

オブジェクトストレージ向け SQL アクセス方式の提案と評価 Proposal and Evaluation of SQL Access Method for Object Storage

大越 淳平[†]
Jumpei Okoshi

近藤 伸和[†]
Nobukazu Kondo

渡辺 聡[†]
Satoru Watanabe

馬場 恒彦[†]
Tsunehiko Baba

[†]株式会社 日立製作所 研究開発グループ

1. 序論

近年、金融分野において改竄防止技術や冗長化技術を搭載したエンタープライズ向けオブジェクトストレージがアーカイブストレージとして活用されている[1]。オブジェクトストレージは、ディレクトリ構造でデータをファイルとして管理するファイルストレージと比較し、データサイズやファイル名の制約が緩い、HTTP 経由でデータの読み書きが可能であるなど、アーカイブ用途に適した特長を有している。

各金融機関は、蓄積されたアーカイブデータを、与信審査、マーケティング、不正取引監視などに活用している。例えば、与信審査においては、勘定系システムで生成された取引データをアーカイブストレージに格納し、格納された取引データと各取引主体（個人、企業など）の属性情報（年齢、年収、売上など）を組み合わせたデータ分析を行うことで取引主体の与信審査を行っている（図1）。




図1 アーカイブデータの利活用例

しかし、アーカイブストレージとして用いられるオブジェクトストレージのAPI (Application Programming Interface) の提供機能は、基本的なデータの追加・削除にとどまっている。このため、BI (Business Intelligence) ツールと連携した高度なデータ分析のためには、ETL (Extract Transform Load) ツールと連携したETL処理により、データ分析の目的に応じたデータベースであるデー

タマートの構築が必要となる。データマートの構築は、一般に、データ分析においてデータ準備と呼ばれ、全工数の6割程度を占める[2]ことから、アーカイブデータ利活用におけるボトルネックとなっている。本研究の目的は、前述のボトルネックを解消し、低工数でオブジェクトストレージに格納されたデータの分析が可能なアクセス方式を提案することにある。

2. SQL アクセス方式の提案

SQLは、データ分析において最も汎用的に用いられる言語の一つであり[3]、SQLIF (InterFace) を備えることで幅広いデータ分析に対応できる。本研究では、BIツールとデータマートのIFがSQLであることに着眼し、オブジェクトストレージに格納されたデータを、データマートの構築なしでSQLにてアクセス可能とするアクセス方式を検討した。

提案するSQLアクセス方式のシステム構成を図2に示す。提案システムは、オブジェクトストレージ、データベースSQLエンジン、およびインメモリSQLエンジンにより構成される。オブジェクトストレージと各SQLエンジン間のIFは、オブジェクトストレージのIFにおいてデファクトスタンダードとなっているS3¹を採用する。




図2 システム構成

本システムの特長として、データベースSQLエンジンとインメモリSQLエンジンの2つを備えていることが挙げられる。大容量のデータ処理が必要となるバッチ系の処理はデータベースSQLエンジンに、応答性の要求されるアドホック系の処理はインメモリで高速にデータを処理するインメモリSQLエンジンに、それぞれ割り当て

¹ <https://docs.aws.amazon.com/AmazonS3/latest/API/>

ることで各 SQL エンジンを使い分ける。これにより、幅広い SQL クエリに対応することが可能となる。オブジェクトストレージに格納されたデータの構造を定義するテーブル定義は、ディスクベース SQL エンジン内部のメタストアに格納され、インメモリ SQL エンジンと共有することで二重管理を避ける構成となっている。

3. フィージビリティ検証

本研究では、提案システムのアーカイブデータ利活用への適用を想定し、(1) エンタープライズ向けオブジェクトストレージを用いたシステム実装、(2) ベンチマークを用いた SQL コンプライアンス (各クエリに対する実行可能性)、の2観点のフィージビリティを検証した。

(1) の実装に関しては、図2に示したシステム構成を日立製オブジェクトストレージである Hitachi Content Platform (HCP)²をベースに、ディスクベース SQL エンジンである Hive³とインメモリ SQL エンジンである Impala⁴の組み合わせにより実装し、単純な SQL クエリが実行可能であることを確認した。

(2) の SQL コンプライアンスに関しては、意思決定支援システム向けのデータベースにおける代表的なベンチマークである TPC-H⁵を採用し、表1に示す環境で検証を行った。その結果、TPC-H の全クエリが実行可能であることを確認した。

表1 検証環境

CPU	Intel Xeon 3.60GHz
メモリ	8GB
TPC-H	1GB (ScaleFactor=1)

以上の検証結果より、エンタープライズ向けオブジェクトストレージと OSS (Open Source Software) ベースの SQL エンジンの組み合わせにより、アーカイブデータの利活用に代表される典型的なデータ分析に対応可能なシステムが構築可能であることを検証できた。

4. 評価

提案手法の評価として、金融機関における与信審査のユースケースを想定し、ETL ツールを用いてデータマートを構築してデータ分析を行う従来手法と、直接 SQL アクセスによりデータ分析を行う提案手法とで、分析工数の観点で削減効果を定量的に評価した。

データ分析は、CRISP-DM[4]の定義によれば、ビジネ

ス・データ理解、データ準備、モデリング、評価・展開のプロセスをたどる。想定ユースケースの与信審査で用いられる勘定系システムは、一般に RDB で構築されている。このため、ETL 処理による構造化が不要であり、データ準備工数の大部分が単純なデータの移行によるデータマートの構築であると想定できる。以上の議論により、提案手法によりデータ準備工数の大部分を削減でき、最大でデータ分析工数の60%を削減できると結論できる(図3、各プロセスの工数は文献[2]による)。




図3 データ分析工数の削減効果

5. 結言

本研究では、オブジェクトストレージに格納されたデータを、データマートの構築なしで SQL によりアクセス可能とする SQL アクセス方式を提案し、実機を用いた実装と SQL コンプライアンスのフィージビリティ検証を行った。また、金融機関の与信審査を想定したユースケースにおいて、データ分析工数を60%削減可能であることを明らかにした。

参考文献

- [1] Hitachi Vantara, "Rabobank Leads with Hitachi Content Platform (HCP) - Case Study," 2018.
- [2] D. Pyle, "Data Preparation for Data Mining," Morgan Kaufmann Publishers, Inc., 1999.
- [3] Stack Overflow, "Developer Survey Results 2017," <https://insights.stackoverflow.com/survey/2017>.
- [4] SPSS, "CRISP-DM 1.0," 2000.

*本書に記載されている会社名・製品名は、一般に各社の登録商標または商標です。

² <https://www.hitachivantara.com/en-us/products/cloud-object-platform/content-platform.html>

³ <https://hive.apache.org/>

⁴ <https://impala.apache.org/>

⁵ <http://www.tpc.org/tpch/>