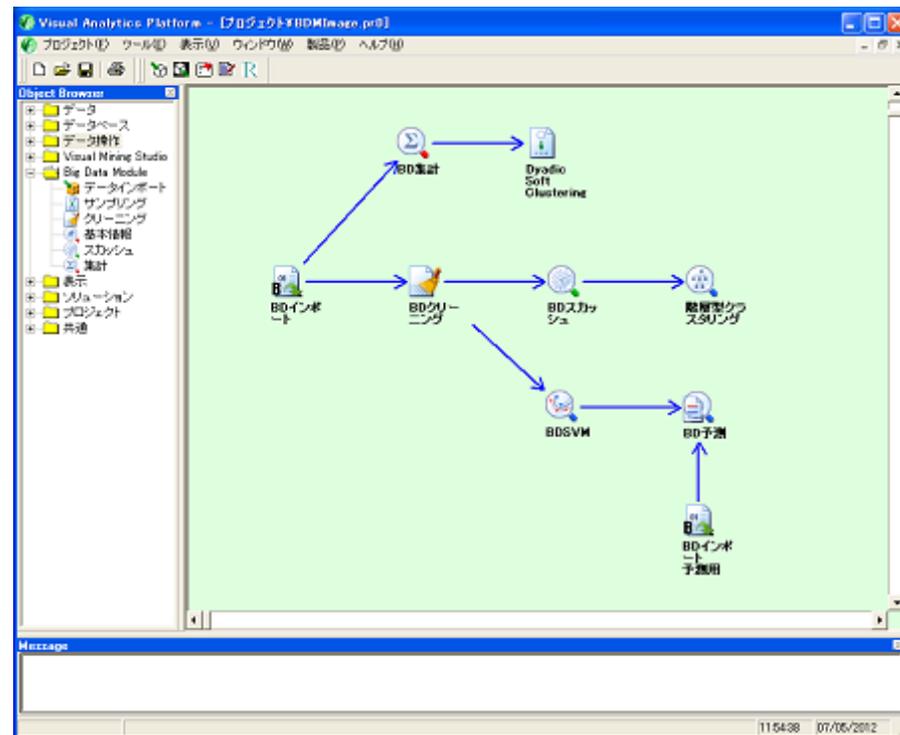




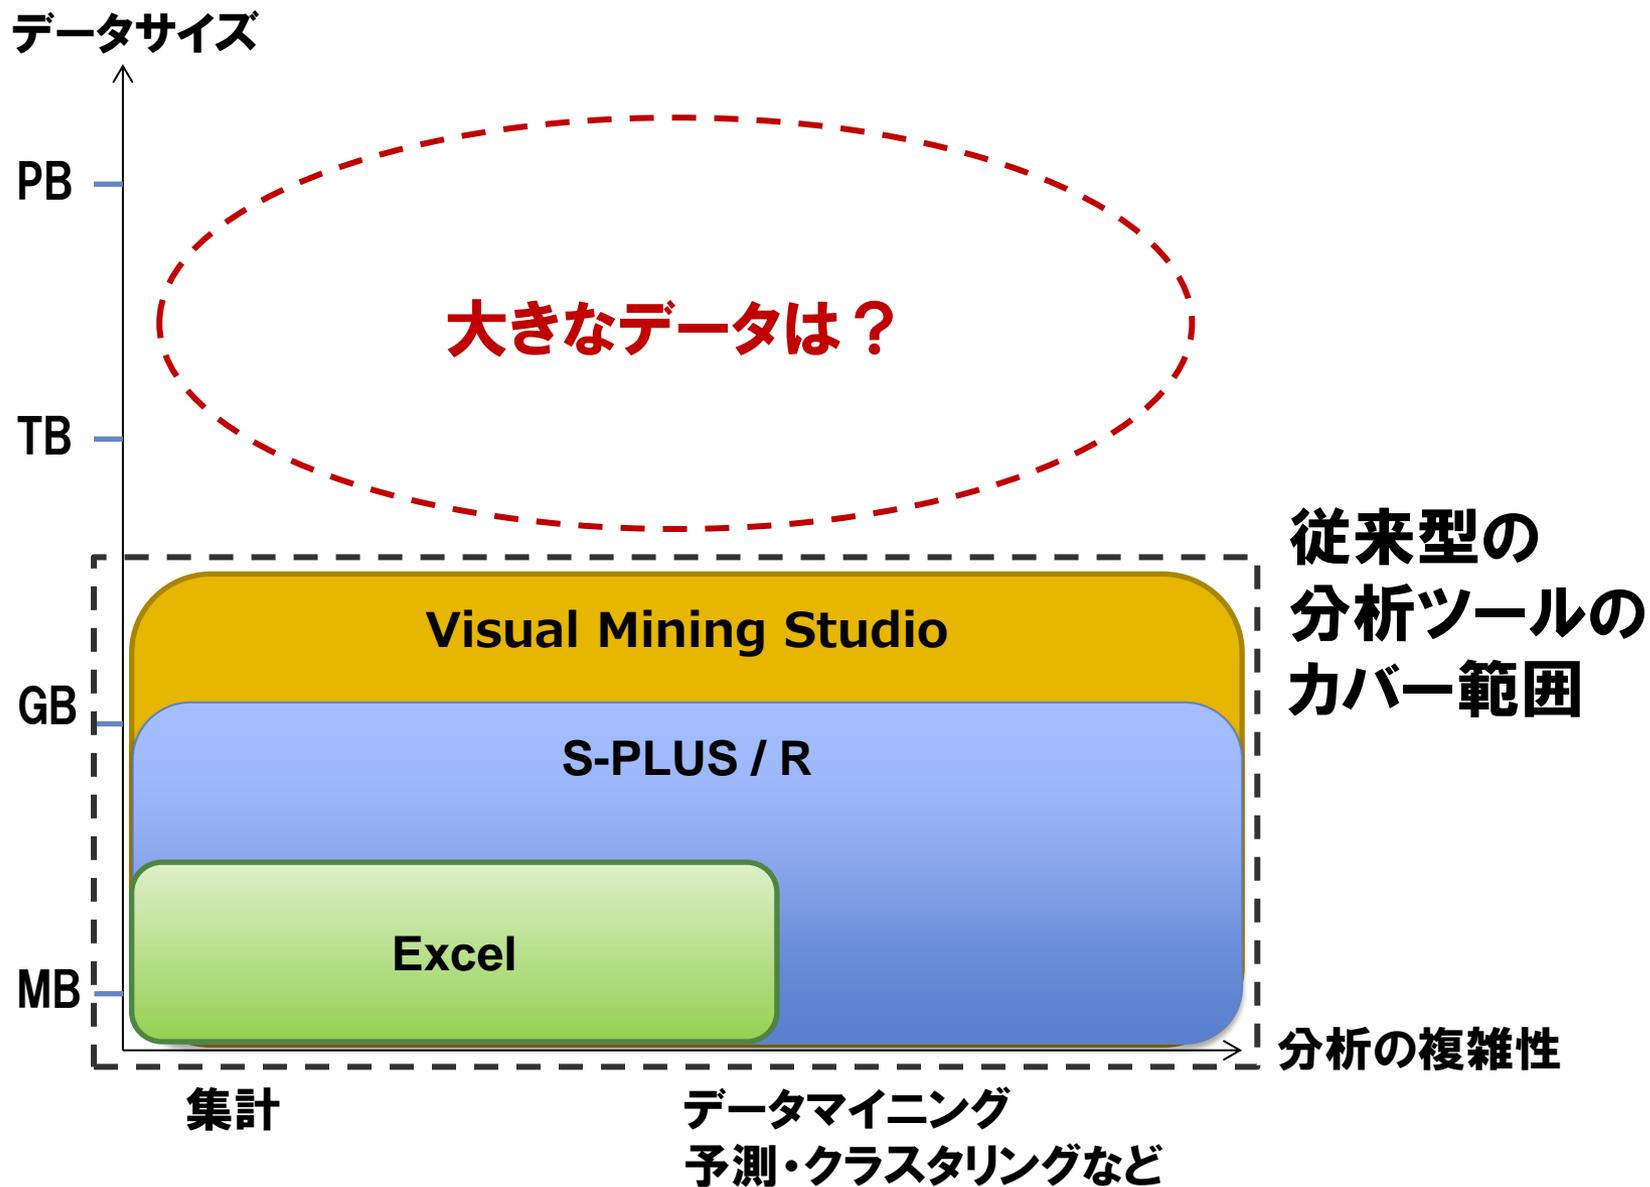
# 大規模データも手軽に分析！ Big Data Module 紹介

数理システムユーザーコンファレンス 2014  
(株)NTTデータ数理システム データマイニング部  
五十嵐 健太

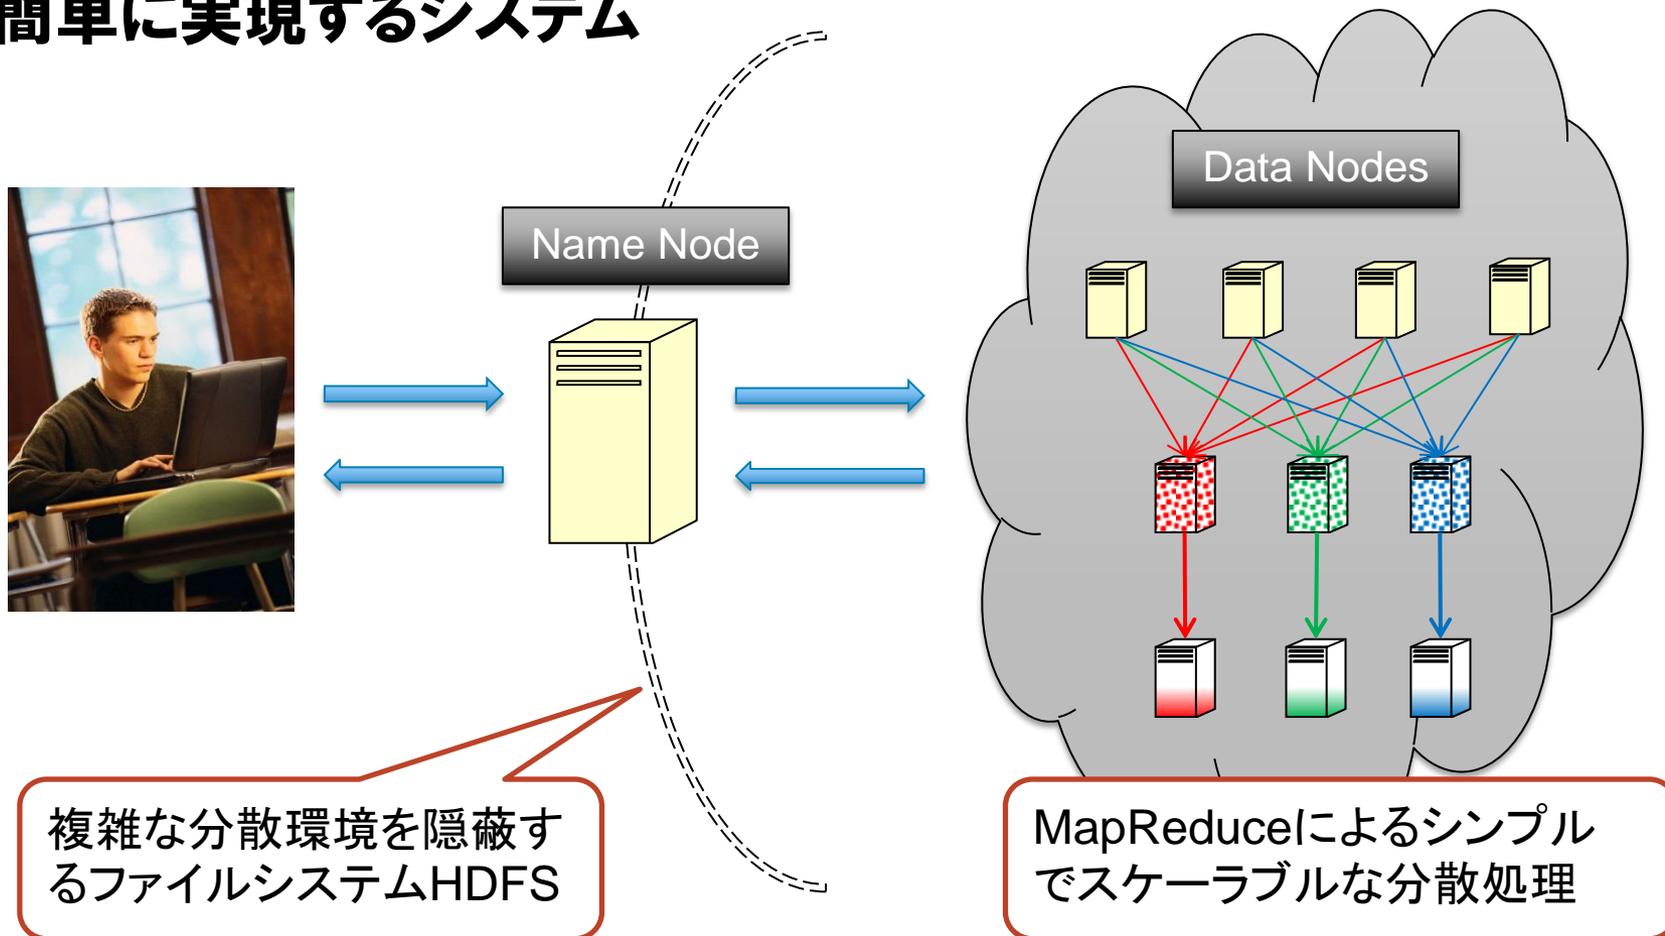
- マウス操作で簡単に  
大規模データのデータマイニングを実現
- 大規模データのための  
高速分析アルゴリズムを搭載
  - オンラインアルゴリズム
  - 並列処理
- 特殊な分析専用マシンは不要  
市販のマシンを1台用意すれば  
それだけで分析が実行可能
- Visual Mining Studio を  
はじめとした、数理システム製品と連係



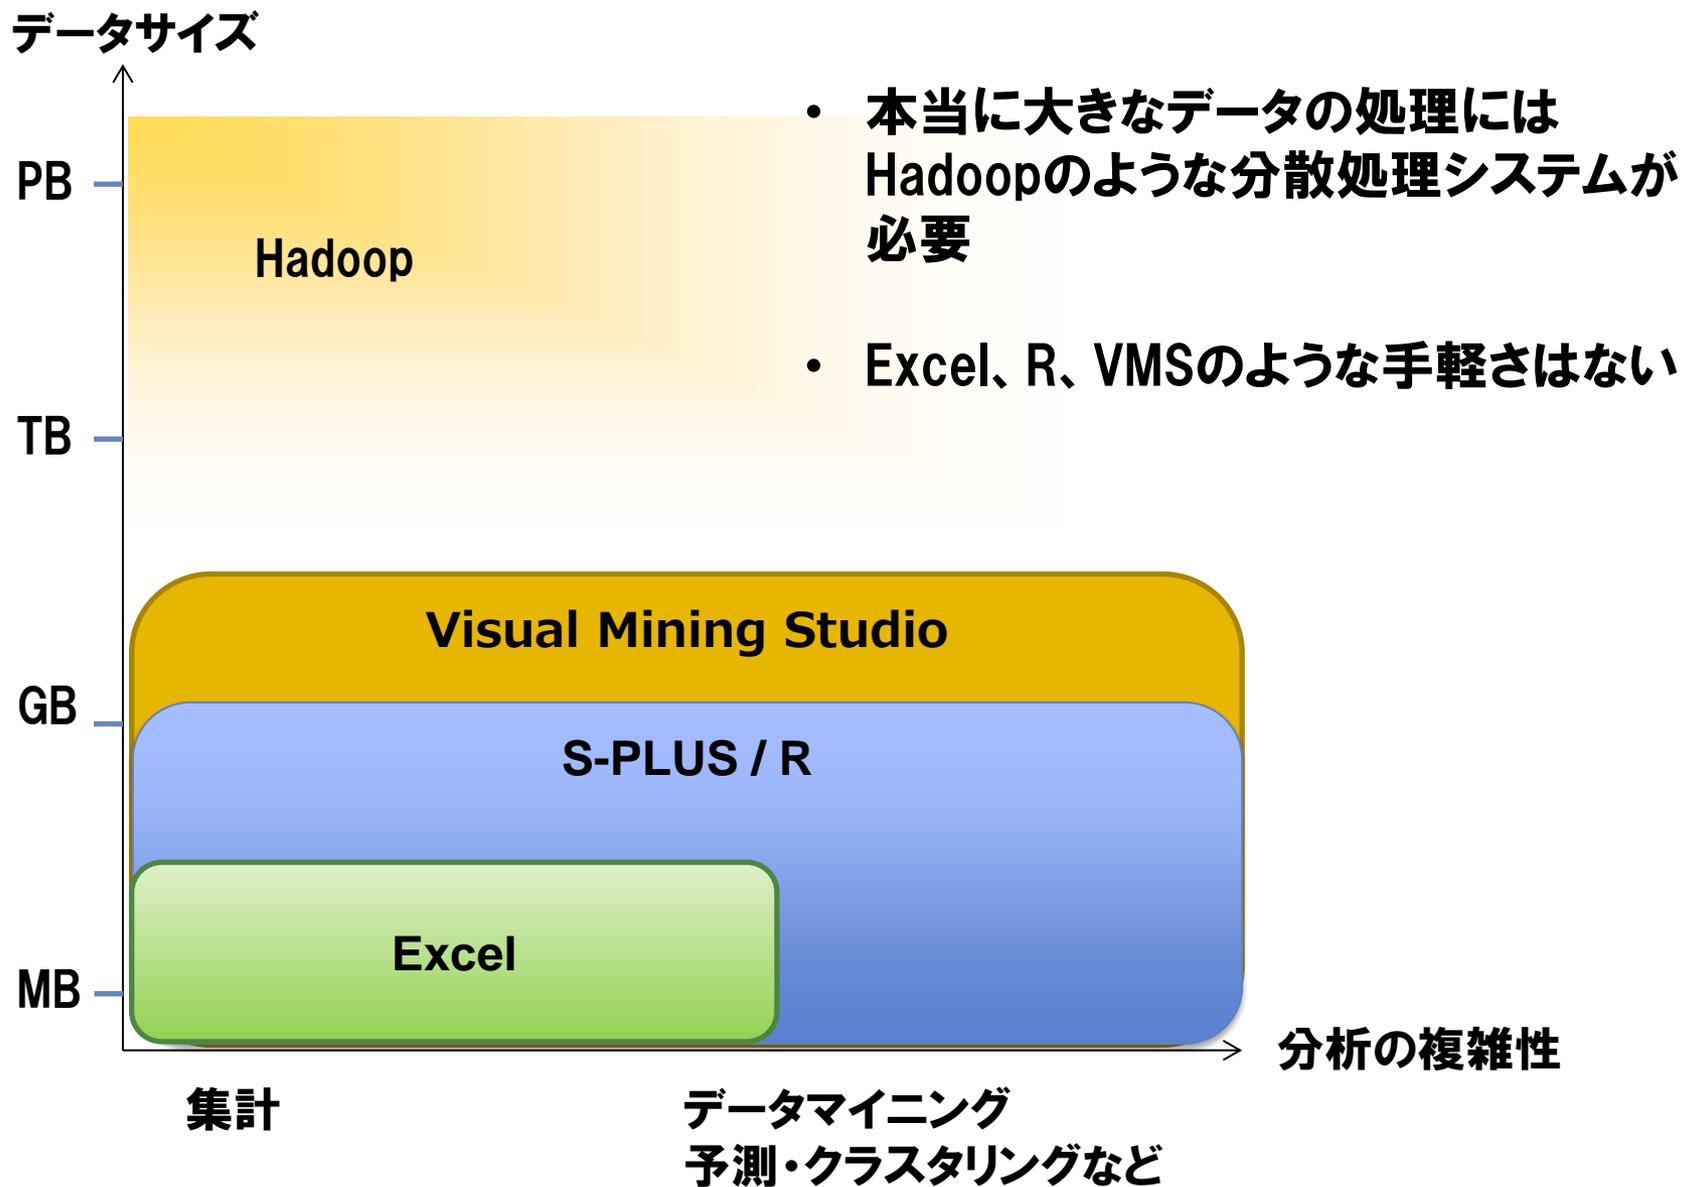
# ー 対象データサイズ ー



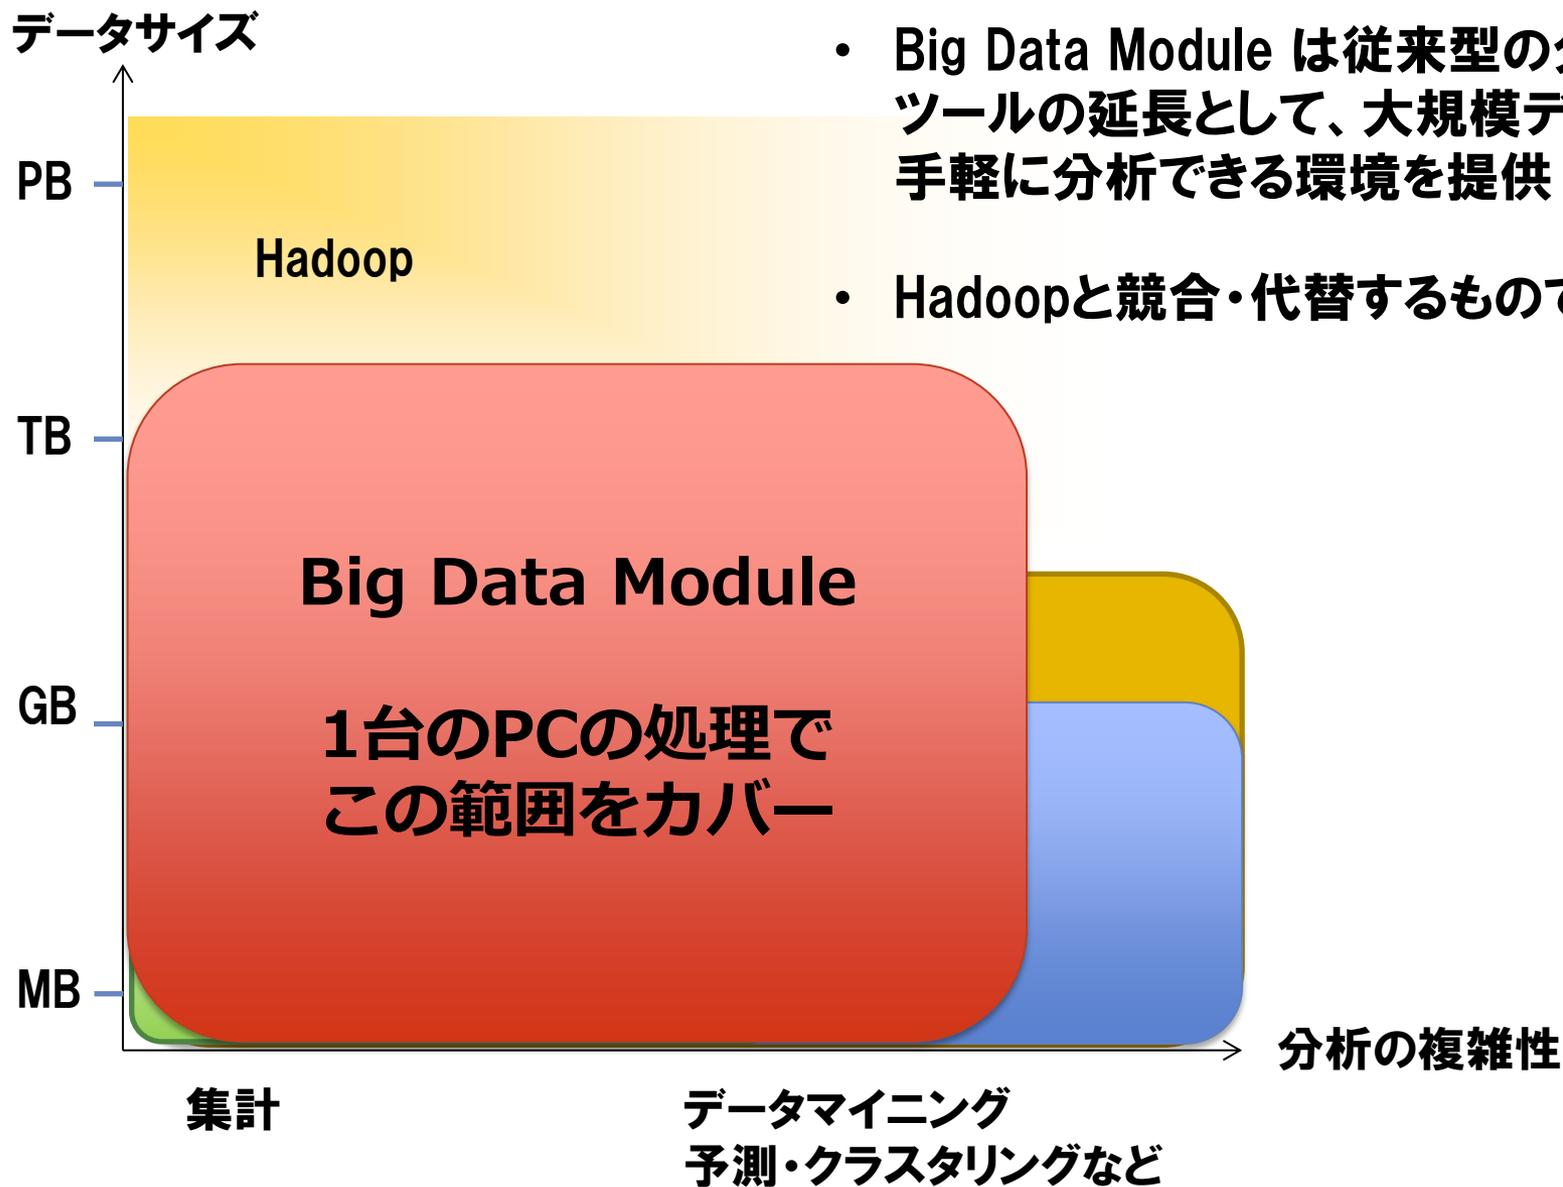
## 従来は面倒だった複数マシンでの分散並列処理を簡単に実現するシステム



多数のマシンで処理を分散することで、  
テラバイト、ペタバイトスケールのデータの処理が可能に



# Big Data Module の位置づけ



データサイズ

PB

TB

GB

MB

関係機能でどんなデータでも高度な分析を実現

Hadoop  
+  
Big Data Module  
+  
Visual Mining Studio

集計

データマイニング  
予測・クラスタリングなど

分析の複雑性

# — 使用イメージ —



売上予測



株価予測



電力需要予測

予測精度を高めるには…

- データ数を増やす
- 説明変数を増やす



計算時間の  
爆発的な増加で  
計算不可能

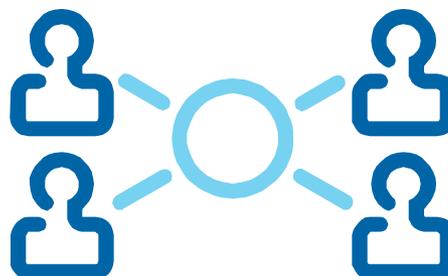
Big Data Moduleなら…

**オンライン線形回帰**でビッグデータでも予測可能

- データ数の線形オーダーの計算時間→**超高速**
- データ数に依存しないメモリ使用量→**超省メモリ**



- ECサイト  
ユーザー×アイテムの  
マッチング



- SNS  
ユーザー×ユーザー  
のマッチング



- セールス  
営業マン×営業先  
のマッチング

膨大な組み合わせの中から  
ベストなパターンを発見



- ~~時間をかけて終わるかどうか  
わからない計算？~~
- ~~一部の情報だけを使って分析？~~

Big Data Moduleなら…

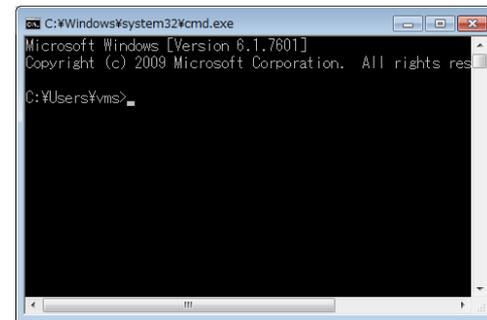
**オンライン行列分解**で協調フィルタリングによる

レコメンデーション

**高速**かつ**高精度**なレコメンデーション

## バッチ処理

- 今の分析ツールだと、処理時間がかかりすぎる
- (WEBアクセス、システム) ログデータの分析がしたい
  - GUIツールとして  
Big Data Module を使用
  - 定型化した分析はバッチ化して  
コマンドプロンプトから実行



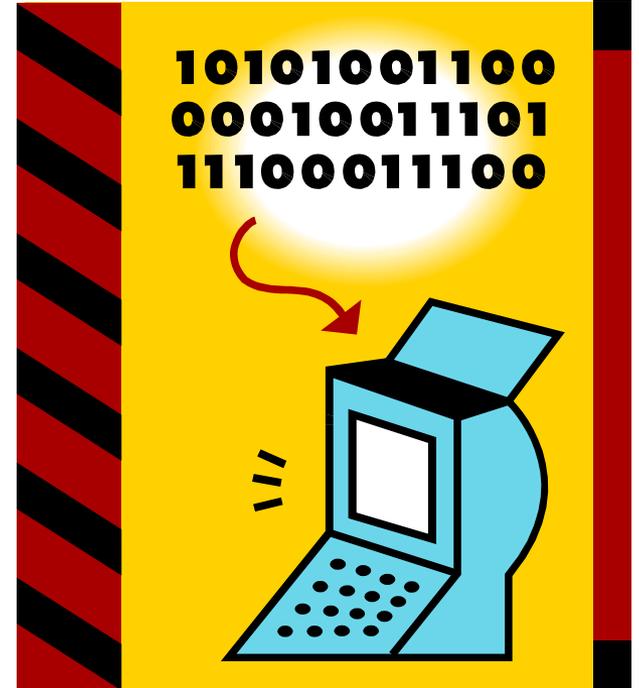
## システム組み込み

- リアルタイムで処理したいのに、分析処理が追いつかない
  - Big Data Module のアルゴリズム部分を取り出して  
システムへ組み込み

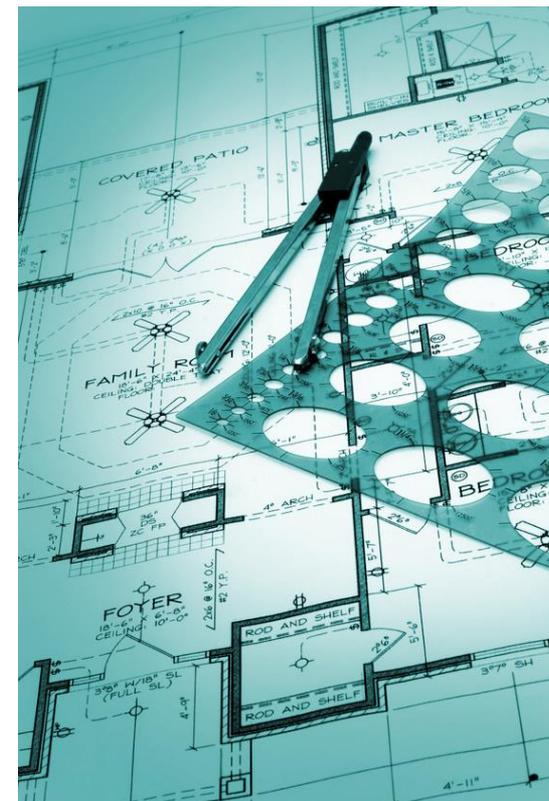


# — 今後の開発について —

- データベースへの接続機能の追加
  - テーブル選択
  - SQL 発行
- データインポート機能の高速化
- 線形回帰での自動変数選択  
正則化方法として
  - Lasso
  - elastic net (Lasso と Ridge のハイブリッド)を選択可能に



- データ加工アイコンの追加  
スクリプトの記述で一通りのデータ操作はできるが…  
アイコン化してGUIで簡単に使えるようにしたい
- 分析機能の追加
  - 最近流行のアルゴリズムを検討  
Deep Learning?  
non-parametric bayes?
- 実務的に使いやすいツールに
  - 外部ツール (python) からの実行
  - VAP関連製品との関係の強化



**テスト利用制度もございます  
お気軽にご相談ください**



**<お問い合わせ先>**

**(株) NTTデータ数理システム Big Data Module 担当**

**bigdata-info@msi.co.jp**

**http://www.msi.co.jp**

**Tel : 03-3358-6681 [ 営業部直通 ]**

**Fax : 03-3358-1727**

変える力を、ともに生み出す。

**NTT DATA**

NTT DATA グループ