「MapRによるHadoopの最新情報 ～市場動向とユースケース～」

2014/11/28

マップアール・テクノロジーズ株式会社
アライアンス&プロダクトマーケティング
三原　茂
smihara@mapr.com

© MapR Technologies

アジェンダ

1. MapR社のご紹介
2. Hadoopとは？
    1. Hadoopのマーケット状況
3. Hadoopの位置付け
    1. DWH
    2. BI
    3. ストレージ
4. MapRディストリビューション
5. まとめ

© MapR Technologies

MAPR®

MapR社概要（1）

MapR Technologies Inc.：

【Founder】 John Schroeder & M.C. Srivas
【設立】 2009年、カリフォルニア州サンノゼで設立
【従業員】 約 300 人
【拠点】 13カ所（米国、イギリス、フランス、ドイツ、シンガポール、オーストラリア、日本、韓国、スウェーデン）
【URL】 https://www.mapr.com/

日本法人：

【会社名】マップアール・テクノロジーズ株式会社
(MapR Technologies K.K.)
【所在地】〒100-0005
東京都千代田区丸の内1-8-3
丸の内トラストタワー本館20F
Tel: 03-5288-5370
eMail : sales-jp@mapr.com
【設立】 2013年4月

© Ma

Hadoopとは？

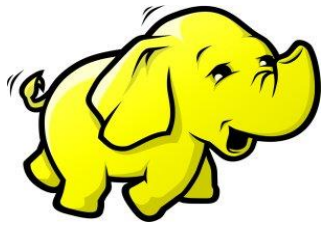

大きく**2つ**のコンポーネントで構成：

HDFS (Hadoop Distributed File System) 分散ファイルシステム

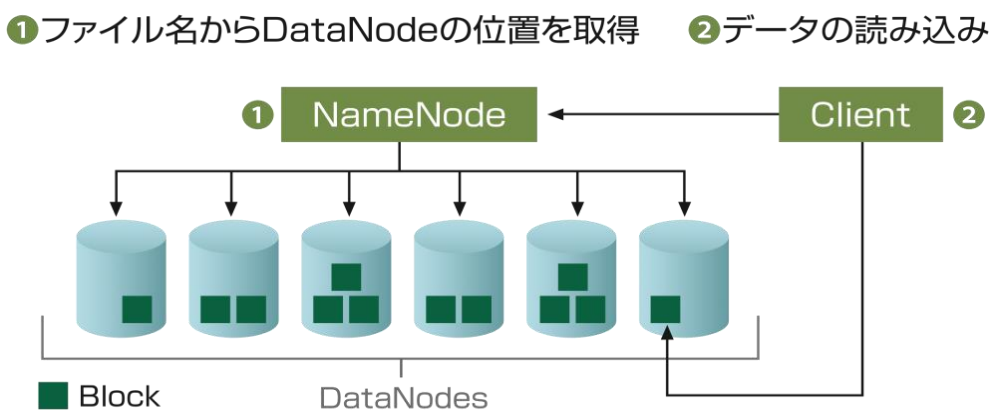

MapReduce 大規模分散処理フレームワーク

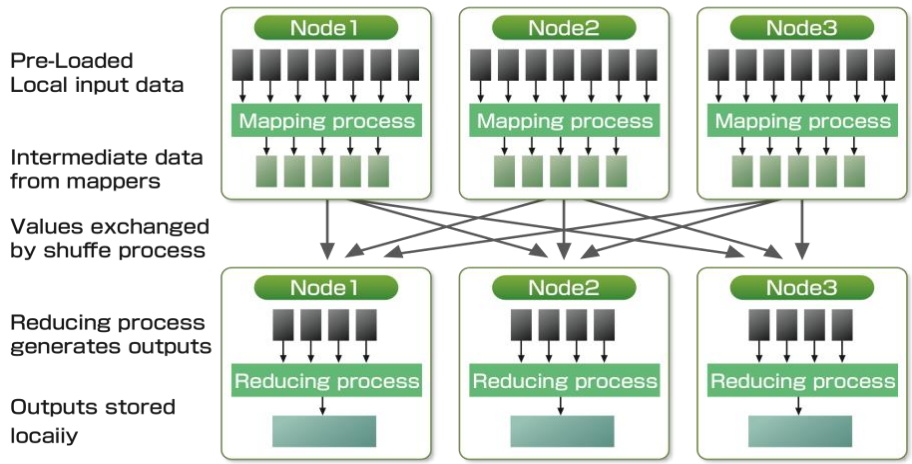

データをためる

データをブロックに分割して複数のサーバに分散配置／3つのレプリカを作成

データを加工する

Map/Reduceというシンプルな処理の組み合わせで、HDFS上にあるデータの分散処理を行う汎用的なフレームワーク

- 処理の近くにデータを置く：データ（保管）と処理能力（加工・分析）をデータのある場所で！
- 設計当初から大規模、大容量、増加し続けるデータに対応（分散処理＆スケールアウト）

MapRのパッケージ

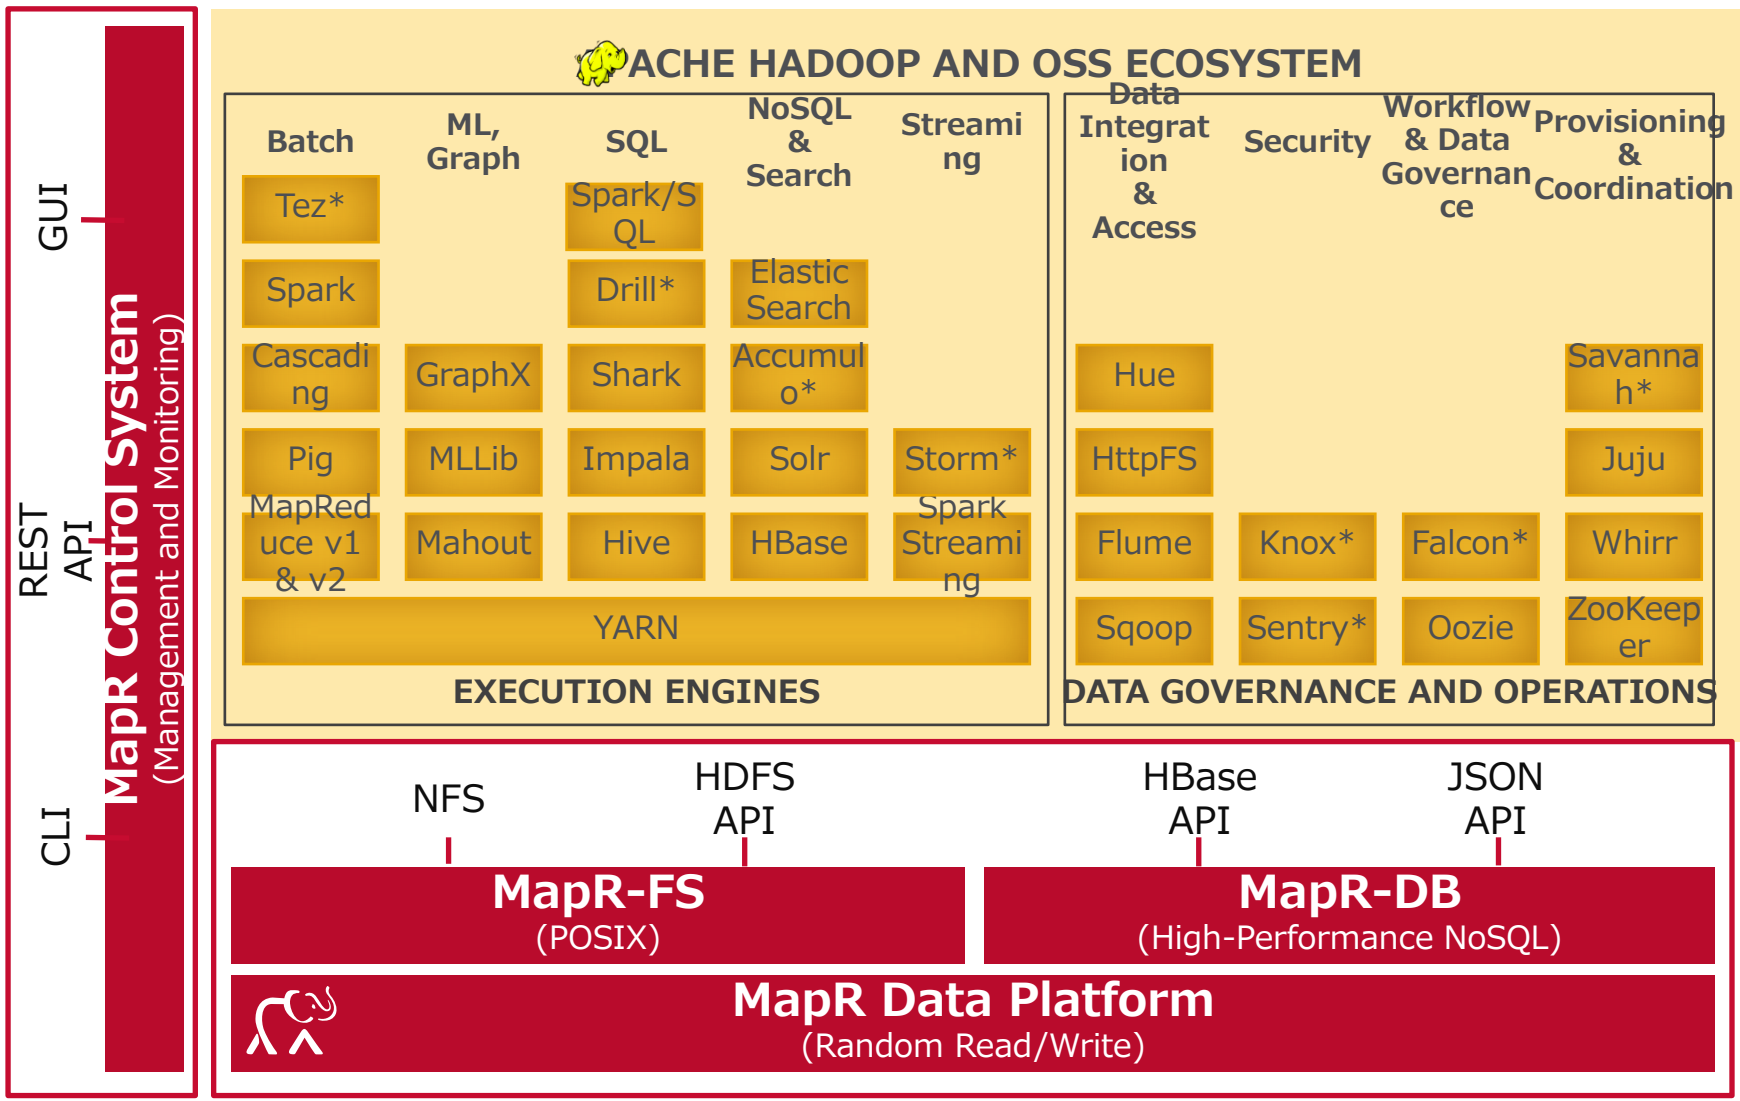

* In Roadmap for inclusion/certification

各Hadoop ディストリビューションの違い

先進性や進化

Apache Hadoop	各商用 ディストリビューション	MapR
	管理機能 イノベーション	管理機能 イノベーション
OPEN SOURCE hadoop	OPEN SOURCE hadoop	OPEN SOURCE hadoop
		インフラストラクチャ イノベーション
	保守/教育サービス	保守/教育サービス

© MapR Technologies

各Hadoopの評価

FORRESTER®

NoSQL: M7 (MapR-DB)

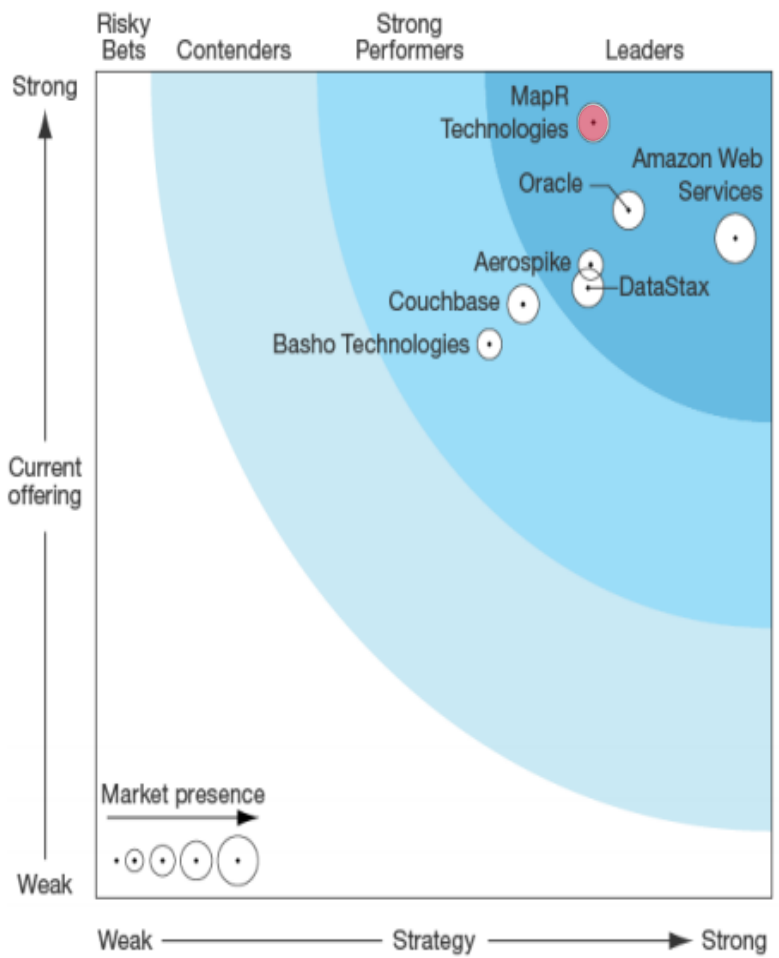

Forrester Wave™ NoSQL Key-Value Databases, Q3 2014

Hadoop: M5

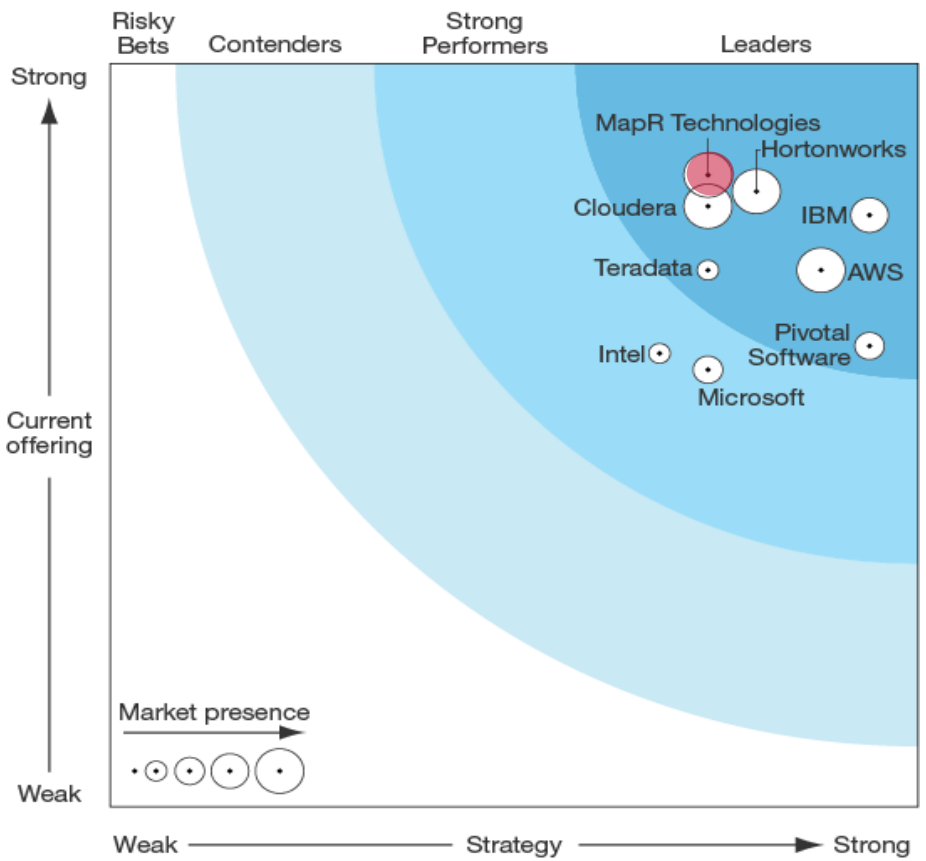

Forrester Wave™Big Data Hadoop Solutions, Q1'14

破壊的技術と採用へのモチベーション

Hadoop as “disruptive Technology”

IT予算の伸び率
2.5%

データの増加率
40%

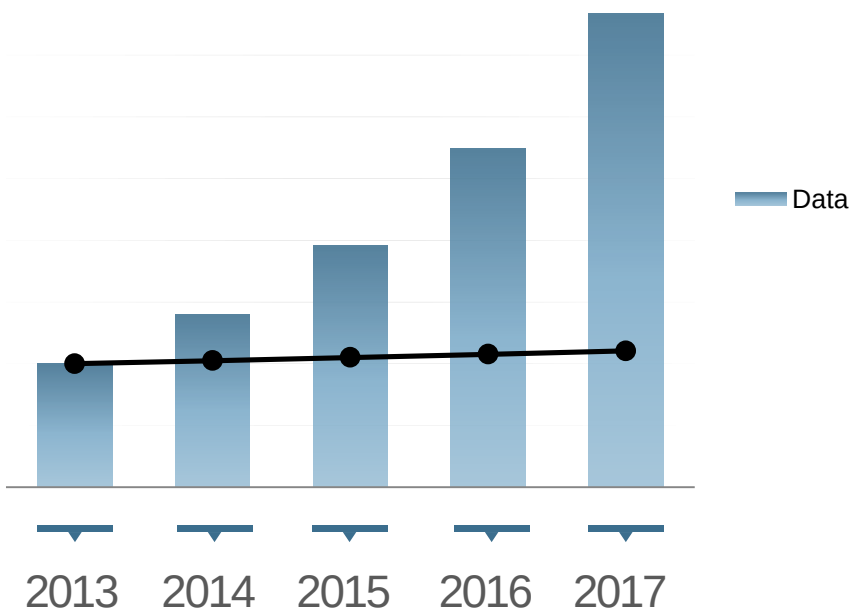

テラバイトあたりの
コスト

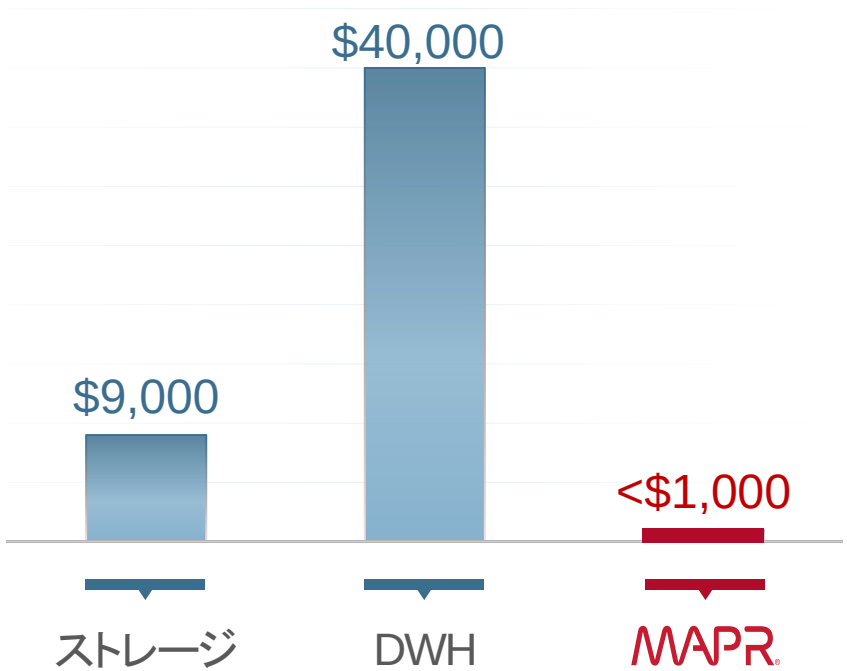

- Gartner, "Forecast Analysis: Enterprise IT Spending by Vertical Industry Market, Worldwide, 2010-2016, 3Q12 Update.“
- Wall Street Journal, “Financial Services Companies Firms See Results from Big Data Push”, Jan. 27, 2014

© MapR Technologies

MAPR

Hadoop活用の主な目的

① セールス/マーケティング
（売上/収益向上）

② リスク回避
（予防保守/不正検知）

③ 情報系IT
（コスト削減）

④ 基幹系IT
（効率向上）

Asakusa

© 2014 MapR Technologies

大手GMSチェーンのMapR活用例

Retail
Point of Sale System

Pharmacy
Information System

On-Line Shopping
Data

Loyalty Program System

Financial Data From
In-Store Bank Branches

Data From
Delivery Trucks

Business Problems

- 既存データはデータベースに関連無く広範囲に存在
- ロックされたバリューを簡単に解除することは困難
- 顧客統合視点では無い
- 効果的なロイヤルティプログラム
- 消費者の購買行動を部分的に理解
- 競合は顧客実装が進んでる ： 小売戦略中心
- ロイヤル顧客へのプロモーション

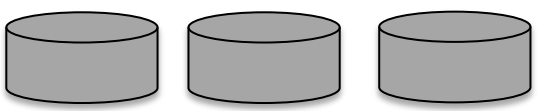

Financial & Logistics Data（構造化データ）

分析

ト
ティング
ンデーション

2500ノード

SNS, On-Line, POS, ポイント,位置情報ログ（非構造化データ）

コンバージョンレート

+2%

上乗せ収益

$1B

Business Benefits

- オンライン及びオフラインの行動を関
- 売れ筋商品の捕捉と理解
- どんな人（性別、年齢）が何時に何
- 動線・陳列最適化による商品クロスセ
  - レジ到達時間等の顧客のより包括的な視点活用
- クロスセリングからアップセリングを加速

© MapR Technologies

MAPR

大手金融業のMapR活用例
～不正検知～

以前のシステム：RDB + DWH

1TBデータ
抽出リピート

Data Analytics Tool

1 TB Memory Limit

100%のデータを
連続的に摂取

Terasort:45秒
Mininutesort:
1.6TB

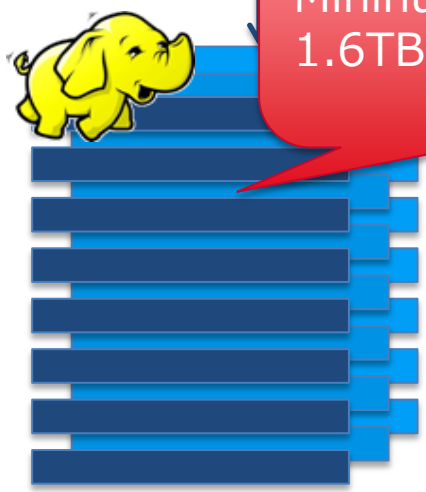

2000ノード+

1. SASにデータ抽出 (一度に1TB)
2. 例外処理を検出
3. 前の分析を基本にクエリを改良
4. 第2の洗練されたデータサンプルを抽出 (1TB)
5. 更なる例外処理を検出
6. 必要であれば繰り返し

矛盾データ検知時間:
巧妙な場合には数時間から数日必要
巨大な違反は検出し停止させるのに1週間必要な場合がある

数分で矛盾検知

- MapReduce + Hive (データウェアハウス 構築環境) + R (統計解析向けプログラミング言語 & 開発実行環境) + Python (オブジェクト指向スクリプト言語) により数分おきに全のデータを連続的に分析
- 不正行為と違反を直ちに検知

© MapR Technologies

分析関連システムのどこに位置付くか？

DWH（データウェアハウス）
各種データを一元的に格納
大量の明細や長期間の履歴を保有
多数のソースデータを高速で格納し、
日々更新するために最適化

DM（データマート）
特定のユーザーや特定用途のために抽出した一部のデータ
多数のユーザーが必要なデータを高速に検索・分析するために最適化

BI(ビジネス・インテリジェンス)
DWH/DMのデータを分析ニーズに合った表、グラフ、レポートとして表示
通常Webベース(ブラウザ)

ETL（データ統合）
複数のソースシステムから、一箇所（DWH）にデータを集める
抽出、変換、クレンジングを行う
DMの切り出しにもETLを活用

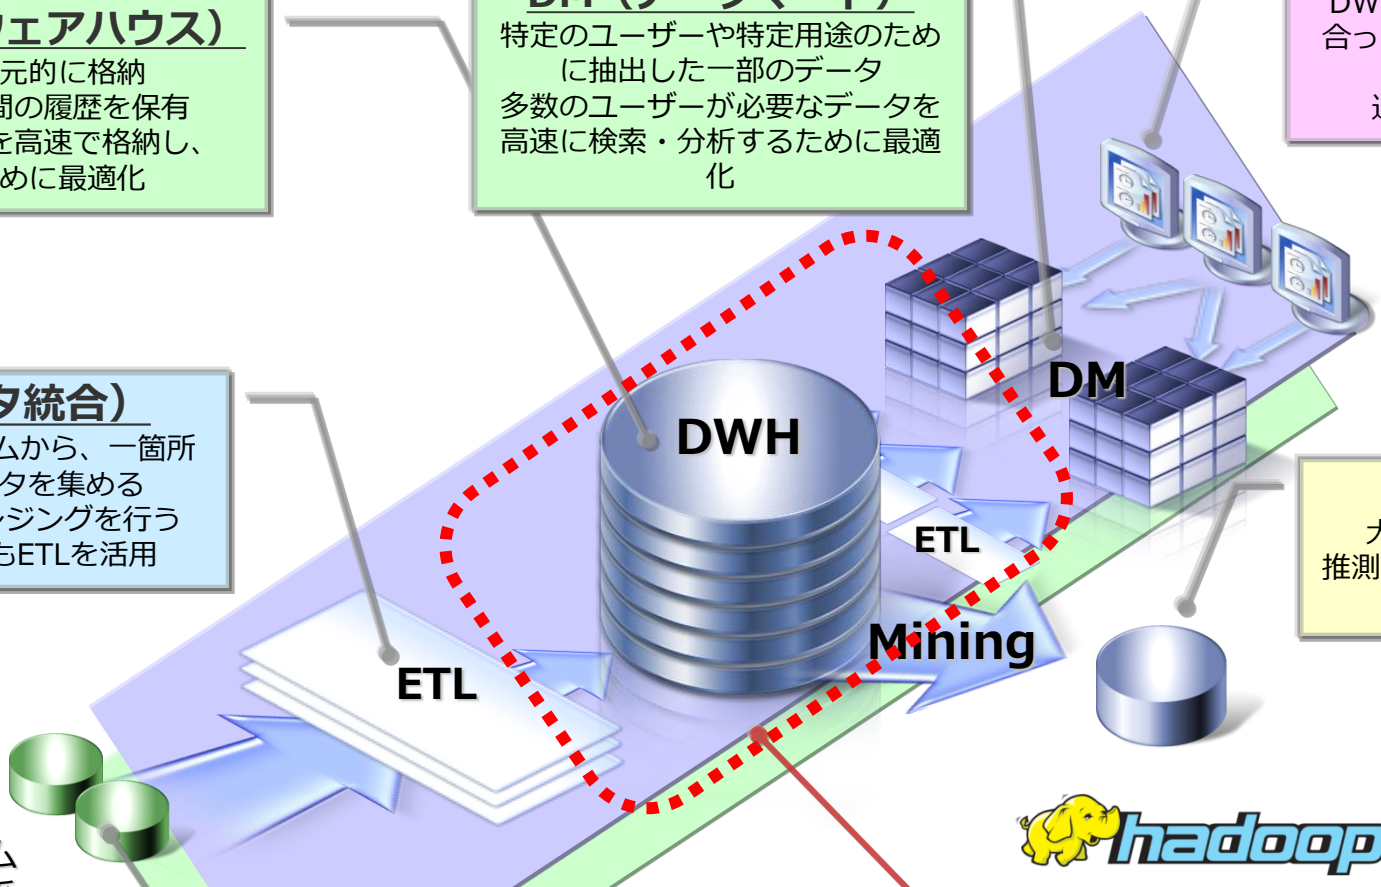

マイニング
大量データから未来を予測
推測統計、パターン発見、検定などの数理を活用

ソースシステム
基幹系、業務系

ソースシステム
基幹系、多数の業務系システム
様々な見るべき情報を保有
配置やデータ品質はバラバラ
（従来はこれを一つづつ見ていた）

Hadoop
大量データを溜め、処理、分析が
1カ所でできる新技術

© MapR Technologies

Verizonのコスト削減方法

1. ベライゾンのユーザが日々どういう使い方をしているか、ユーザプロファイルや営業/請求についての詳細を知る
2. サービス品質とサービス向上への修理や増設の元データが欲しい

1. 解約率を下げる
2. DWH関連コスト削減

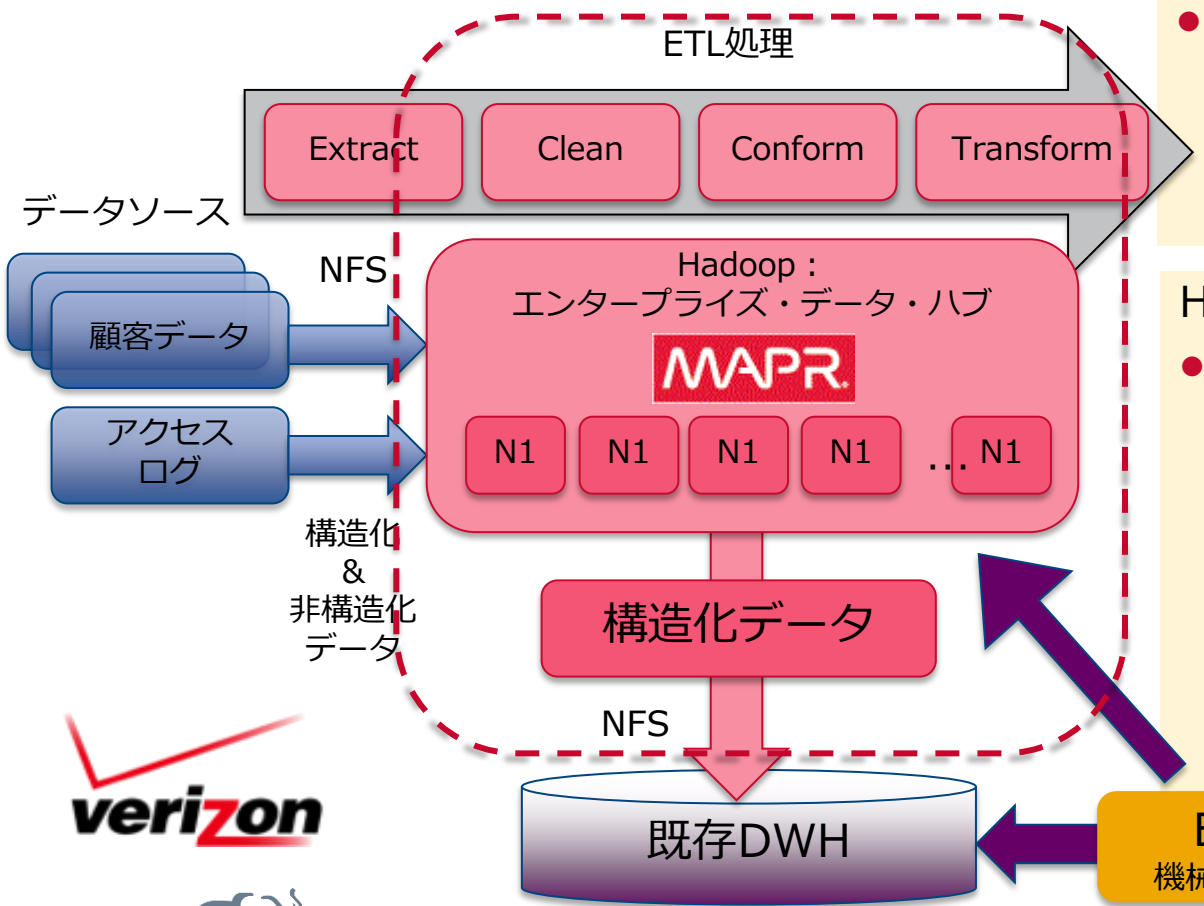

お客様のDWHの課題：

- 増え続けるデータに既存DWHでは対応できない
  - コスト
  - パフォーマンス
  - 非構造化データ（ログ等）への対応

Hadoop導入のメリット：

- DWHに入れるべきデータを選別でき、データ量とコストのバランスを取れる
  - DWH増設より圧倒的に低コスト（1/10に削減）
  - どこまでもスケールするパフォーマンス（3倍）
  - あらゆるデータを格納・処理
  - ソースから分析までの一環したデータフローを実現

verizon

Data Warehouse and Analytics

© MapR Technologies

MAPR

分析・レポートのニーズと現状

1. データ量を増やしたい — DWHの弱点
2. データ種を増やし、様々なニーズを拾いたい — DWHの弱点
3. コストは掛けられない — DWHの弱点
4. 既存SQLをなるべくそのまま活かしたい
   - BI等の既存ツールを継続利用したい — Hadoopの弱点
   - MapReduceをJavaで書くのは敷居が高い
5. セルフサービス化をしたい — DWHの弱点
   - 情シス負荷は増やせない
6. リアルタイム性を上げたい — Hadoopの弱点

© 2014 MapR Technologies

多様化するHadoop環境へのアクセス

データはHadoop基盤に集約
分析の結果はHadoop基盤、DWH基盤の両基盤で活用

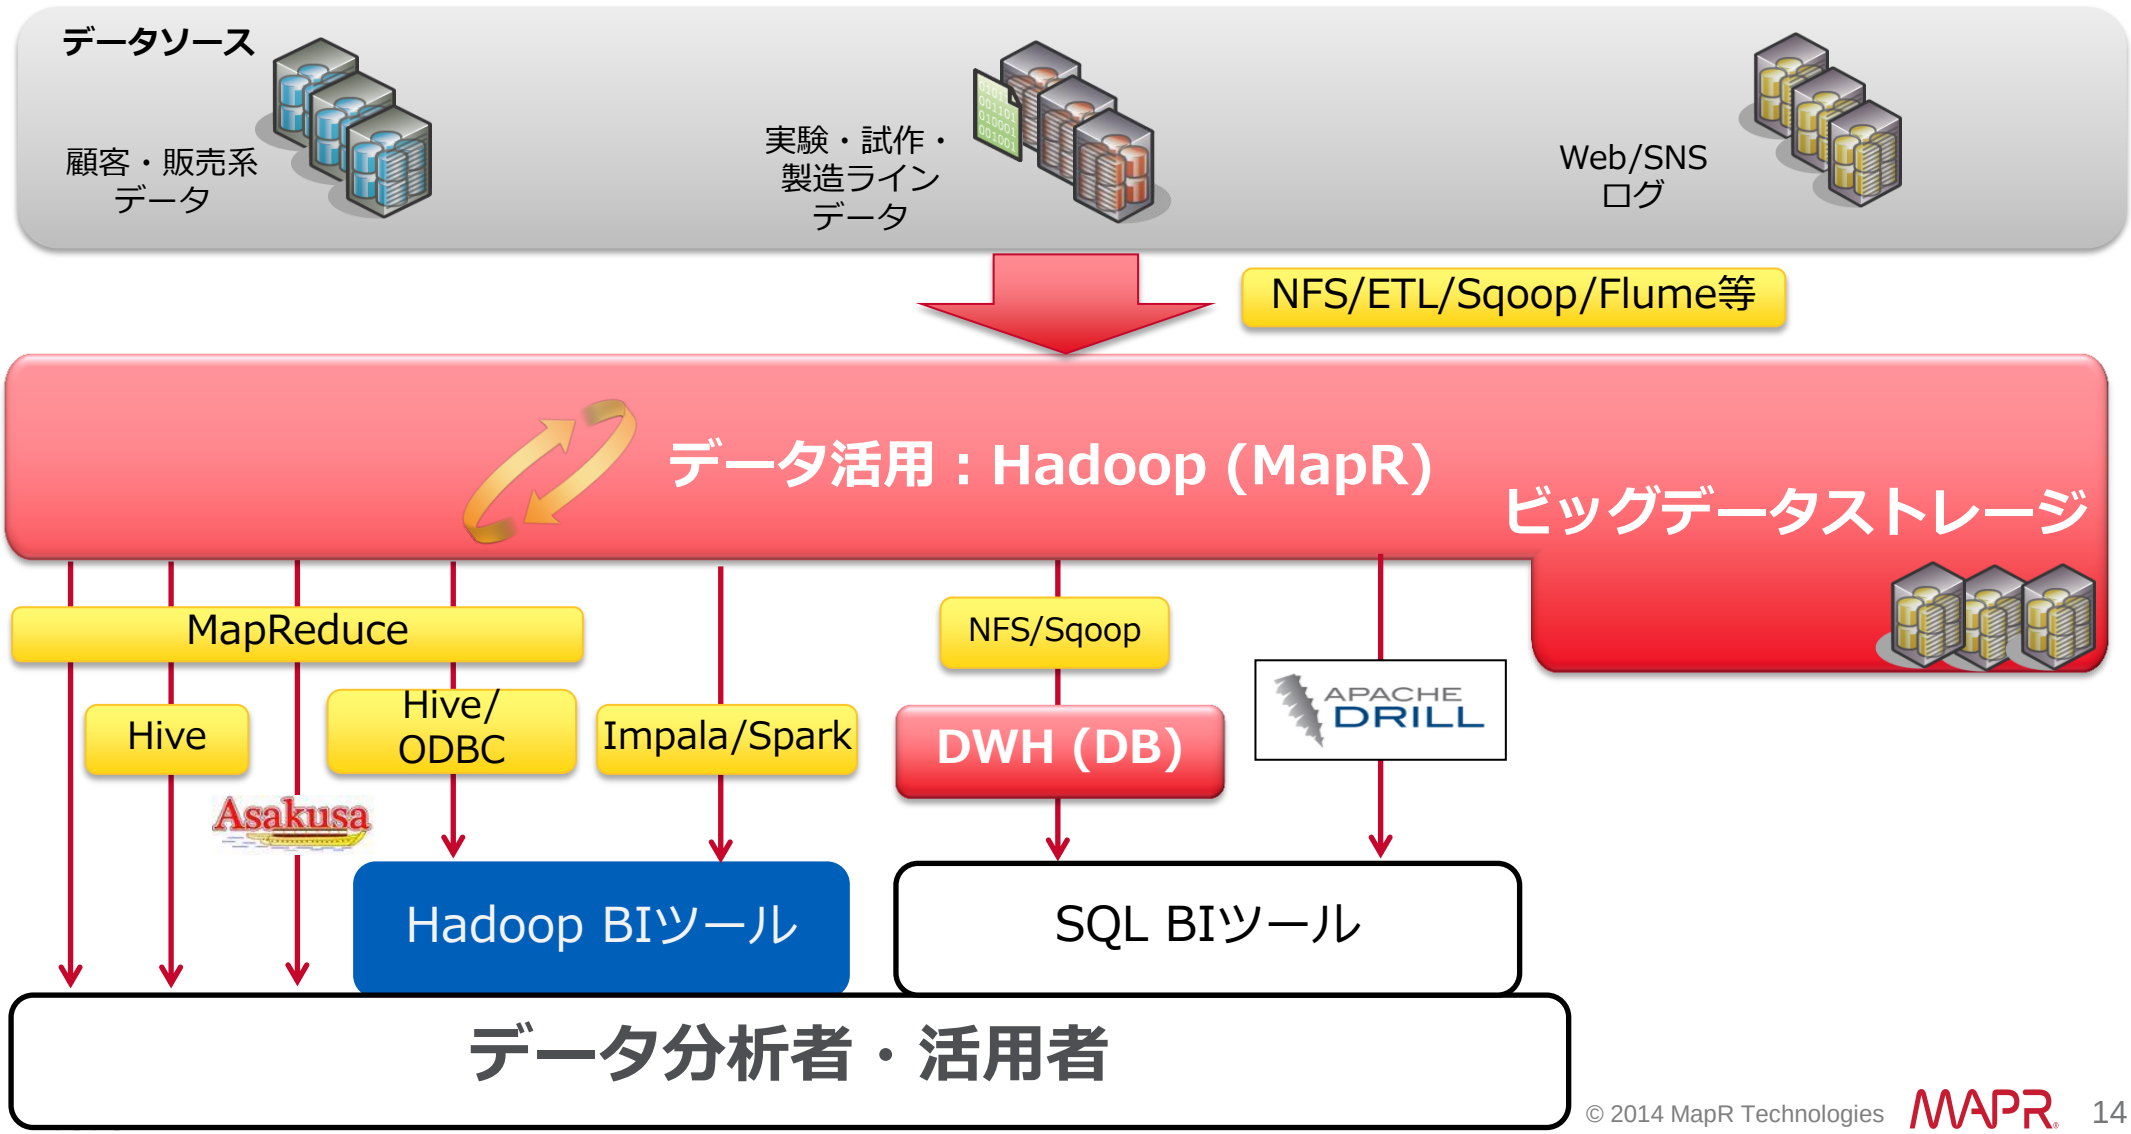

© 2014 MapR Technologies

分析システム最適化のロードマップ

DWH1.0

TERADATA

NETEZZA an IBM Company

ORACLE EXADATA

DWH2.0

TERADATA

NETEZZA an IBM Company

ORACLE EXADATA

hadoop

DWH2.5

VERTICA

hadoop

次世代 DWH

APACHE DRILL

hadoop

© MapR Technologies

MAPR

Hadoop上のSQLソリューション

	Drill	Hive + Tez	Impala	Spark
レイテンシ	**Low**	Medium	**Low**	Medium
ファイル検索	Yes (all Hive file formats)	Yes (all Hive file formats)	Yes (Parquet, Sequence)	Yes (all Hive file formats)
HBase/MapR-DB 検索	**Yes**	**Yes**	Various issues	**Yes**
スキーマ	**Hive or schema-less**	Hive	Hive	Hive
クエリ言語	**ANSI SQL**	HiveQL	HiveQL (subset)	HiveQL
クライアント接続	ODBC/JDBC	ODBC/JDBC	ODBC/JDBC	ODBC/JDBC
大規模JOIN	Yes	Yes	No	No
階層データ	**Yes**	Limited	No	Limited
Hive UDF	Yes	Yes	Limited	Yes

APACHE DRILL

© 2014 MapR Technologies

Hadoopのデータに既存BIやSQLも

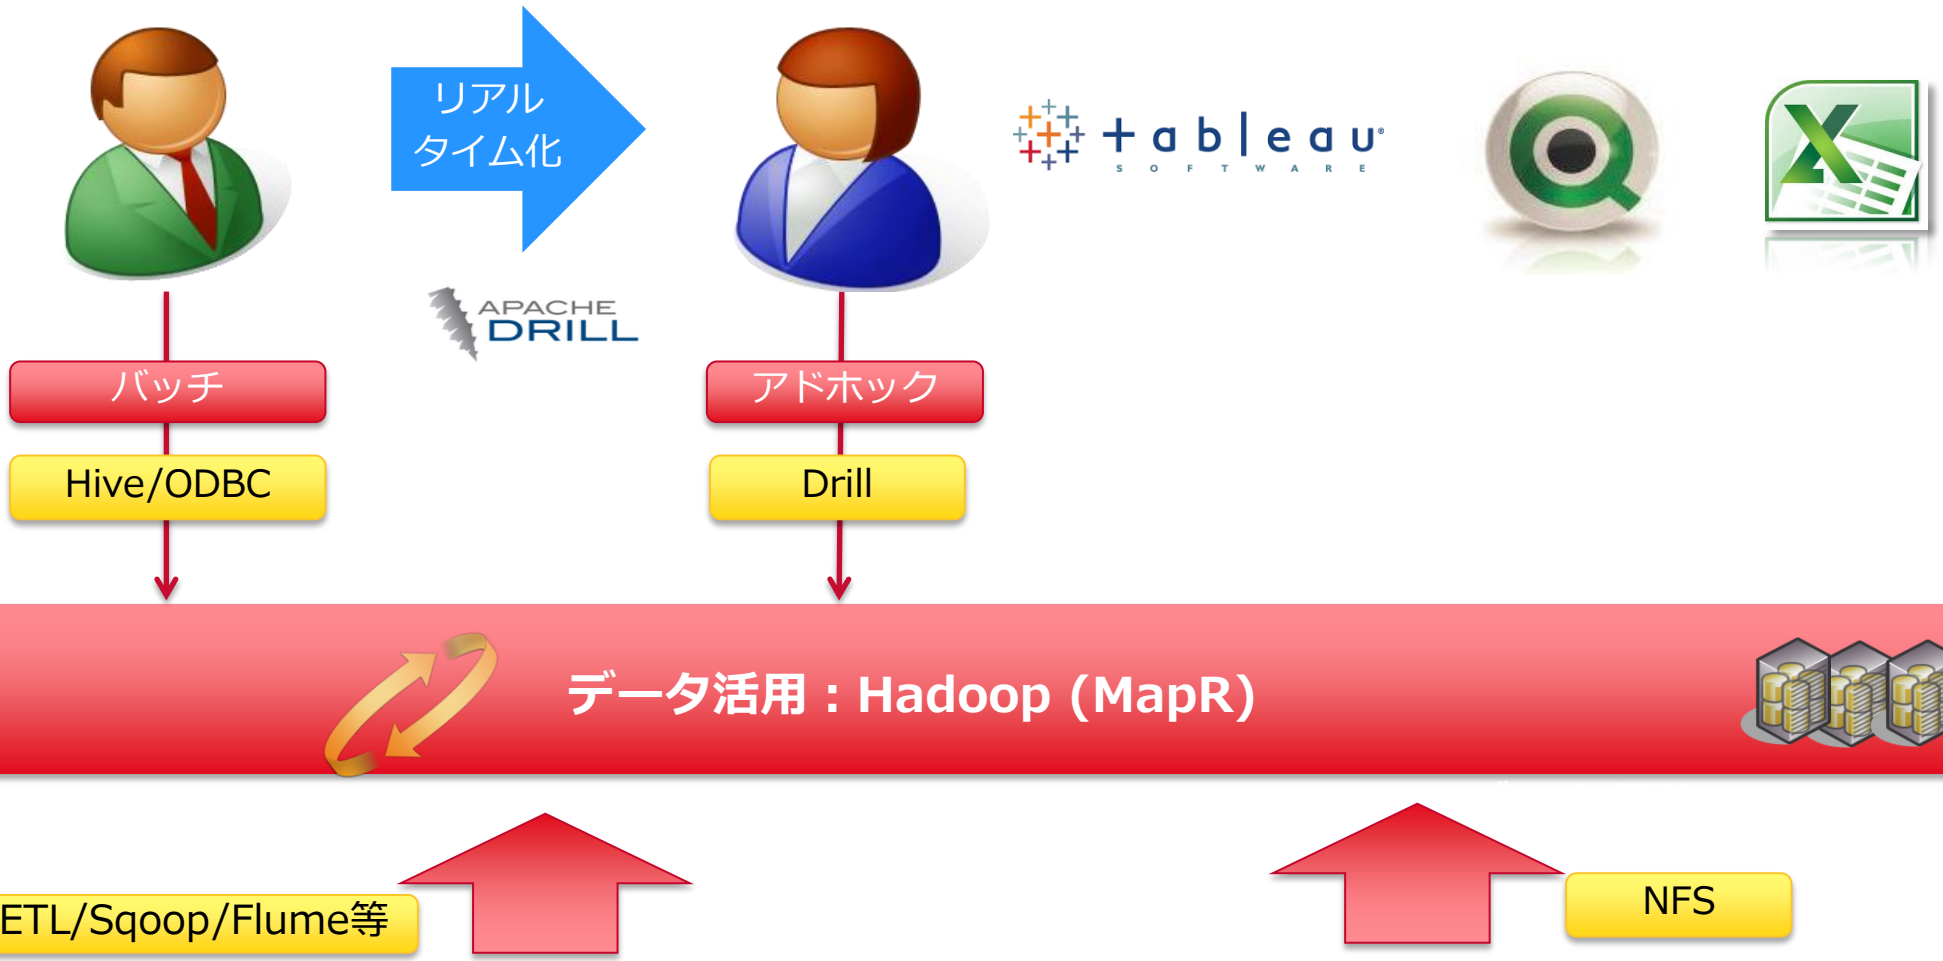

俊敏性とセルフサービス化

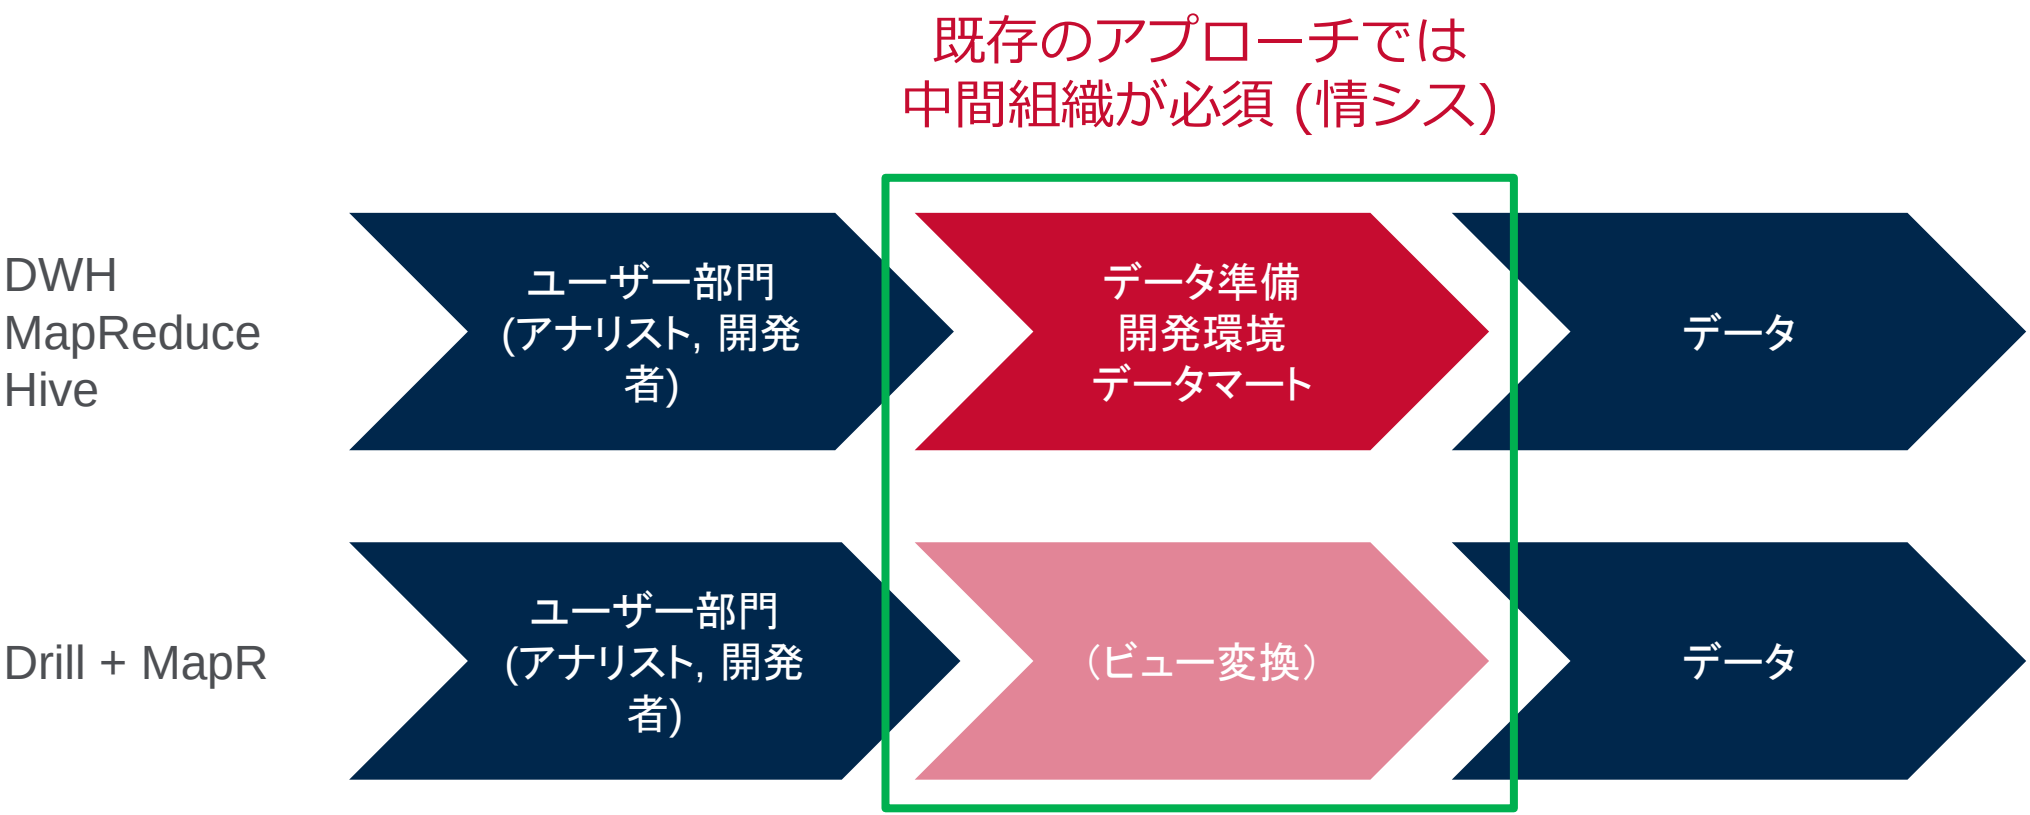

© 2014 MapR Technologies

リアルタイム分析環境例
（電通レイザーフィッシュの事例から）

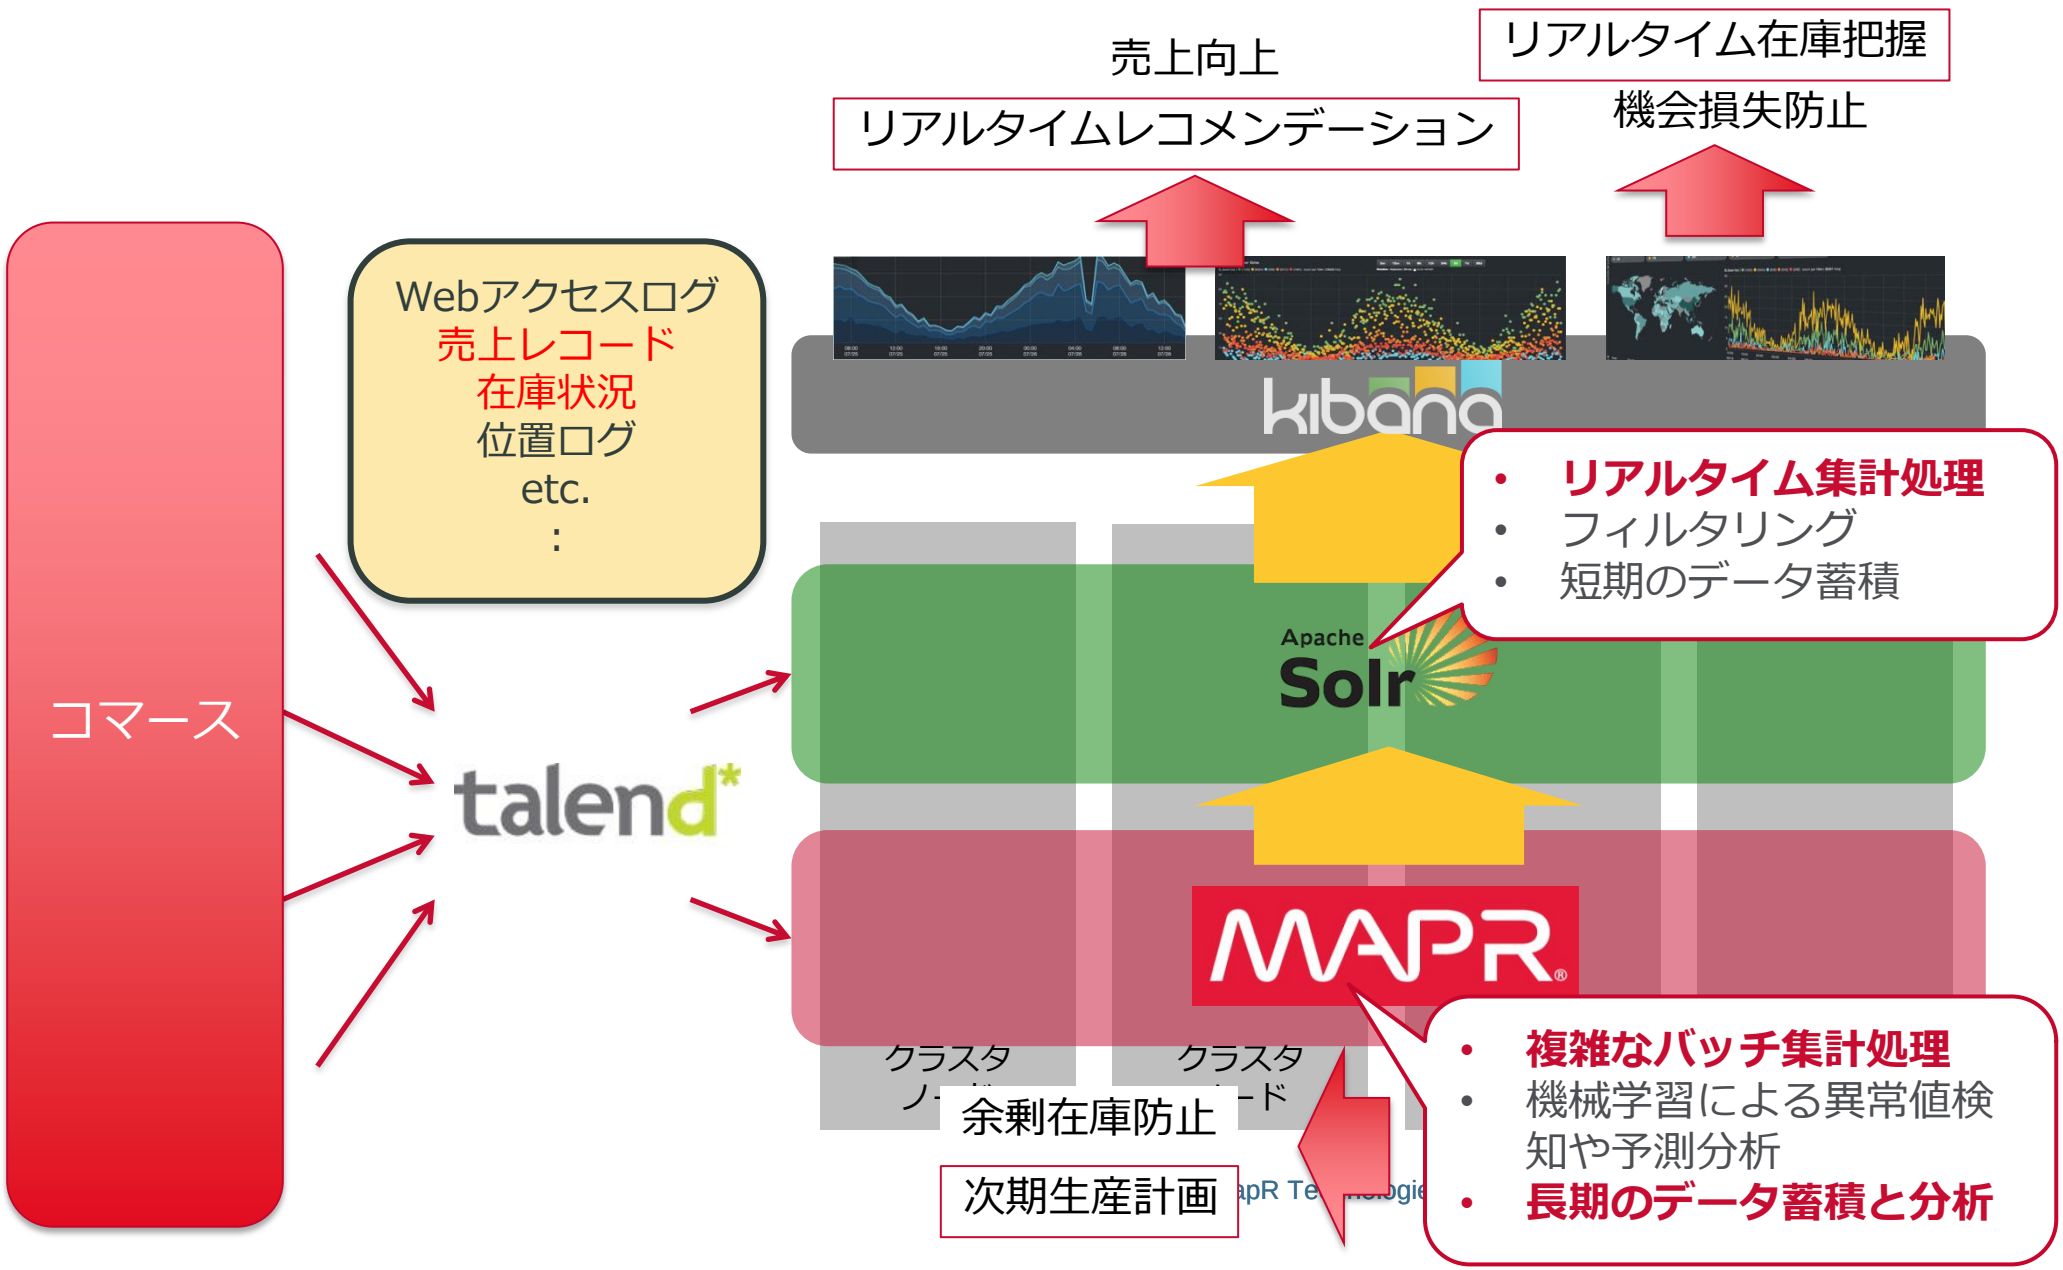

Q:ビッグデータ活用していますか？

「もうやっている」（データウエアハウスとして）

ビジネスへの具体的な活用が明確で無い

ビジネスとデータ分析の両方の観点からの
戦略を考える人材が存在しない

投資効果を説明できない

© MapR Technologies

MAPR

難しい（？）目的とKPI設定
～エンタープライズの悩み～

© MapR Technologies

アプローチを変える

分析を意識したストレージにデータ蓄積をすることが重要
（後日、分析のためにTB/PBのデータ移動は高コスト）

売上増 or コスト/リスク削減 or 効率化？
（ただし、データは共通なハズ）

© MapR Technologies

ビッグデータストレージ（analysis ready）としてのMapR

<従来>

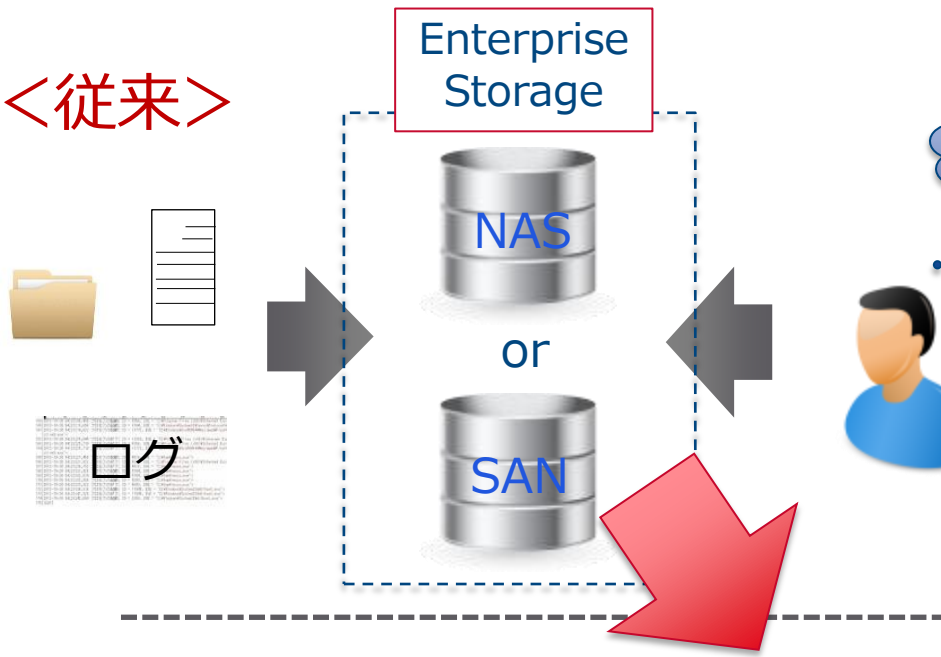

- 膨大、かつ増え続けるログデータ等をどこに保管？
- スケールアウト型のNASは種類が少なく高価

<これから>

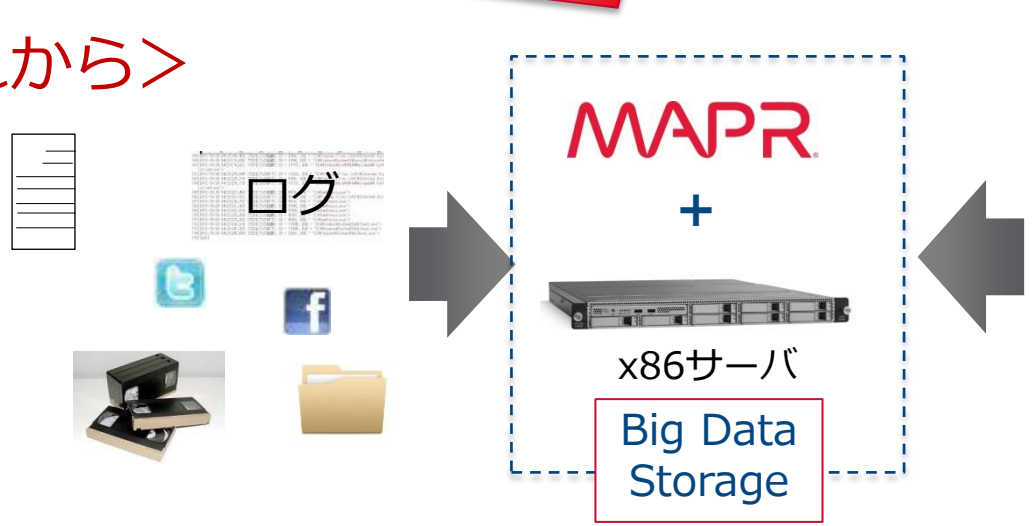

- MapR FS上に置くことで、コスト効率良く保管
- 分析や活用のために他にデータ移動することなく、いつでもHadoopを使ってデータ処理
- バックアップやスナップショットが取れるのはMapRだけ

© 2014 MapR Technologies

More DATA beats better algorithms

**（より多くのデータは、
より良いアルゴリズムを凌ぐ）**

The Unreasonable Effectiveness of Data, published by Google

© 2014 MapR Technologies

Zions Bank:

ビッグデータストレージと不正検知

データプラットフォームを統合することでコスト効果高く、セキュリティ分析と不正検知を行う

ZIONS BANK.
WE HAVEN'T FORGOTTEN WHO KEEPS US IN BUSINESS®

目的

不正を発見するチームとセキュリティ分析のチームが共同で利用するデータストアのプラットフォームを構築し、その上に統計モデリングを載せ、不正や不正につながる怪しい行動を発見する

チャレンジ

- 既存のインフラはスケールしない
- この数年レポート作成に時間がより掛かるようになっていた

MapR利用のメリット

- データストレージコストを50%削減
- 1.2PBのデータからのクエリが24時間から30分に削減
- 限界の無いスケーラビリティにより、より多くのデータを使え、より正確なモデルと洞察を得られた

Business Impact

“Zions Bankでは初めてセキュリティ分析のために全データを中央集権的に集め利用したが、不正検知にもそのデータが使えることが分かっただけではなく、不正検知に非常に役に立つことがわかった

Michael Fowkes - SVP Fraud Operations and Security Analytics

© MapR Technologies

MAPR

MapR 製品

M3
COMMUNITY EDITION

- Hadoop (M5) & NoSQL (M7)
- 管理ツール
- NFS アクセス
- パフォーマンス
- ノード数の制限なし
- 無料

M5
ENTERPRISE EDITION

- 管理ツール
- NFS アクセス
- パフォーマンス
- HA
- スナップショット
- ミラーリング
- 24 X 7 サポート
- サブスクリプション

M7
ENTERPRISE DATABASE EDITION （MapR-DB）

- Hbase互換のNoSQL DB
- M5の機能＋
- HBaseの運用を簡素化
- HBaseの高速化
- 安定したレスポンスタイム、低レイテンシー
- ファイル/テーブルの統合スナップショット

Also Available through:

amazon web services™

Google Compute Engine

© MapR Technologies

MAPR®

MapRによるOSS Hadoopの強化とメリット

Apache Hadoopをエンタープライズで利用する際に問題となるポイントを1つ1つ解消

効果 / メリット	強化ポイント
パフォーマンス	● ネイティブファイルシステム ● ダイレクトシャッフルによるシャッフルの最適化 ● 分散Name Node(CLDB)によるボトルネック解消
運用性	● POSIX対応NFS I/FとランダムRead/write可能ファイルシステム ● マルチテナント ● リニアなスケーラビリティ ● ノード数減
信頼性	● 単一障害点の除去(NameNode, Job Tracker) ● スナップショットによるデータ保護 ● ミラーリングによる簡単バックアップとDR

エンタープライズ用Hadoopのために！
アーキテクチャ再設計と再実装による強化

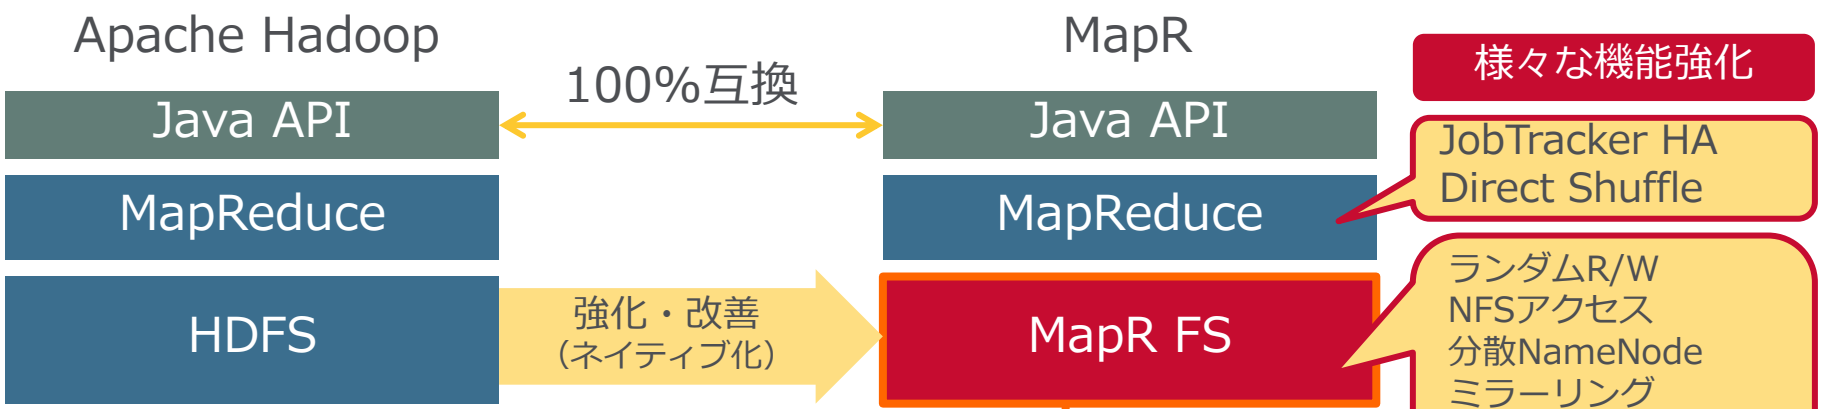

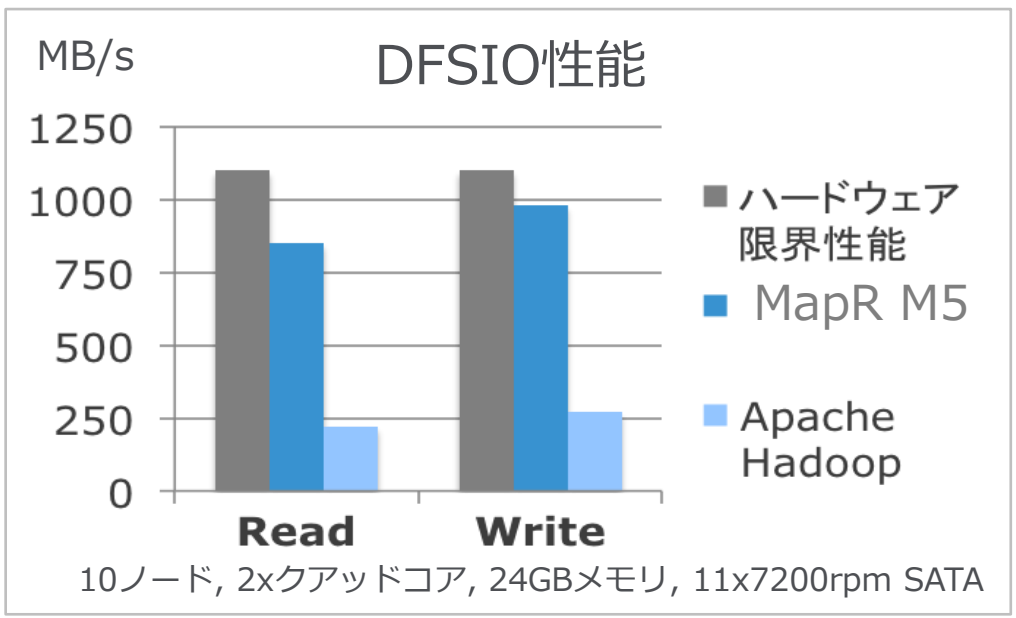

ハードウェアの限界性能を引き出すための
アーキテクチャ設計・再実装

- ロックの排除による並列処理の最適化
- ビルトイン圧縮によるI/O削減
- 分散NameNode
- RPC経由のShuffle転送
- Java GCの影響の排除

© MapR Technologies

高パフォーマンス = TCO 改善

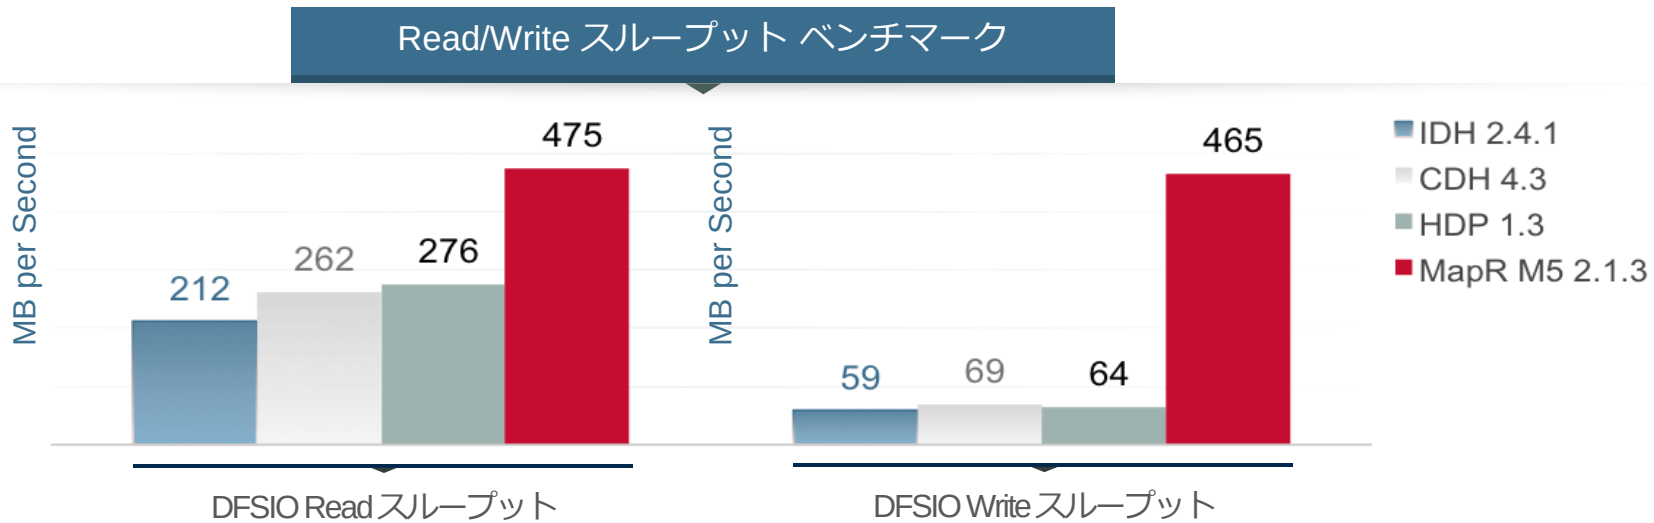

ソース: Flux7 Labs Study, 2013年10月

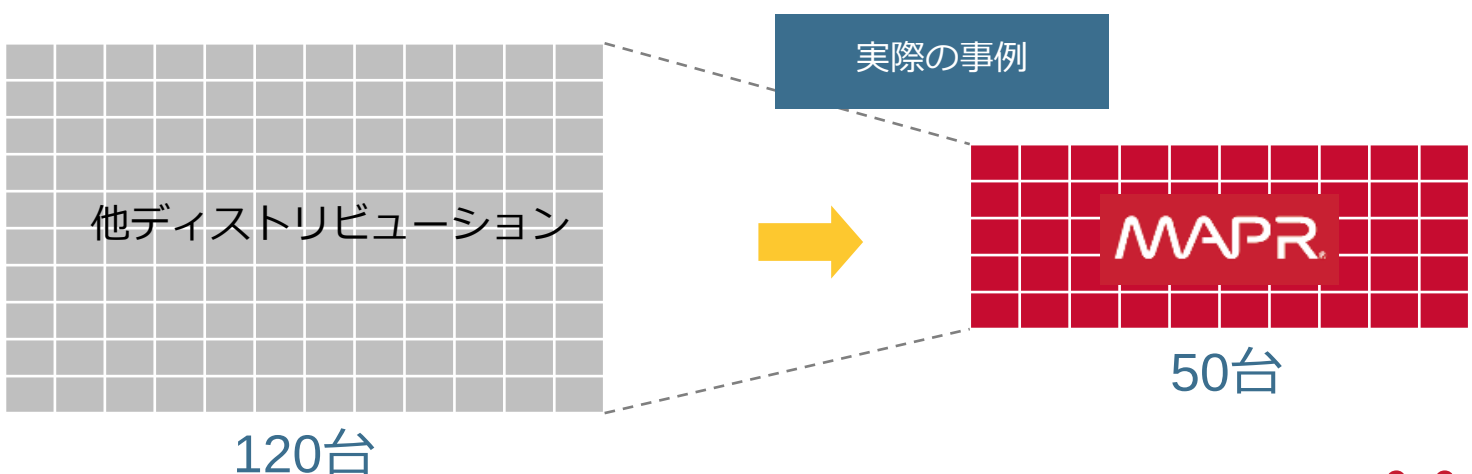

© MapR Technologies

バイアスのないオープンソース (Linux を例に)

- オープンソースディストリビューションは選択肢の提供が鍵
  - Linux は MySQL, PostgreSQL, SQLite の**すべて**を含む
  - Linux は Apache httpd, nginx, Lighttpd の**すべて**を含む
- MapR はバイアスのない選択肢を提供する唯一の Hadoop

	MapR Distribution for Hadoop	**ディストリビューションA**	**ディストリビューションB**
Spark	Spark および Shark （全スタックをサポート）	Spark のみ	なし
インタラクティブ SQL	Shark, Impala, Drill, Hive/Tez	単一の選択肢 (Impala)	単一の選択肢 (Hive/Tez)
バージョン	Hive 0.11, 0.12, 0.13, 0.14 Pig 0.11, 012 HBase 0.94, 0.98	単一のバージョン	単一のバージョン

まとめ

- Hadoopをよりフレンドリーにするツールが存在
  - Asakusa：基幹系のも活用が可能
- Hadoop自身もエンタープライズでの利用を考慮したものに進化
  - MapR
- さらにユーザはリアルタイム性とセルフサービス化を求める
  - Drill：SQL on Hadoopを使って既存BIやSQLを活用

© MapR Technologies

MAPR

ご静聴ありがとうございました

© MapR Technologies

MAPR