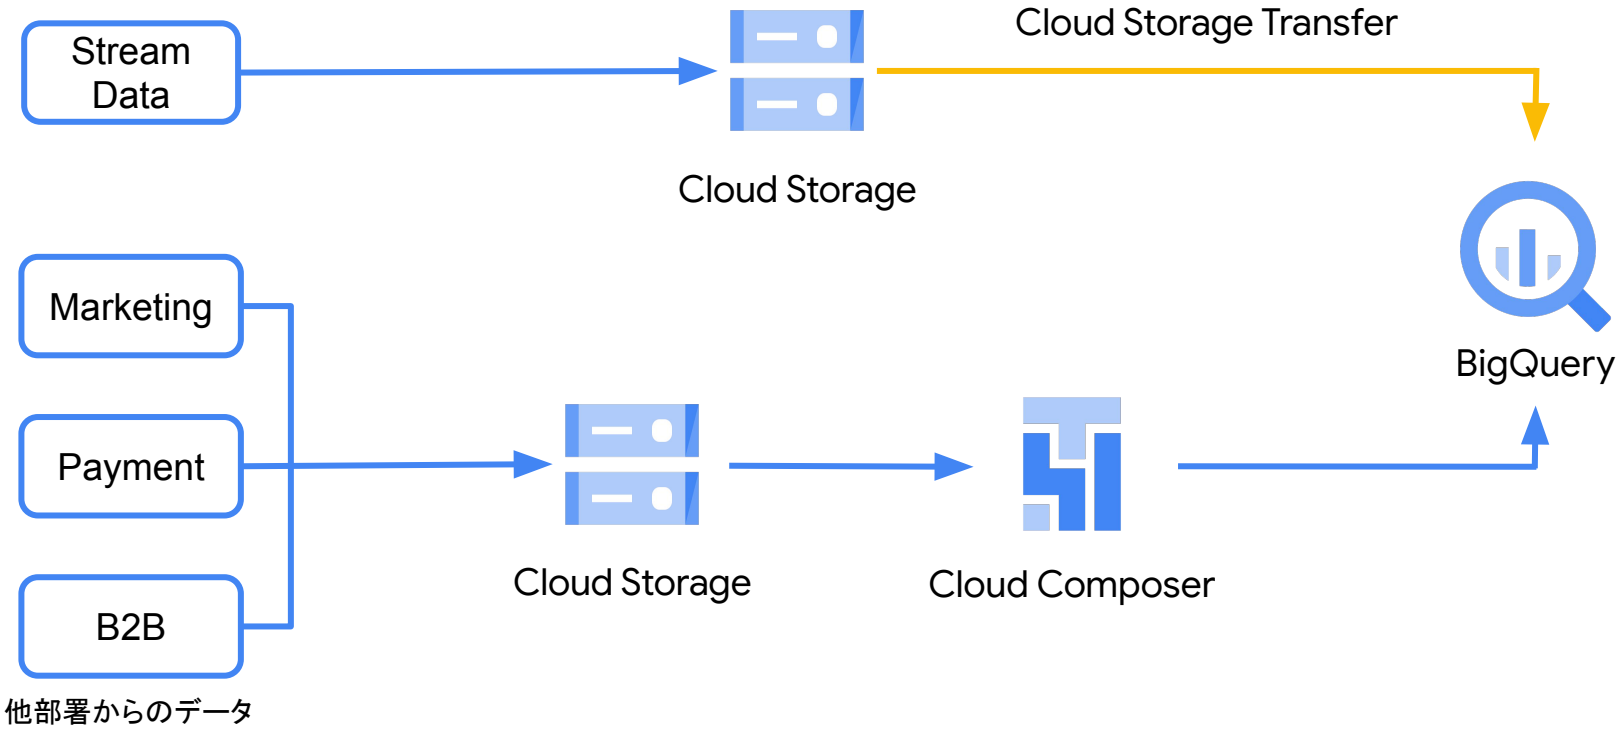

データ分析基盤のアーキテクチャ

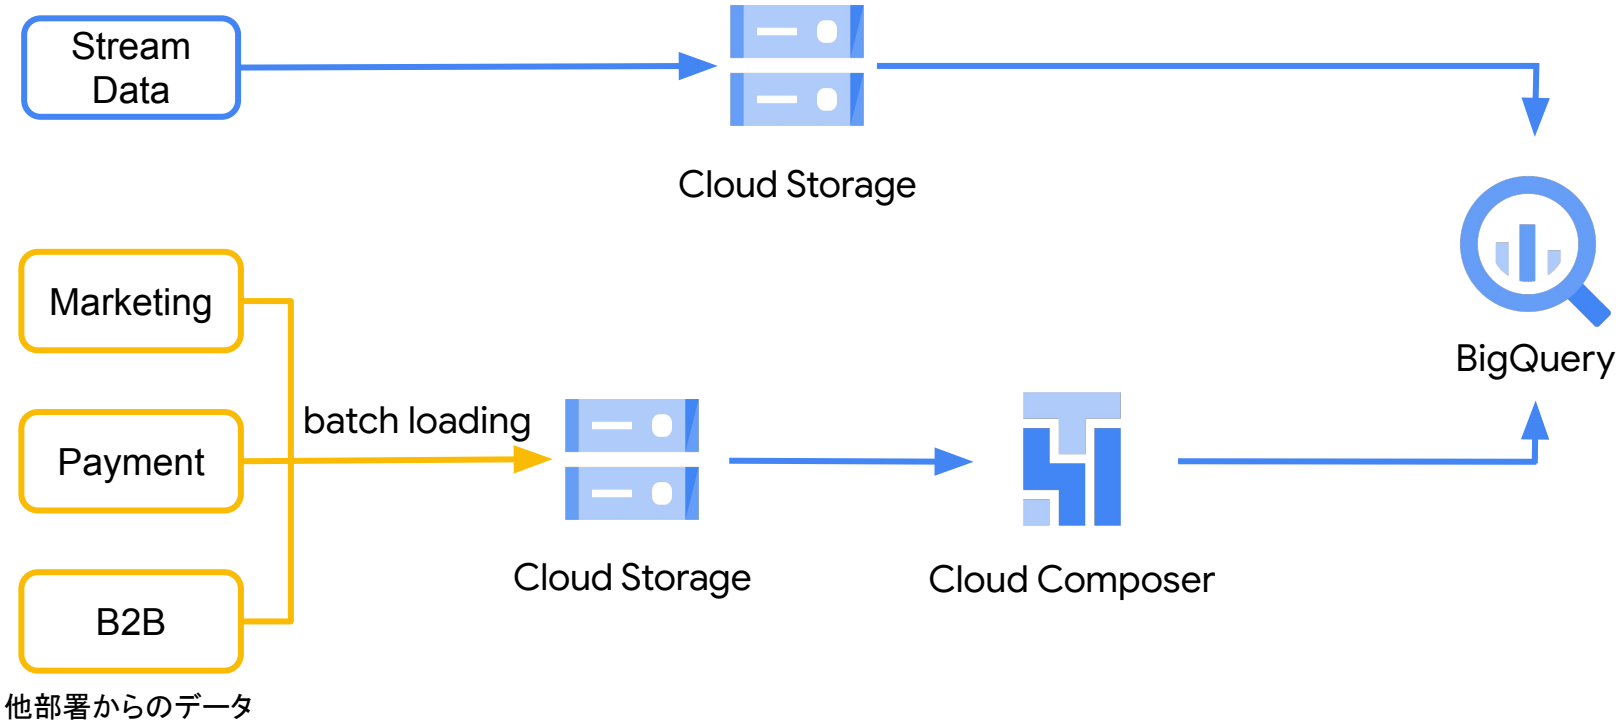

データ分析基盤のアーキテクチャ

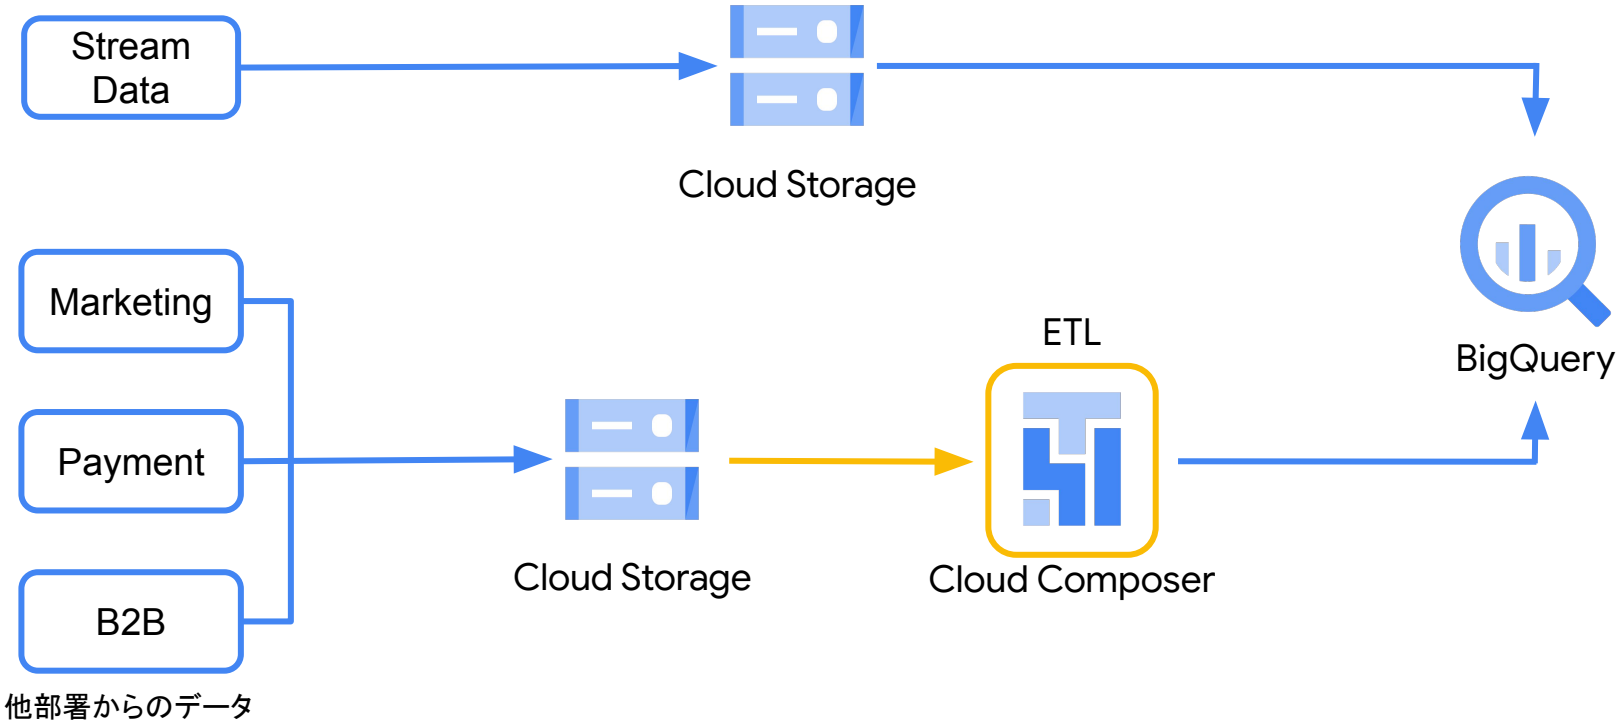

データ分析基盤のアーキテクチャ

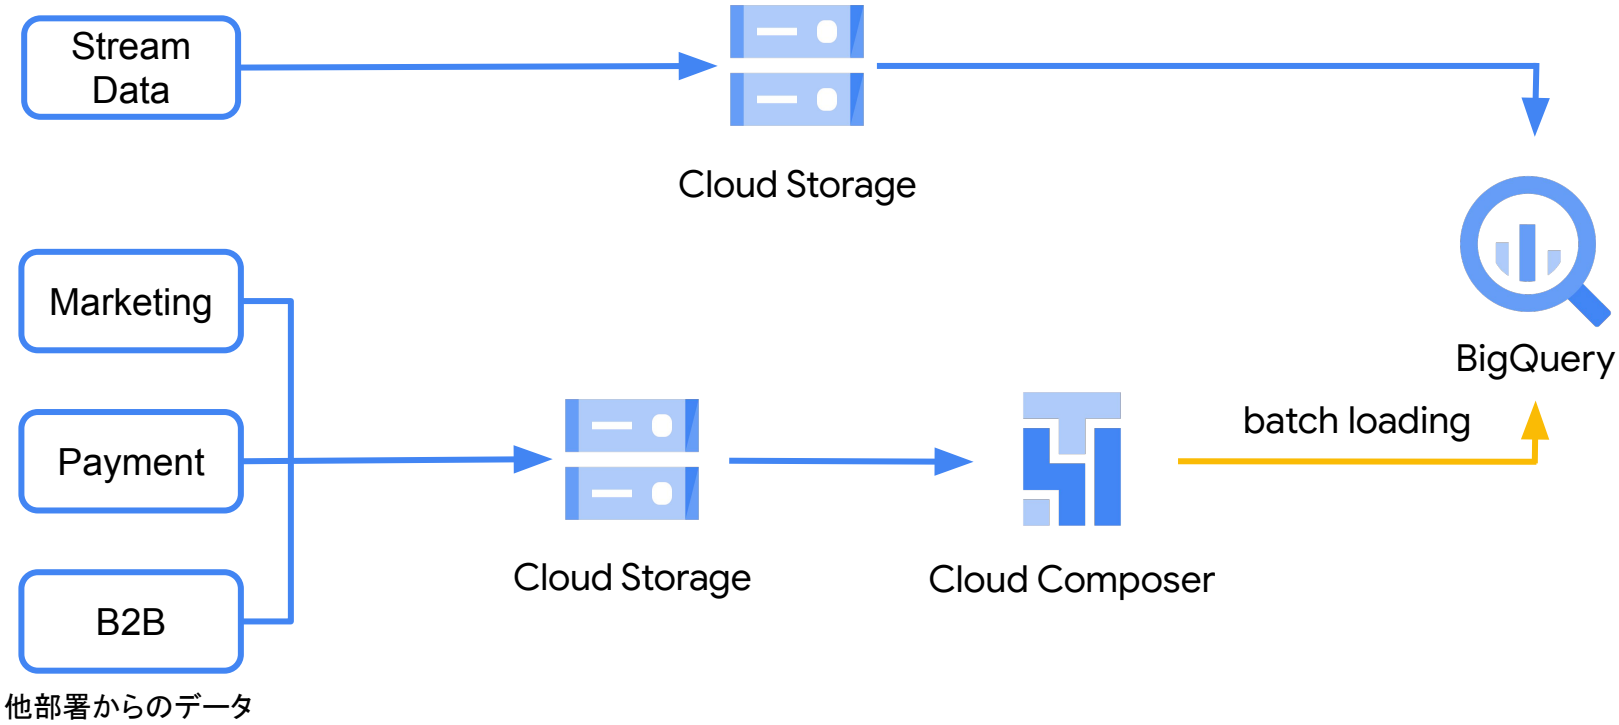

BigQuery の活用法

- 日経ではかなりのアドホック クエリが実行されるためコストの把握しやすい**定額料金モデル**で利用している
- また、夜間バッチなどの急激な利用の増加に対しては**Flex Slots** を利用している
  - 仕様としてコミット期間が 60 秒、その後はいつでもキャンセル可能
  - 秒単位の課金

待機ジョブをトリガーにした Flex Slots の割当

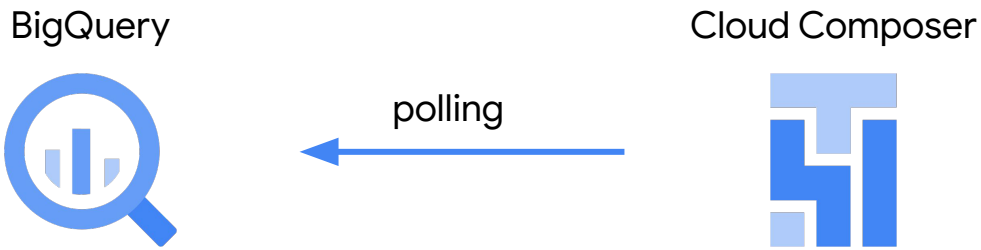

Cloud Composer から BigQuery API を呼び出してジョブ一覧を取得。待機ジョブ数が一定の閾値を超えたら BigQuery Reservation の API を呼び出して Flex Slots を割り当てる。

実際に Flex Slots を割り当てたときの様子

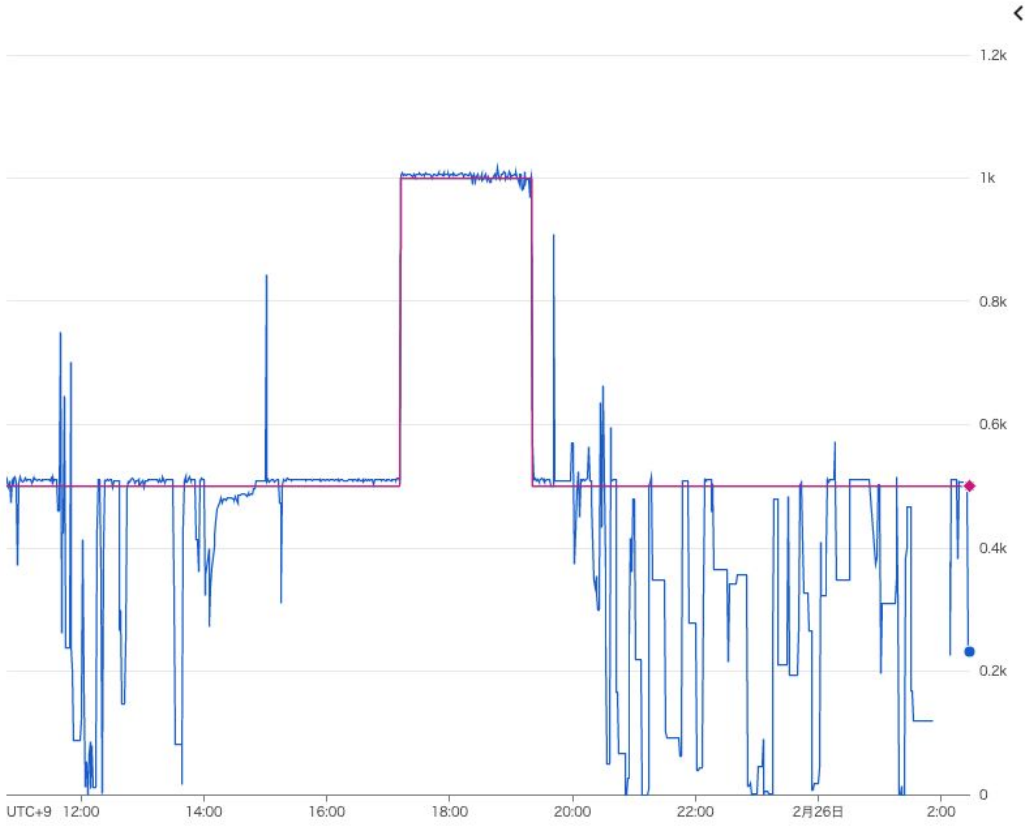

スケーラビリティの解決

- BigQuery のストレージ容量は無制限なため、
  データ量が増加するごとにノードの追加やデータの
  退避などの必要がなくなった
- Flex Slots の利用により急激な利用増加に対する
  スケールが容易になった

運用工数増大の解決

terraform の活用

- Google Cloud 上のインフラはほぼすべて terraform を利用して構築している
- テーブル作成やカラム追加等の作業はテンプレート化された terraform モジュールに対してPull Request を送って貰う形で依頼する方式に変更

テーブル作成のコードの例

terraform を書きなれていない方でも Pull Request が出来るように抽象化。

```
variable "tables" {
  type = map(map(string))
  default = {
    "example.table1" = {
      description = "example table",
      partition = "column1",
      clustering = "column2,column3"
    }
  }
}
```

テーブル定義の例

テーブル定義はJSON で
記述出来るようになって
おり、フォーマットはBigQuery
標準のものに
則っている。

```
[
  {
    "name": "column1",
    "type": "DATETIME",
    "mode": "REQUIRED",
    "description": "example column 1",
  },
  {
    "name": "column2",
    "type": "STRING",
    "mode": "NULLABLE",
    "description": "example column 2",
  },
  {
    "name": "column3",
    "type": "INTEGER",
    "mode": "NULLABLE",
    "description": "example column 3",
  }
]
```

Pull Request からテーブル作成までのフロー

Pull Request からテーブル作成までのフロー

Pull Request からテーブル作成までのフロー

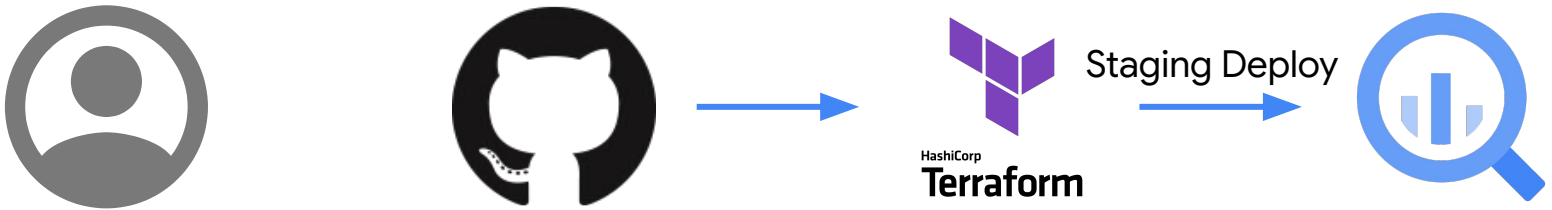

Pull Request からテーブル作成までのフロー

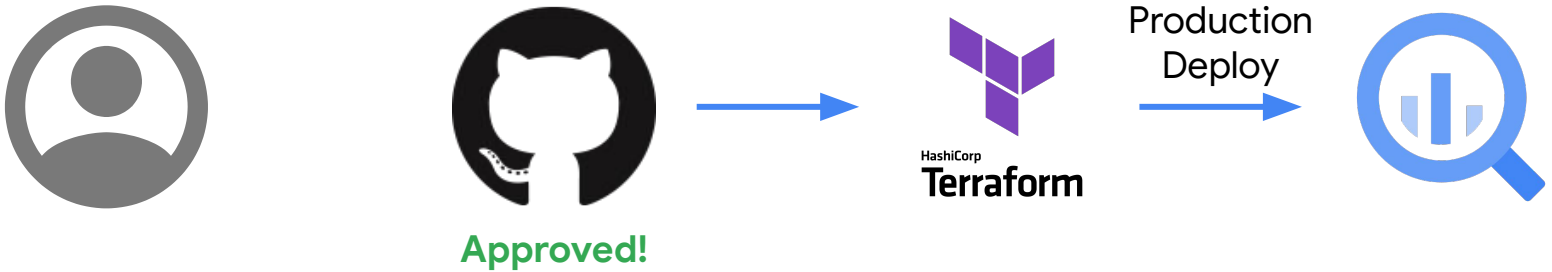

terraform によるアクセス制御

- BigQuery のデータセットやテーブルへの
  アクセス権限の付与もすべて terraform によって
  管理している
- テーブル作成等と同様にテンプレート化
- BigQuery の基本ロールでは必要以上の権限が
  付与され、不意にテーブルが変更されてしまう等の
  問題が発生したため現在ではカスタムロールを
  定義して利用者に付与している

アクセス制御のコードの例

```
variable "bigquery_dataset_access_control" {
  default = {
    example_dataset = {
      "user1@example.iam.gserviceaccount.com"
= "WRITER"
    }
  }
}
```

Data Catalog による ドキュメンテーション

Data Catalog とは

“Data Catalog は、Google Cloud の
データ分析プロダクト ファミリーに含まれる、
フルマネージドのスケーラブルな
メタデータ管理サービスです。”

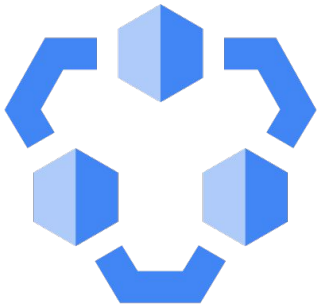

出典: https://cloud.google.com/data-catalog/docs/concepts/overview

Data Catalog の活用

- 日経ではデータ分析基盤の利用者向けのドキュメント用の Web サイトを社内に公開している
- その中で Data Catalog を利用して BigQuery のテーブルやカラムの意味を検索できるページを作成

Data Catalog によるドキュメンテーション

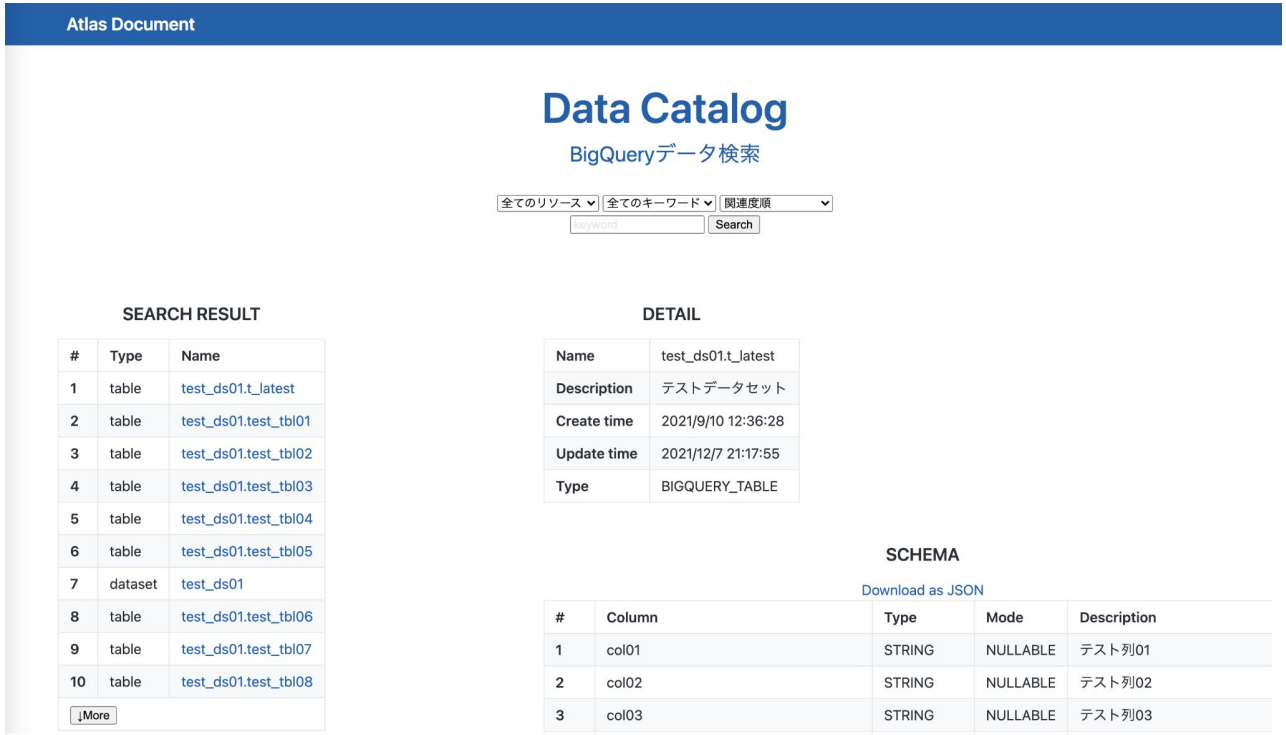

Atlas Document

Data Catalog

BigQueryデータ検索

全てのリソース | 全てのキーワード | 関連度順

keyword | Search

SEARCH RESULT

#	Type	Name
1	table	test_ds01.t_latest
2	table	test_ds01.test_tbl01
3	table	test_ds01.test_tbl02
4	table	test_ds01.test_tbl03
5	table	test_ds01.test_tbl04
6	table	test_ds01.test_tbl05
7	dataset	test_ds01
8	table	test_ds01.test_tbl06
9	table	test_ds01.test_tbl07
10	table	test_ds01.test_tbl08

↓More

DETAIL

Name	test_ds01.t_latest
Description	テストデータセット
Create time	2021/9/10 12:36:28
Update time	2021/12/7 21:17:55
Type	BIGQUERY_TABLE

SCHEMA

Download as JSON

#	Column	Type	Mode	Description
1	col01	STRING	NULLABLE	テスト列01
2	col02	STRING	NULLABLE	テスト列02
3	col03	STRING	NULLABLE	テスト列03

Cloud Composer を利用したジョブの運用

Cloud Composer とは

“Cloud Composer は、フルマネージドのワークフロー オーケストレーション サービスです。クラウドとオンプレミス データセンターにまたがるワークフローの作成、スケジューリング、モニタリング、管理ができます。”

出典: https://cloud.google.com/composer/docs/concepts/overview

Cloud Composer の活用

- DWH を BigQuery に移行する際に
  ジョブ スケジューラも Cloud Composer に移行
- 以前は様々なジョブが別々のスケジューラで
  動いていたためジョブの依存関係の把握が困難だった
- DAG をそのまま利用者に書かせるのはハードルが
  高いので頻繁に利用されるケースはテンプレート化

ジョブのコードの例

select 結果を特定の S3 バケットに転送するジョブ(SQL は別途必要)

```
variable "bigquery_select_to_s3" {
  type = map(object(...))
  default = {
    "example_job" = {
      schedule_interval = "timedelta(minutes=30)",
      start_date        = "datetime(2022,4,19,0,0,0)",
      retries           = 3,
      retry_delay       = "timedelta(minutes=5)",
      email             = "xxx@example.slack.com",
      aws_conn_id       = "s3_example",
      dest_s3_prefix    = "s3://example_bucket/file_{{ ts_nodash }}_",
      replace           = "True",
      format            = "CSV",
      plus_extention    = "",
      compression       = "",
      option = {
        "header"          = "true",
        "field_delimiter" = ","
      }
    }
}
```

まとめ

- 全社に DX を推進していく中での課題
  - 少人数のエンジニアでもスケール出来る運用体制の確保
  - 利用が拡大してもスケールできる DWH
- BigQuery、Cloud Composer と terraform の活用
  - 多くの人に利用してもらうためにリソースが
    作りやすくする仕組み作り

We’re Hiring!

- データエンジニアを絶賛募集中です
- 興味がある方は、
  - Twitter (@nikkeideveloper) に DM
  - 技術ブログ・採用サイト: https://hack.nikkei.com
- カジュアル面談大歓迎
  - https://herp.careers/v1/nikkei

Thank you.

Google Cloud