

BigQuery で始める SQL

～SQL を覚えて BigQuery を使い倒そう～

2022 / 06 / 07

Google Cloud

Data Analytics Specialist

Tetsunori Nishimura

データ分析基盤のステークホルダー	01
SQL で何ができるようになるのか	02
SQL を使った分析例	03
まとめ	04

01

データ分析基盤のステークホルダー 前回のおさらい

データ分析のステークホルダー



ビジネスユーザー



グロースハック/
デジタルマーケ



データアナリスト
データサイエンティスト



IT部門

データの在り処やそれに対する
アクセス方法が不明

できる人でも Excel の関数やピボットテー
ブルが限界、SQL は無理

IT 部門の用意してくれた BI ツールのダッ
シュボードでは要件が
満たされない、変更を依頼しても
待たされる

専門の分析ツールには慣れている
(web なら GA / アプリなら
Firebase など)

チャネル横断での分析まで手がけたい

業態によってリアルタイム データに
対する要求が強い

自分の得意とする言語でデータを
触りたい

データの素性を重視する

クエリ速度に生産性が大きく
依存するが、IT 部門の管理する
インフラに手が出ない

分析結果を共有する方法がない


将来のデータ増加予測に基づく
インフラのサイジングが困難→サ
イロ化

ビジネス部門の要件が曖昧で頻繁にか
わる、それに合わせた DB のチューニン
グが辛い

要件を全て実現するとストレージ
枯渇やバッチ突き抜けリスクがある

セキュリティ・ガバナンスの
観点から LoB 側に勝手に BI ツールや
DWH を持ってほしくない

ステークホルダーと Google Cloud 機能の関連




02

SQL で何ができるようになるのか？

SQL を使うメリット

- 思考にあわせて自由に分析できる

- データの抽出をエンジニアにお願いしなくてもいい
- 自由にデータを加工、変換して分析に利用できる
- データ探索がしやすい




年齢層、金額の範囲等を軸にし集計
次にその範囲変えてみて分析


購入回数の分布をヒストグラムにする

ID	住所	年齢	購入金額	購入回数

BI 側で定義して処
理する



SQL で定義して
DWH で処理する



SQL を使うメリット

- 過去から最新のデータまで明細レベルで分析ができる
 - ツール側では保持できないデータ
- 設計した分析作業を他者と共有しやすい
- どのデータ ウェアハウス製品に対しても分析できるスキルが身につく
 - 方言はあるものの SQL の基本的な考え方は同じ

SQL を使うメリット

- BigQuery を使っていると
 - **機械学習**ができる
 - PostGIS の関数を使って**位置情報の分析**ができる
 - **GA の生データ**を使って分析ができる
 - 大量の**データを高速**に分析することができる
 - Web Console からすぐに SQL を始められる

SQL を使う場合の注意点

- ガバナンス
 - 同一の指標でも定義がバラバラになりやすい
 - 分析に必要なデータがどのテーブルにあるかわからないことがある
 - ツールだけでなくデータ ウェアハウス側でのアクセス制御もしっかりする必要がある

03

SQL を使った分析

SQL の基礎

テーブルからデータを抽出する

SELECT 取得する列を指定

FROM 検索対象のテーブルを指定

WHERE 検索条件を指定(行を指定)

event_date	event_timestamp	event_name	event_params
20210131	1612069510766593	page_view	[{"key": "gclid", "value": {4}}, {"key": "gclidsrc", "value": {4}}, ...]
20210131	1612069529243877	scroll	[{"key": "debug_mode", "value": {4}}, {"key": "session_engaged", "value": {4}}, ...]
20210131	1612069515781635	page_view	[{"key": "debug_mode", "value": {4}}, {"key": "engagement_time_msec", "value": {4}}, ...]
20210131	1612069530073506	user_engagement	[{"key": "page_location", "value": {4}}, {"key": "ga_session_id", "value": {4}}, ...]
20210131	1612069510766593	session_start	[{"key": "ga_session_number", "value": {4}}, {"key": "ga_session_id", "value": {4}}, ...]
20210131	1612069510766593	first_visit	[{"key": "engaged_session_event", "value": {4}}, {"key": "ga_session_number", "value": {4}}, ...]
20210131	1612111667188347	session_start	[{"key": "engaged_session_event", "value": {4}}, {"key": "page_location", "value": {4}}, ...]
20210131	1612111667188347	first_visit	[{"key": "engaged_session_event", "value": {4}}, {"key": "ga_session_number", "value": {4}}, ...]

```
SELECT event_date, event_name
```

```
FROM
```

```
`bigquery-public-data.ga4_obfuscated_sample_ecommerce.events_20210131`
```

```
WHERE event_name = 'page_view'
```

SQL の基礎

テーブルを結合する

結合ができると例えば

購入履歴表と顧客表を結合して、どのユーザが購入したのか等を分析できる

表 1 INNER JOIN 表 2 ON (表 1 のキー = 表 2 のキー)

結合キー

o_orderkey	o_custkey	o_orderstatus	o_totalprice
358616487	8867686	F	224573.16
358625184	2992948	F	2013.07
358687397	7880134	F	52223.76
358767175	4195423	F	173464.79
21636	8665708	F	264330.92

c_custkey	c_name	c_address	c_nationkey
7455354	Customer#007455354	0RKKQGxbYdfU0tYE9UBvyGhFuE	0
12503661	Customer#012503661	s E8lQpssiyc,BGUaOtby	0
4024604	Customer#004024604	o2s3aYYMSciQ2zcrw	0
8809228	Customer#008809228	ZFvua,hbfe	0
3444683	Customer#003444683	k6L9A7S8Rzxl,guB4DD,rmeO5LhuYeE	0
6846117	Customer#006846117	,Fy3Z7,36kUEJ04GXTrUM18UluibG5Npwx	0

```
SELECT c_custkey, o_orderkey, o_totalprice,  
       c_nationkey, c_mktsegment  
FROM orders INNER JOIN customer ON (o_custkey =  
                                     c_custkey)  
WHERE c_custkey = 8867686
```

c_custkey	o_orderkey	o_totalprice	c_nationkey	c_mktsegment
8867686	363939173	219154.71	22	BUILDING
8867686	76866624	18903.95	22	BUILDING
8867686	32364512	63341.24	22	BUILDING

よく使う結合方式

内部結合

結合条件に指定した列の値が
両方のテーブルで一致する
レコードを連結

```
SELECT o.productid,  
       productname, totalprice  
FROM   orders o  
       INNER JOIN products p  
       ON (o.productid = p.productid)
```

productid	productname	total price
1	本	100
1	本	100
2	CD	300
3	ビデオ	40

外部結合

結合条件に指定した列の値が
両方のテーブルで一致する
レコードを連結し、一致しない
ものはそのままレコードを抽出

```
SELECT o.productid,  
       productname, totalprice  
FROM   orders o  
       LEFT OUTER JOIN products p  
       ON (o.productid = p.productid)
```

productid	productname	total price
1	本	100
1	本	100
2	CD	300
3	ビデオ	40
5	null	50

orders

orderid	productid	total price
1	1	100
2	1	100
3	2	300
4	3	40
5	5	50

products

productid	productname
1	本
2	CD
3	ビデオ

SQL の基礎

テーブルを集計する

集計ができると例えば

購入履歴表と顧客表を結合して、顧客セグメントごとの購入金額が分析できる

GROUP BY 列名 列の値ごとにグループ化する

SUM(列名) GROUP BY で指定した列の値ごとに集計する

o_orderkey	o_custkey	o_orderstatus	o_totalprice
358616487	8867686	F	224573.16
358625184	2992948	F	2013.07
358687397	7880134	F	52223.76
358767175	4195423	F	173464.79
21636	8665708	F	264330.92

c_custkey	c_name	c_address	c_mktsegment
7455354	Customer#007455354	0RKKQGxbYdfU0tYE9UBvyGhFuIE	AUTOMOBILE
12503661	Customer#012503661	s E8lQpssiyc,BGUaOtby	AUTOMOBILE
4024604	Customer#004024604	o2s3aYYMSciQ2zcrw	AUTOMOBILE
8809228	Customer#008809228	ZFvua,hbfe	AUTOMOBILE
3444683	Customer#003444683	k6L9A7S8Rzxl,guB4DD,rme0SLhuYeE	AUTOMOBILE

```
SELECT c_mktsegment, SUM (o_totalprice) AS  
totalprice  
FROM orders INNER JOIN customer ON  
(o_custkey = c_custkey)  
GROUP BY c_mktsegment
```

c_mktsegment	totalprice
FURNITURE	4537422598685.3232
BUILDING	4532175220620.9922
MACHINERY	4532294919624.94
AUTOMOBILE	4533727886178.2393
HOUSEHOLD	4532547817309.1123

集計関数の一部

- COUNT(列名)列の値をカウントする
- COUNT(DISTINCT 列名)列の値のユニーク数をカウントする
- SUM(列名)列の値を合計する
- AVG(列名)列の値を平均する
- MAX(列名)列の値の最大値を返す
- MIN(列名)列の値の最小値を返す

SELECT 文を組み合わせる サブクエリ

サブクエリを使うとクエリ内に複数の SELECT 文をネストしてより複雑な分析ができる
例えば、一定回数以上購入しているユーザ ID から、それに合致するユーザ情報を抽出

IN サブクエリ

5 回以上、購入しているユーザ

```
SELECT *
FROM customer
WHERE
  c_custkey IN (
    SELECT o_custkey
    FROM orders
    WHERE o_orderdate BETWEEN '1994-01-01' AND
'1994-01-31'
    GROUP BY o_custkey
    HAVING count (1) >= 5)
```

テーブル サブクエリ

```
SELECT customer.*
FROM customer INNER JOIN
  ( SELECT o_custkey
    FROM orders
    WHERE o_orderdate BETWEEN '1994-01-01' AND
'1994-01-31'
    GROUP BY o_custkey
    HAVING count (1) >= 5)
ON (c_custkey = o_custkey)
```

[サブクエリ](#)

条件式や関数等を使って値を変換する

条件式や関数等を使うことで値を変換することができる。
例えば、購入金額から顧客ランクをつける

```
SELECT
  o_custkey,
  CASE
    WHEN totalprice <= 100000 THEN 'NORMAL'
    WHEN totalprice <= 1000000 THEN 'MEDIUM'
    WHEN totalprice > 1000000 THEN 'ROYAL'
  END AS user_rank
FROM (
  SELECT o_custkey, SUM (o_totalprice) AS totalprice
  FROM orders
  WHERE o_orderdate BETWEEN '1994-01-01' AND '1994-01-31'
  GROUP BY o_custkey)
```

o_custkey	user_rank
8332000	ROYAL
8073208	ROYAL
13364107	ROYAL
8781157	ROYAL
6387151	ROYAL
10903121	MEDIUM
201529	MEDIUM

条件式や関数等を使って値を変換する

関数を使ってランク分けをする場合

```
SELECT
  o_custkey,
  RANGE_BUCKET (totalprice, [100000.0, 1000000.0]) AS user_rank
FROM (
  SELECT o_custkey, SUM (o_totalprice) AS totalprice
  FROM orders
  WHERE o_orderdate BETWEEN '1994-01-01' AND '1994-01-31'
  GROUP BY o_custkey);
```

o_custkey	user_rank
8781157	2
13364107	2
6387151	2
8332000	2
8073208	2
10910896	0
14346352	0

分析関数(Window 関数)を使って高度な分析をする

分析関数(WINDOW 関数)を使うことで行のグループに対しての値を計算し、各行に対して 1つの結果を返すことができる。

例えば、前月比、移動平均、ランク付けなどの分析ができる

monthly_sales 表

month	totalprice
1994-01-01	292071034855.67004
1994-02-01	263744269826.45023
1994-03-01	291904061988.78986
1994-04-01	282901983538.46973
1994-05-01	292129896276.40009
1994-06-01	283177418168.96039

```
SELECT
  month,
  totalprice,
  LAG (totalprice,1) OVER (ORDER BY month)
  AS last_month
FROM monthly_sales
```

1994-02-01 の行にとって 1 行前の
totalprice つまり、1 月の totalprice

month	totalprice	last_month
1994-01-01	292071034855.6701	null
1994-02-01	263744269826.45029	292071034855.6701
1994-03-01	291904061988.78986	263744269826.45029
1994-04-01	282901983538.46985	291904061988.78986

表全体をグループ化し、month 順に
並び替えて、1 行前の値をもってくる

分析関数(Window 関数)を使って高度な分析をする

3ヶ月移動平均の例

monthly_sales 表

month	totalprice
1994-01-01	292071034855.67004
1994-02-01	263744269826.45023
1994-03-01	291904061988.78986
1994-04-01	282901983538.46973
1994-05-01	292129896276.40009
1994-06-01	283177418168.96039

```
SELECT
  month,
  totalprice,
  AVG (totalprice) OVER (ORDER BY month ROWS
    BETWEEN 2 PRECEDING AND CURRENT ROW) AS
    moving_average
FROM monthly_sales
ORDER BY 1
```

1994-03-01 の行は、1 月、2 月、3 月の
totalprice の平均値

month	totalprice	moving_average
1994-01-01	292071034855.6701	292071034855.6701
1994-02-01	263744269826.4502	277907652341.06018
1994-03-01	291904061988.78986	282573122223.63672
1994-04-01	282901983538.46973	279516771784.56995
1994-05-01	292129896276.40009	288978647267.88654

表全体をグループ化し、month 順に並び替えて、2
行前から現在行の値の平均を計算する

機械学習を使って予測分析をする

SQL で変換、集計したデータを元に BigQuery ML で機械学習をすることができる。

例えば、firebase analytics のデータから解約予測をすることも可能

train 表

列名	説明
user_pseudo_id	ユーザーID
country	国
operating_system	OS
language	言語
cnt_user_engagement	user_engagement イベントの回数
cnt_level_start_quickplay	level_start_quickplay イベントの回数
cnt_level_end_quickplay	level_end_quickplay イベントの回数
cnt_level_complete_quickplay	level_complete_quickplay イベントの回数
cnt_level_reset_quickplay	level_reset_quickplay イベントの回数
cnt_post_score	post_score イベントの回数
cnt_spend_virtual_currency	spend_virtual_currency イベントの回数
cnt_ad_reward	ad_reward イベントの回数
cnt_challenge_a_friend	challenge_a_friend イベントの回数
cnt_completed_5_levels	completed_5_levels イベントの回数
cnt_use_extra_steps	use_extra_steps イベントの回数
user_first_engagement	最初の user_engagement イベントのタイムスタンプ
month	最初の user_engagement イベントの月
julianday	最初の user_engagement イベントのユリウス日
dayofweek	最初の user_engagement イベントの曜日
churned	解約したかどうか

XGBoost の分類を使い解約予測をする
モデルを作成

```
CREATE OR REPLACE MODEL bqmlga4.churn_xgb
OPTIONS (
  MODEL_TYPE="BOOSTED_TREE_CLASSIFIER",
  INPUT_LABEL_COLS=["churned"]
) AS
SELECT
  * EXCEPT (user_pseudo_id)
FROM
  bqmlga4.train
```

機械学習を使って予測分析をする

モデルの評価、モデルを使った予測も SQL で実行することができる

モデルの評価

```
SELECT
*
FROM
ML.EVALUATE (MODEL bqmlga4.churn_xgb)
```

precision	recall	accuracy	f1_score	log_loss	roc_auc
0.60330578512396693	0.19783197831978319	0.78459611772072635	0.29795918367346941	0.44179696790300887	0.79088511488511493

モデルで予測

```
SELECT
user_pseudo_id,
churned,
predicted_churned,
predicted_churned_probs[OFFSET (0)].prob as
probability_churned
FROM
ML.PREDICT (MODEL bqmlga4.churn_xgb,
(SELECT * FROM bqmlga4.train))
```

user_pseudo_id	churned	predicted_churned	probability_churned
383F4B98EC31DD2A915427D36A30354E	0	0	0.311443030834198
648F91A3D0D868FC410FC4614FF11811	0	0	0.11782803386449814
D0E006B5E441969283C94713E308A11D	0	0	0.40376183390617371
84F55D39B331B4D51467A32FEC5F0A5	0	0	0.3510470986366272
469473B2E1C330A74286BA52BA3CACF5	1	0	0.36152374744415283
F81A7FACD9640F8169D8DE2E27D217E6	0	0	0.40376183390617371
7B4198B05CE36E11C2623428A090BE16	0	0	0.311443030834198

BigQuery GIS で地理空間の分析をする

位置情報を BigQuery の GEOGRAPHY 型に格納し、BigQuery GIS を使うことで地理空間分析ができる

緯度経度 (-122.021, 37.406) から半径 50 KM 以内にあるウェザー ステーションを検索しその距離を計算

```
SELECT
  id,
  name,
  ST_GeogPoint (longitude, latitude) AS loc,
  ST_Distance (ST_GeogPoint (longitude,
latitude), ST_GeogPoint (-122.021, 37.406)) AS dist_meters
FROM
  `bigquery-public-data.ghcn_d.ghcnd_stations`
WHERE ST_DWithin (ST_GeogPoint (longitude,
latitude), ST_GeogPoint (-122.021, 37.406), 50*1000)
```

id	name	loc	dist_meters
USC00041206	BURLINGAME	POINT(-122.35 37.5833)	35087.780902089311
USC00046144	NEWARK	POINT(-122.0325 37.5147)	12129.452834746844
US1CASM0016	HALF MOON BAY 0.7 NW	POINT(-122.4454 37.4777)	38307.237462838872
US1CASZ0025	SANTA CRUZ 2.6 ESE	POINT(-121.9912 36.961)	49552.193255534607
USW00023293	SAN JOSE	POINT(-121.9239 37.3592)	10034.222760456691
USC00046642	PALO ALTO	POINT(-122.1667 37.4333)	13220.272376055093
US1CASZ0052	LIVE OAK 1.3 WNW	POINT(-122.0026 36.9879)	46519.228750611124

04

まとめ

まとめ

- BigQuery はユーザの使い慣れたツールで分析することができる
- さらに、SQL を使えるところにあわせて自由に分析できるようになる
- 機械学習や地理空間分析などの高度な分析も可能に

Thank you.