ビッグデータ

ビッグデータ活用を支える技術

目次

第１章　ビッグデータを支える技術　クラウド、IoT

目次

第２章　ビッグデータを支える技術　データ収集・加工

目次

第３章　ビッグデータコア技術　NoSQL

目次

第４章　ビッグデータコア技術　分散処理

目次

第５章　ビッグデータにおけるデータ解析

目次

第６章　ビッグデータとAI、機械学習

第１章

ビッグデータを支える技術

クラウド、IoT

ビッグデータ周辺技術　クラウド

クラウドコンピューティングとは

メールやグループウェア、その他様々なサービスをインターネット上で提供し、インターネット上にデータまでをも保存するようなサービス形態のことをいいます。

アプリケーションの実行場所が、雲（クラウド）のようにどこにあるのかが分からないモヤモヤとした場所にあることから、このように呼ばれています。

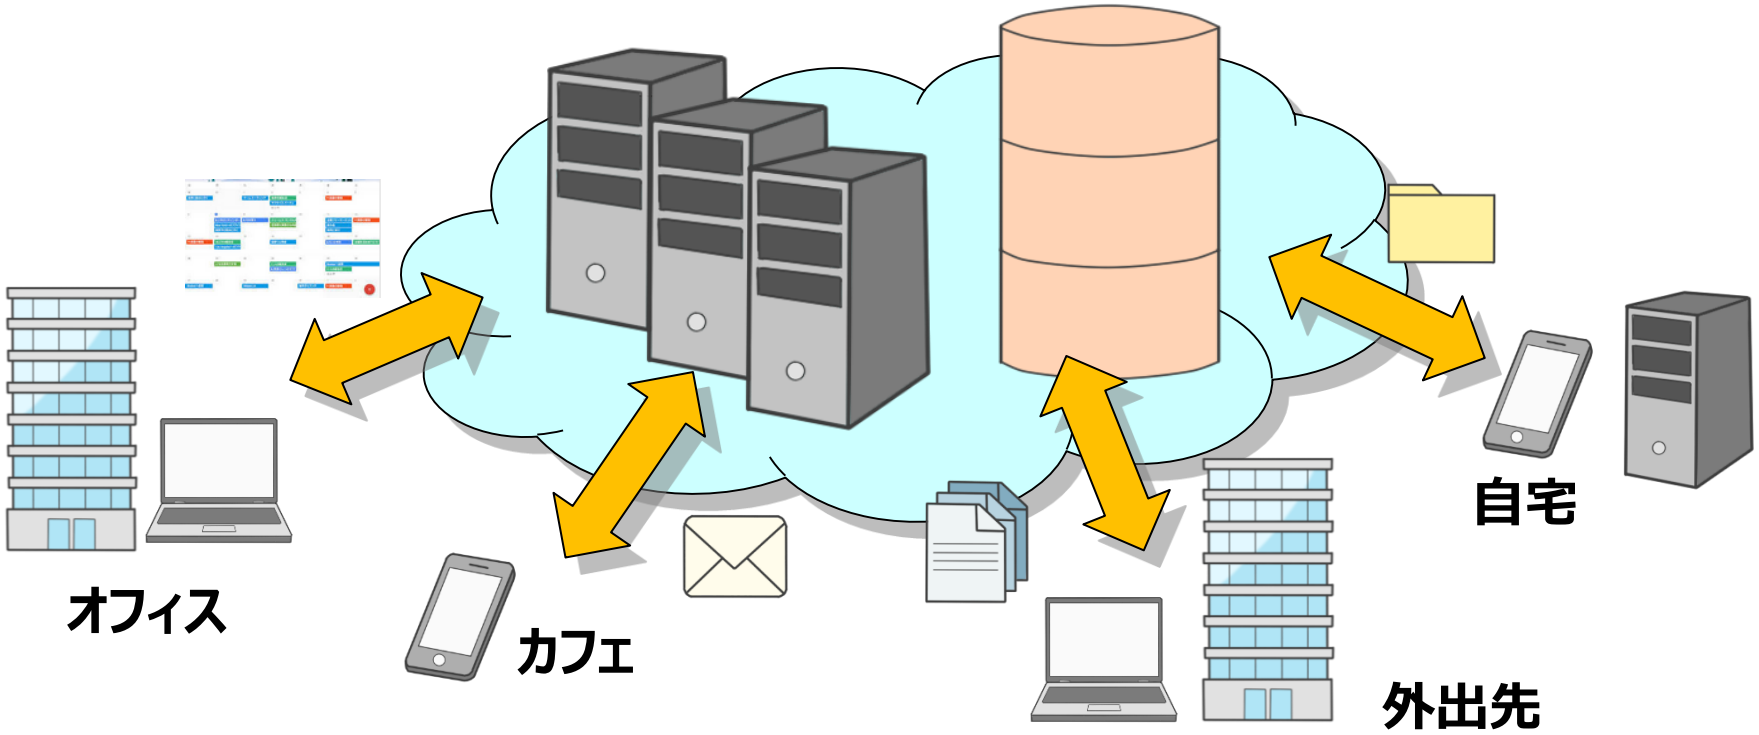

クラウドサービスの種類

クラウドサービスの種類

・SaaS（Software as a Service）

インターネットを経由してソフトウェアパッケージを提供するサービスのこと。
アプリをPCにダウンロードしなくても、Webなどのブラウザ上で利用することができる。
例・メール　・カレンダー　・チャット

・PaaS（Platform as a Service）

インターネットを経由してアプリの開発・運用環境全体を提供するサービスのこと。システム管理者、開発者向けである。

・HaaS / IaaS（Hardware as a Service / Infrastructure as a Service）

インターネットを経由してハードウェアや回線などのインフラを提供するサービスのこと。ユーザーはハードウェア資産を所有することなく、仮想サーバーやストレージ（外部記憶装置）を利用することができる。

クラウドサービスのメリット・デメリット

メリット

- ・サーバー・ソフトウェアを購入する必要がない
- ・システム構築期間を短縮できる
- ・効率的なIT投資やリソース配分を実現できる
- ・メンテナンスが不要である
- ・IT部門の負担が軽減される

デメリット

- ・カスタマイズが基本的にできない、もしくは難しい
- ・不特定多数が利用するため、安定して稼働できないリスクがある
- ・セキュリティー面のリスクがある
- ・利用するデータ量、時間によっては費用が増加するリスクがある

クラウドコンピューティングとビッグデータ

クラウドサービスに蓄積されるビッグデータ

クラウドサービスは、ビッグデータの蓄積場所に有力な選択肢です。

実際、以下はビッグデータがクラウドに保存されています。

- GREE、mixi、Facebook、Twitterなどに代表されるSNSのユーザーデータ
- IoTのようにセンサーなどで発生したデータ

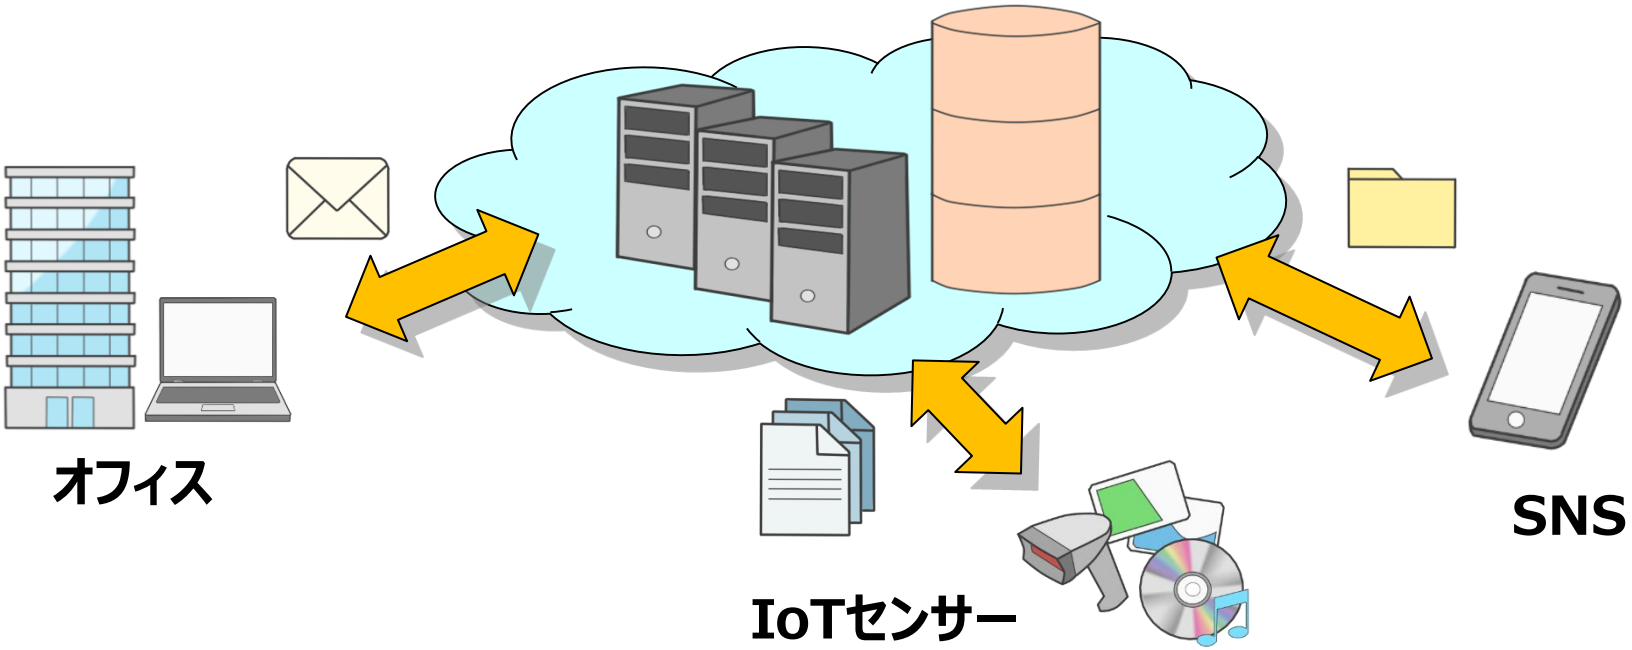

ビッグデータ周辺技術　IoT

IoTとは

IoT ＝ Internet of Things　「モノのインターネット」

ここで、「モノ」とは、ネットワークに繋がるあらゆる物のことです。

従来はインターネットとは関係のなかったもの、例えば、

・眼鏡　・服　・時計　・冷蔵庫　・電力メーター　・自動車
・太陽光パネル　・家　・スマートフォン

もすべて「モノ」です。

IoTとは、モノがネットワークに繋げられることによって、モノとインターネットが相互に情報交換をできるようになった状態のことをいいます。

IoTとは

・Internet of Thingsという用語は1999年、ケビン・アシュトン（イギリス）によって初めて提唱されました。

・当初はRFIDによる商品管理システムをインターネットに例えたものでした。

→ 徐々にスマートフォンやクラウドコンピューティングが普及。

→ IoTはモノ自体がインターネットを形作るという環境全体のことを表す概念として捉えられるようになる。

・IDC（ICT市場調査会社）による定義
「IP接続による通信を人の介在なしにローカルまたはグローバルに行うことができる識別可能なエッジデバイスから成るネットワークのネットワーク」

IoTとユビキタス社会

ユビキタスネットワークとは

いつでもどこでもインターネットを利用できるという概念のことをいいます。
1988年ゼロックス社パロアルト研究所のマーク・ワイザーにより提唱されました。

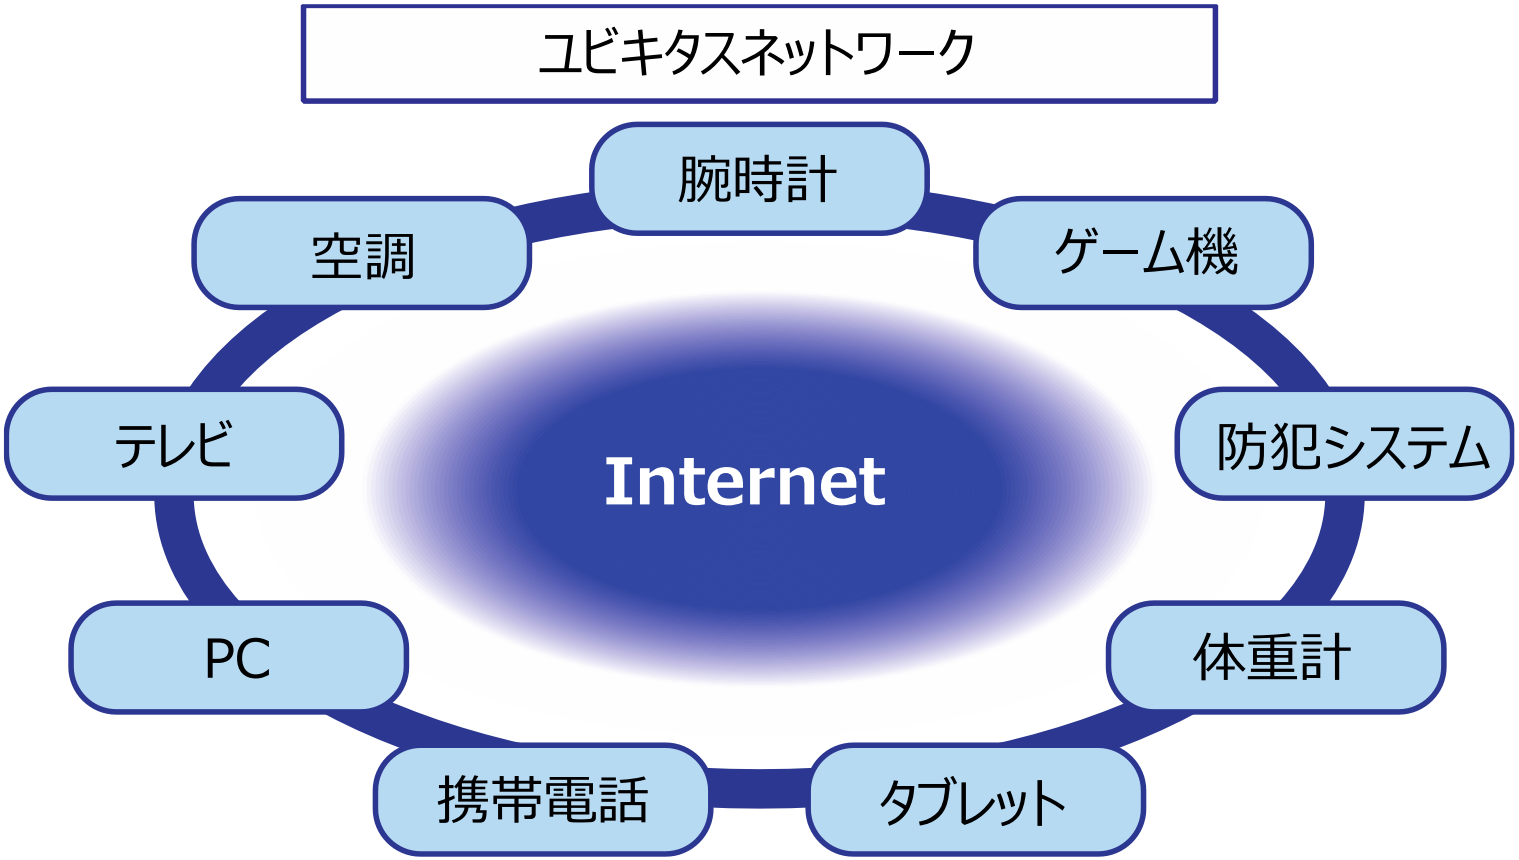

IoTとユビキタス社会

IoTとユビキタスの違い

・IoT：モノとモノが相互に制御し合っている状態を表す。
　　…「モノ」を中心とした概念

・ユビキタス：ユーザーが時間や場所にとらわれずインターネットに繋がって様々なサービスを受けられる状態を表す。
　　…ユーザーという「人」を中心とした概念

参考

ユビキタス (ubiquitous) は、遍在（いつでもどこでも存在すること）をあらわす言葉。

パロアルト研究所のマーク・ワイザーが、1991年の論文『The Computer for the 21st Century』にて、コンピュータやネットワークなどの遍在を表す意味合いで用いた。以来、ユビキタスコンピューティングやユビキタスネットワーク、さらにはそれらが当たり前になった社会を指す「ユビキタス社会」の意味で用いられるようになった。

Wikipedia

IoTとM2M

M2M = Machine to Machine

機械同士が、人を介在しないで情報をやり取りするシステムのことをいいます。

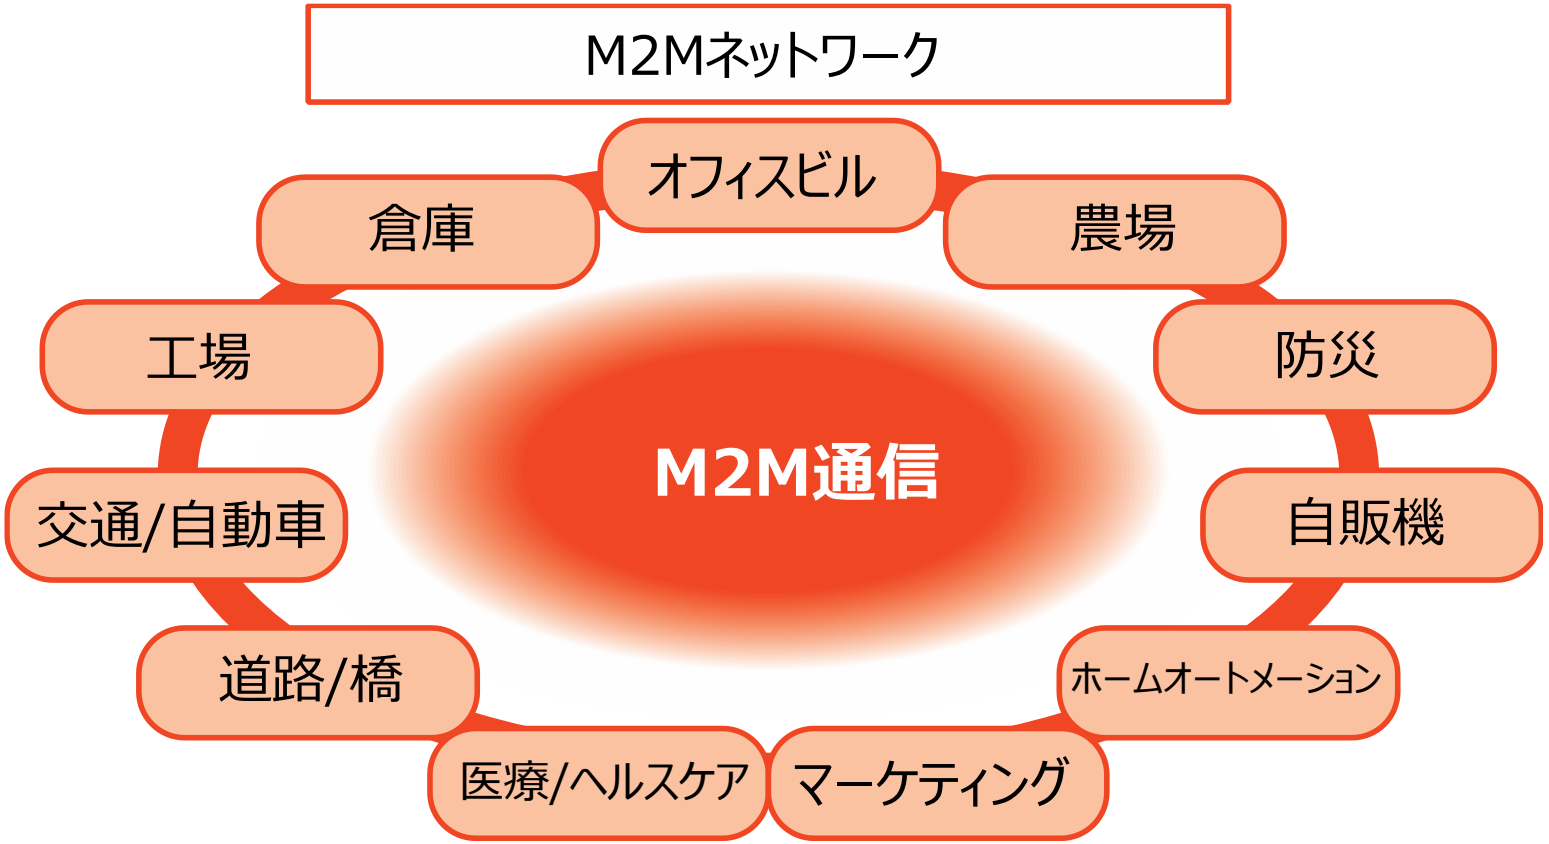

IoTとM2M

IoTはユビキタスとM2Mを包括する概念といえます

IoT社会
Machine to Machine、Human to Machine、Human to Human

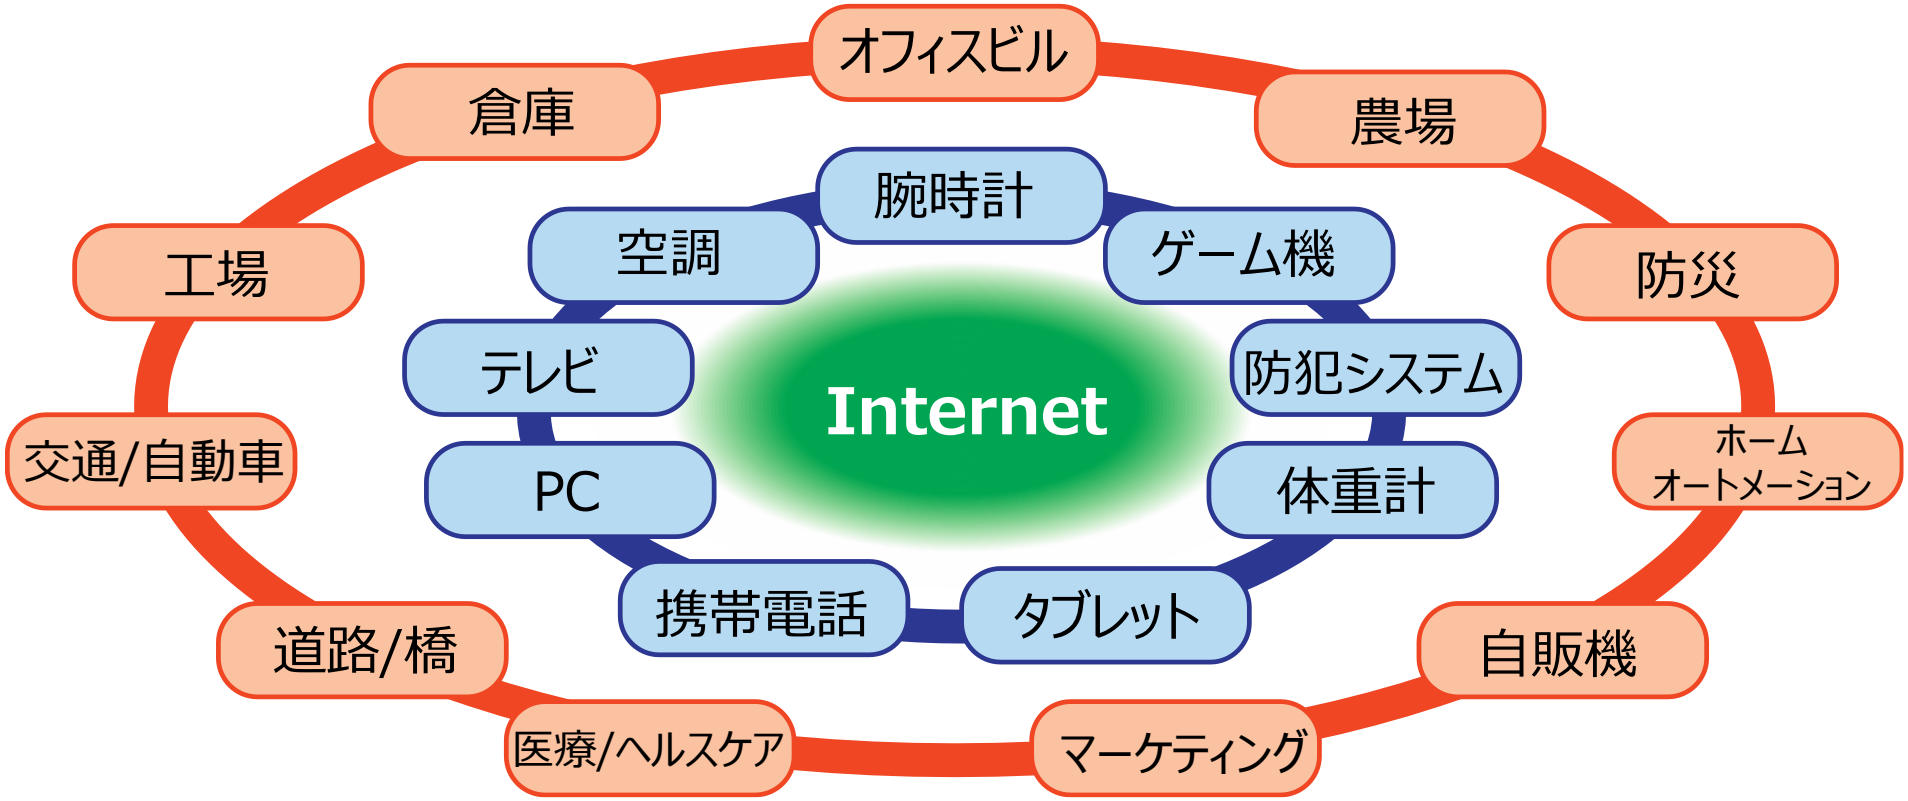

IoTを構成する技術要素

・センサー：物理的な現象を検知し、電気信号として出力する装置。

・デバイス：センサーが組み込まれることによって、ネットワークに接続された装置やモノ。

例　スマホ、時計、メガネ

・ネットワーク：デバイスをIoTサービスに繋ぐ、あるいはデバイス同士を繋ぐことでデータを共有、処理するシステム。

・IoTサービス：　①デバイスとのデータの送受信 … IoT
②データの処理と保存 … ビッグデータの技術的守備範囲
を行うサービス。

・データ分析：蓄積したデータについて統計分析や機械学習を行う。

→最適な判断や行動方針を導き出す。

IoTを構成する技術要素　センサー

センサー

物理的な現象を検知し、電気信号として出力する装置のことをいいます。
多くの場合、一つのデバイスに対して複数のセンサーが埋め込まれています。

・画像センサー：光を捉えて処理することで、画像や動画を撮影する。
　　赤外線を検知して画像処理するものもある。
・光センサー：光の強度を測定する。
・温度センサー：温度を測定する。
・湿度センサー：湿度を測定する。
・振動/速度/加速度センサー：機器の振動や速度、加速度を測定する。
・地磁気センサー：地磁気を検出することで、方角を計測する。
・ジャイロセンサー：デバイスの傾きを検知する。
・音声マイク：機器が発する音や、人の声などの音声を収集する。

IoTを構成する技術要素　センサー

センサーの代表的なデータフォーマットとしては、
・XML　・JSON　・MessagePack
があります。

XML
```
<xml>
  <info>
    <id>12996</id>
    <name>RoomSensor</name>
    <date>20170123112255</date>
  </info>
  <data>
    <temperature>27.8</temperature>
    <humid>72</humid>
  </data>
</xml>
```

人が読んで分かりやすい
データ量が多い

JSON
```
{"info":{"id":123,
          "name":"RoomSensor",
          "date":20170123112255
         },
 "data"{"temperature": 27.8,
          "humid":72
         }
}
```

データ量が少ない

いずれも各言語のライブラリが充実していますが、文字データであることから、パース（解析）をしないとプログラムで利用できません。
MessagePackは、バイナリデータをそのまま扱いたい場合、有利です。

IoTを構成する技術要素　センサー

MessagePack

・センサーの代表的なデータフォーマットの一つ。
・JSONと似た形式だが、値はバイナリのままである。
・軽量でプログラム間処理に向いている。

MessagePackの特徴

・シリアライズ（データの直列化）、デシリアライズ：非常に高速
・シリアライズされたデータのサイズ：小さい
・フォーマット定義：不要
・ストリーム処理：可能

JSONとMessagePackの比較

JSON　{“a”:null,”b”:10,”c”:[20],”d”:”30"}　… 35byte

→ MessagePack に変換すると…

84 a2 61 c0 a2 62 0a a2 63 91 14 a2 64 a2 33 30　… 16byte

IoTを構成する技術要素　デバイス

デバイス

センサーが組み込まれることによって、ネットワークに接続された装置、モノのことをいいます。例えば、スマホ、時計、メガネはいずれもデバイスです。

デバイスの２つの機能

・センシング：センサーを利用して、デバイス自身や周りの環境の状態を収集し、IoTシステムに通知すること。

例・画像センサーによる人の有無の検知
・スマホの位置情報や加速度の計測

・フィードバック：システムからの通知を受け、指示や動作をもとのシステムに返すこと。次のような方法がある。

・可視化：センシング結果表示、デバイスの管理、画面表示
・通知：システムが判断した結果を画面に表示
・制御：デバイス自身や環境の状態そのものを変更

IoTを構成する技術要素　IoTサービス

IoTサービス

以下を行うサービスのことを指します。

①デバイスとのデータの送受信
②データの処理と保存

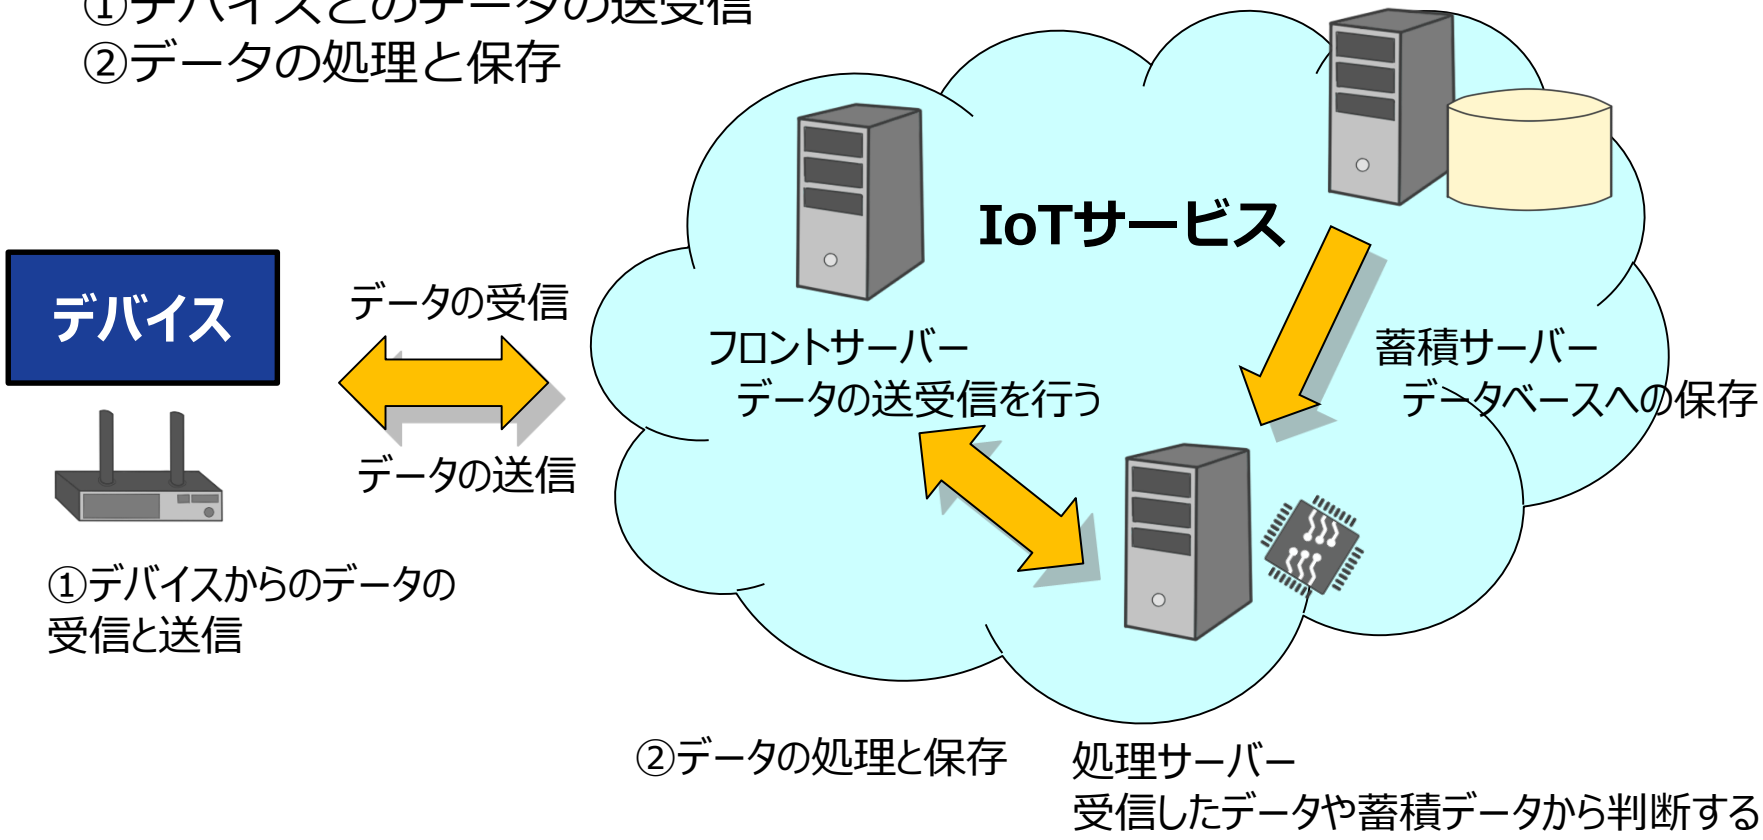

IoTを構成する技術要素　IoTサービス

サーバー構成

IoTサービスの役割は、フロントエンド、処理、蓄積の大きく３つに分けられます。

蓄積されるデータは膨大な量となります。

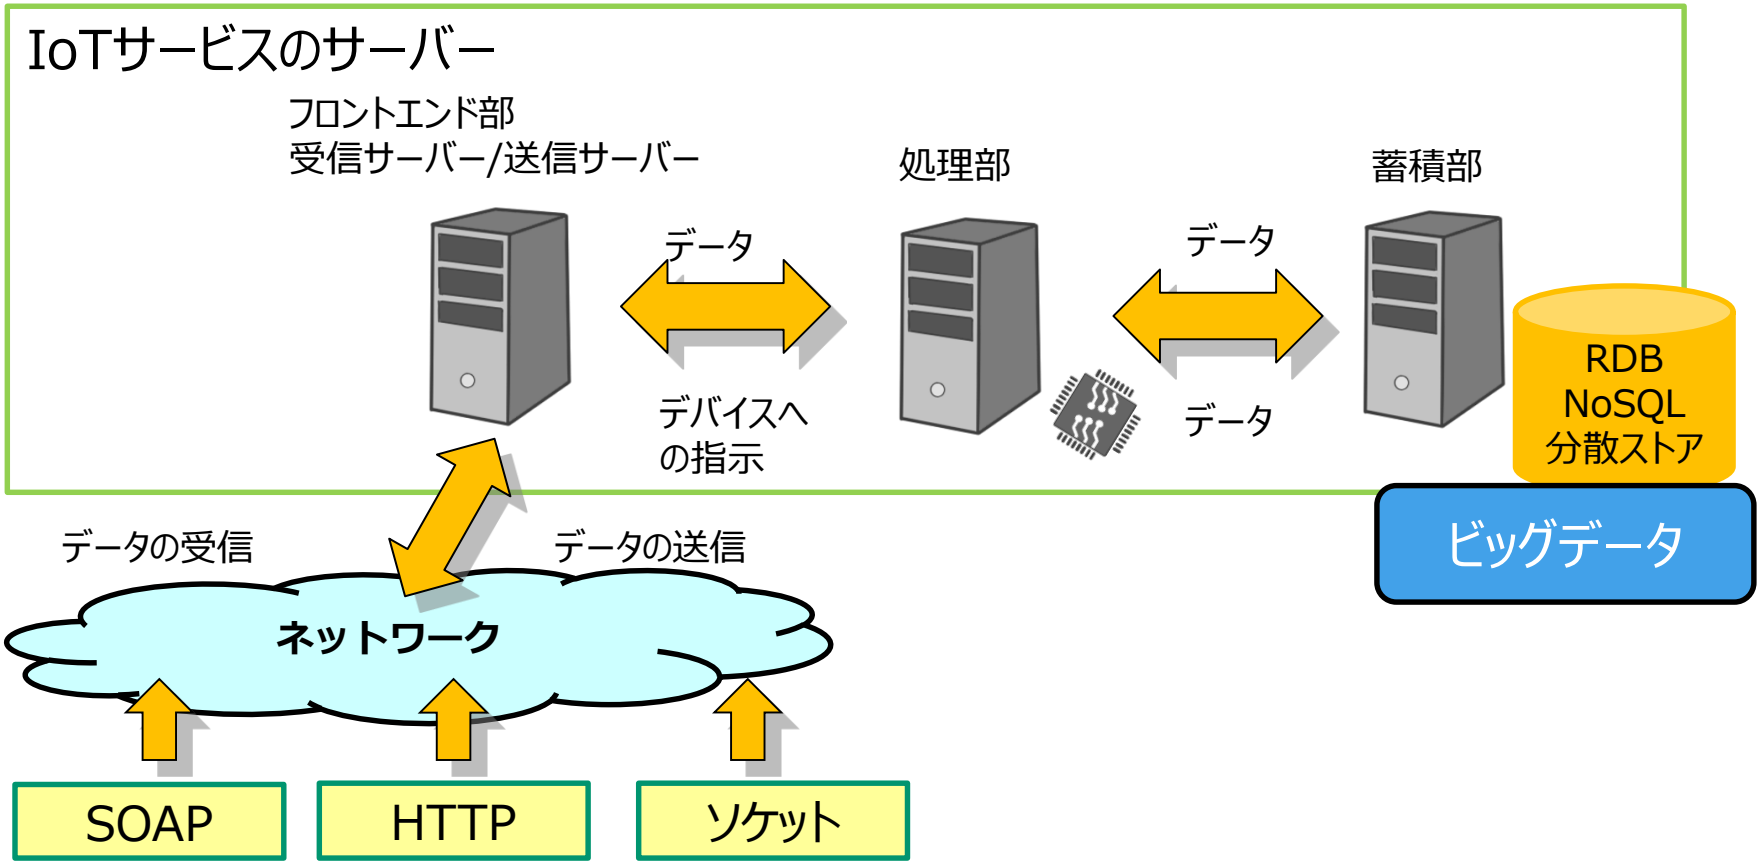

第２章
ビッグデータを支える技術

データ収集・加工

ビッグデータの解析までの流れ

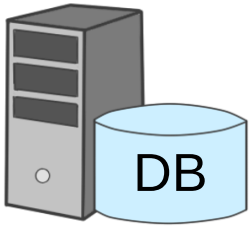

社内の実績データ

SNSデータ
社外の取引データ
Webサイトログ

音声・画像・
センサーデータ

オープンデータ・
統計データ・
科学データ

ビッグデータ
蓄積基盤

BIツール

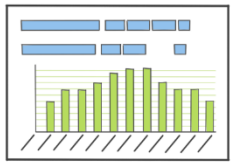

統計解析
ツール

機械学習・
AI

収集

蓄積

解析

データ蓄積までの流れ

以下のようにして、ビッグデータは分析可能な状態に処理されます。

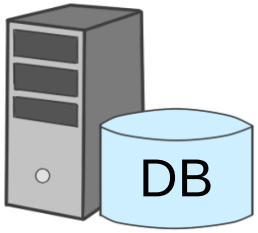

社内の実績データ

SNSデータ
社外の取引データ
Webサイトログ

音声・画像・
センサーデータ

オープンデータ・
統計データ・
科学データ

データ転送システム

クレンジング

- 名寄せ
- 型の変換
- 文字・日付の分割・結合
- 置換・マスター変換
- 数値演算

ETLツール

- RDB
- DWH カラムナDB
- NoSQL
- Hadoop

ストリーミング処理

データ蓄積手法

データ収集例

データ収集と通信方法

IoTの受信サーバの通信方法は3種類に分類できます。

- HTTPプロトコル
  通常のWebシステムと同様、HTTPプロトコルを利用したWeb APIを利用してデバイスからアクセスを行う。
- WebSocket
  音声や動画のリアルタイム通信を行う。
- MQTT
  送受信を媒介する第三者の存在により、柔軟な通信を可能にするメッセージ・キュー方式を利用する。

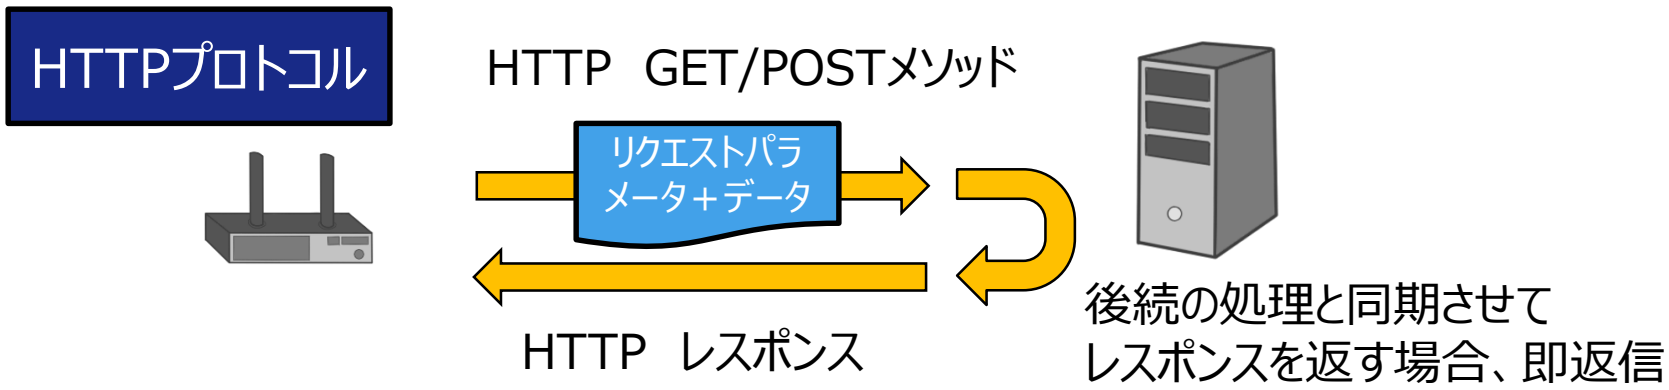

データ収集例

WebSocket

WebブラウザとWebサーバー間でデータを双方向かつ連続的に送受信するための通信プロトコルです。
IoTでWebSocketを用いることで、インターネット上でソケット通信が可能になります。

HTTPプロトコルを用いると送信毎に接続の依頼が必要ですが、WebSocket通信を行うと、接続を継続したままにすることが可能となります。

HTTPプロトコルの場合 WebSocketコネクション確立

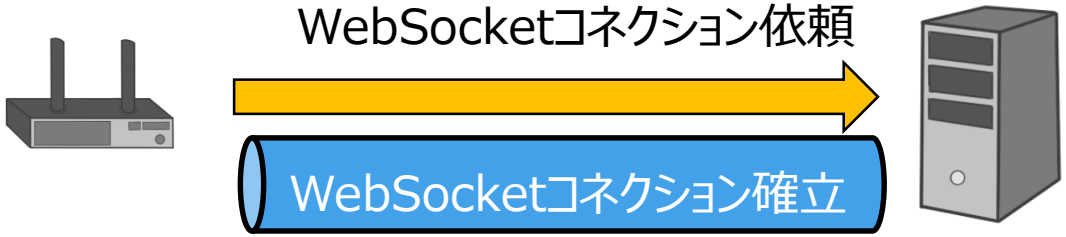

送信毎にクライアントから
コネクション依頼の必要がある

WebSocket通信

クライアントから一度
コネクションを確立すれば
継続して利用可能

データ収集例

MQTT（MQ Telemetry Transport）

IBM社により提唱され、現在はオープンソースとなっているプロトコルです。

・仲介役のブローカー（Broker）
・情報発信者のパブリッシャー（Publisher）
・情報受信者のサブスクライバー（Subscriber）
の３つの機能から成り立ちます。

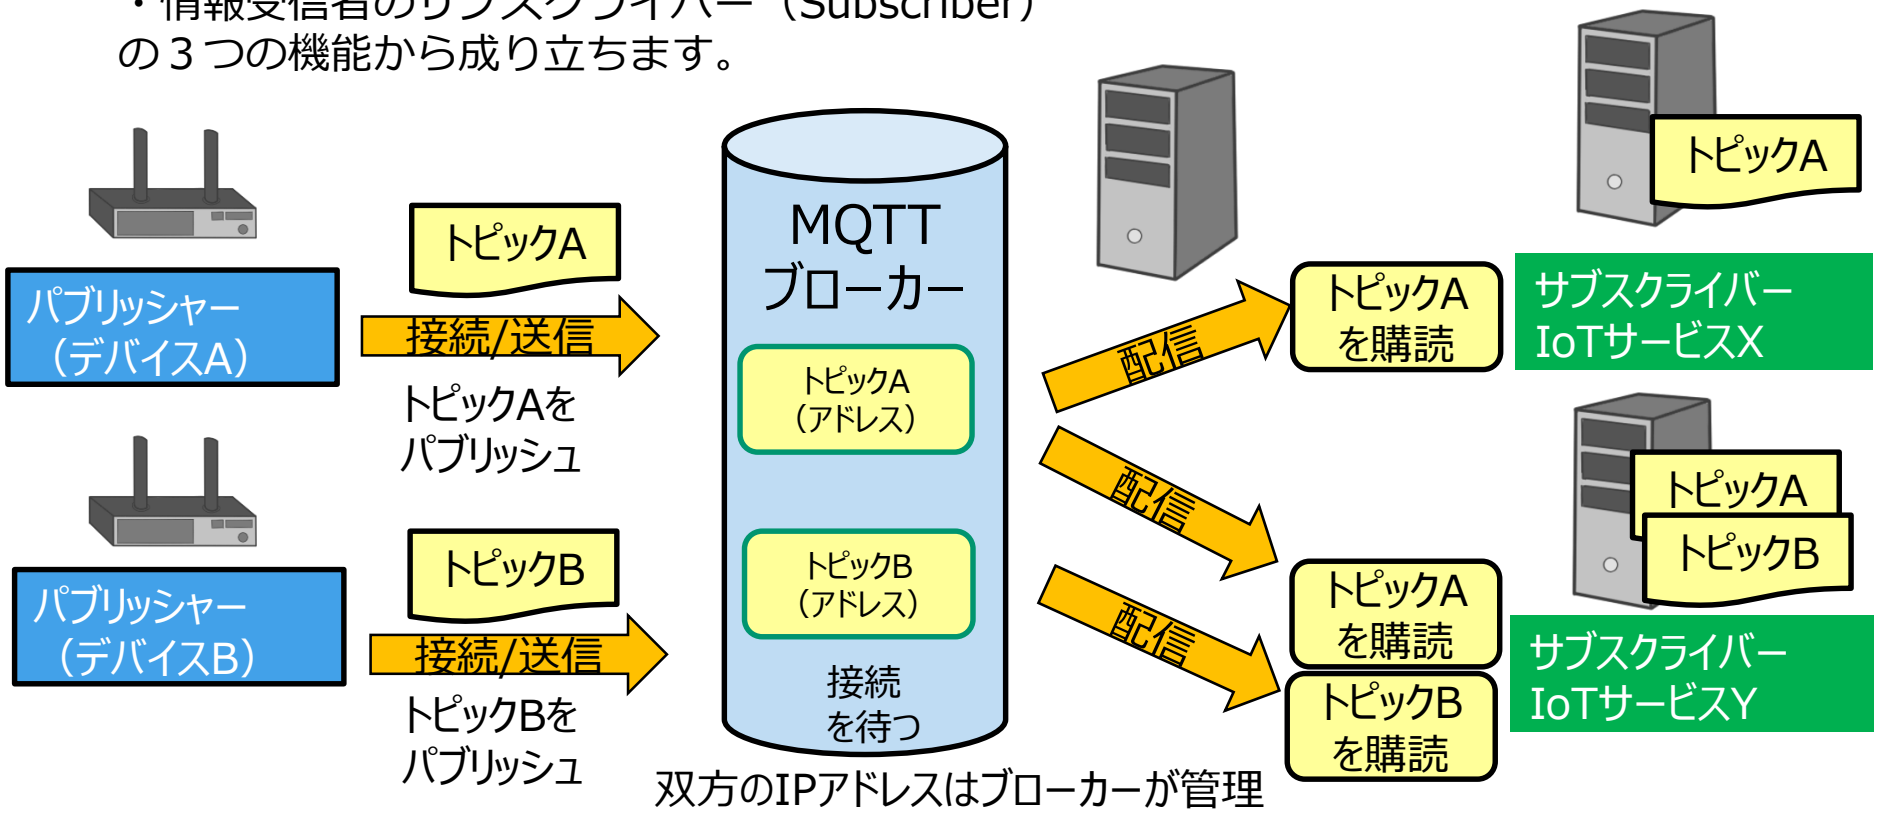

双方のIPアドレスはブローカーが管理

同期通信と非同期通信

デバイスとの通信には同期通信と非同期通信があります。

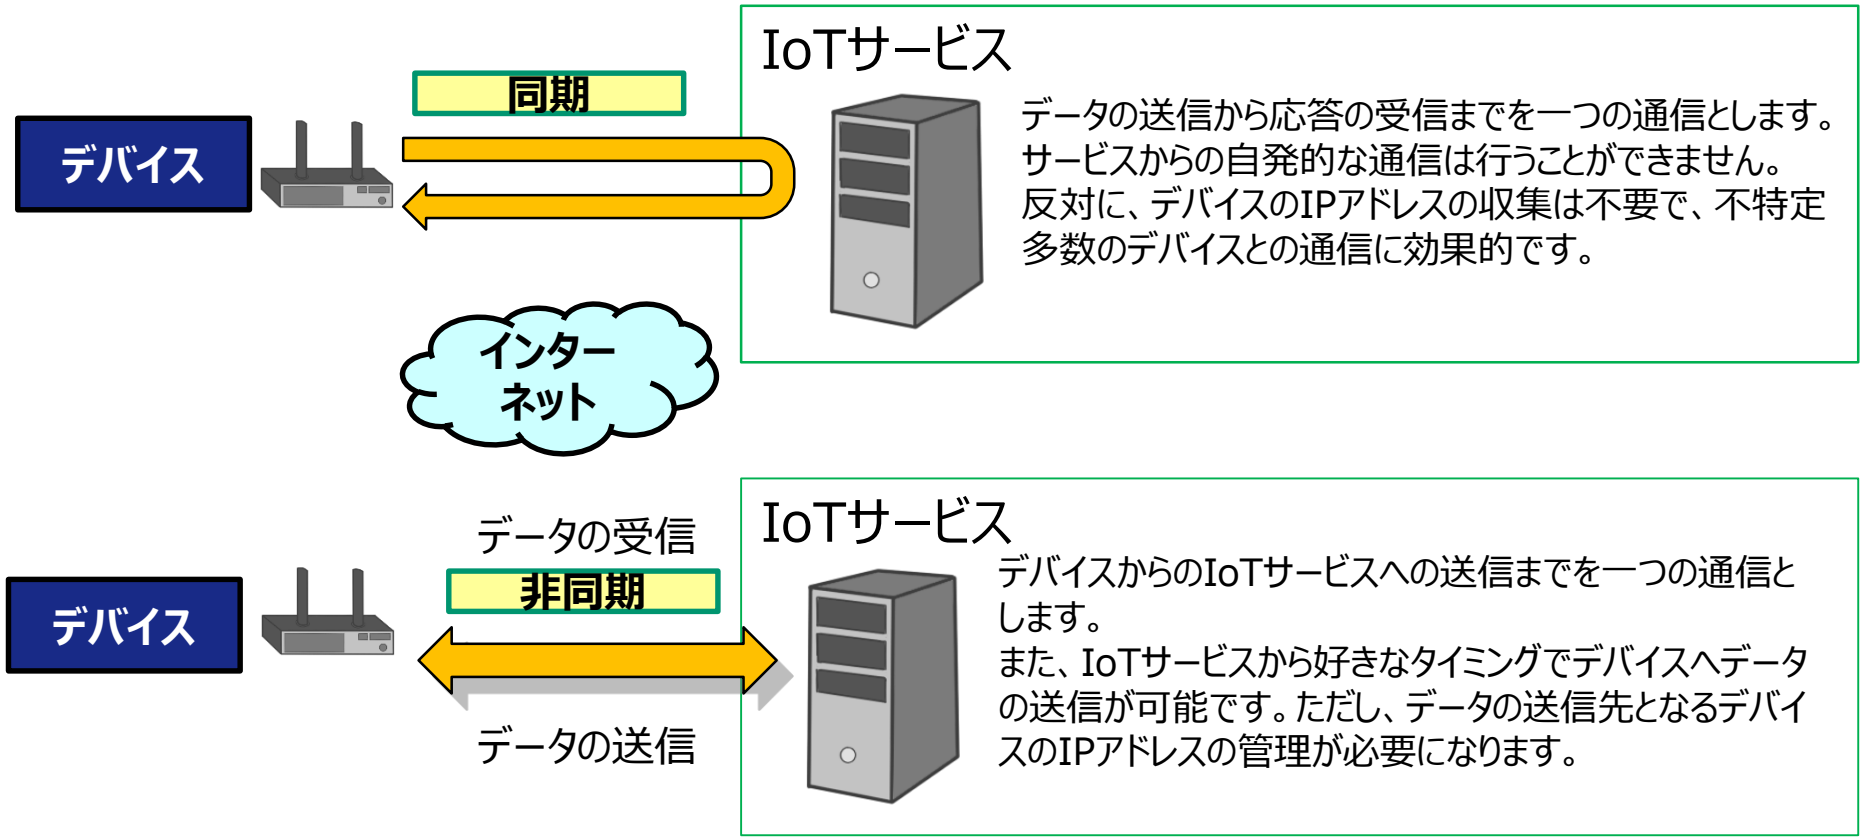

ビッグデータの処理と保存

ビッグデータの処理

受信したデータは、データベースや分散ファイルシステムなどに保存されます。
また、受信したデータからデバイス制御の判断を行います。

処理と保存の方法には、ストリーム処理とバッチ処理の2種類があります。

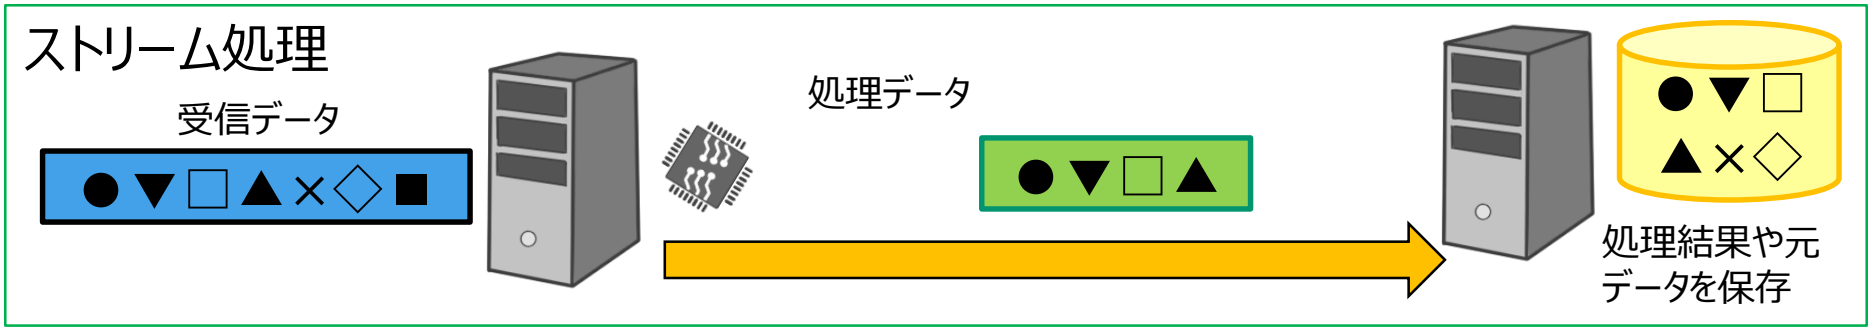

データ内容を常に判断し、即座にデバイスを制御したい場合に利用

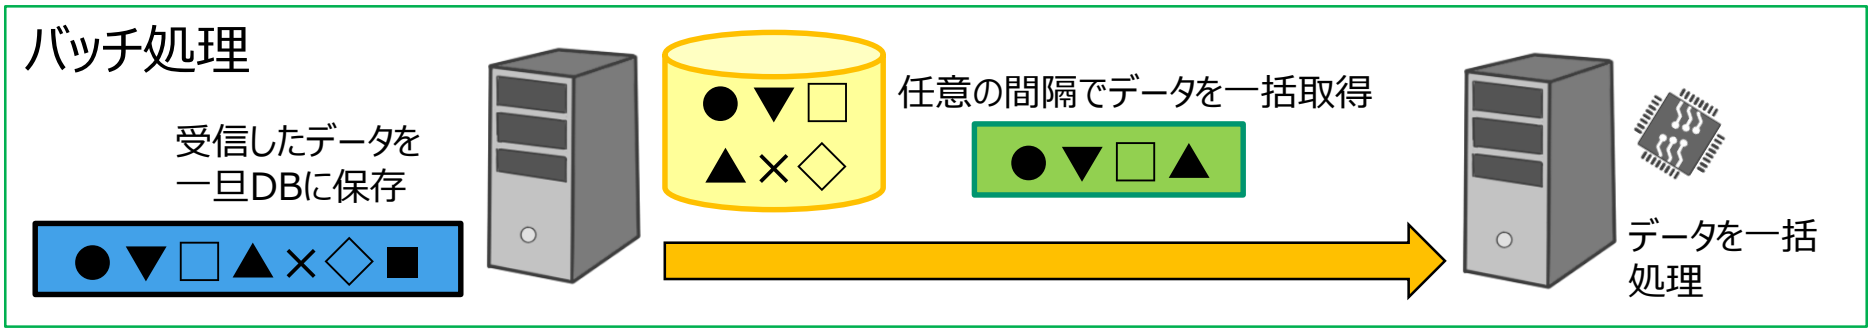

記録とデバイス制御にタイムラグがあっても問題ない場合に利用

ストリーム処理

ストリーム処理

ストリーム処理はデータを保存せずに、処理サーバーに到着したデータを逐次処理する方法です。与えられたデータにリアルタイムで反応することができます。

Spark Streaming

Spark Streamingは、ストリーム処理を行うためのSparkのライブラリです。
時系列的に連続したデータ列をRDDで分割し、分割されたRDDに対して小さな処理単位のバッチを実行します。

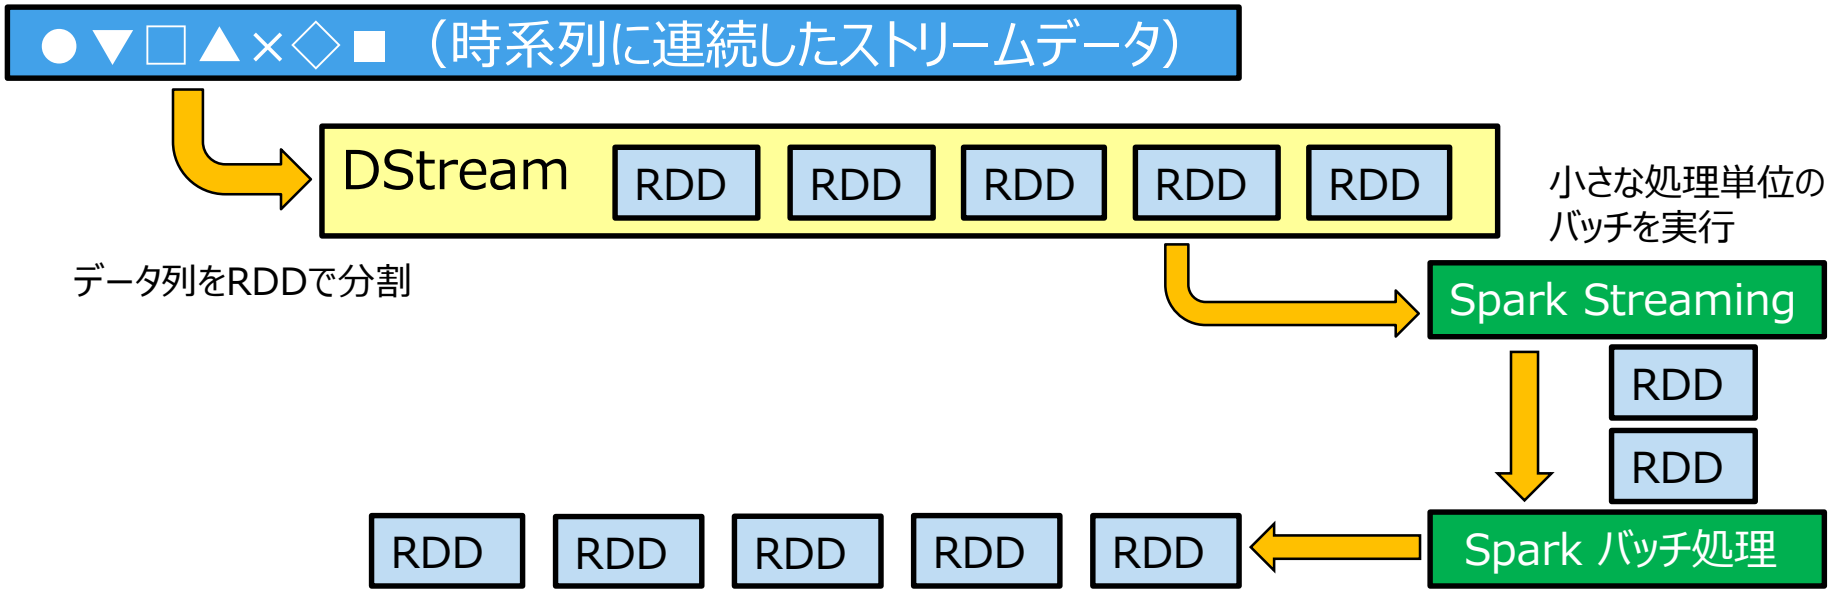

ストリーム処理

Apache Storm

Apache Stormとは、ストリーム処理のためのフレームワークです。

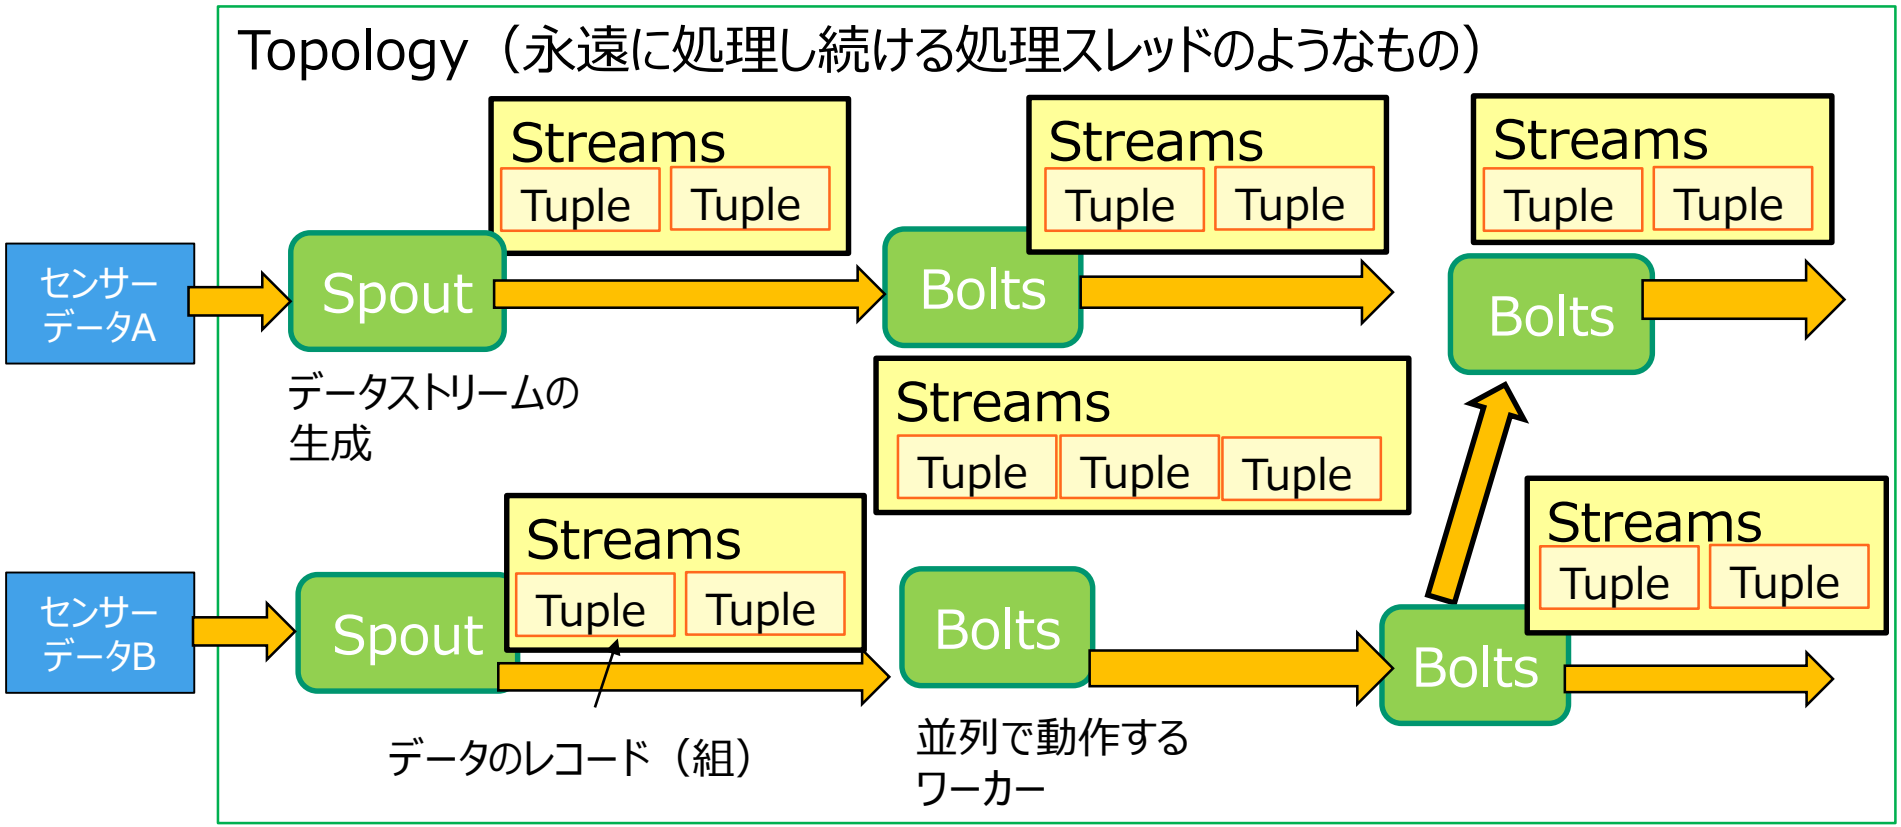

データ蓄積までの流れ

ビッグデータを分析可能な状態に処理する流れは以下のようになっています。

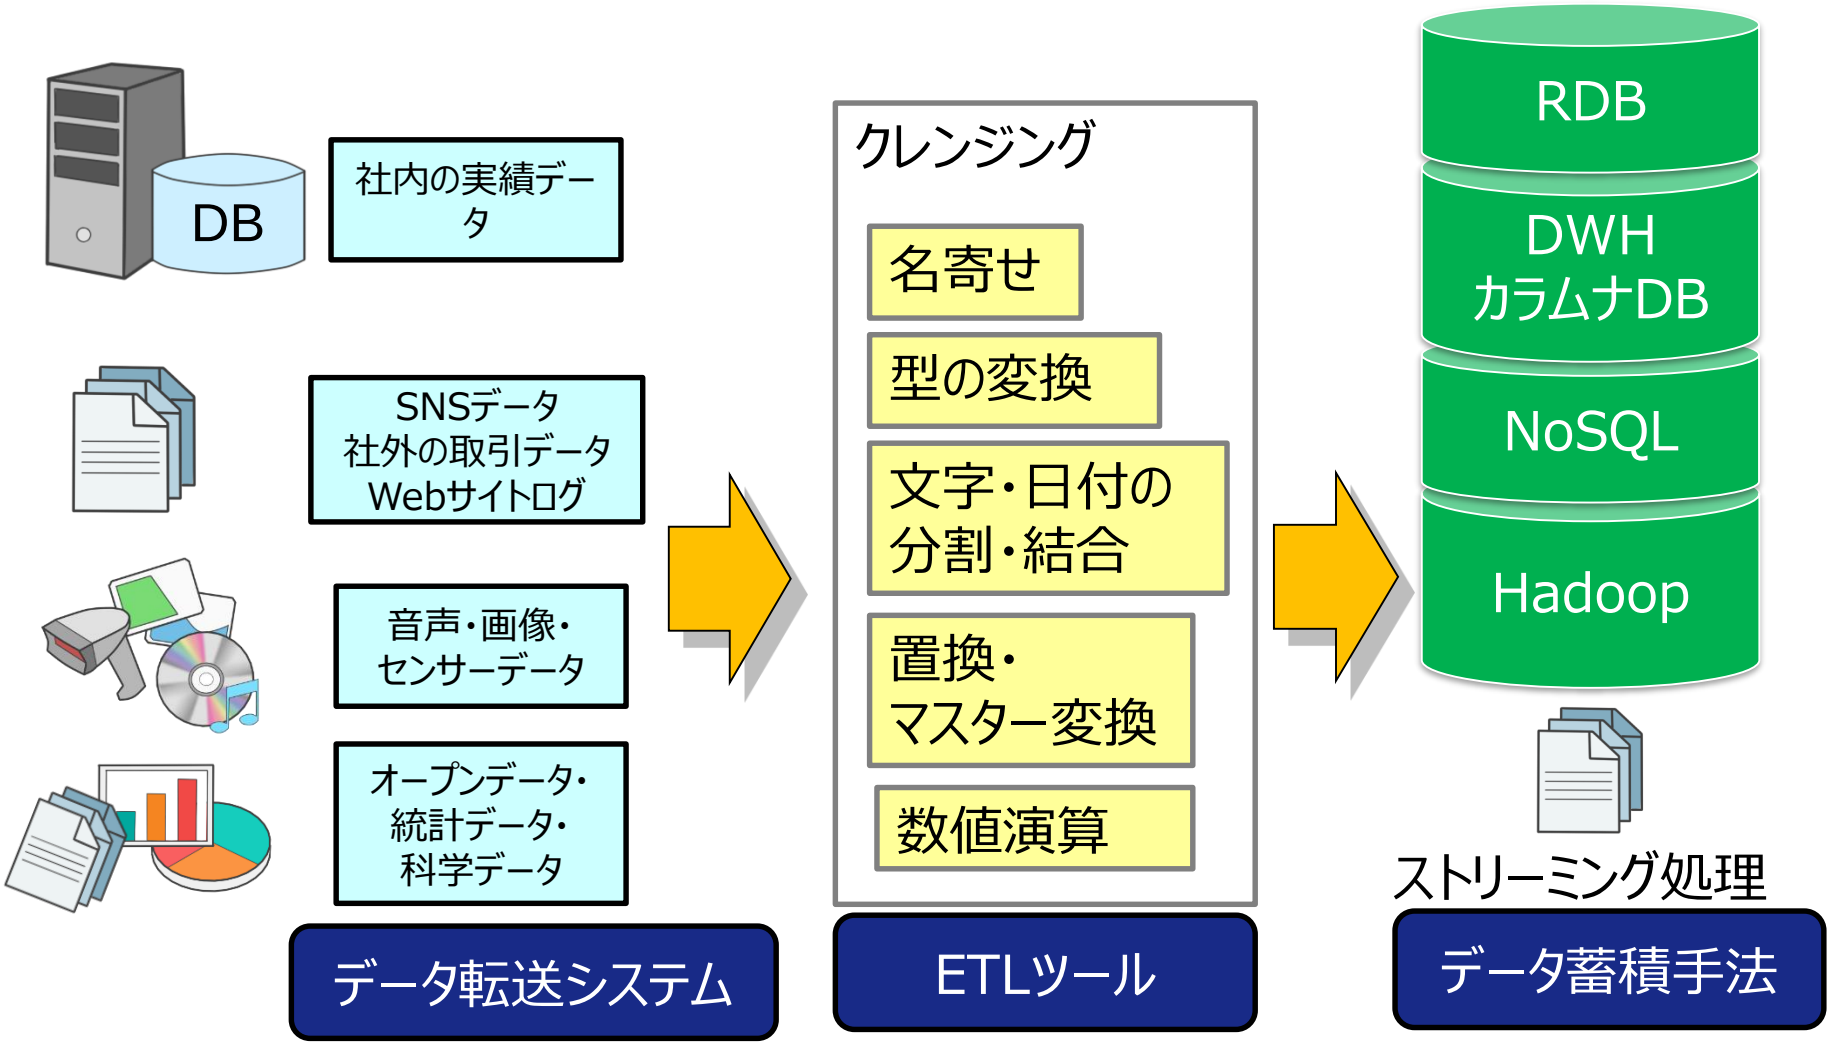

データ管理：クレンジング

クレンジング

データの整理や加工を行うことで、効率的に分析できるようになります。
これをクレンジングもしくはデータ加工と呼びます。
専用のツールやR、Python、GOなどのスクリプト言語で実施できます。

クレンジング対象	具体例	対処例
型の統一、日付、数値など	数値演算を行いたいデータに文字が入る場合など	基準を用意し、基準に合わないデータ修正
書式の不適合・表記ゆれ	住所、会社名、電話番号、郵便番号などの表記の不統一、通貨や数値の単位、文字コードなど	表記方法や単位の基準を定義し、基準に従うようにデータを修正する
異常データ	ある条件下でのセンサーの誤動作、データの無記入による空データ、データ入力ミスによる意味のないデータ	回帰やクラスタリングにおいて、結果の精度を下げる原因に異常値を検知し、事前に外す
個人情報およびプライバシー情報の保護	氏名、住所、メールアドレスなど個人を直接特定できる情報	個人を直接特定できる情報を削除または匿名化処理を施す

データ管理：クレンジング具体例

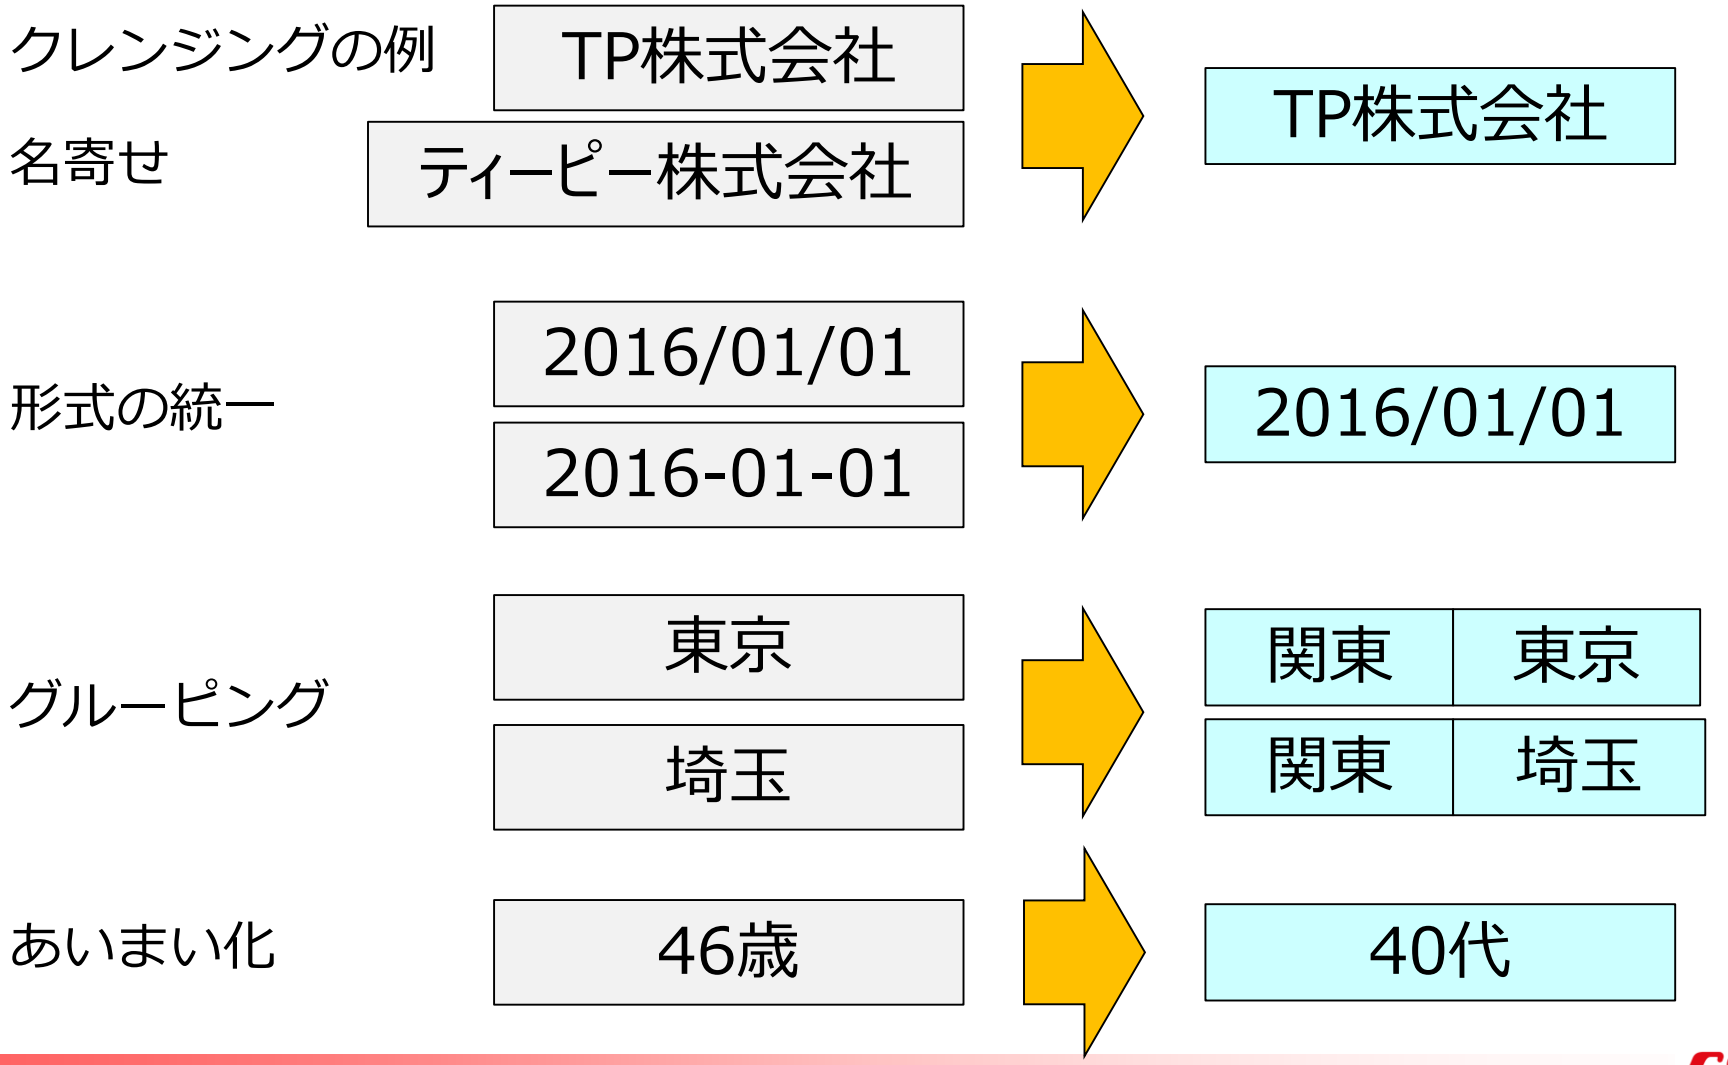

データ管理：ETLとELT

ETL（Extract Transform Load）

収集したデータを抽出(Extract)した後、利用しやすいように加工(Transform)し、DWHなどの蓄積先に書き込む(Load)一連の処理を表します。
大量データをバッチ処理する商用のETLツールなどが存在します。

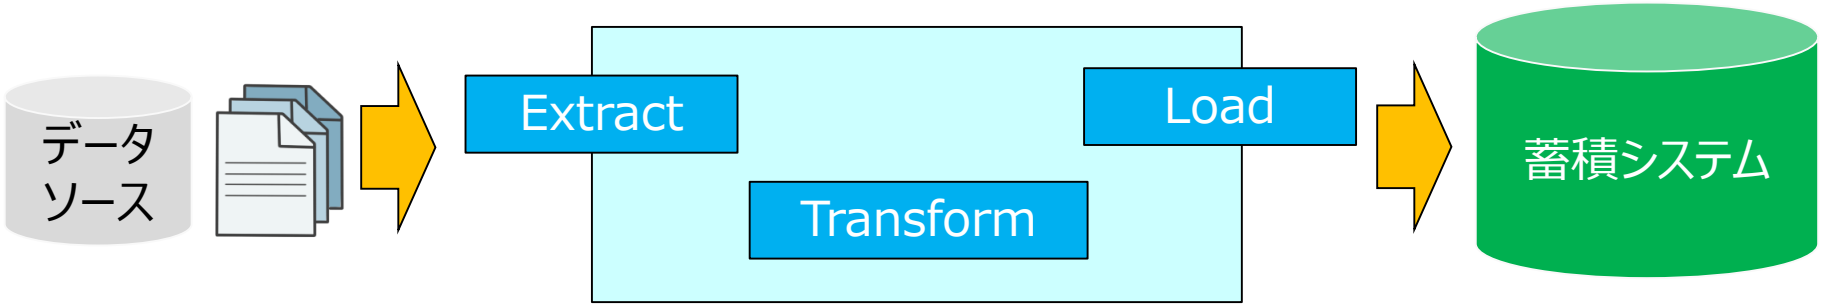

ELT（Extract Load Transform ）

収集したデータを抽出(Extract)し、DWHなどの蓄積先に書き込み(Load)をした後、利用する時に初めて加工(Transform)を行う方式です。

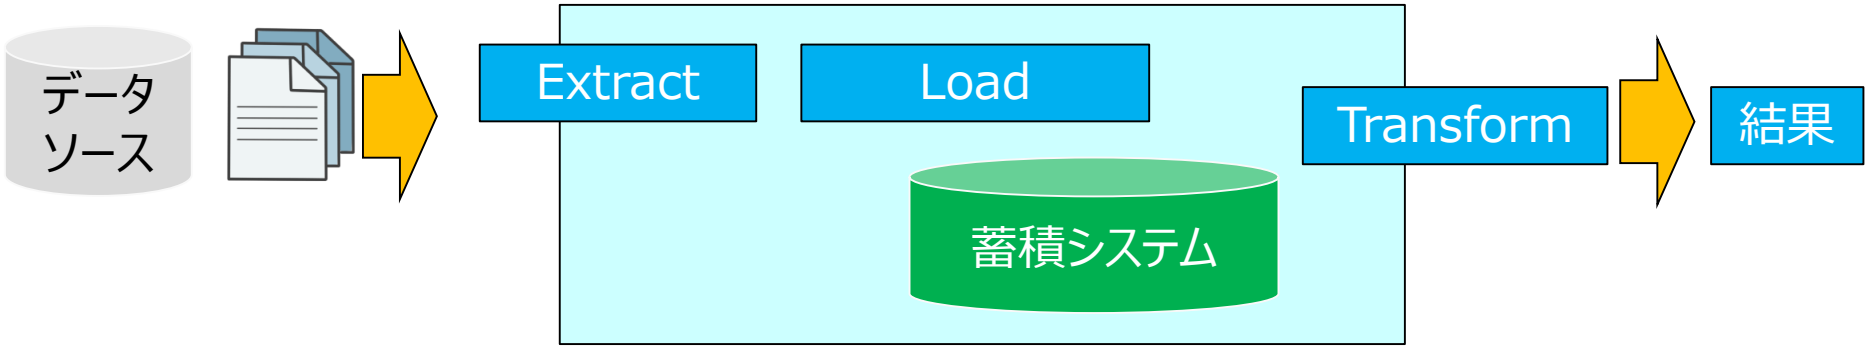

データ管理：従来型データ蓄積

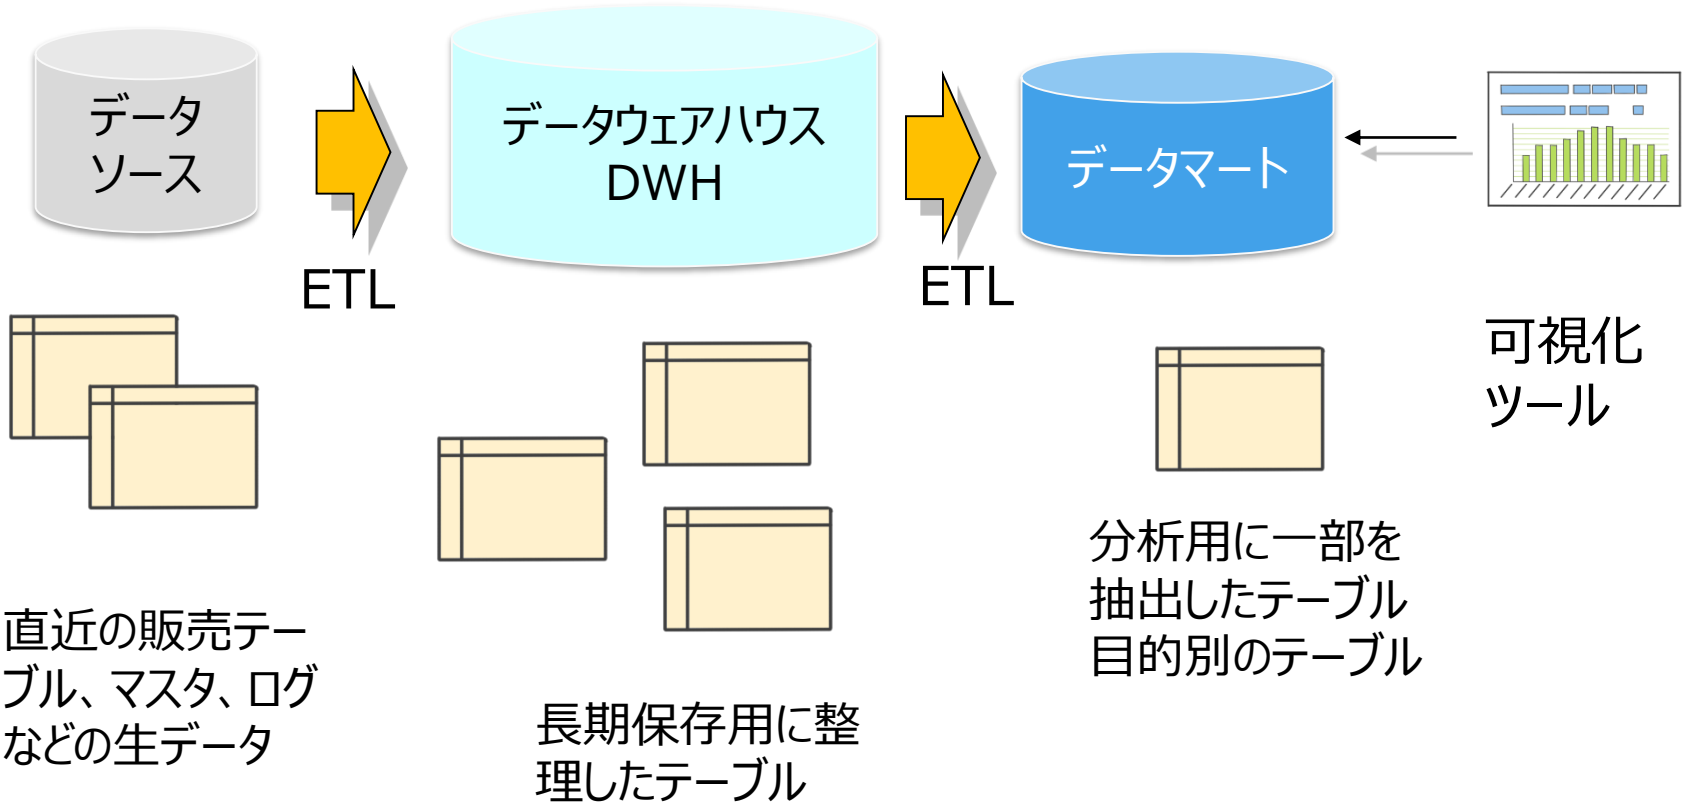

データ管理：データレイク

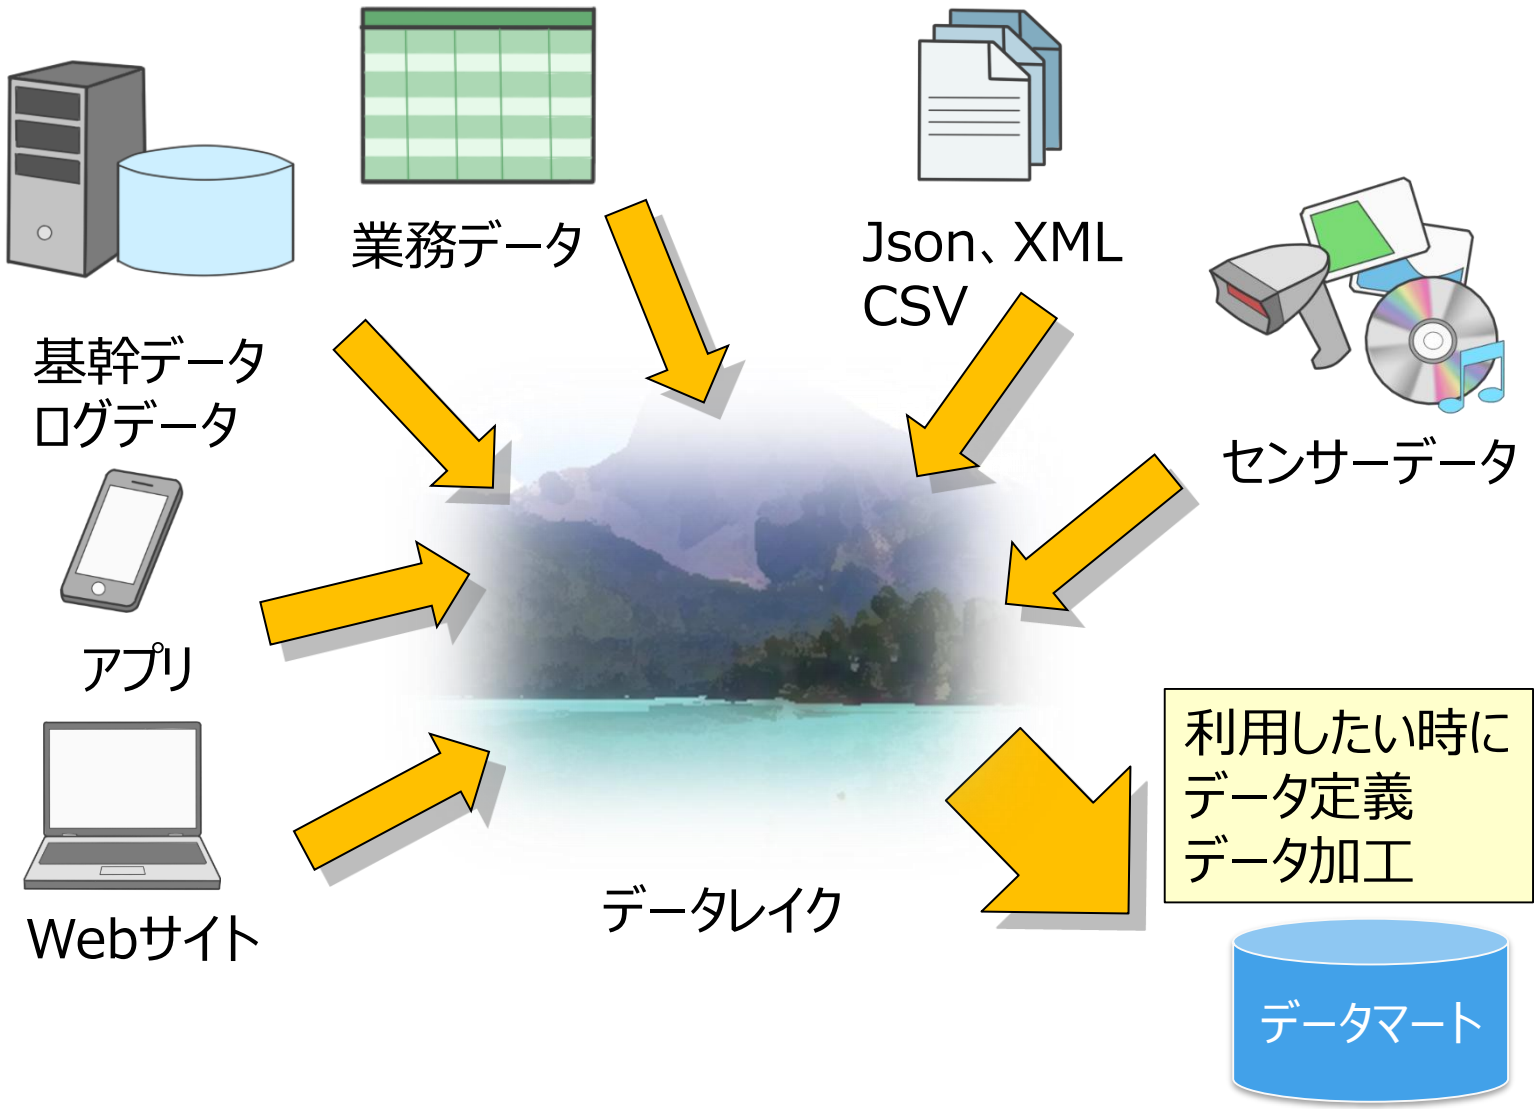

スループットとレイテンシ

ビッグデータ処理性能を測る指標

・スループット
一定時間に処理できるデータの総量。
WHやデータレイクなど、データの量が多い処理を行う時に重視。

・レイテンシ
データ処理が終わるまでの待機時間。
アドホック集計、データマート、BIツールなどで重視。

スループットとレイテンシは両立しないことが多く、複数のシステムで役割を分担することがあります。

従来型のデータベース：行指向DB

行指向データベース

テーブルの行を一つのデータとしてディスクに保存する方法です。

追記は末尾に加えるだけなので容易です。
トランザクションが多く発生する業務アプリなどで利用されます。

ディスク格納イメージ

2017-01-01	商品A	5000	10
2017-01-02	商品B	3750	1
2017-01-03	商品C	2160	5

高速化のためにIndexを利用することがありますが、分析対象となる列がわからないため、ディスクI/Oの軽減にならない場合が多いです。

従来型のデータベース：列指向DB

列指向データベース

テーブルのデータを列単位にまとめて保存する方法です。

集計に必要な項目だけを読み込むことができ、ディスクI/Oの軽減ができます。

ディスク格納イメージ

2017-01-01 2017-01-02 2017-01-03	商品A 商品B 商品C	5000 3750 2160	10 1 5

また、カラム単位での重複は集約が容易なため、圧縮効率が高いです。

従来型のデータベース：MPP

MPPデータベース（Massively Parallel Processing ）

一つのクエリを多数の小さなタスクに分解し、多くのCPUコアやコンピュータを並列的に稼働することで結果を得る手法です。

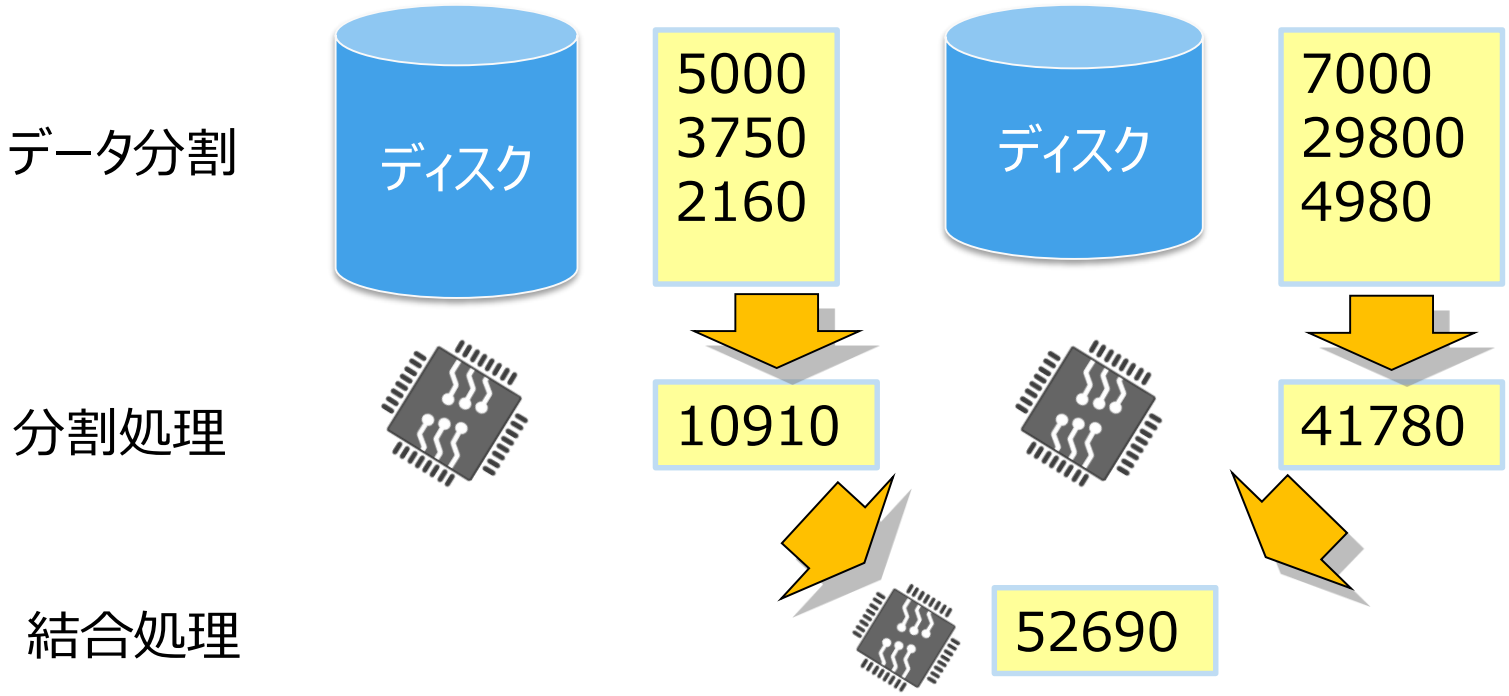

第３章

ビッグデータコア技術

NoSQL

NoSQLとは

NoSQLとは

・Not only SQL = RDBMS以外のデータベースの総称
・SQLを否定するものではない。
・1998年にCarlo Strozzi氏が初めて名称を使用した。(NoREL)
・非構造化データの蓄積や管理に利用される。

BASE

・Basically Available Soft-state Eventual consistency
・処理速度を優先するNoSQLで採用されているトランザクションの考え方。
…「稼動が第一で、厳密な整合性は過程ではなく結果でのみ重要視する」

ビッグデータで扱うデータの種類

ビッグデータの種類	データの例
構造化データ	データベースに格納されたデータ など (顧客テーブルデータ、 受注テーブルデータ など)
準構造化データ	ログデータ、センサーデータ、SNSに書き込まれたデータ など
非構造化データ	文書、音声、動画、画像 など

NoSQLのメリット、デメリット

NoSQLのメリット

・前もったデータの構造の定義が不要で、柔軟な変更が容易である
・特定の形式に固執しないため、複数のサーバにデータの分散ができる
・データ構造が単純で、更新や検索処理の速度が速い
・基本的にPutとGetのみを行えばよく、JOINがないため操作が明快

NoSQLのデメリット

・RDBMSと比較すると、データ間の整合性を維持する機能が弱い

NoSQLのメリット、デメリット

NoSQLとRDBMSとの比較

	RDBMS	NoSQL
保存に適するデータ	構造化データ	非構造化データ
スキーマ定義	事前定義が必要 固定的で変更しにくい	事前定義不要 データ構造を変更しやすい
データの整合性	同時実行制御がある データ整合性を重視	比較的緩い 大容量データの高速処理を優先、結果整合重視
データ操作命令	SQL言語 (SELECT、INSERT、UPDATE、DELETE)	Put(書き込み) Get(読み出し)
拡張方式	スケールアップ	スケールアウト

NoSQLのメリット、デメリット

データベースの拡張方式の比較

RDBMS　：スケールアップを行う
NoSQL　：スケールアウトを行う

スケールアップ

1台のサーバの処理性能やストレージを拡張します。

スケールアウト

サーバを増設し処理性能を向上させます。

NoSQLのメリット、デメリット

データベースの拡張方式の比較

RDBMS ⇨ スケールアップ

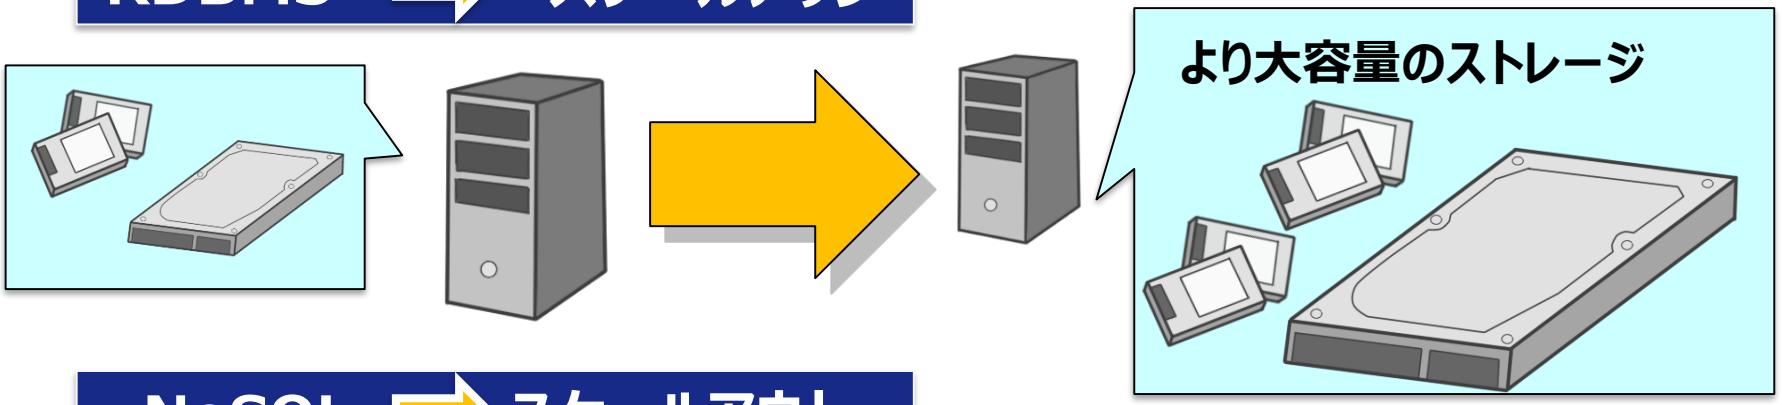

NoSQL ⇨ スケールアウト

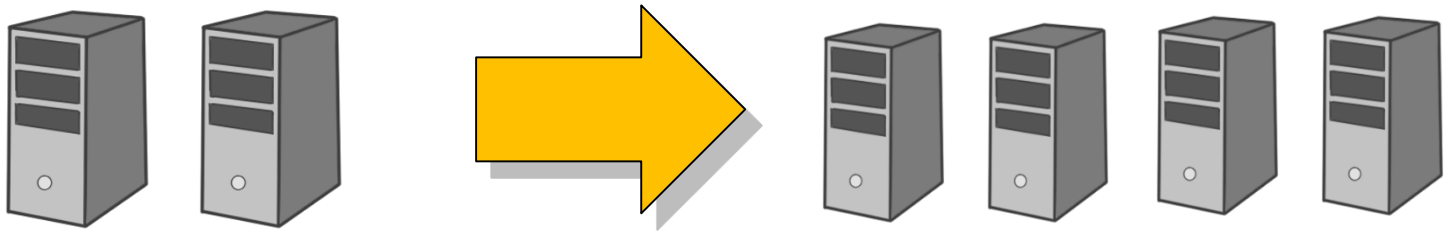

NoSQLのメリット、デメリット

スケールアップ

ハードウェアの性能(ディスク、CPU、メモリ)の増強により、特定の1台のサーバの性能を向上させます。

RDBは以下の特徴を持つため、スケールアップが効果的です。

・複数のサーバで運用すると、データ分割や配置作業が必要となる

・サーバ間の大規模トランザクションによりパフォーマンスが低下する

スケールアウト

サーバの台数を増やし、全体での処理能力を向上させます。

高性能がサーバに求められないため、低コストで処理性能を上げることが可能です。

また、1台サーバの停止による影響は少なく、稼働率は向上します。

NoSQLは、データベースで扱うデータが非構造化データなため、複数のサーバへの分割・複製が容易、つまりスケールアウトの手法に向いています。

NoSQLの代表的な種類

キー・バリュー型

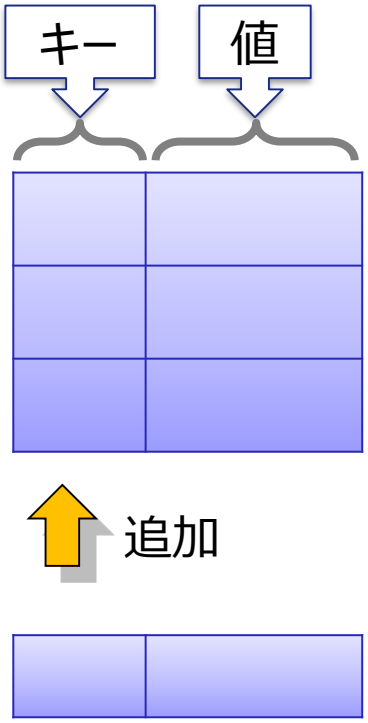

列指向型（ワイドカラム型）

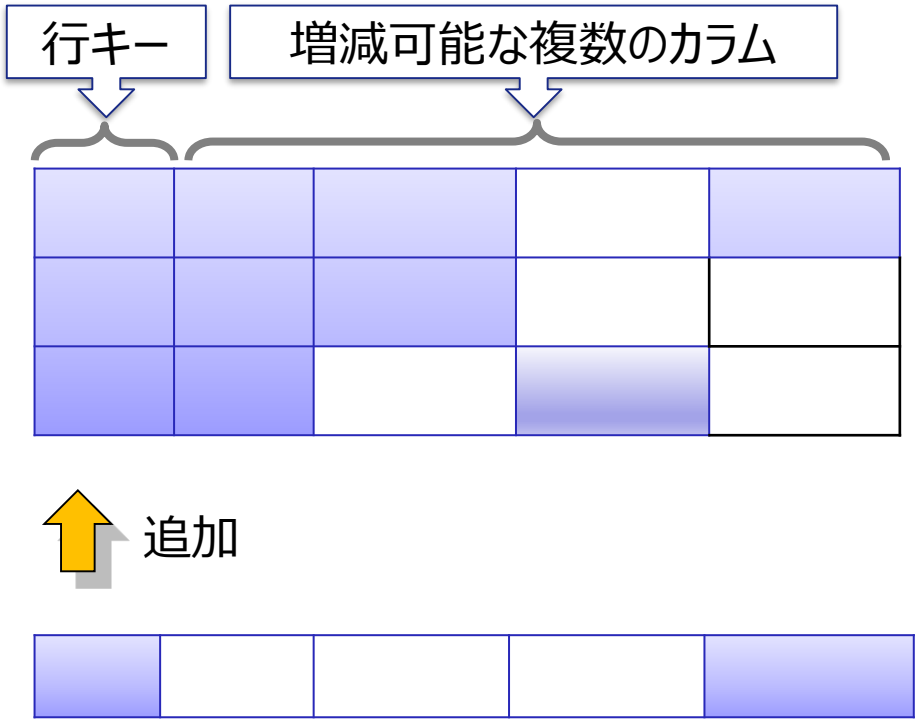

列は後から追加も可能。列がない行データも許容。

NoSQLの代表的な種類

ドキュメント型

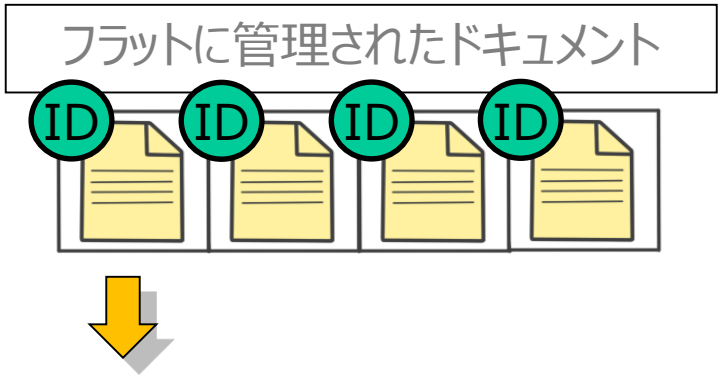

ドキュメントの例 (JSON)

```
{
“title” : “今日のランチ”
“userName” :
“Morimoto”
“postedDateTime” :
“2014/10/10 13:00”
“content” : “カレー”
 }
```

グラフ型

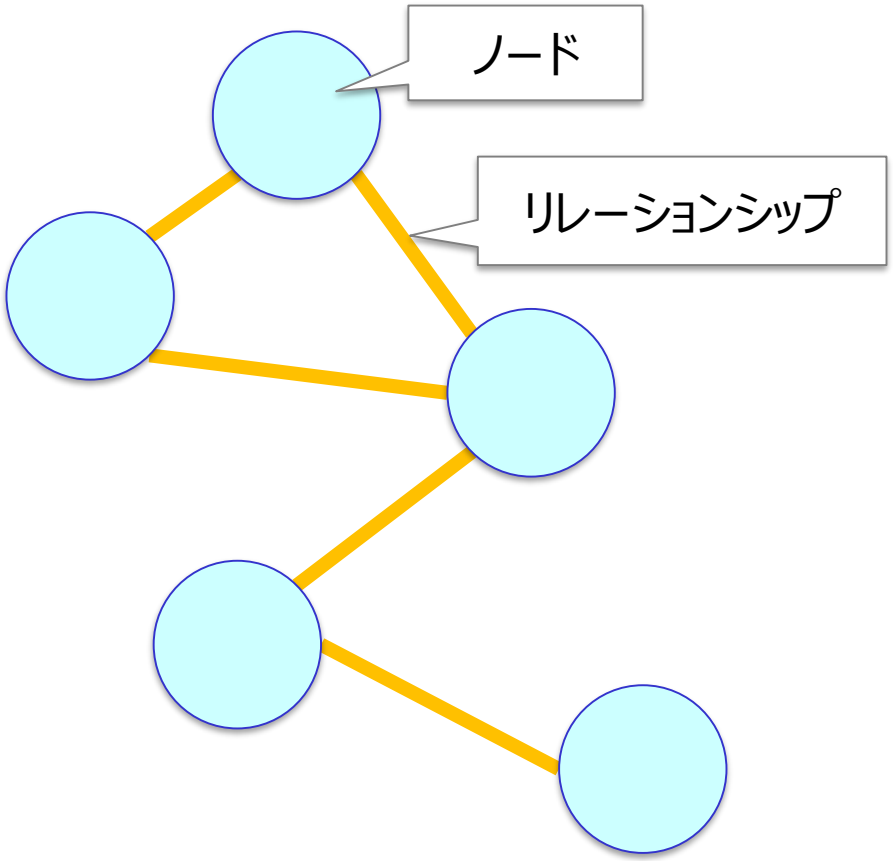

キー・バリュー型の特徴

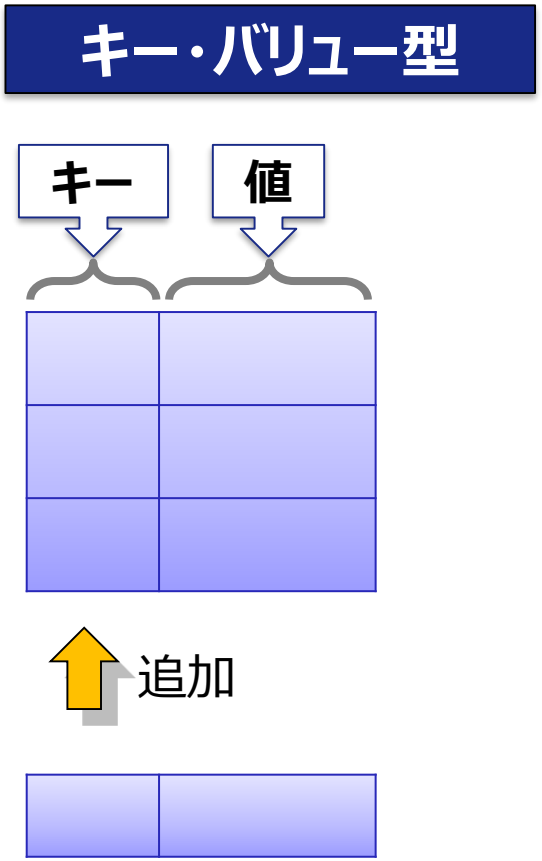

キー・バリュー型

キーとバリュー(値)のセットでデータを整列します。
キーは、値に対する識別子となるデータです。
値はバイナリデータであれば、BLOB型の画像や音声も格納できます。

キーとキーに紐付けられたデータという単純な構造であるため、スキーマ定義が不要で、検索が高速化でき、またサーバの追加やデータの分割・配置作業が容易となります。つまり、簡単にスケールアウト環境が構築できます。

Dynamo、Voldemort、Riak、Hibari、Redis、Scalaris、TokyoCabinet/Tylantなどで採用されています。

キー・バリュー型の特徴

RDBとキーバリュー型NoSQLのスケールアウト比較

キーバリュー型では、整合性を確認する必要性がないので、キーの管理さえしていればサーバを増やすだけで問題はありません。

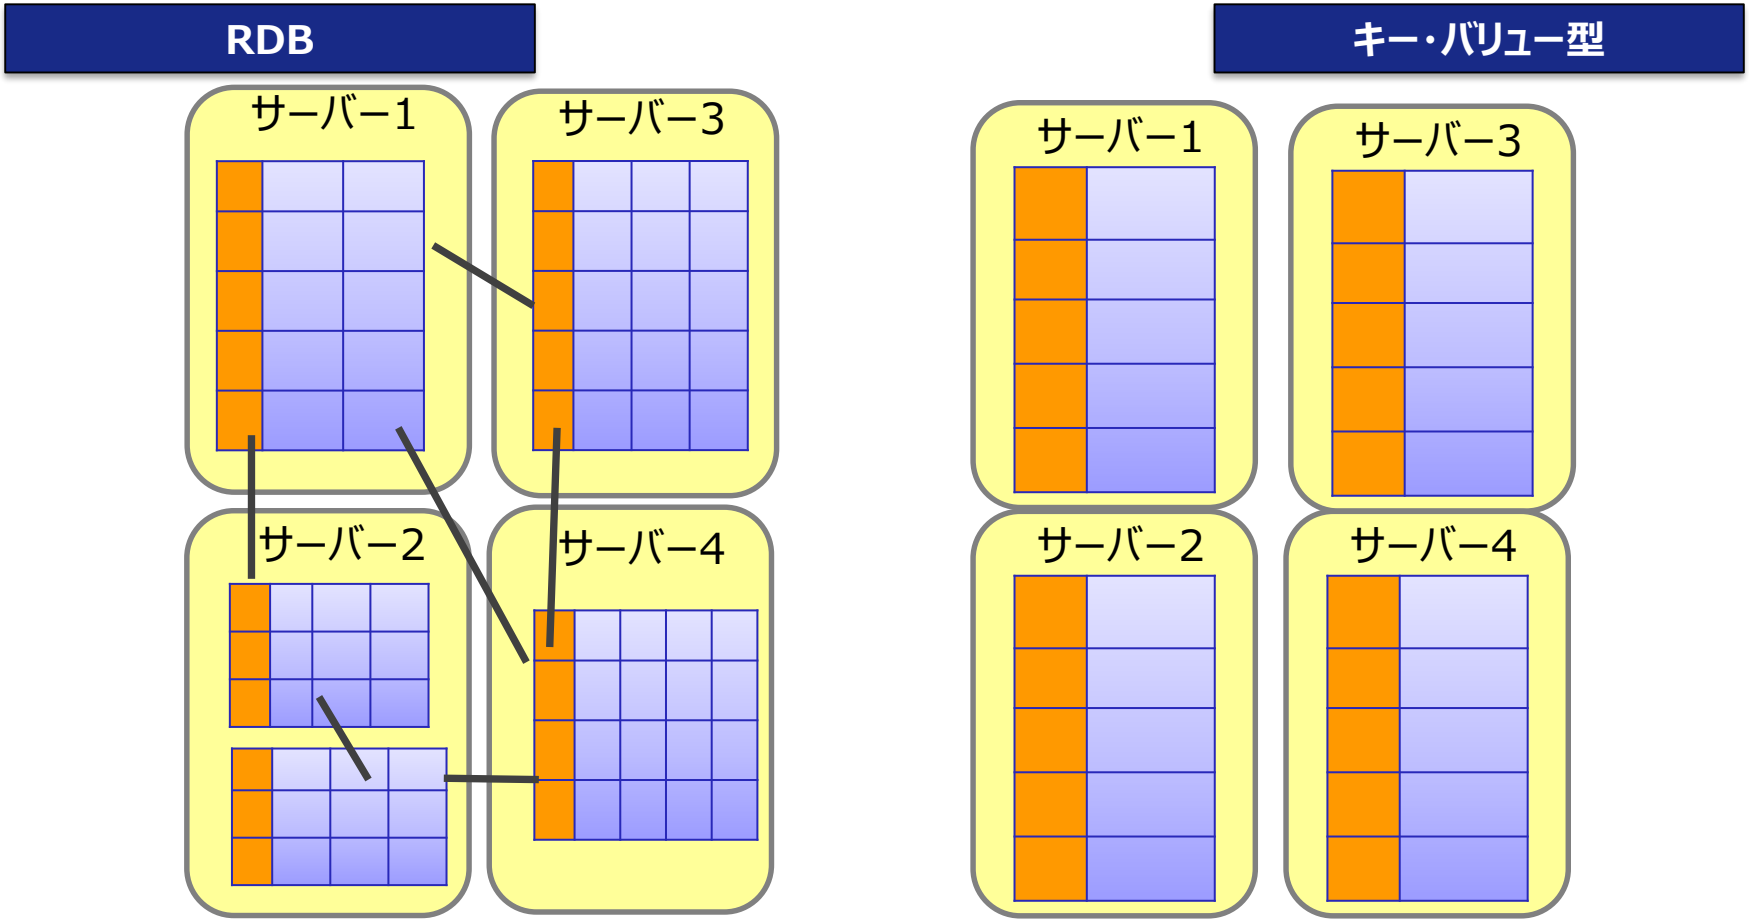

キー・バリュー型の特徴

シャーディング / Sharding

あらかじめサーバ毎に保存するデータのキーの範囲を設定しておくことで、検索や管理を容易にする機能です。

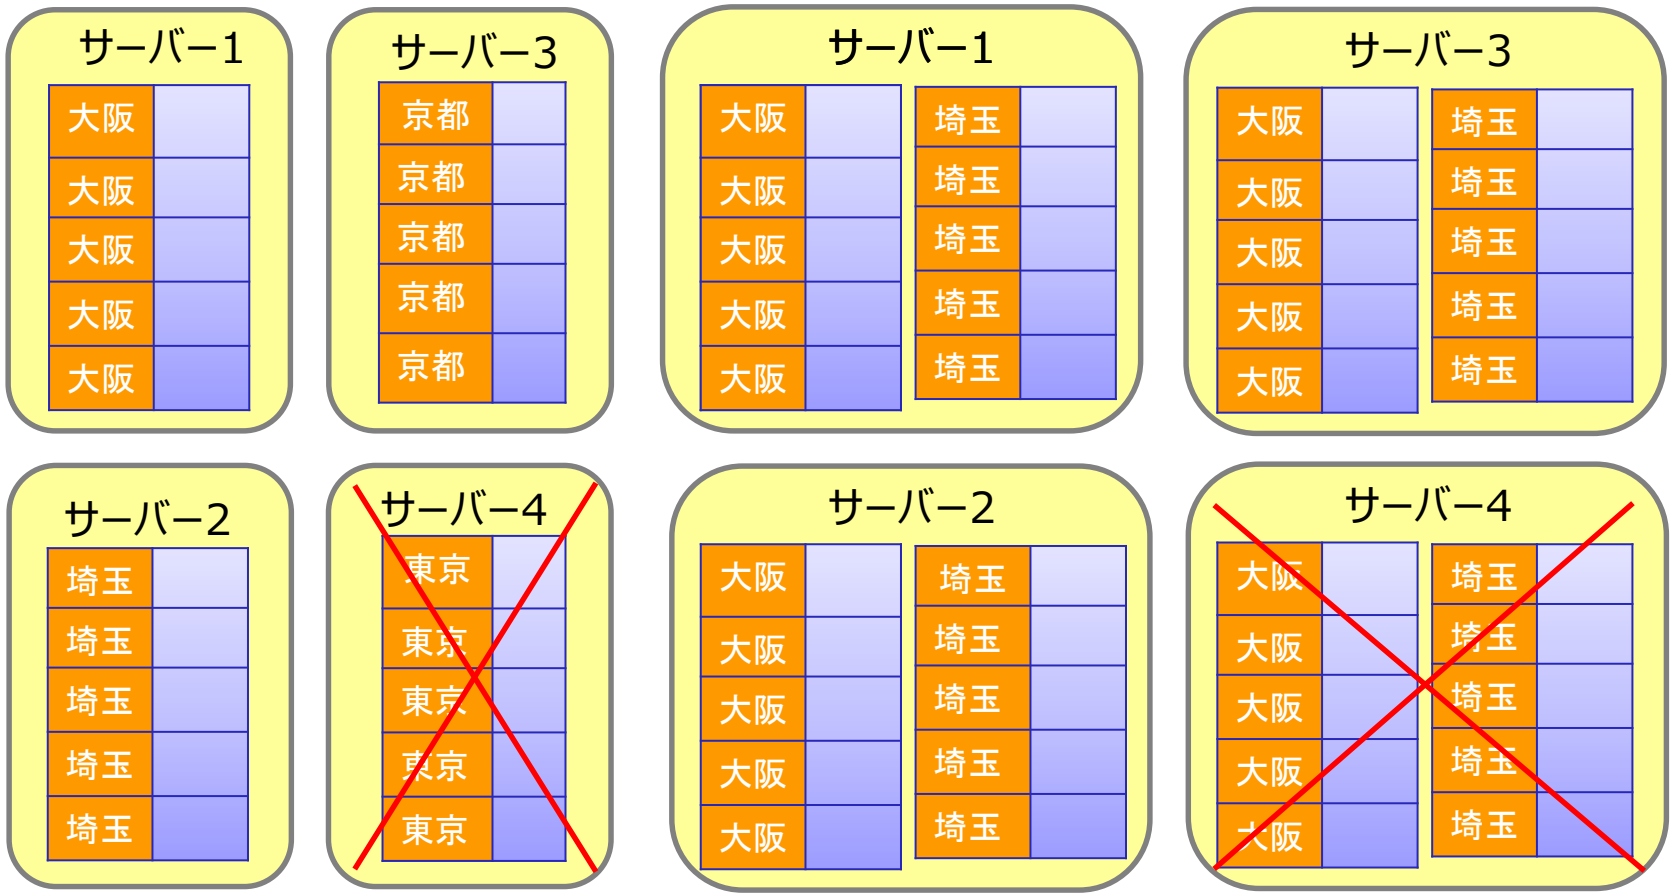

列指向型の特徴

キー・バリュー型を機能強化したもので、各行のキーが複数の列(カラム)の値を持つことが可能です。

列単位でデータの保存や読み込み処理を行うことができ、列の集計処理などを高速に実行することができます。

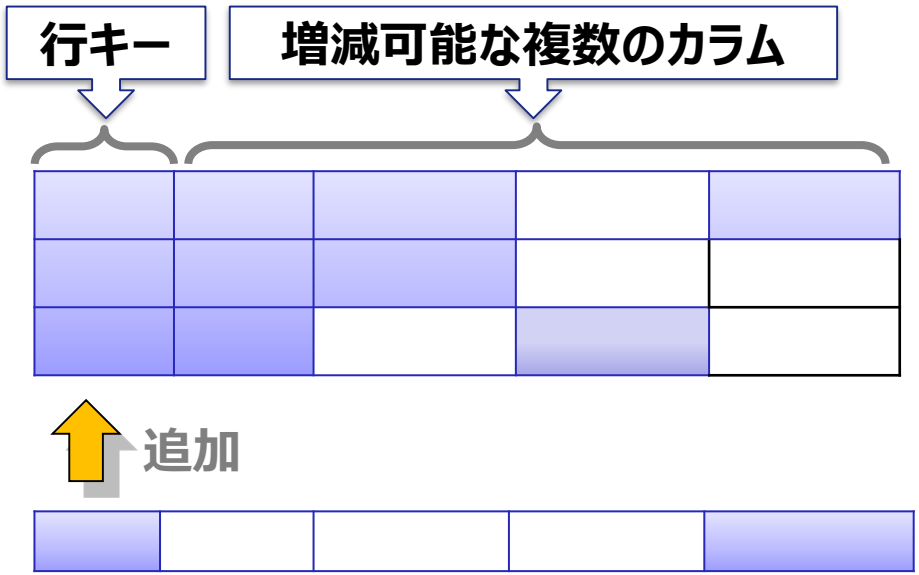

一部の列のデータが欠けている行があっても問題ありません。また、行や列の数は自由に好きなだけ拡張可能です。

Bigtable、Cassandra、Hbase、Hypertableが採用

※カラムナデータベースとは別物です。

列指向型の特徴

Twitterの例

行キー：ユーザーネーム
カラムの名前：ユーザーID
カラムファミリー ＝ カラムをまとめる入れ物

ユーザーネーム・カラムファミリー

行キー	カラム
ユーザーネーム	ユーザーID
Tanaka	A1234

ユーザータイムライン・カラムファミリー

行キー	カラム1	カラム2	カラム3	カラム4	カラム5
ユーザーID	a1234	a1235	a1236	a1237	a1238
A1234	t1234	t1238	t1276	t1287	t1299

横に増える

ユーザー・カラムファミリー

行キー	カラム1	カラム2
ユーザーID	ユーザーネーム	パスワード
A1234	Tanaka	sder5k

ツイート・カラムファミリー

行キー	カラム1	カラム2	カラム3	カラム4	カラム5
ツイートID	ユーザーID	ユーザーネーム	ボディ	タイムスタンプ	
t1234	A1234	Tanaka	やぁ	a1234	

縦に増える

ドキュメント型の特徴

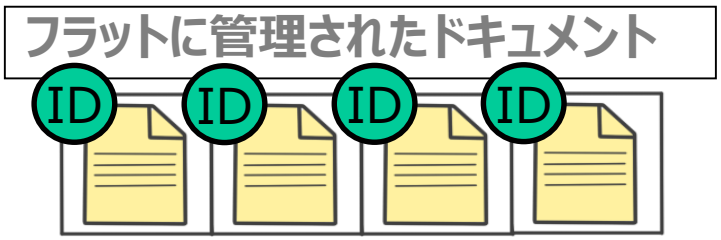

ドキュメントの例 (JSON)

```
{
“title” : “今日のランチ”
“userName” : “Morimoto”
“postedDateTime” :
“2014/10/10 13:00”
“content” : “カレー”
“count” :2
 }
```

ドキュメント指向型

JSONやXMLなどのデータ記述書式のドキュメントを格納します。

階層構造は持たないフラットなドキュメントの形式でデータを管理します。各ドキュメントには管理のためのユニークIDが割り振られます。

スキーマレスです。(データ設計が不要です。)

ドキュメントの内部構造はDB、アプリケーションからわかり、任意の内容でクエリを作成できます。

MongoDB、CouchDBで採用されています。

グラフ型の特徴

グラフ型

- キーバリュー型格納の例

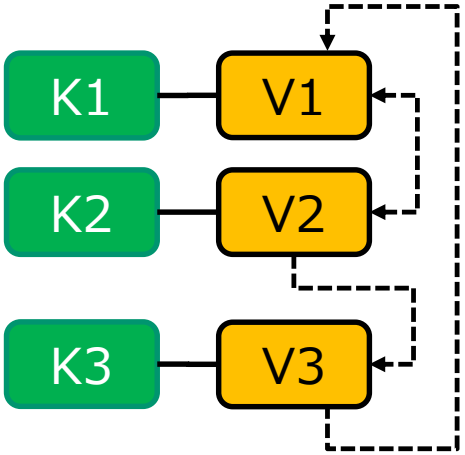

グラフ型格納の例

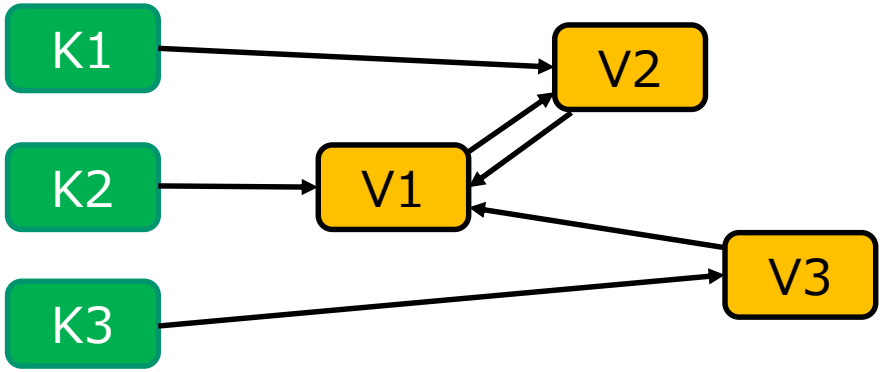

データ同士の入り組んだ関係を独立して表現します。
グラフ型は以下の要素により構成されます。

ノード (node) … 他のノードと関係をもつ要素を表す。
リレーションシップ（RelationShip） … ノード間における関係の有無と方向を矢印で示す。
プロパティ（Property） … ノードとリレーションシップの具体的な属性を示す。

代表的なNoSQL製品

代表的なNoSQL製品

NoSQL製品はさまざまなものが多数存在します。

NoSQL分類	製品	ベンダー
キー・バリュー型	Amazon DynamoDB	Amazon
	Hibari	クラウディアン
	Riak	Basho Technologies
	memchached	(オープンソース)
列指向型	HBase	(オープンソース)
	Apache Cassandra	(オープンソース)
	Bigtable	Google
ドキュメント型	Apache CouchDB	(オープンソース)
	MongoDB	(オープンソース)
グラフ型	InfiniteGraph	Objectivity, Inc.
	Neo4j	オープンソース　/ 商用ライセンス(Neo Technology)

NoSQLの基本的概念と技術

NoSQLのデータベースアーキテクチャ
サーバの配置方法には、マスタ型やP2P型の2つがあります。

マスタ型

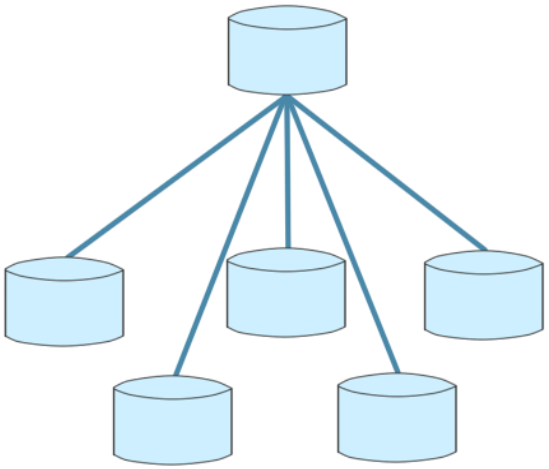

マスターノードはノード管理を役割を持ちます。
単一障害点(SPOF)が存在します。
※マスターノードがSPOFです

例 BigTable、CouchDB、
Hbase、Hibari、MongoDB

ピア・ツゥ・ピア(P2P)型

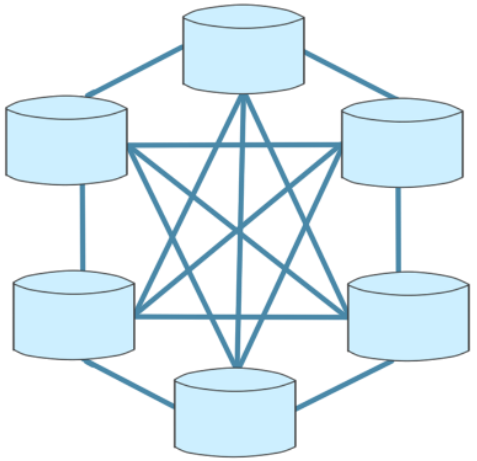

単一障害点はありません

例 Cassandra、Dynamo
Riak、Voldemart

NoSQL時代の必要要件

必要要件

NoSQLに求められることは様々であり、全てをみたすデータベースは存在しません。

- 膨大なデータ　：複数のサーバを必要とするデータ量を扱う
- 分散配置　：データを複数のサーバに分けて保存する
- コスト　：性能は求めず、安価なハードウェアを多数用意する
- 信頼性　：データの欠損や漏洩を防ぐ
- 可用性　：稼働率を高く維持する
- 耐障害性　：障害による影響を最小限にとどめる
- 性能　：処理や応答をできる限り早く行う

NoSQLの基本的概念と技術（整合性）

データの整合性（Consistency）とは
　作業の実行後に複製(レプリケーション)されたデータ間に矛盾がないことを示します。
整合性には、「強い整合性」と「緩い整合性」があります。

強い整合性

必ず最新の更新データが出力されることを保証します。特に、RDBでは重要視され、保持されます。

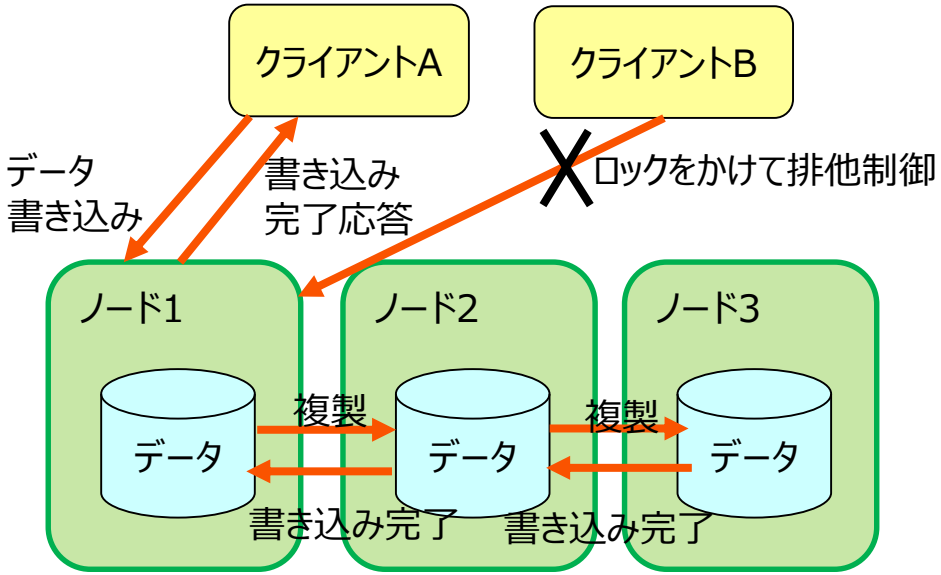

緩い整合性

更新から少し時間をおいた後であれば、全てのノードで最新のデータが読み出せればよいとする考え方です。

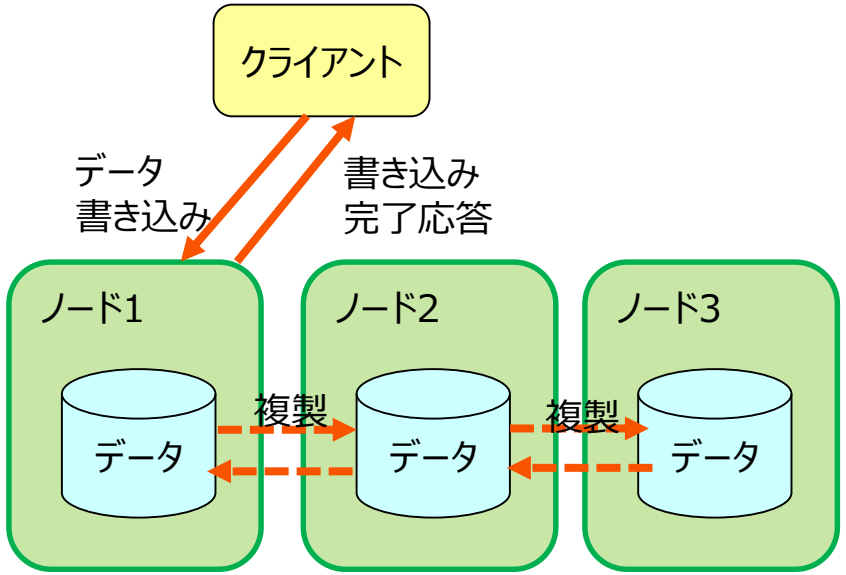

書き込み完了確認がない状態でクライアントに完了通知を行う

NoSQLの基本的概念と技術（整合性）

データベースの特性でも重要な以下の3つの要件を考えます。

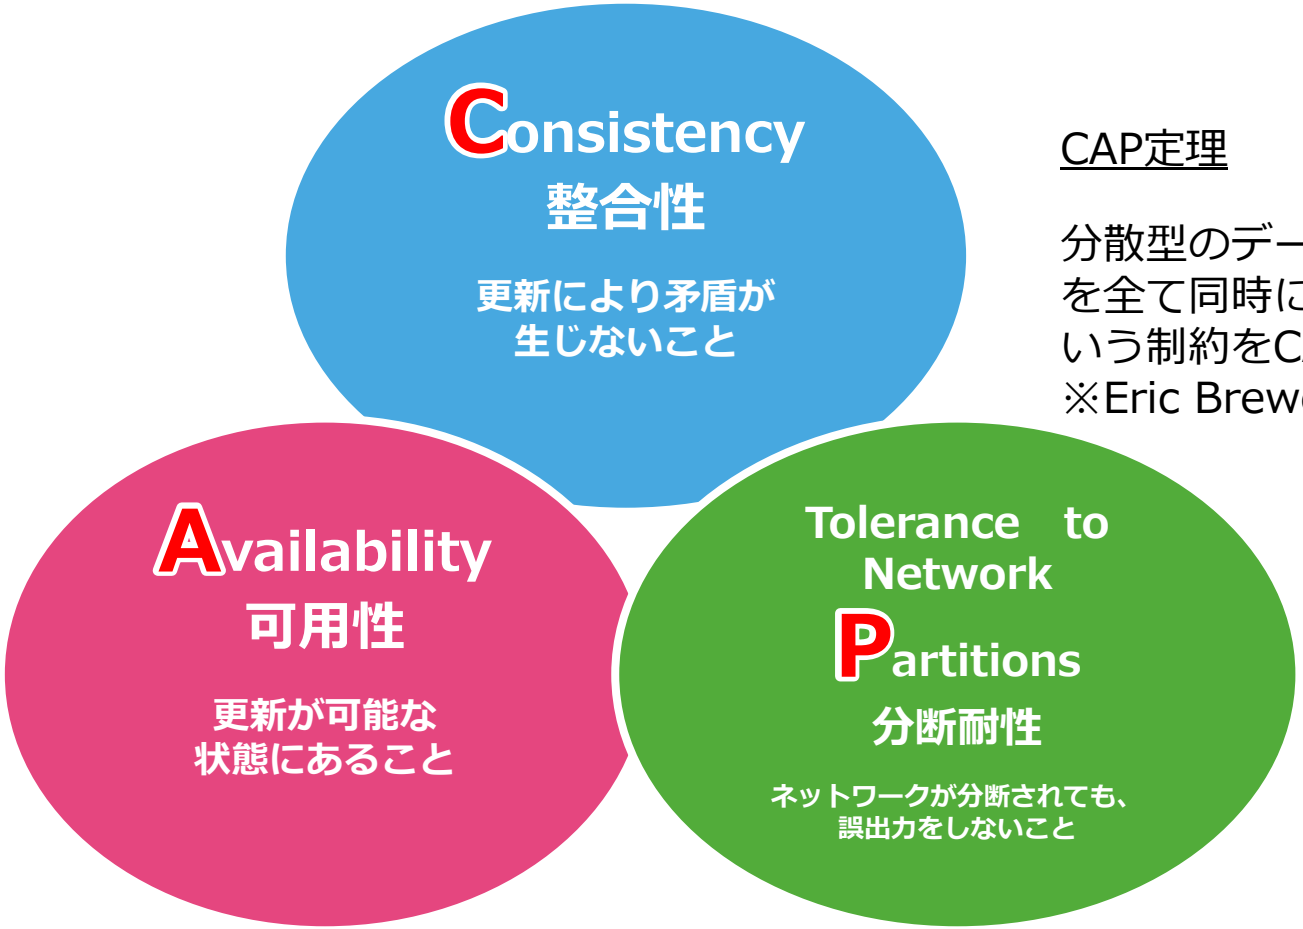

CAP定理

分散型のデータベースでは、3つの要件を全て同時に満たすことはできない、という制約をCAP定理と呼びます。
※Eric Brewer氏により提唱されました。

NoSQLの基本的概念と技術（整合性）

NoSQLではCPかAPのいずれかが保証されることが基本です。

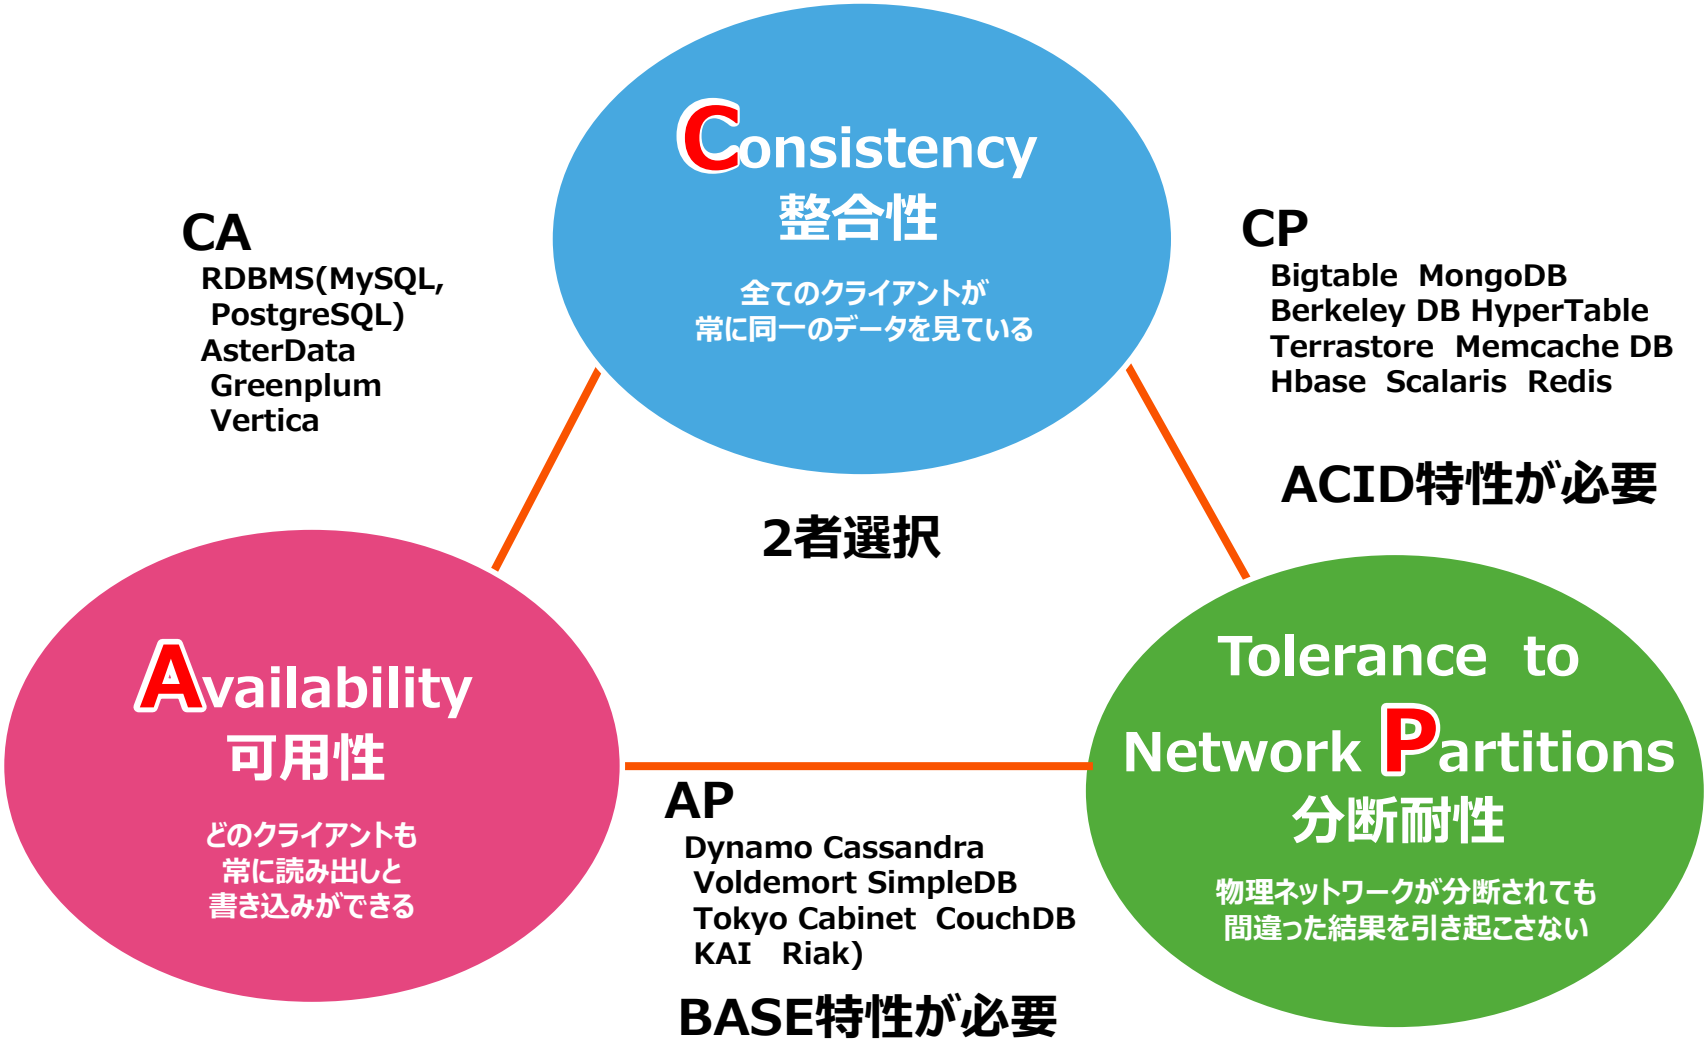

NoSQLの基本的概念と技術（整合性）

ACIDとBASE

・ACID(Atomicity、Consistentry、Isolation、Durability)

トランザクションは、全ての処理完了または処理以前の状態への復元のいずれかを行う仕組み。

Atomicity 原子性	：手順が全て実行されるか、一つも実行されないか
Consistency 一貫性	：トランザクションの前後で整合性が保たれる
Isolation 独立性	：実行中に他の処理に影響を与えない
Durability 耐久性	：データが正しく記録され、損失の可能性がない

・BASE(Basically Available、Soft-state、Eventual Consistency)

アプリは基本的に常に動作し（Basically Available）、強い整合性は持っていないが（Soft-state）、最終的に整合性をもつ（Eventual Consistency）という特性を備えているべきであると言う考え方。

NoSQLの基本的概念と技術（整合性）

ネットワーク障害時のCPとAPの対応

CP（整合性と分断耐性）

リクエストは片方のグループだけが受け付け、他のグループは自動的に停止します。データを受け付けないグループは更新が起きないため、整合性が乱れる心配はありません。

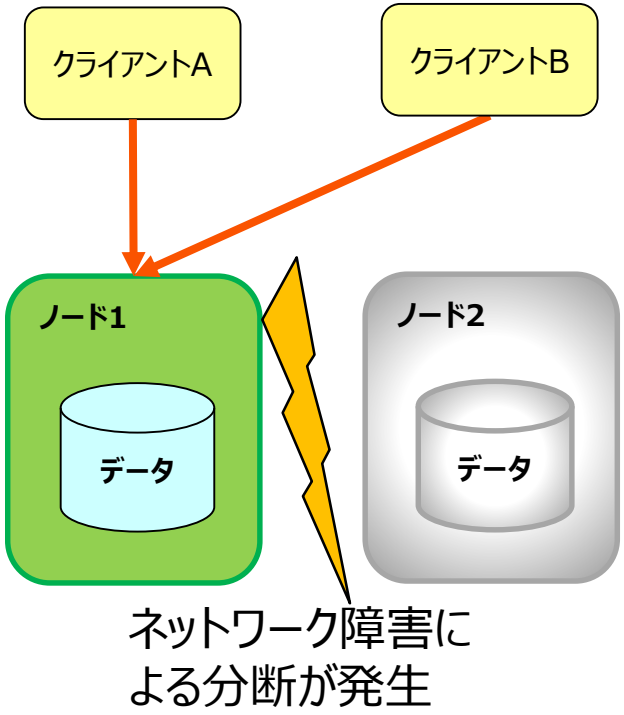

AP（可用性と分断耐性）

全てのノードで更新を行えるようにするため、リクエストは全てのグループが受け付けます。情報の共有ができないノード間で不整合が発生します。

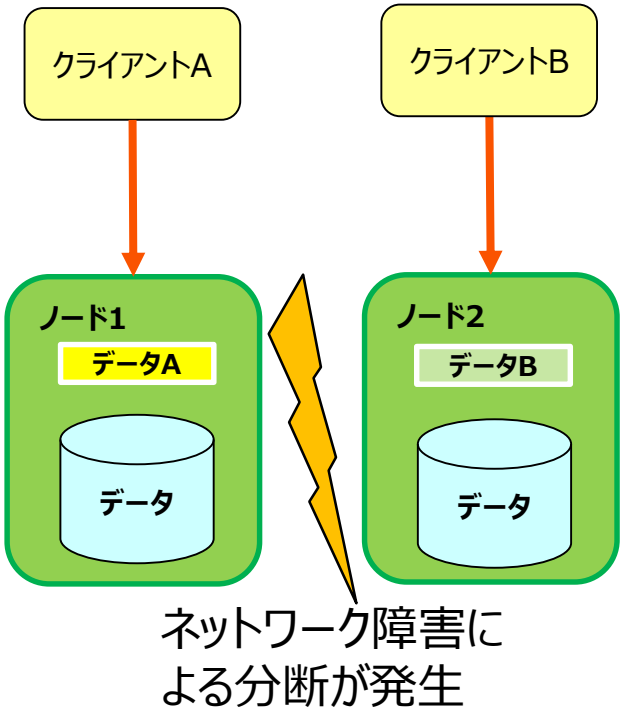

NoSQLの基本的概念と技術（整合性）

整合性と性能のトレードオフ

R(ノードから読み込む数)とW(ノードに書き込む数)の和がN(レプリカの数)より大きければ、整合性が保証することができます。

複数の書き込みと読み出しを行う事は、応答速度とのトレードオフになります。

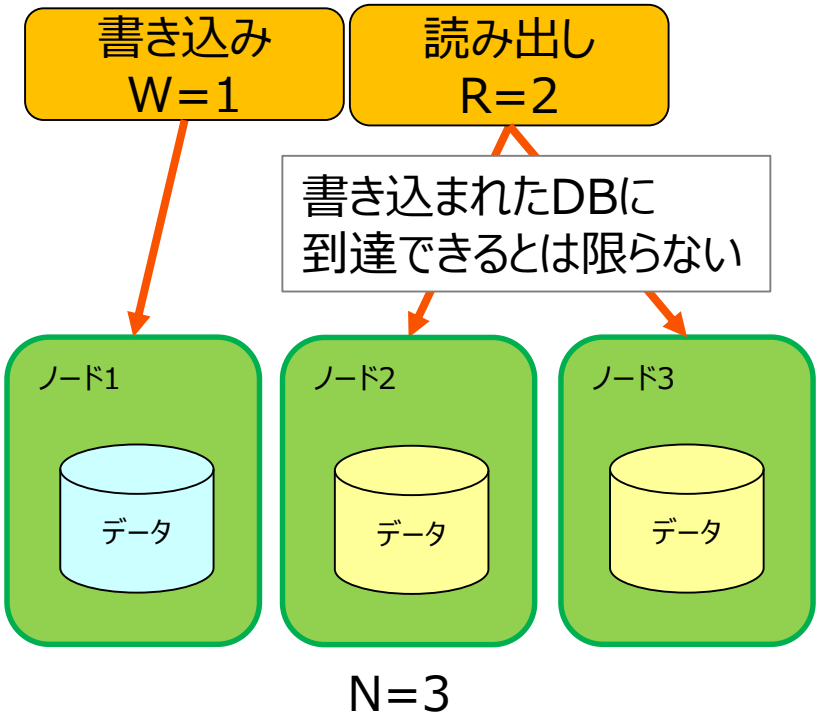

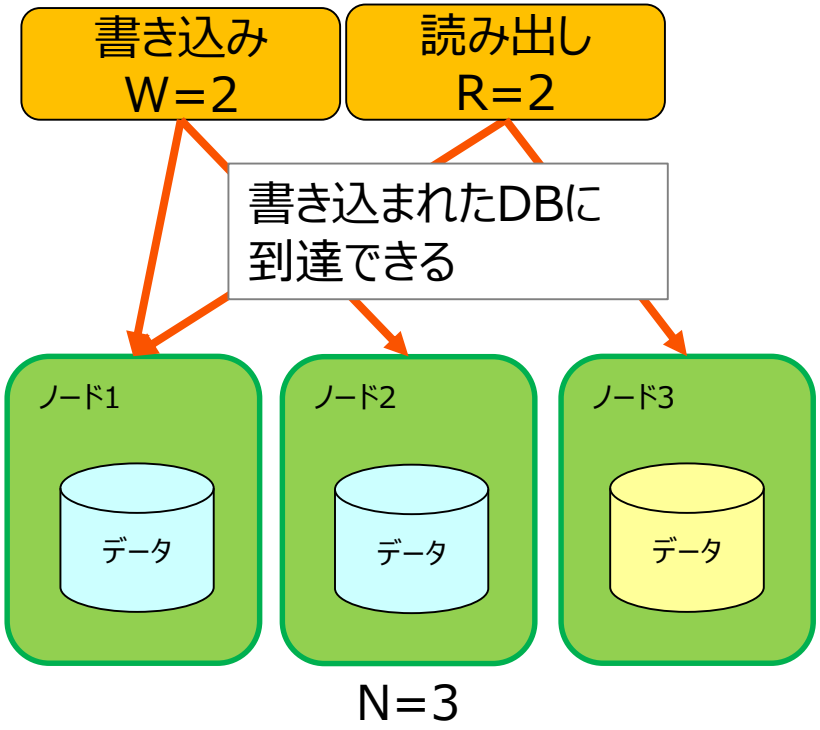

NoSQLの基本的概念と技術（整合性）

データのバージョン管理

- タイムスタンプ(TimeStamp)
  データの更新時間を記録する。
  新しいタイムスタンプを持つものを重要視することでバージョンを管理する。
- ベクタークロック(Vector Cloks)
  複数のバージョン間の仲裁をする仕組み。
  変更が行われたノードと、そのノードで変更が行われた回数を記録する。

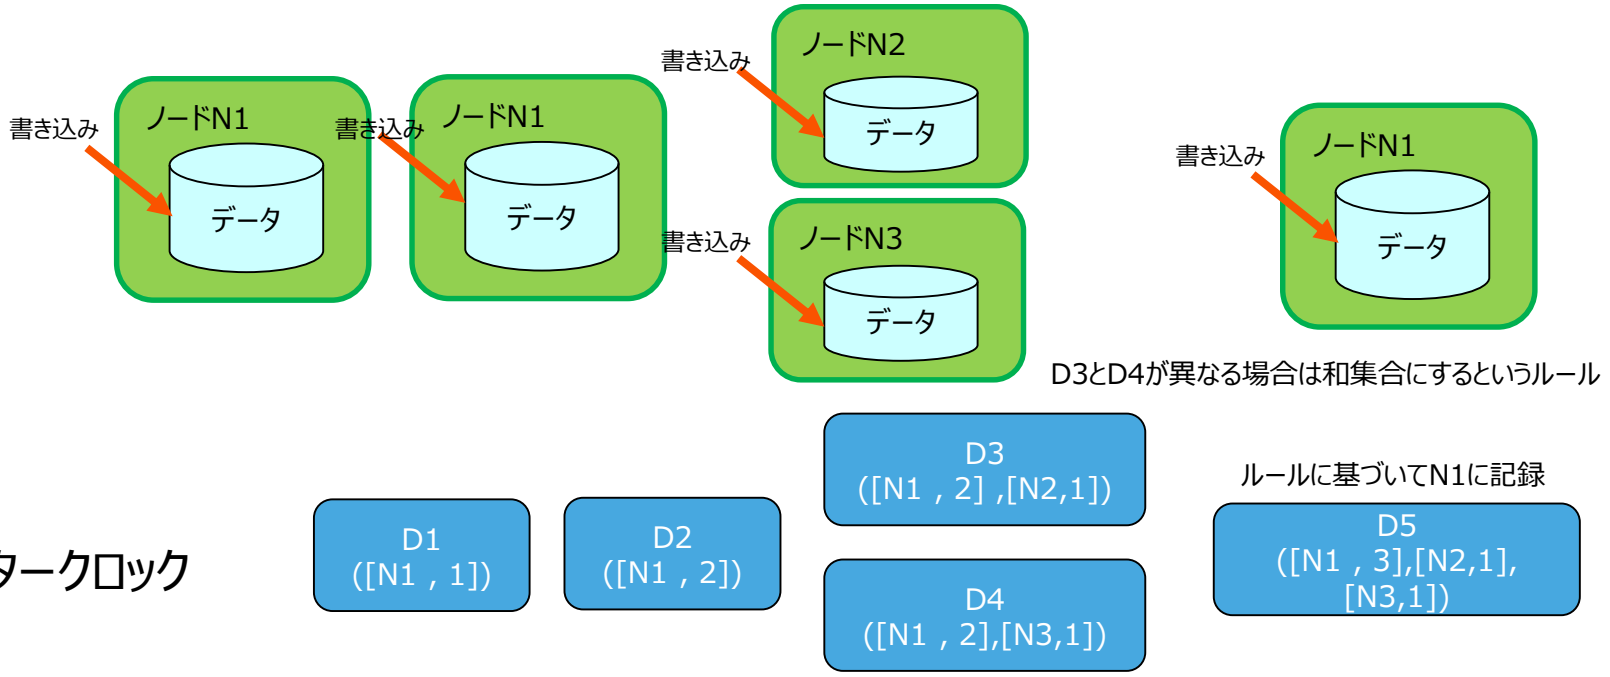

NoSQLの基本的概念と技術（データ分割）

整合性を後から修復する仕組み

・リードリペア（Read Repair）
全てのノードで複製データの読み出し要求を行い、データに矛盾がないかを確認する。発見された矛盾はバックグラウンド処理で修復する。

・ヒンテッド・ハンドオフ（Hinted Handoff）
故障が発生した場合、他の稼働中のノードに、故障の復旧後の更新手続きを指示する仕組み。

・マークル・ツリー（Markle Tree）
Markle Treeという樹形図構造のアルゴリズムによりデータの整合性を確認し、整合性に問題がある場合は手動での修復を行うもの。

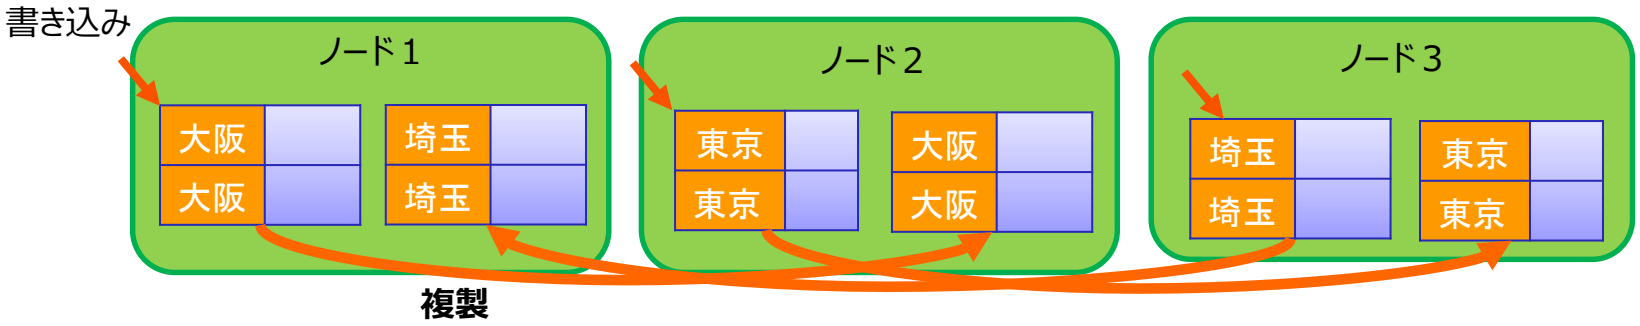

NoSQLの基本的概念と技術（データ分割）

シャーディング（Sharding）

あらかじめ、サーバ毎に保存するデータのキーの範囲を設定しておくことで、検索や管理を容易にする機能です。

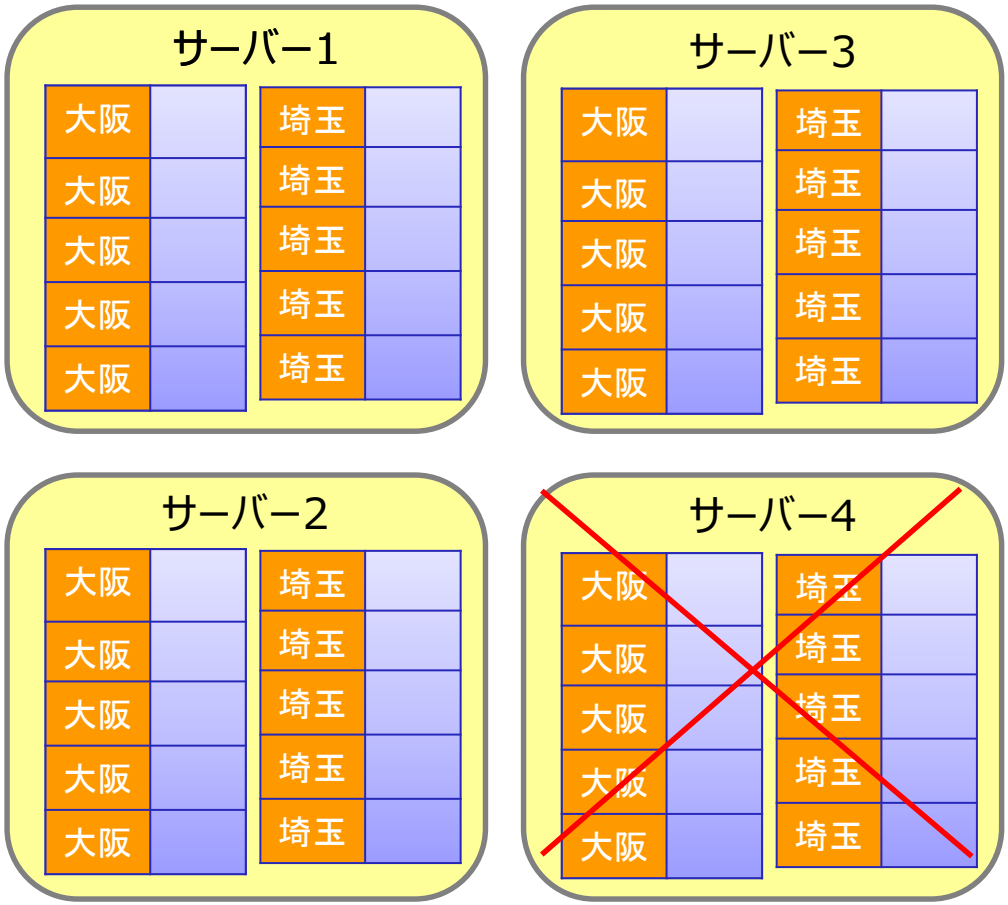

他、アルファベットA～G、H～N、O～Z
ID 1 ～1000、1001～2000…など

データの偏りがあった場合、適切な負荷分散ができません。なので、データ単位を小さくし、ノード数より多くすることなどにより、データの偏りを減らす工夫が必要です。

BigtableやHbaseは再分割、再配置を自動的に行います。

NoSQLの基本的概念と技術（データ分割）

Bigtableのデータ割り当て

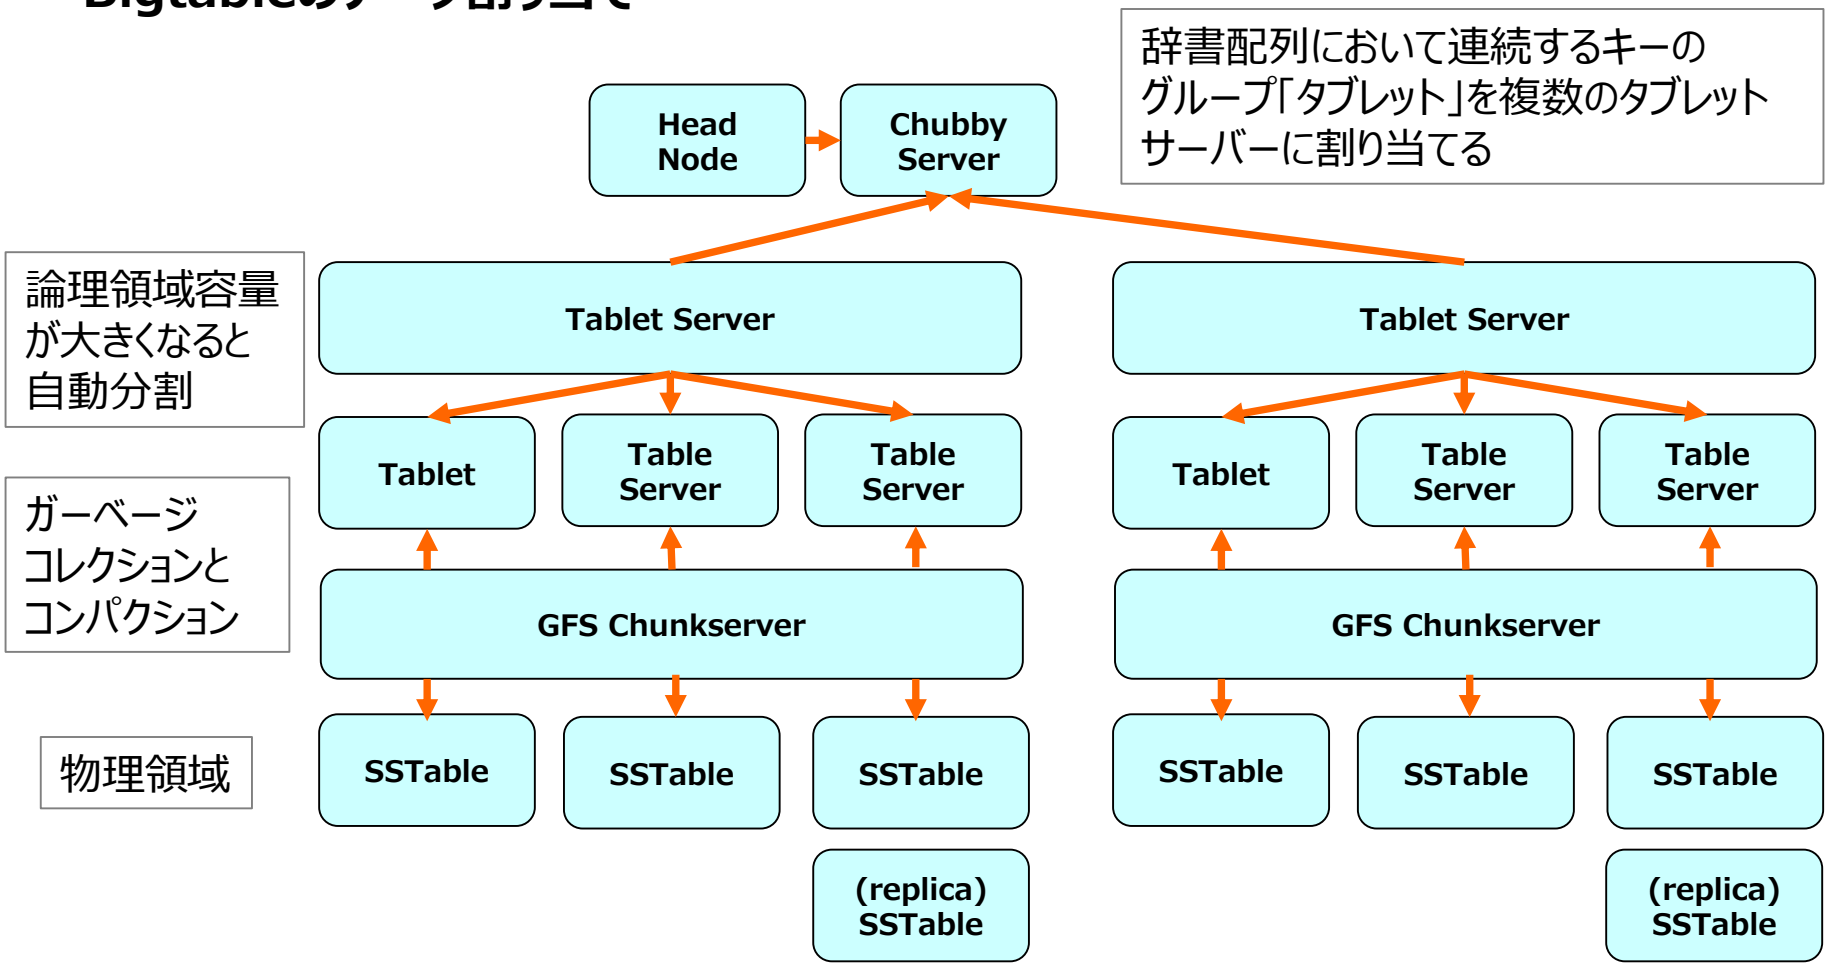

NoSQLの基本的概念と技術（データ分割）

コンシステントハッシング Consistent Hashing

分散型システムを構成するノードを、論理的に輪を形作るよう配置します。データのキーのハッシュ値をハッシュ関数によって求め、不規則な値であるハッシュ値を元に、データを保存するノードを選択します。ノードの位置を変更することで、負荷の代償を変更することも可能です。

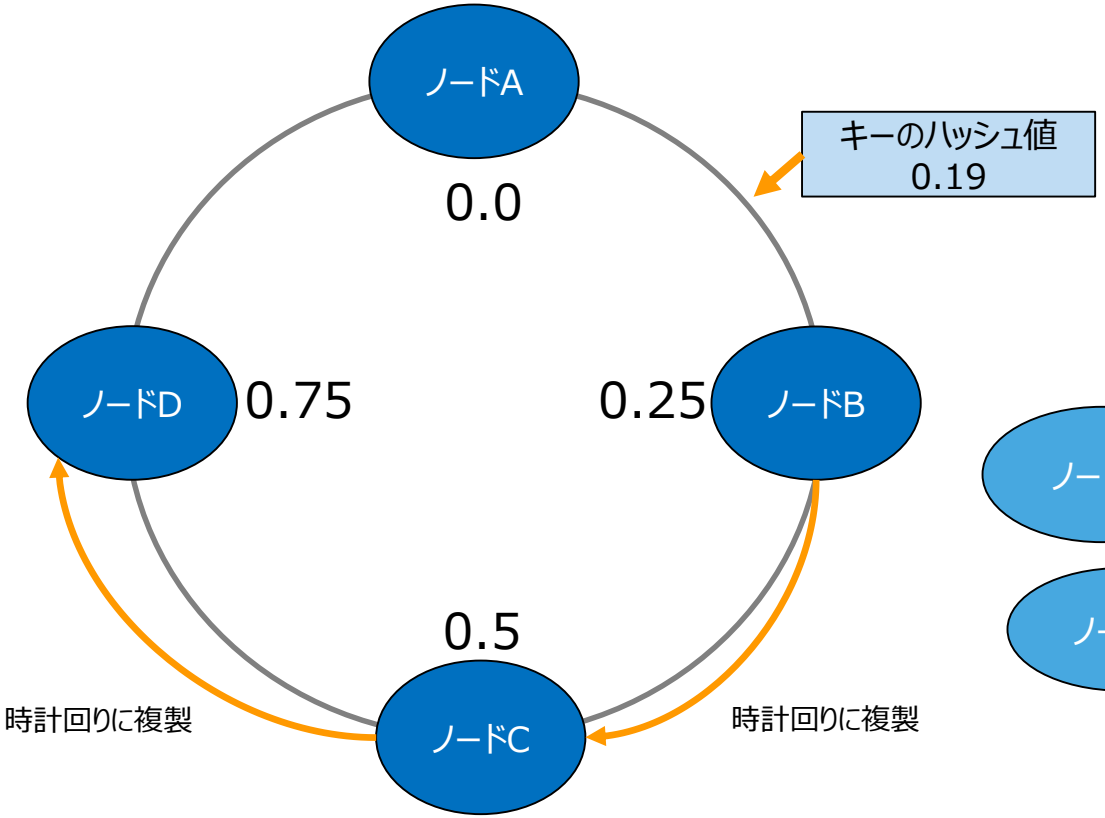

例えば、0.0から1.0の間のハッシュ値の場合、一番近い時計回りのノードに割り当てられるようなルールを定めます。

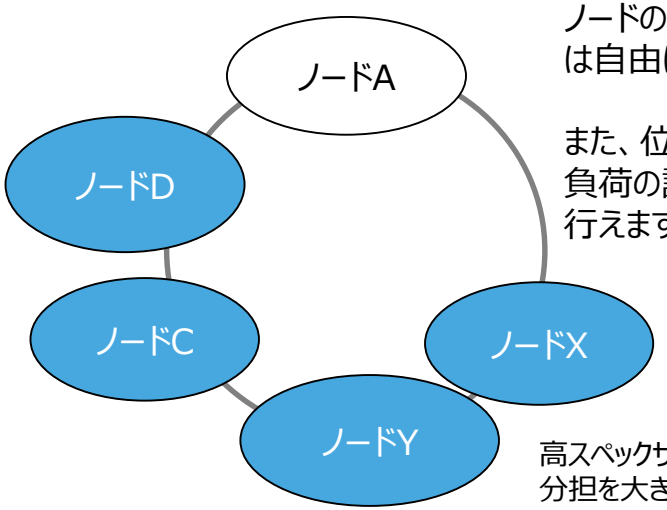

ノードの追加・削除は自由に行えます。

また、位置をずらして負荷の調整も行えます。

高スペックサーバーは分担を大きく

NoSQLの基本的概念と技術

ストレージレイアウトの技術

・LSM-Tree（Log Structured Merge Tree）
メモリを使って応答性能を高めつつ、ハードディスクにデータを格納することでデータの安全性を保つ機能。

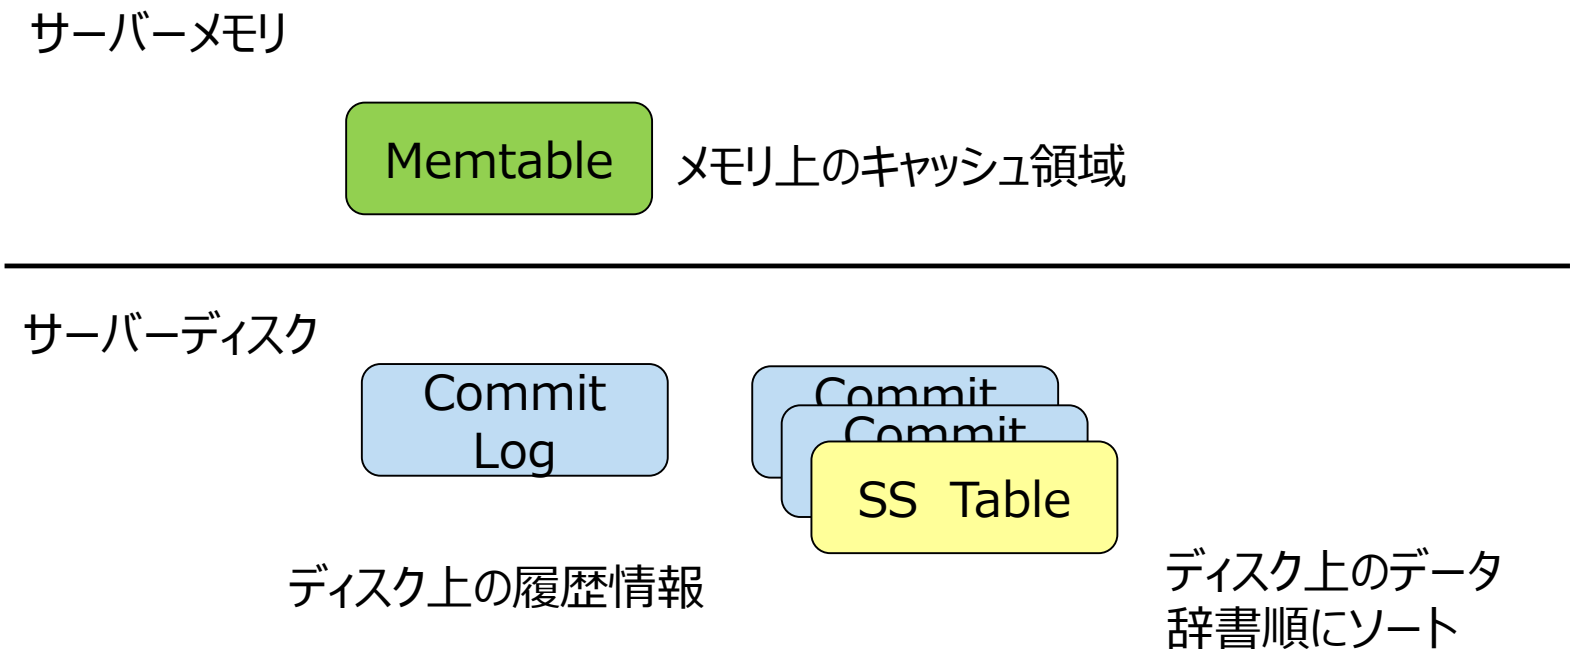

NoSQLの基本的概念と技術

ストレージレイアウトの技術

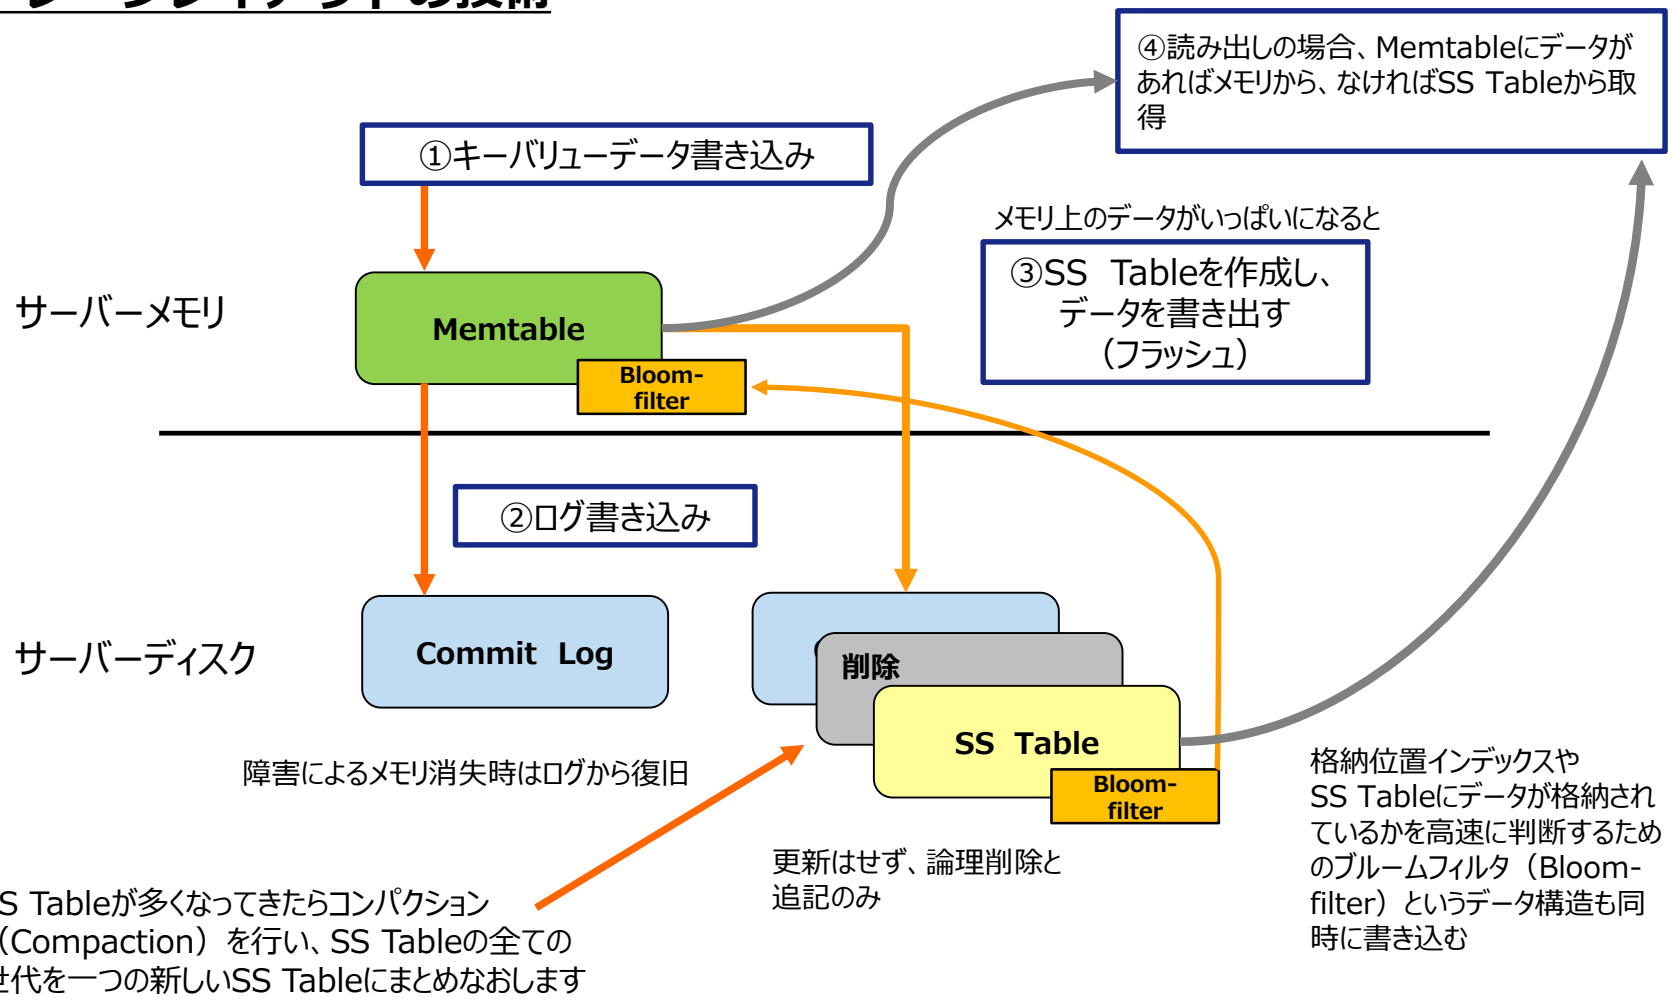

第４章

ビッグデータコア技術

分散処理

分散処理とは

分散処理とは

ビッグデータを分割し、複数のサーバで同時に並行して処理した後、処理結果を統合することで全体の処理結果を生成する処理方法です。

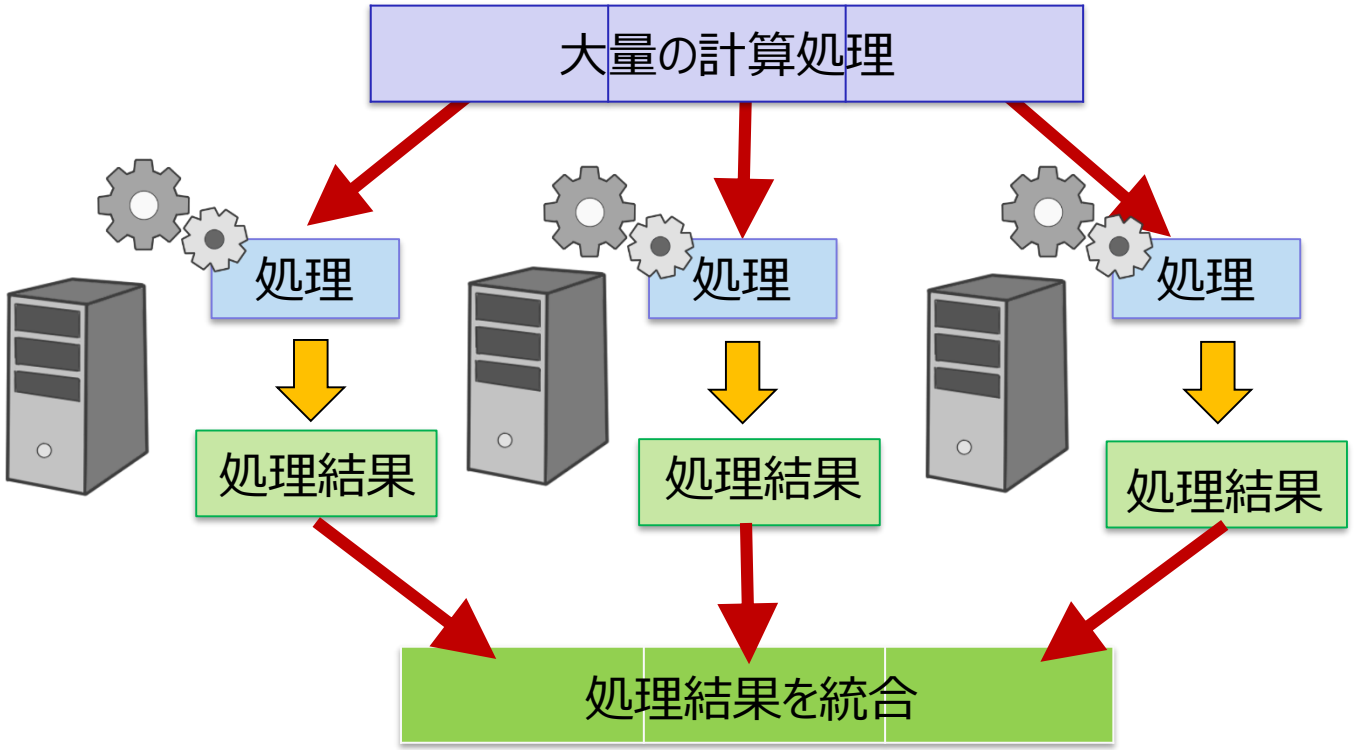

分散処理とは

分散処理による処理時間の短縮

サーバでは、分割されたデータを処理するので、CPUでの処理時間や、ディスクからの読み込み、ディスクへの書き込みの時間が短縮されます。

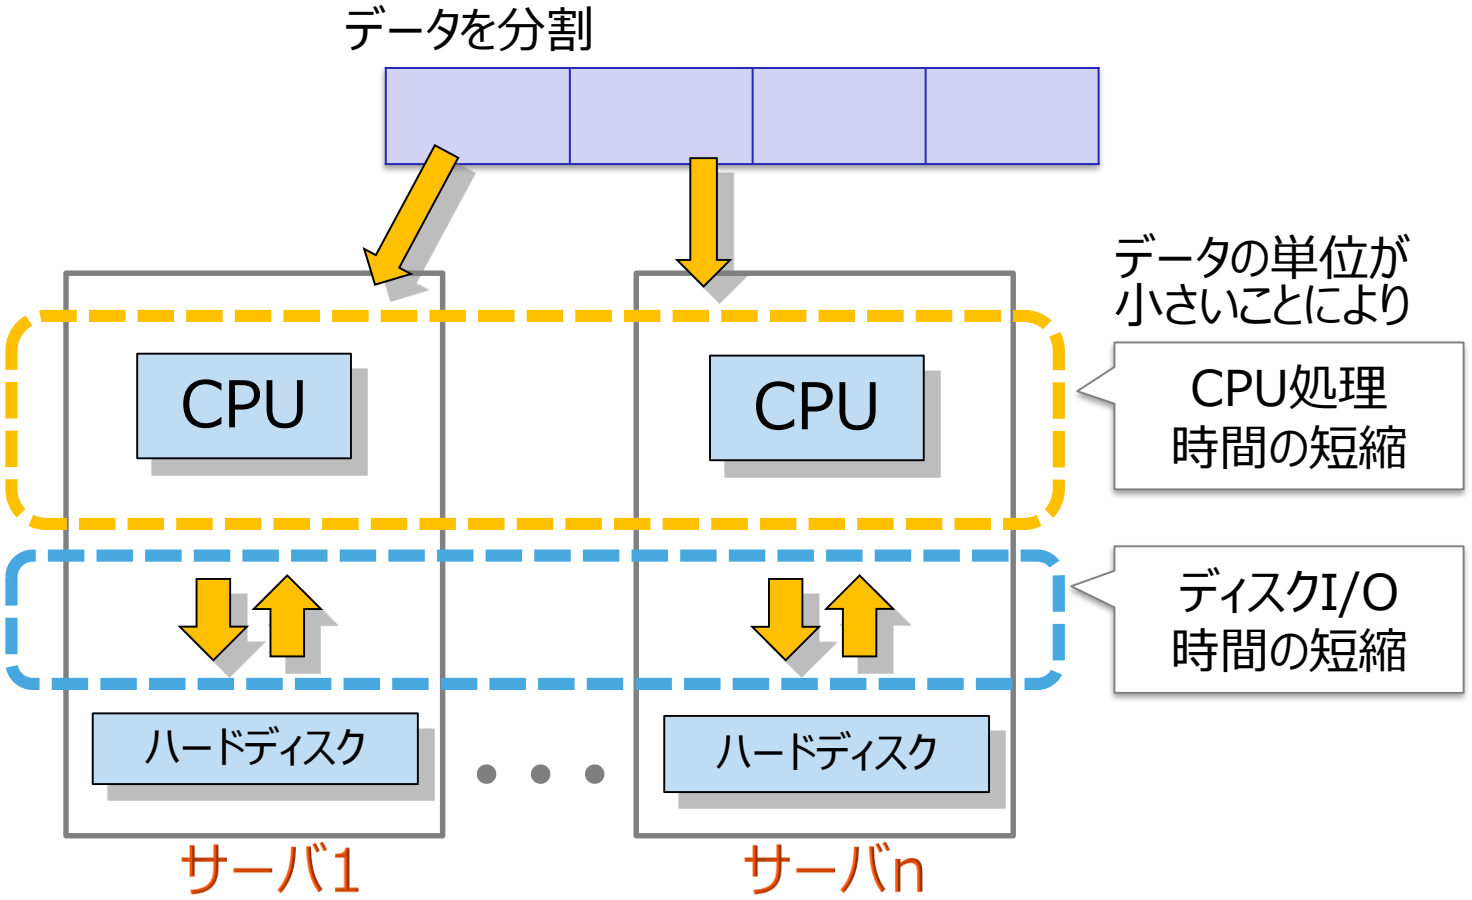

分散処理のメリット・デメリット

分散処理のメリット

ビッグデータの処理時間を短縮することができます。
スケールアウトによる拡張が可能で、比較的低コストになります。
一台の故障が全体の停止には直結しないので、稼働率が高いです。

分散処理のデメリット

データが複数コンピュータにまたがるので、厳密な整合性が必要なオンライントランザクション処理に向きません。
少量のデータ処理には効果が薄いです。
システム全体の性能は、ネットワークの帯域幅や稼働率から大きな影響を受けます。

Hadoopとは

Hadoop

Hadoopはデータベースではなく、複数のソフトウェアからなる分散処理フレームワークです。
一定期間のデータを一括処理する、バッチ向けのフレームワークです。

2つの主要プロダクト

・ファイルシステム(HDFS)：Hadoop Distributed File System
バッチ処理向けに高いスループットを分提供する分散ファイルシステム。

・分散処理アルゴリズム(MapReduce):Hadoop MapReduce
複数のサーバでの並列分散処理するプログラミングのためのソフトウェア。
HDFS上のファイルを読み込み、集計結果を別のHDFS上に書き込む。

Hadoopとは

Hadoopの特徴

オープンソースソフトウェアフレームワークで、非構造化であるビッグデータの解析や大量のバッチ処理に用いられます。 Googleによる開発の後、Apache Software Foundationが現在は開発、公開を行っています。

HadoopはLinuxで動作します。また、システムはJavaで構築されているため、JVMが必要です。

MapReduceフレームワークやHDFSを操作するためのJavaのAPI（クラスライブラリ）が提供されています。

専門スキルが導入に必要なため、商用のサポートサービスを提供している会社があります。 (クラウデラ、ホートンワークス、MapRなど)

Hadoopの基本構成

Hadoopの基本コンポーネントは、

・分散ファイルシステムのHDFS
・リソースマネージャーのYARN
・分散データ処理を行うMapReduce

です。その他のシステムは、Hadoopから独立して開発されたものです。

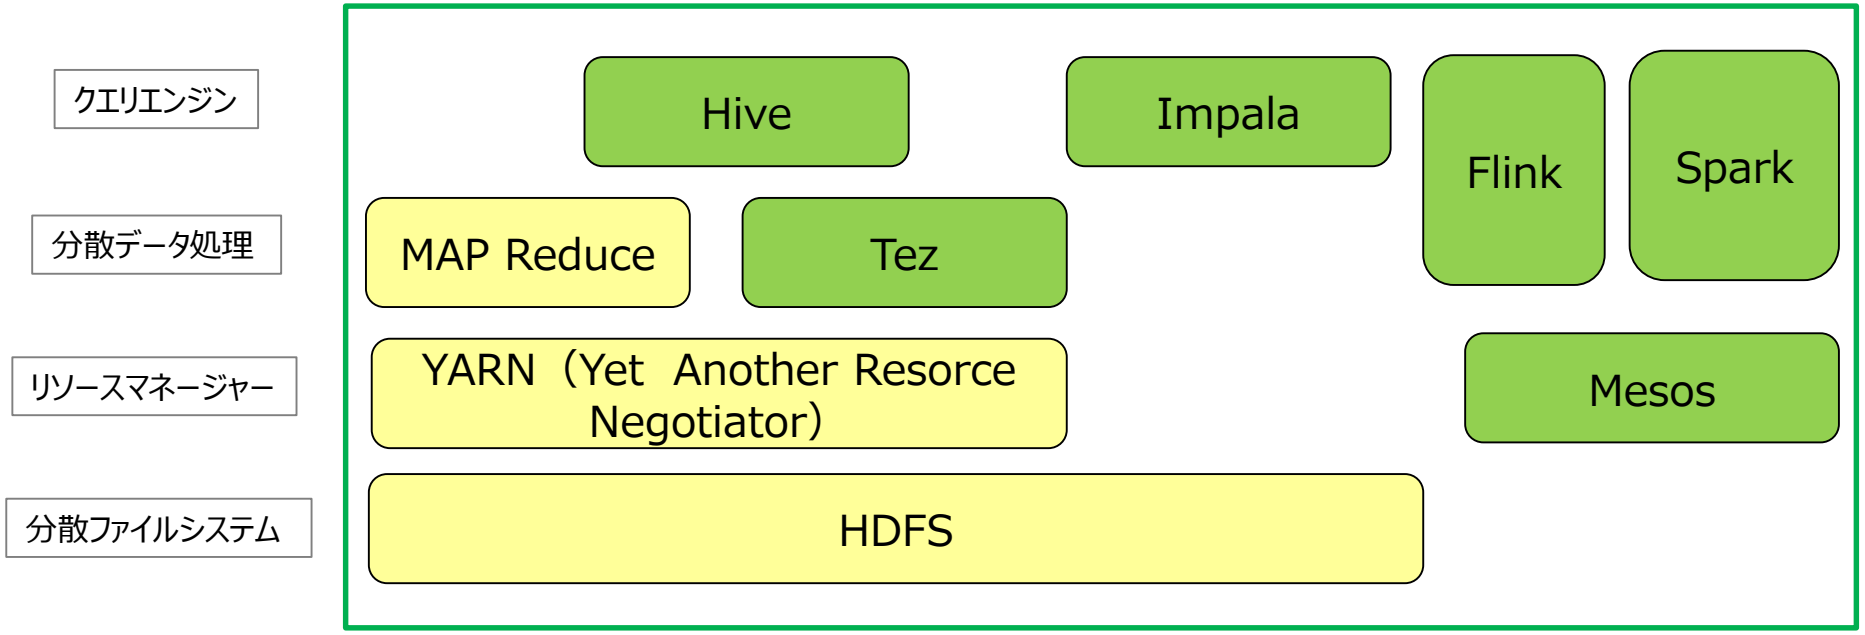

HDFS (Hadoop Distributed File System)

HDFS

HDFSはマスタ型で、データを管理するスレーブノード群と、スレーブノードを管理するマスターノードから構成されています。全体で、仮想的な一つのファイルシステムとなっています。

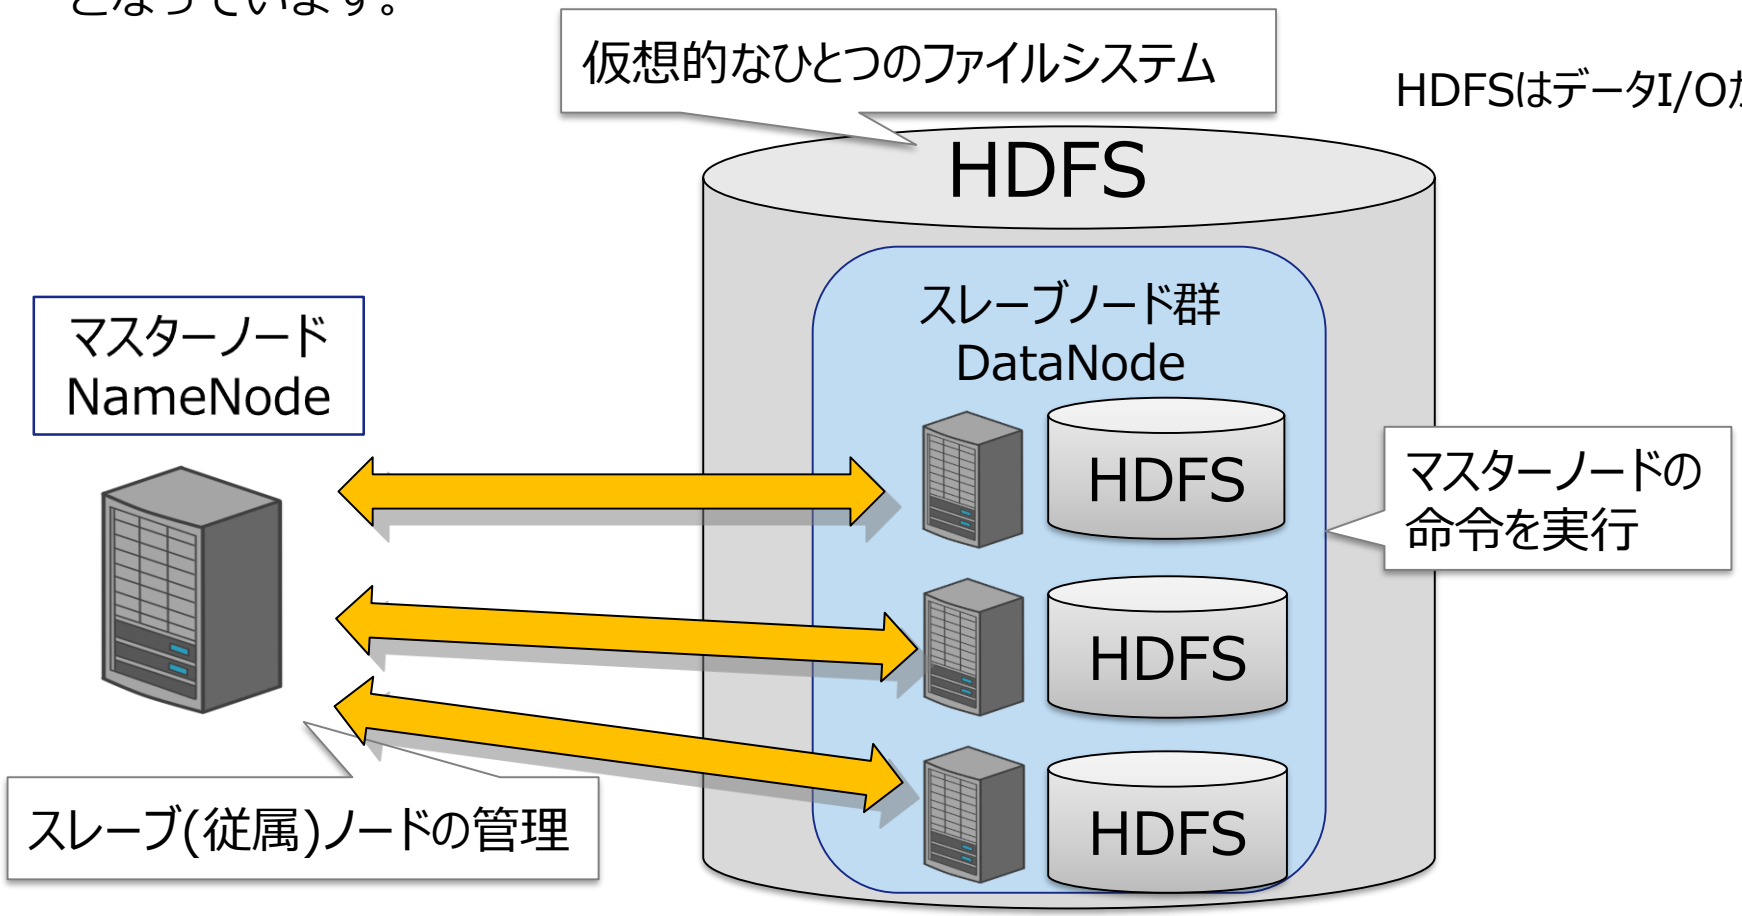

HDFSはマスタ型

マスタースレーブ型

NameNode、DataNodeに役割が分かれます。

NameNodeはメタ情報(他のノードのデータやブロックの対応関係など)を保持するマスターノードです。単一障害点となるため、バックアップノードを作成します。

DataNodeがデータ(ブロック)を保持します。障害対策として、同じデータを複製し、ノードを跨って保存されます。

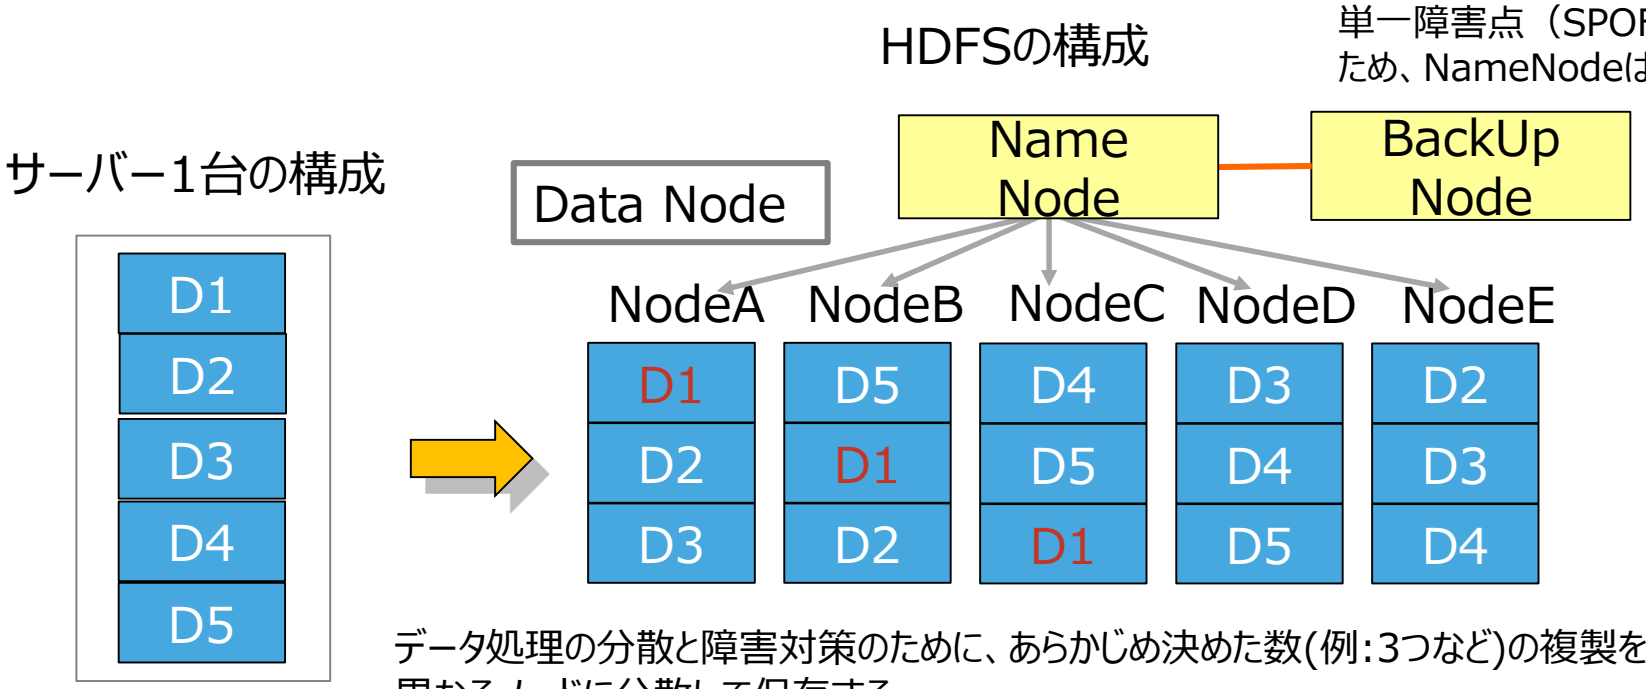

データ処理の分散と障害対策のために、あらかじめ決めた数(例:3つなど)の複製を作成し、異なるノードに分散して保存する。
大きなサイズのファイルは任意のブロックサイズに分割して格納。（デフォルト64MB）

HDFSの読み書き

HDFSへの書き込み・読み出し

データは、クライアント側で任意のサイズのブロックに分割され、NameNodeがどのDataNodeに格納するか指示し、書き込みを行います。
読み出しは、 NameNodeがクライアントに対して目的のデータが保存されているDataNodeを示し、直接ブロックを読み出します。

データの複製と耐障害性

データ処理の分散と障害対策のために、一定数複製を作成し、複数のノードにまたがってデータを保存します。障害時は、障害のあるノードをクラスタから切り離し、切り離されたノードにあった複製の分を、他のノードに複製します。

リバランシング

ノードの追加や削除された場合に、データの分散に偏りが生じないようにデータの再配置を行います。

MapReduce処理とは

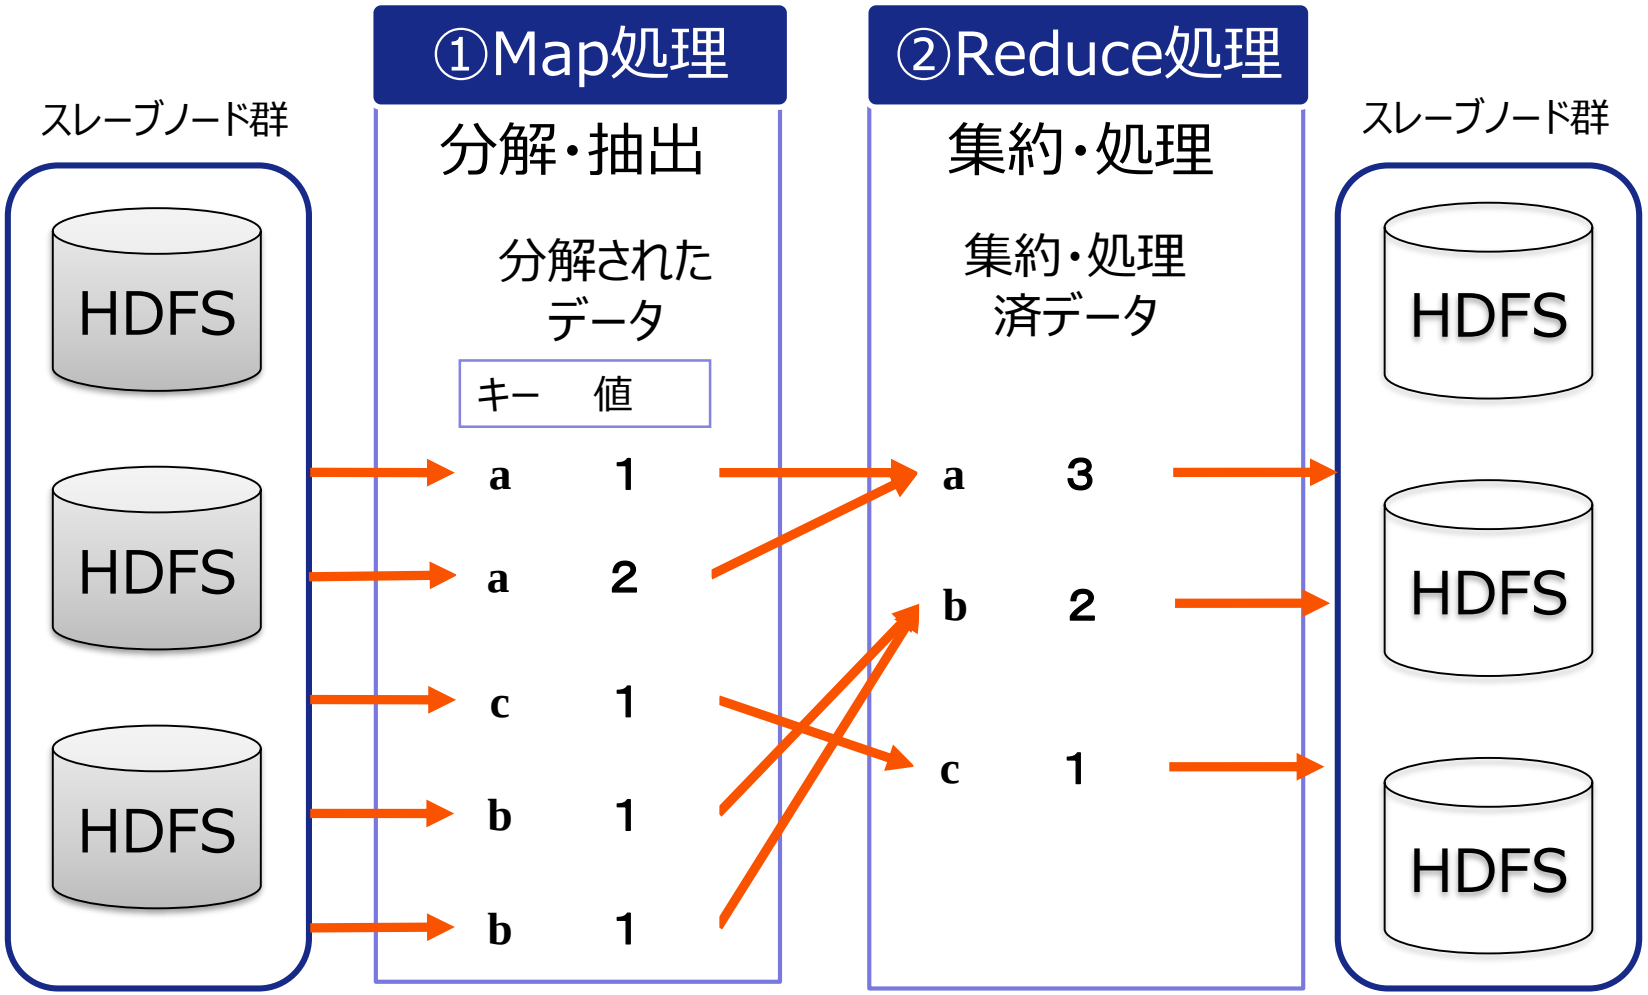

MapReduce処理とは

MapReduce

大量データを分割し、複数のサーバで並列処理するための方法です。複数のスレーブノードで同一の処理を実行します。次の2段階の処理に分かれます。

①Map処理

データを小さく分割し、必要な情報を選んで出力します。出力データはキーバリュー型の構造となります。

②Reduce処理

キーごとにデータを集約し加工を行なった上で、HDFSに出力します。

Map処理とReduce処理の開発には、Hadoopが提供するJavaのAPI(クラスライブラリ)を利用します。複雑な分散処理アルゴリズムや障害対応処理などの実装は不要で、開発者は業務ロジックの開発に集中できます。

MapReduceのアーキテクチャ

MapReduceのアーキテクチャ

MapReduceのマスターはJobTrackerと呼ばれ、全てのMapReduce処理工程の調整・管理とスレーブとなるTaskTrackerの維持管理を行います。

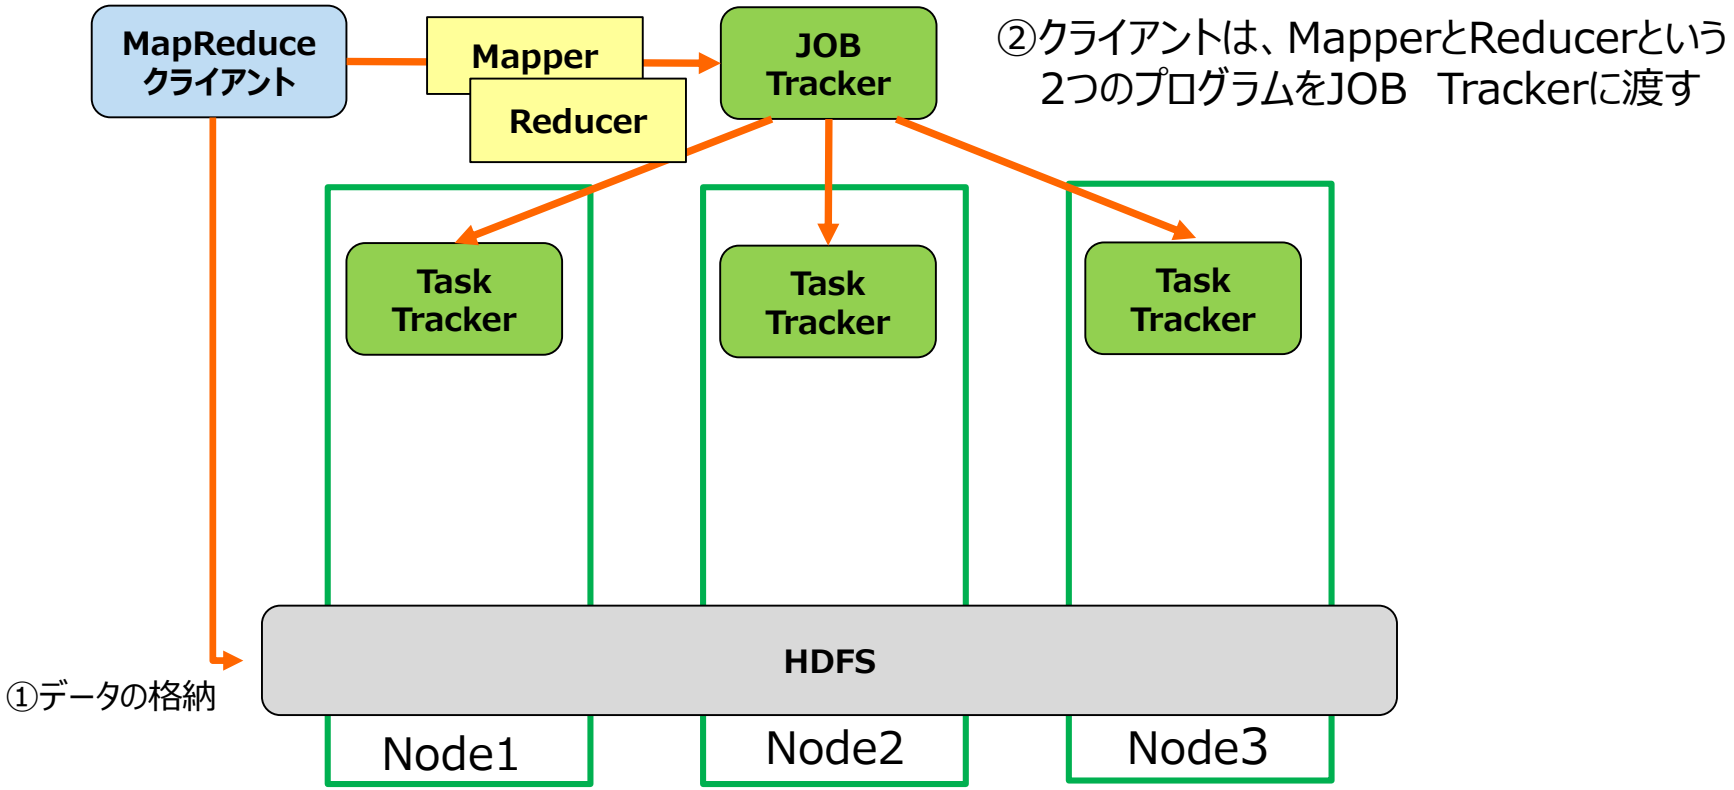

MapReduceのアーキテクチャ

MapReduceのアーキテクチャ

JobTrackerはMapperとReduceプログラムをTaskTrackerに配布し、HDFSブロックと同じ数だけMapタスクを生成します。 Mapタスクは、データが存在するTaskTrackerに割り当て、必要なデータ転送のみを行います。

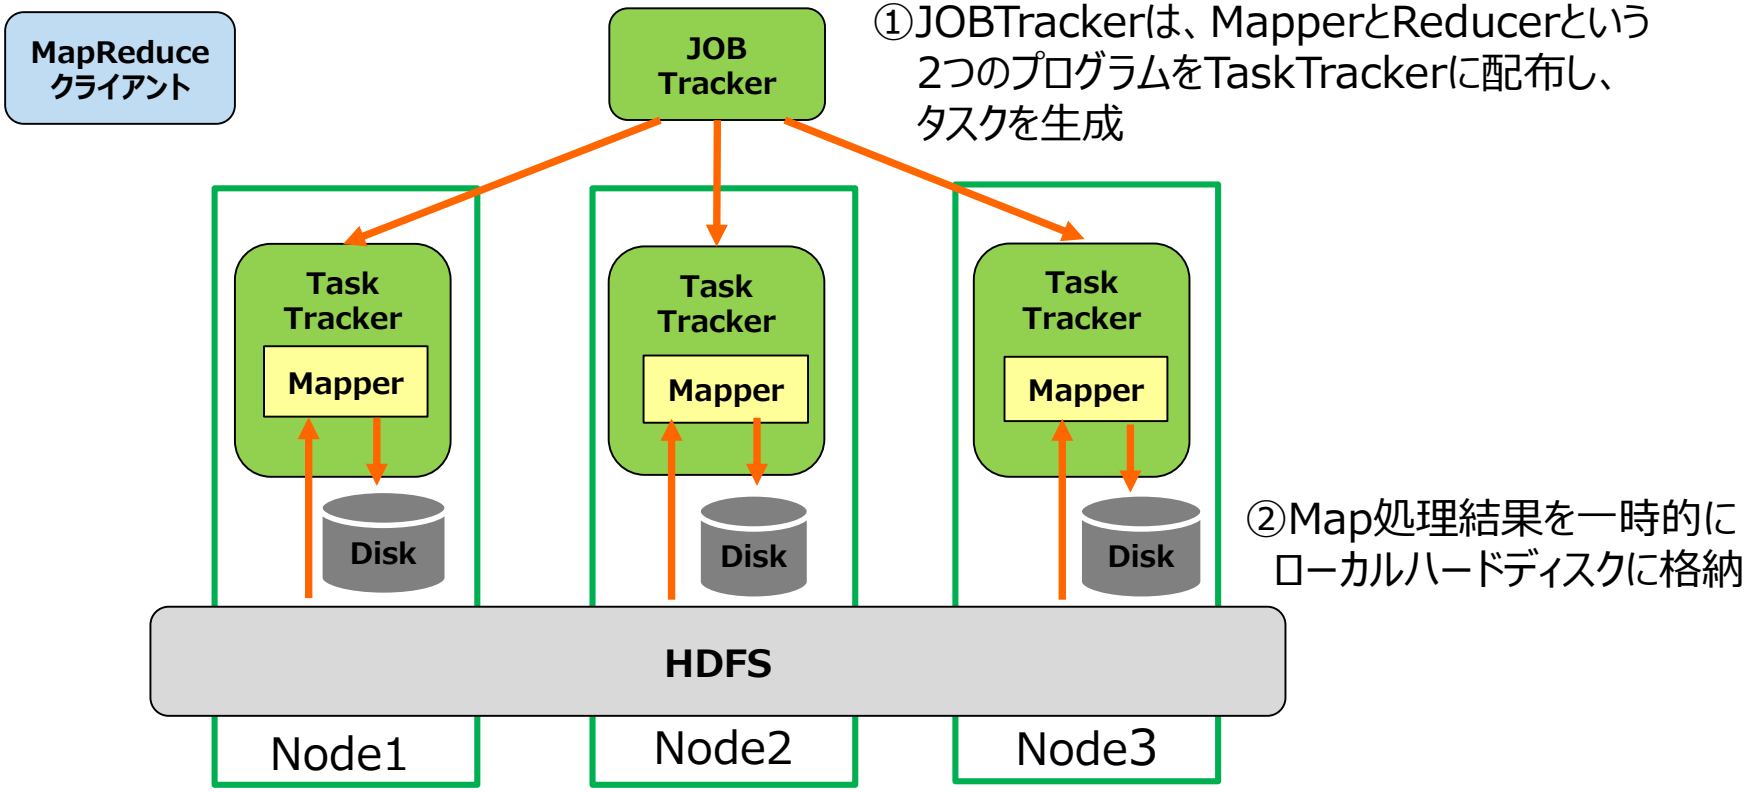

MapReduceのアーキテクチャ

MapReduceのアーキテクチャ

JobTrackerは、ある程度処理が進むとShuffle&Sort処理を起動します。

Mapタスクにより処理された中間データを、キーの値よって、ノードを跨っているものを含めて1箇所にグループ化します。

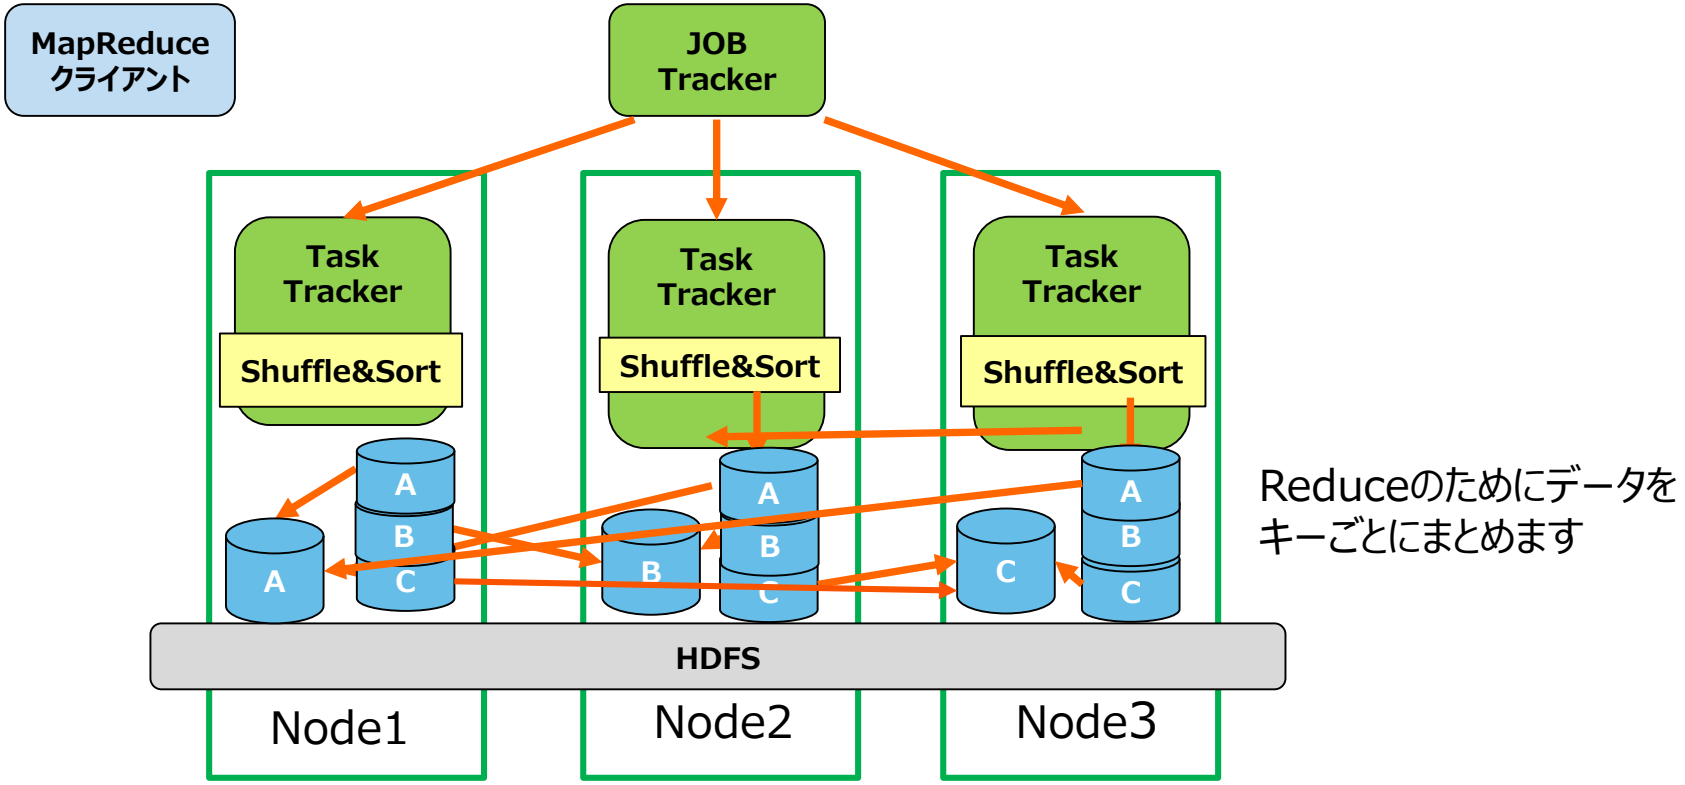

MapReduceのアーキテクチャ

MapReduceのアーキテクチャ

処理がさらに進むとJobTrackerはReduceタスクをTaskTrackerに割り当てます。TaskTrackerはReduceタスクを実行し、処理結果をHDFSに書き込みます。全てのタスクが終了するまで繰り返し行います。

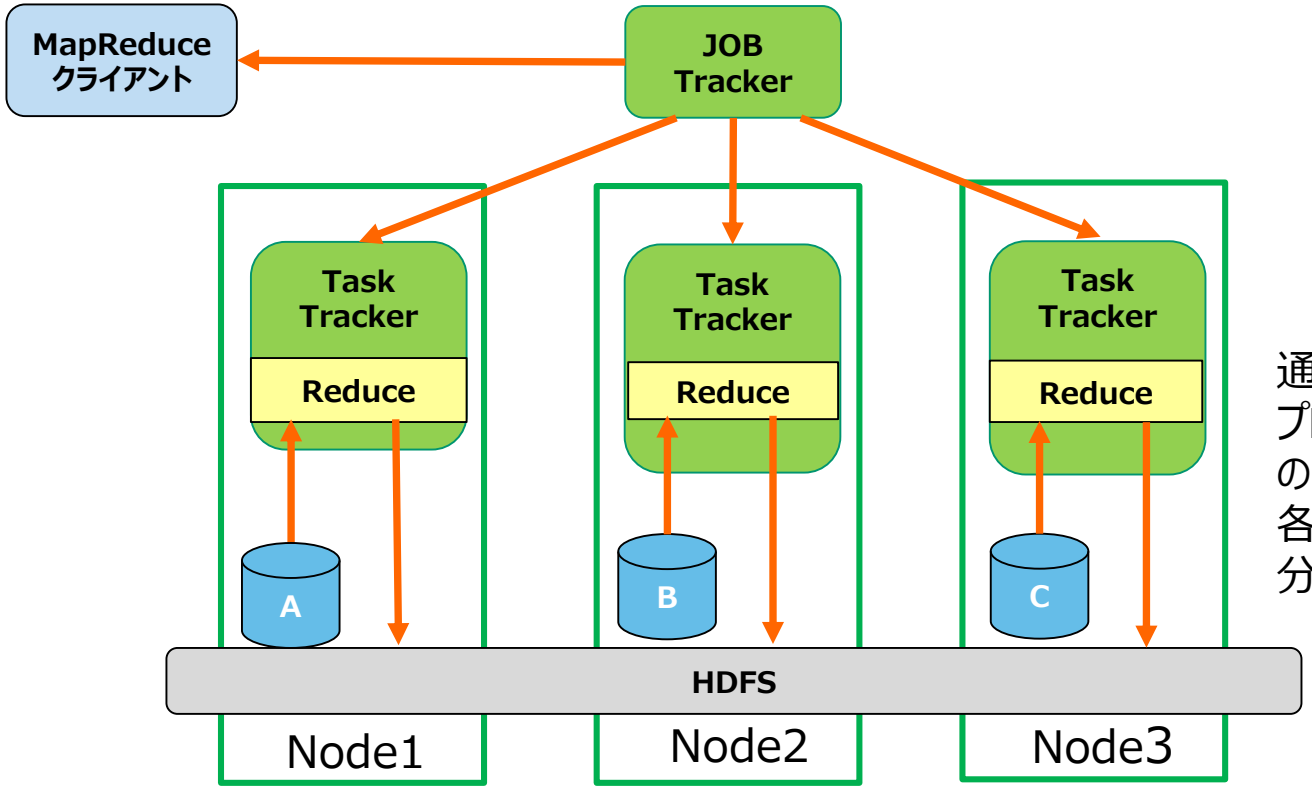

通常のプログラミングでは、プログラムがデータを呼び出すのですが、プログラムの方を各ノードに配布している点が分散処理のポイントです。

分散ファイルシステムとリソースマネージャー

YARN

CPUやメモリなどの計算リソースはリソースマネージャーであるYARNにより管理されます。
CPUコアやメモリをコンテナと呼ばれる単位で管理します。

分散アプリケーションが実行された時に、クラスタ全体の負荷のバランスを見てコンテナが割り当てます。

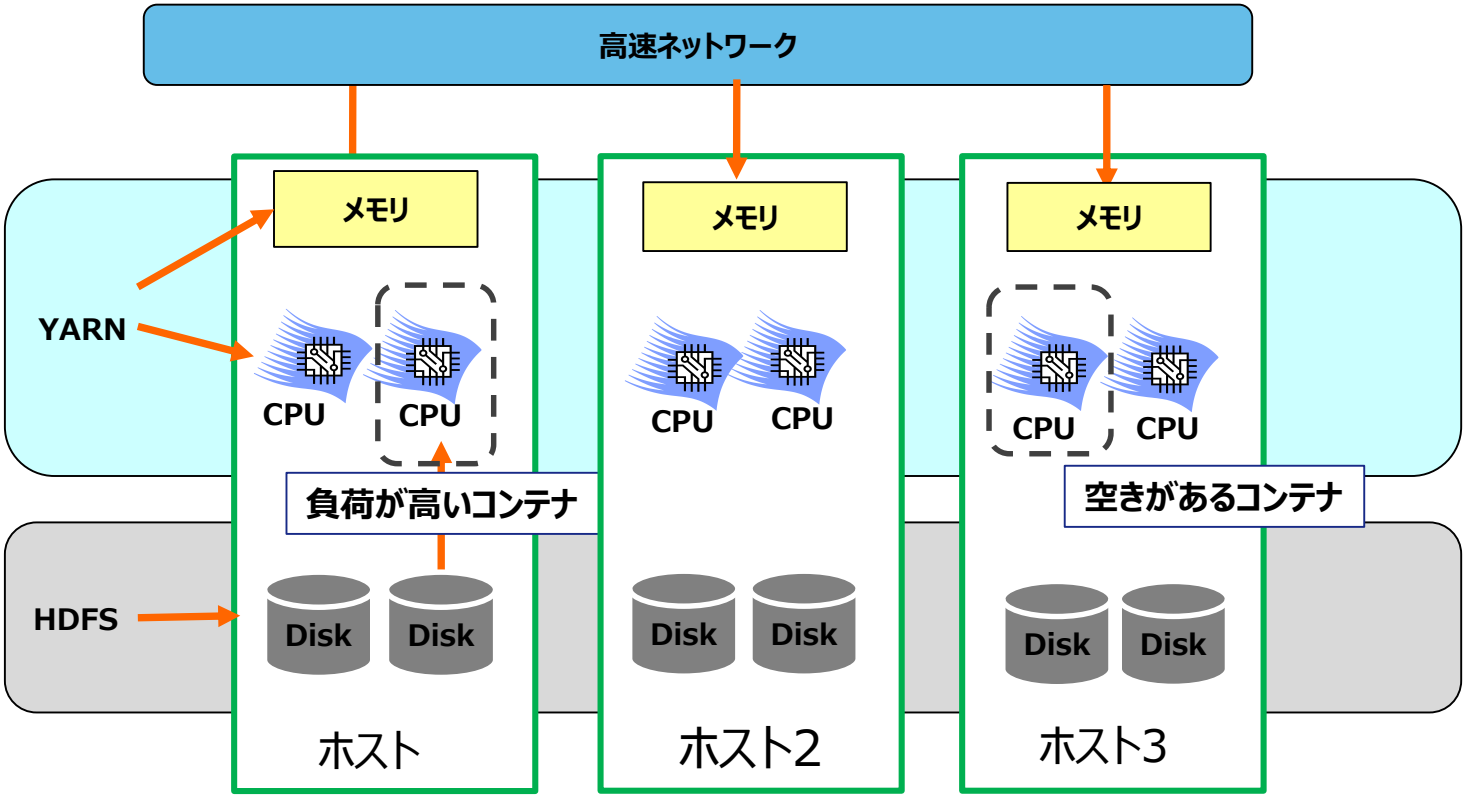

分散データ処理とクエリエンジン

Hive on MapReduce

MapReduceはJavaプログラムをデータに対し実行できるため、加工には便利です。SQLに対応させる場合、専用に設計されたクエリーエンジンApache Hiveを利用します。

Hiveは応答性能が重要視される場合や少量データを扱う場面などではには不適です。

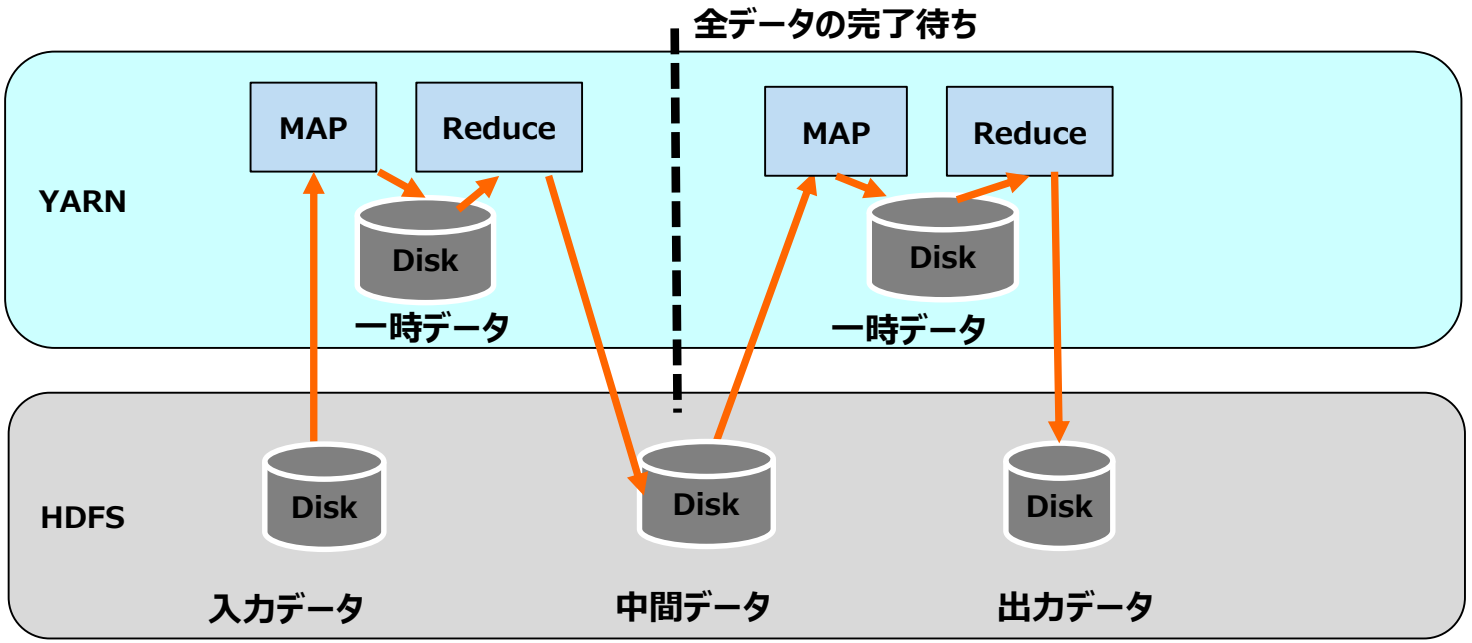

データ処理ステージが変わるタイミングで待ちが発生。
中間データを毎回Diskに保存するため低速

分散データ処理とクエリエンジン

Hive on Tez

Apache TezはHiveの高速化するために開発されたコンポーネントです。
Mapreduceの仕組みを調整し、処理段階の終わりで他のプログラムの情報を保持せずに後続の処理へと受け渡す仕組みに変更しました。

ステージの合間にあったディスクへの書き込み、待ち、Map処理を省略

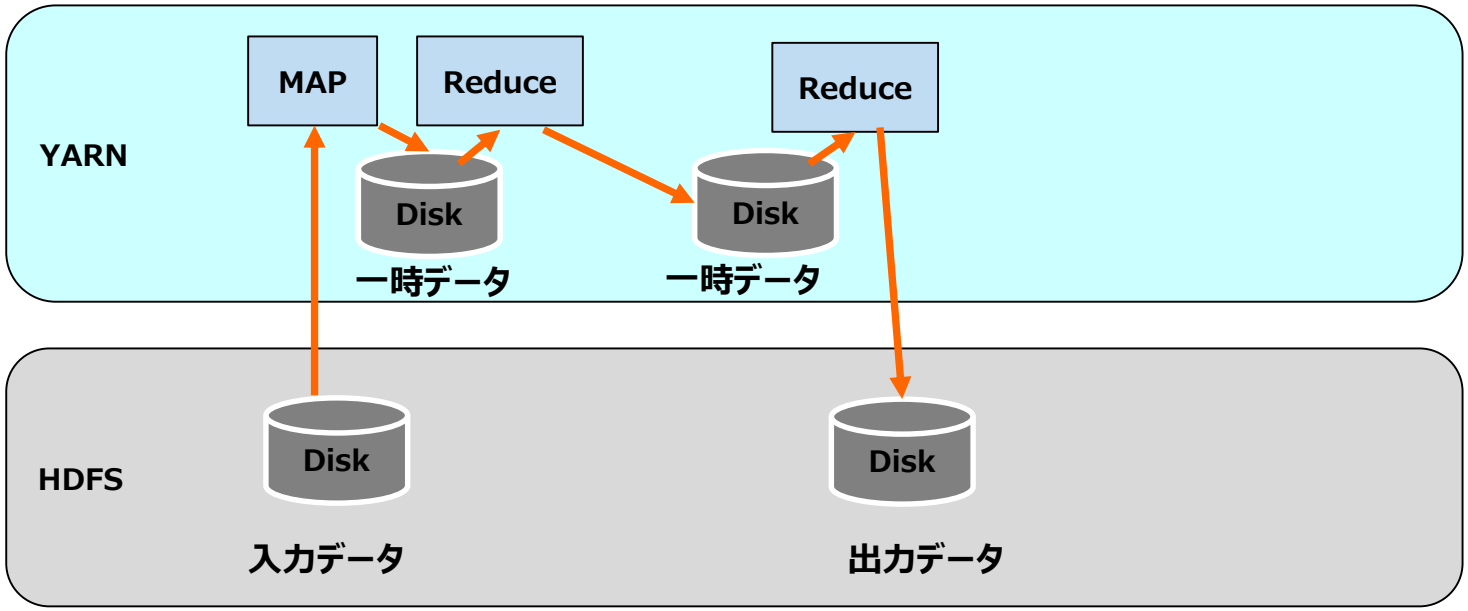

現在、Hive on Sparkというものも存在します。RDDがMapreduceに代わる存在として活用されています。

分散データ処理とクエリエンジン

Impala / Presto

ImpalaとPrestoは、Hiveの高速化ではなく、対話型クエリ実行に特化させることで、SQLに対応させた製品です。バッチ処理ではなく、最大瞬間速度を最大にするため、あらゆるリソースを有効活用するよう設計されています。

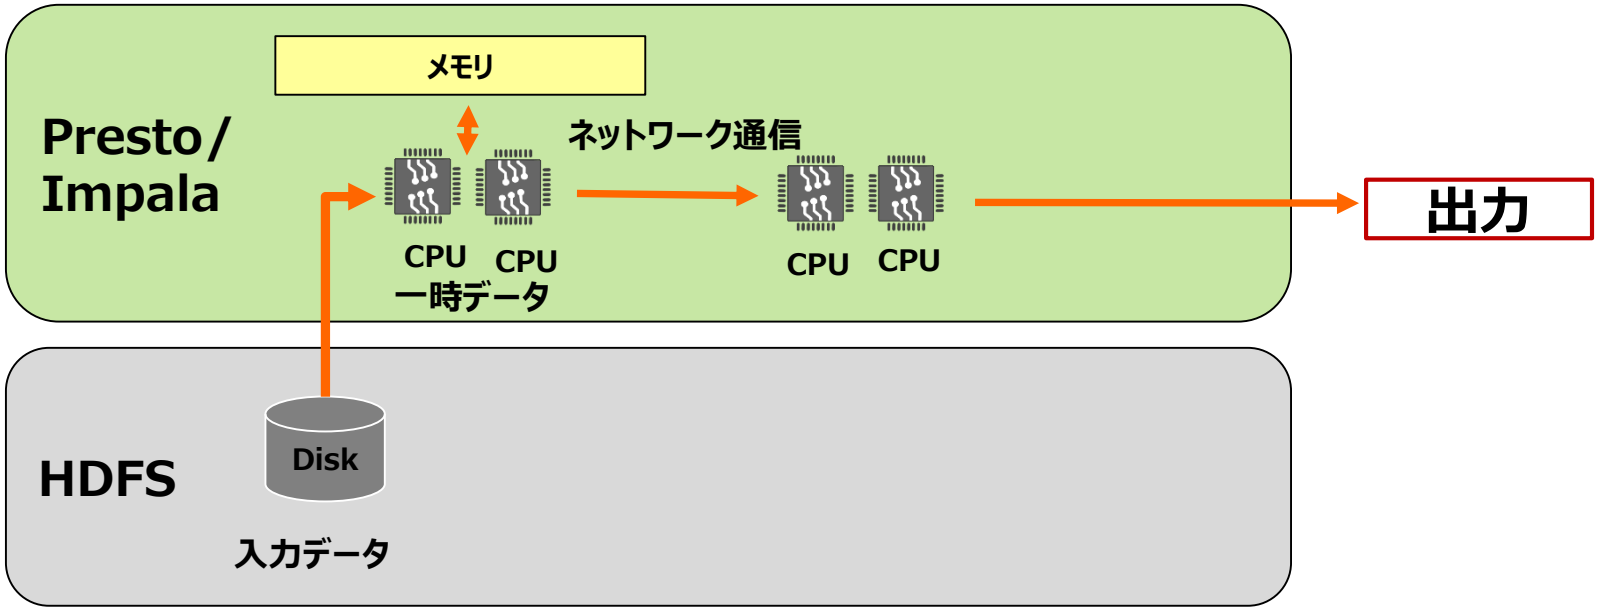

自前の分散処理機構を実装し、マルチコアを活用しながら並列化処理を実行

分散データ処理とSpark

Spark

Apache SparkもMapReduceより効率良くデータ処理をするために開発されました。メモリの使用量増やすことで高速化を実現します。Sparkの実行にはJavaランタイムが必要ですが、Java、Scala、Python、Rからも呼び出すことができます。

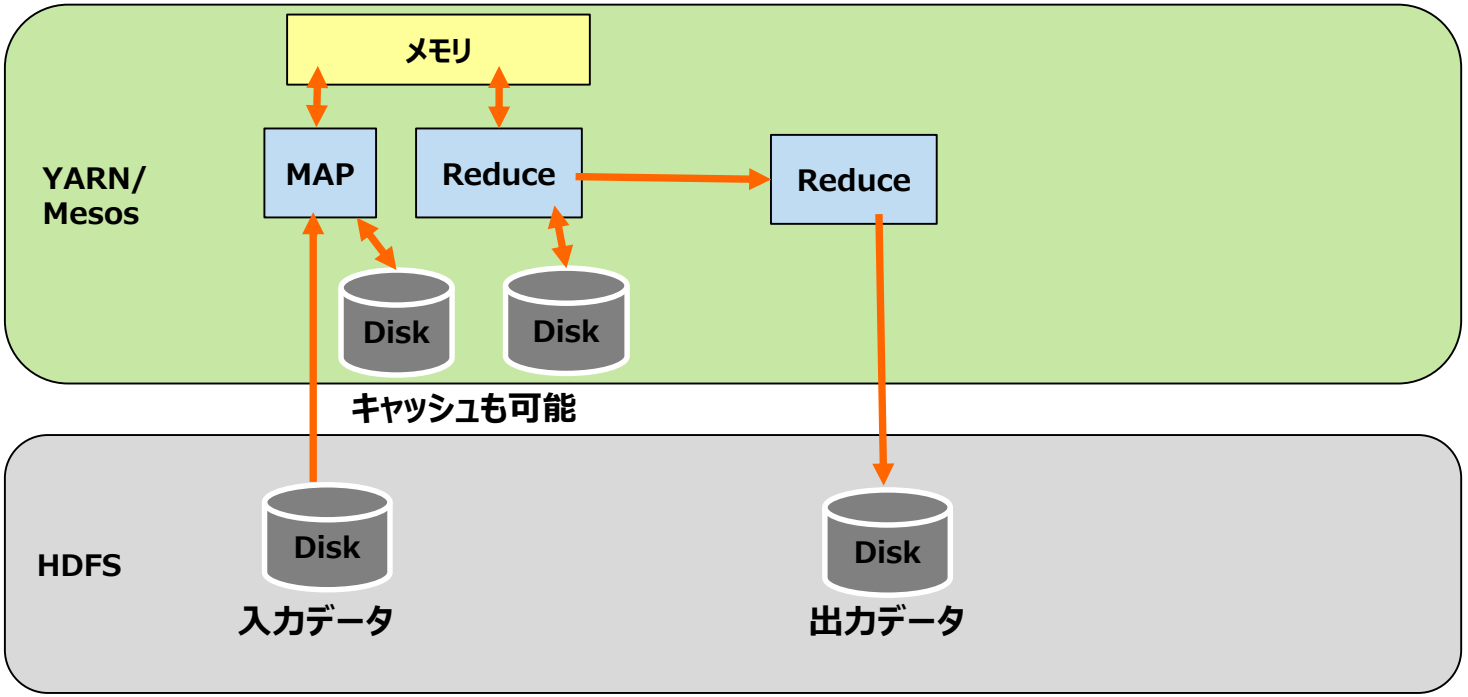

Sparkは中間DBにデータを書き込むことなくメモリ上に保ち続けます。
障害でデータが失われるともう一度最初からやり直します。

第５章

ビッグデータにおける データ解析

ビッグデータにおけるデータ解析

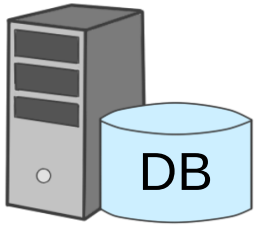

社内の実績データ

SNSデータ
社外の取引データ
Webサイトログ

音声・画像・
センサーデータ

オープンデータ・
統計データ・
科学データ

ビッグデータ
蓄積基盤

BIツール

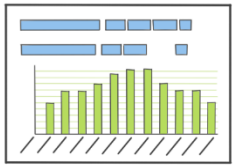

統計解析
ツール

機械学習・
AI

収集

蓄積/集計

解析/可視化

アドホック分析ツール

データを可視化するためのソフトウェアは多種多様に存在します。

アドホック分析ツール

行錯誤を繰り返しながら、繰り返しデータを見ていく際に利用するものです。
アドホック分析環境には次のようなものがあります。

・Jupyter Notebook

Python、Ruby、Rなどのソースを書き留めながら実行することが可能。
matplotlibライブラリを利用してグラフを作成することもできる。

・Apache Zeppelin

Spark/Hadoopなどの分散処理システムに対してコードを実行し、
実行結果をグラフとして描画することが可能。
シェル／SQL／scala／python言語に対応している。

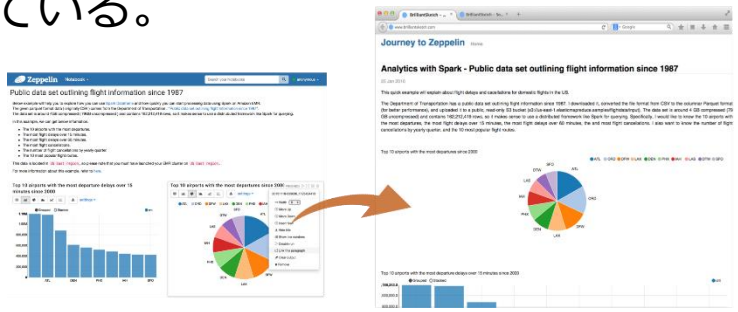

https://zeppelin.apache.org/

ダッシュボードツール

ダッシュボードツール

傾向の把握が進むと、定期的にクエリを実行し、レポートやグラフなどを用いたダッシュボードを作成するツールです。

対話的なBI商用ツールとしてTableau、ClikViewなどが存在します。
オープンソースのダッシュボードツールも存在します。

- Redash
  Python製のダッシュボードツール。
  SQLクエリの実行結果を直感的に可視化できる。搭載したDBに結果を記録するため、表示自体は高速だが、クエリ結果が大規模になるとエラーや遅延が生じる。
- Superset
  Python製のWebアプリケーションで対話的なダッシュボードを作成する。
  集計は外部ストレージ「Druid」で行い、リアルタイムな出力を行える。
- Kibana
  JavaScript製の対話的可視化ツール。
  Elasticsearchのフロントエンドでよく用いられる。

データ活用：一般的な統計分析手法

度数分布とヒストグラム	データを範囲に区切って表したもので、データの分布を知ることができる
平均と標準偏差	状況を特定することができる
正規分布	統計的なデータを元に、可能な予測を立てることができる
標本調査（全体像の推測）	標本（一部のデータ）を元に、全体像を把握できる
標本平均	標本の平均を求めることで、全体の平均を推測できる

度数分布とヒストグラム

度数分布

度数分布表を用いて表します。
※度数分布表：データをいくつかの範囲に分け、その範囲に入るデータの個数を書き表した表。
データがどのような値を中心にして、どのように広がっているのかを調べることができます。

値）	人数
21～25（23）	1
26～30（28）	4
31～35（33）	9
36～40（38）	16
41～45（43）	21
46～50（48）	5
51～55（53）	3
56～60（58）	1

ヒストグラム

ヒストグラムとは、データの分布状態（度数分布）を表す棒グラフのことです。
度数分布の他の表現方法としては、箱ひげ図があります。

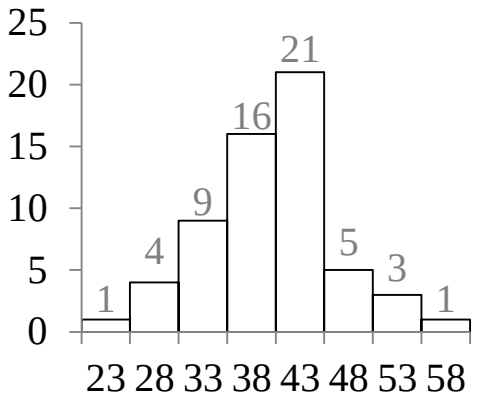

平均と標準偏差

・平均：データの代表値としてよく利用される。
　　平均の代わりに、最頻値、中央値を用いることもある。

$$\text{平均値} = \frac{\text{データの値の総計}}{\text{データ数}}$$

・分散：データがどのくらいばらついているかを表す。

$$\text{分散} = \frac{(\text{各データの値} - \text{平均})^2 \text{の総計}}{\text{データ数}}$$

… 平均との差の２乗の平均

・標準偏差：そのデータの傾向や性質を把握するために利用される。
　・異なるデータ間でのデータのばらつきの度合いを比較できる
　・平均値からのばらつきの幅を測定できる。

$$\text{標準偏差} = \sqrt{\frac{(\text{データの値} - \text{平均})^2 \text{の総計}}{\text{データ数}}}$$

… 分散の平方根

正規分布

正規分布とは

- 確率分布の１つ。
- 平均値（または中央値）を中心に左右対称な、釣鐘型の分布。
- 平均値で最も発生確率は高くなり、平均値から離れるほど低くなる。
- 正規分布をしていると想定できるデータに関しては、平均値と標準偏差さえわかれば、どのように分布が広がっているかを推定できる。

標準偏差が大きい＝ばらつきが大きい

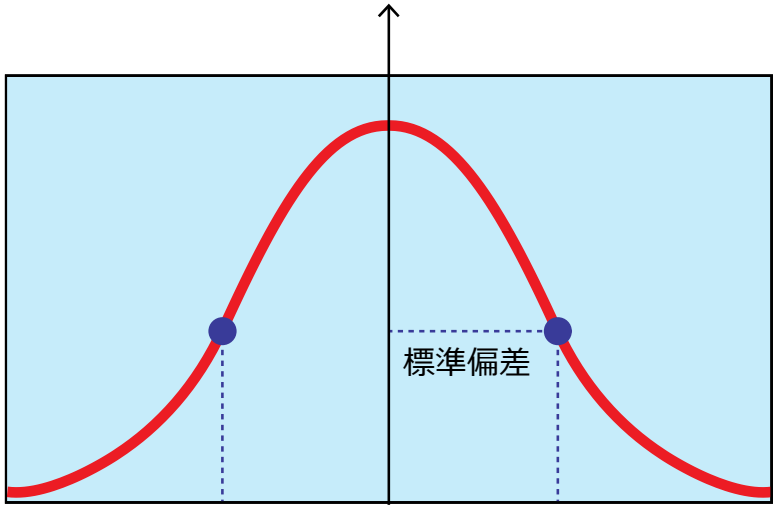

標準偏差が小さい
＝ばらつきが小さい

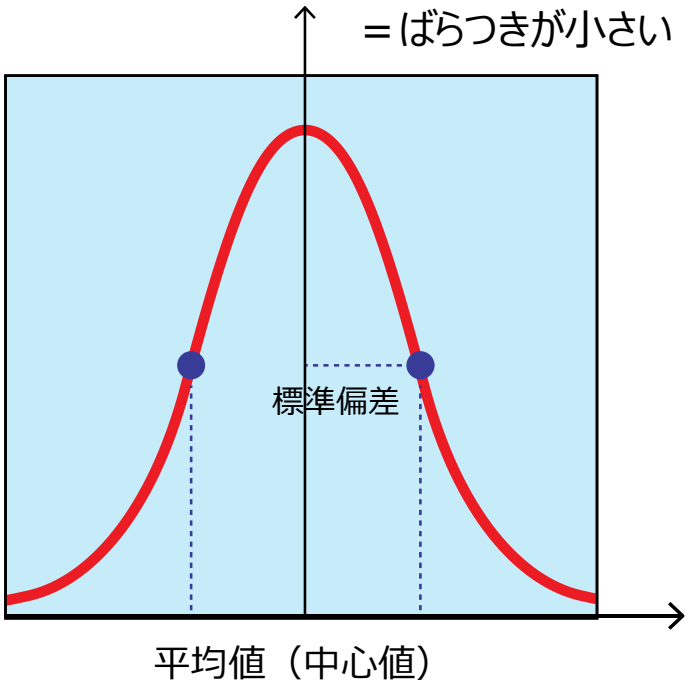

標本調査と標本平均

標本調査とは

標本、つまり大量のデータ（母集団）の一部を入手、観測した際に、その母集団を推測するために仮説検定の考え方を用いて行う統計的推定の手法のことを言います。

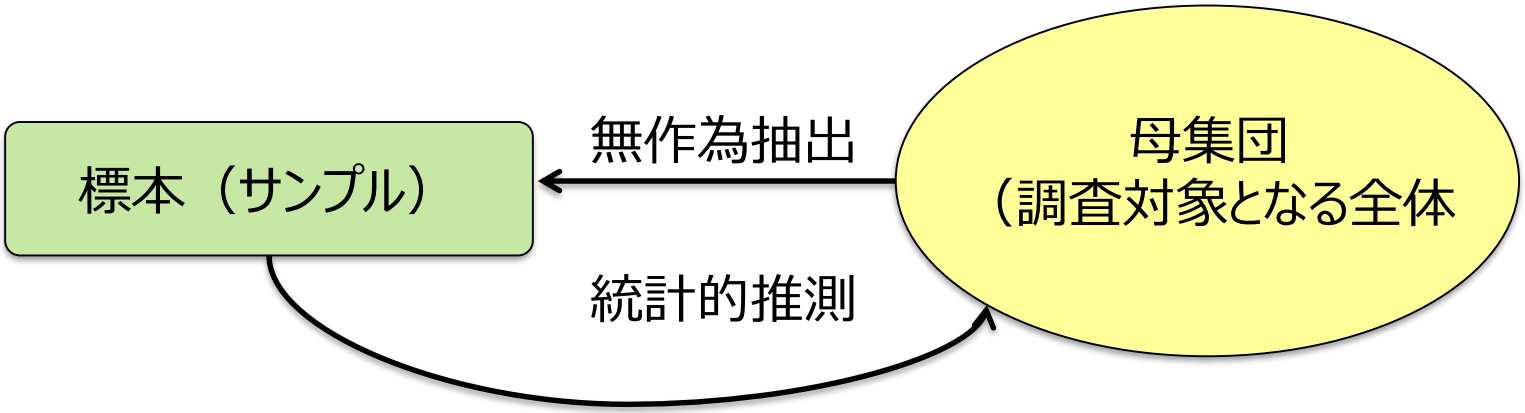

標本平均とは

標本データの平均値を利用することで、母集団の平均を推測することができます。母集団の傾向を推測するために利用されます。

…（標本平均）＝（抽出した標本データの合計）÷（抽出した標本データ数）

相関関係

相関関係とは

一方の値の変化に伴って、もう一方の値が変化するという、２つの値の関係のことを相関関係と言います。

・正の相関：２つのデータのうち、一方の値が増加すると、もう一方の値も増加するような関係。

・負の相関：２つのデータのうち、一方の値が増加すると、もう一方の値は減少するような関係。

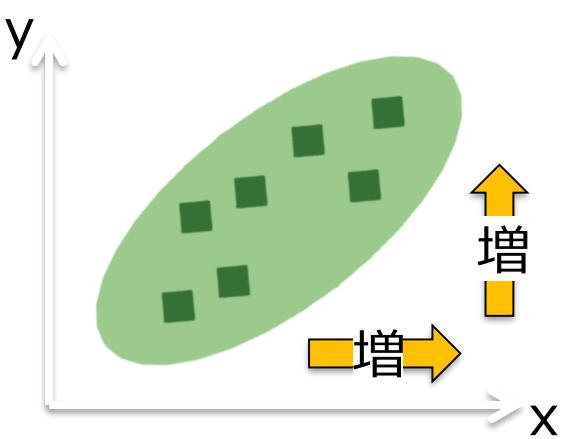

正の相関（右上がり）

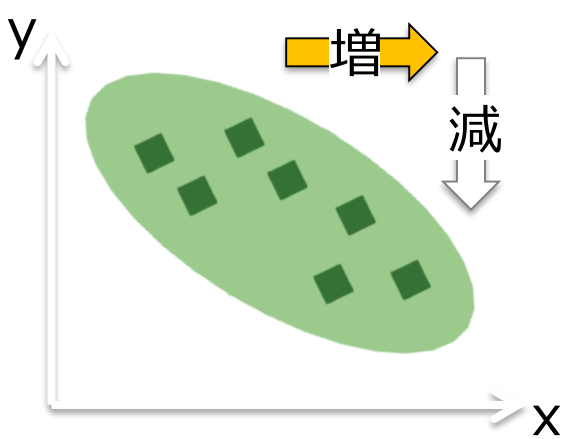

負の相関（右下がり）

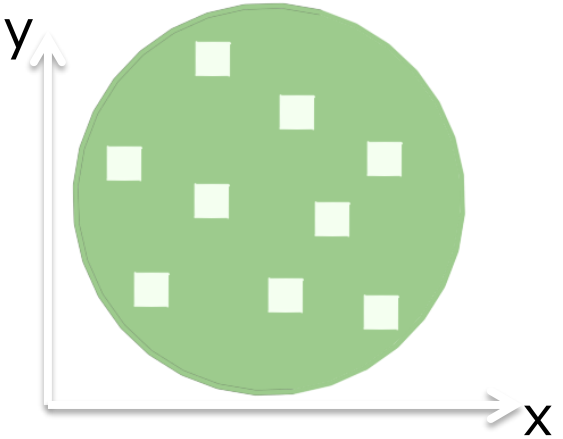

無相関

相関係数

相関係数とは

２つのデータ間の相関関係の強さを表す値のことで－１から１までの値を取ります。

相関係数が０に近いほど相関は弱く、１に近いほど相関は強くなっています。

…（相関係数）＝（共分散）÷（一方の標準偏差 × もう一方の標準偏差）

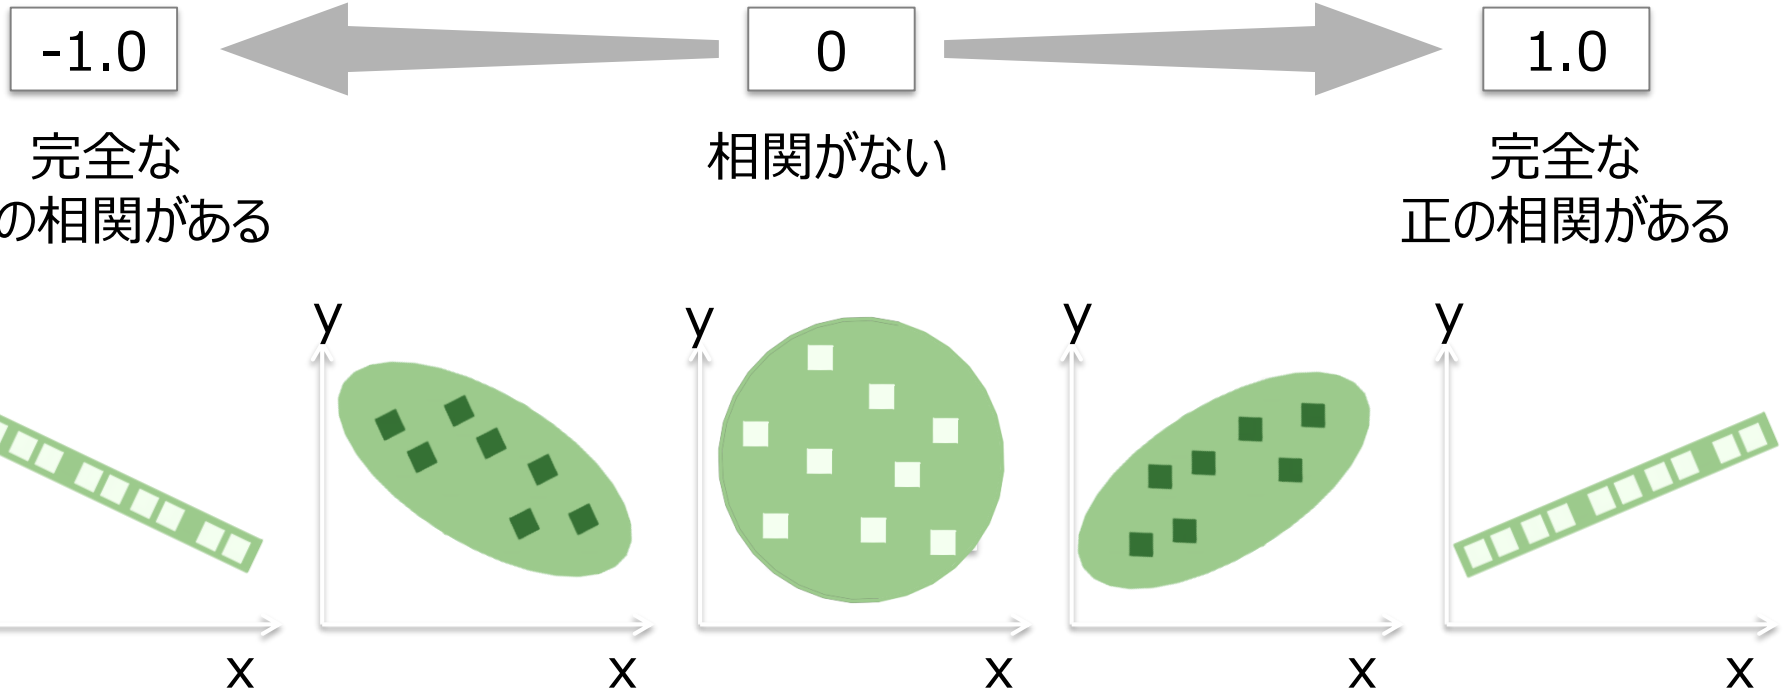

相関関係と因果関係

・相関関係：一方の値が変化すると、もう一方の値も変化するという２つの値の関係のこと。

・因果関係：２つ以上のものの間に原因と結果の関係が成り立っていること。つまり、一方によって、もう一方が引き起こされるという関係。

相関関係があっても因果関係があるとは限りません。

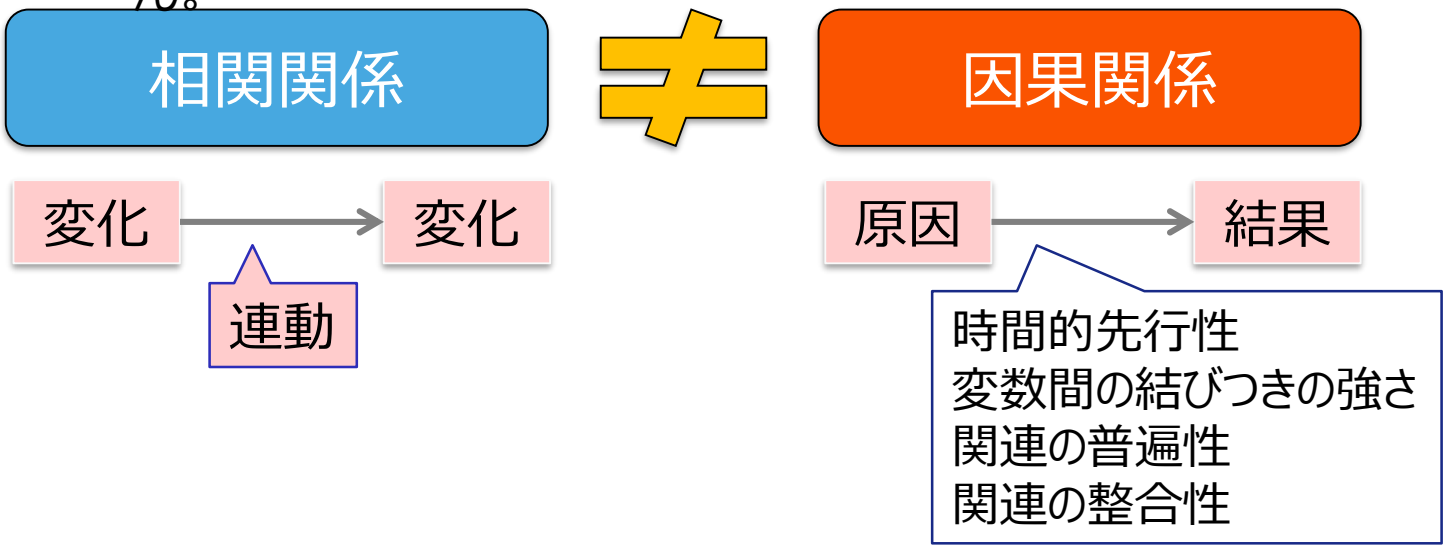

回帰分析と重回帰分析

回帰分析とは

「原因となる数値」と「結果となる数値」との関連性を、統計的手法によって分析することを言います。
回帰分析を行うことで、一方の数値（説明変数）の変化から、もう一方の数値（被説明変数）の変化を推測することができ、仮説を立てることが可能になります。式にすると、 $Y = aX + b$ のように表されます。

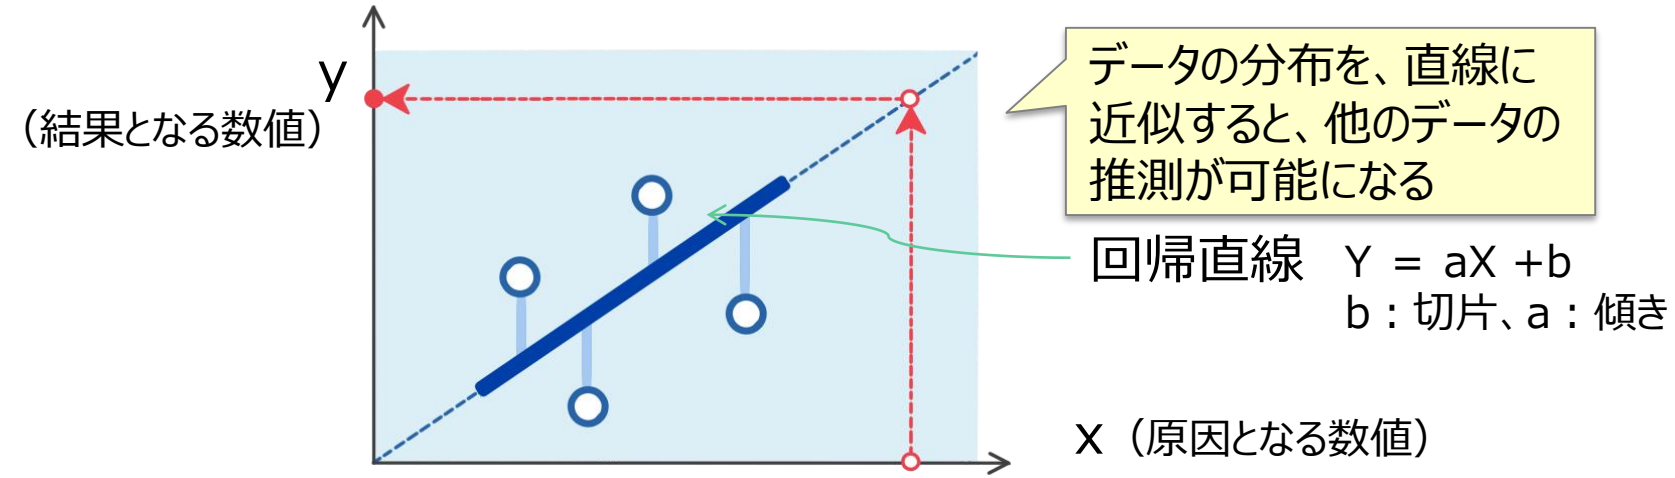

重回帰分析とは

１つの目的変数を複数の説明変数を用いて推測する統計的手法のことを言います。
式にすると、 $Y = a + b_1X + b_2X + b_3X + \ldots + b_nX$ のように表されます。

多項式回帰曲線のイメージ

回帰曲線を用いて、データをモデル化することを考えます。

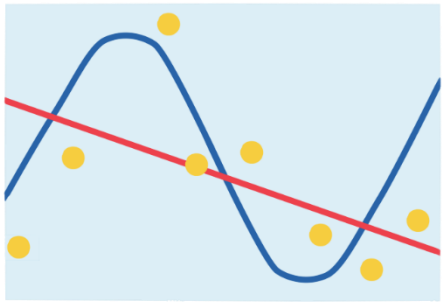

1次回帰線

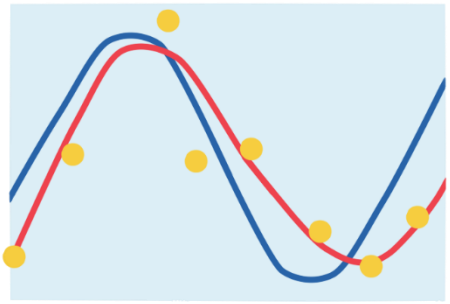

３次回帰線

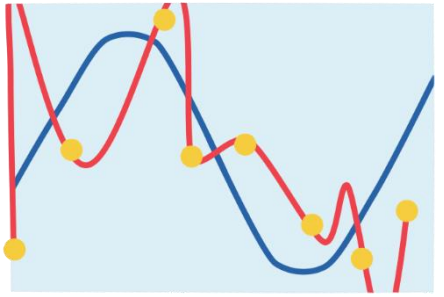

９次回帰線

ここでは３次回帰曲線を用いて表すのが適当だと考えられます。
上の図からも分かるように、９次回帰線は全ての点を通っていますが、実態とはかけ離れています。従って、新たな点が現れた時にその点が９次回帰線上にある確率は却って下がってしまい、予測には向いていません。
これを、過学習（オーバーフィッティング）といいます。

テキストマイニング

テキストマイニングとは

大量のテキストデータから、トピックの傾向や、役立つ知識、情報などを見つけ出す分析技術のことを言います。

まず膨大に蓄積されたテキストデータを単語や文節（形態素）に分解し、それぞれの形態素の出現頻度や相関関係を解析します。
そして、係り受けなどの関係や時系列の変化といった構文解析を行うことで、結果的に客観的な意味内容を掴むことを目的とします。

図表　テキストマイニングの流れ（イメージ）

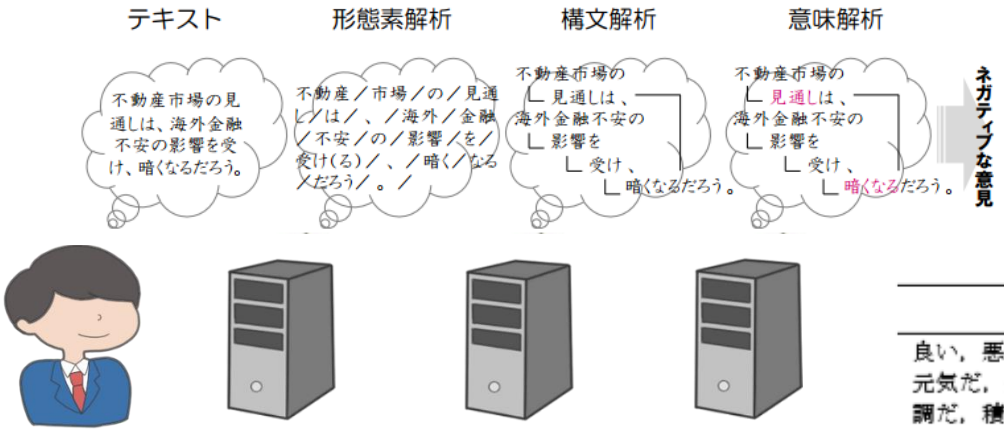

図表　評判辞書のキーワード例（抜粋）

ポジティブ単語	ネガティブ単語
良い，悪い（否定），良好だ，活発だ，元気だ，効果的だ，最適だ，最高だ，順調だ，積極的だ，調子よく，適切だ，明るい，しっかり，安全だ，快調だ，経済的だ，上々だ，心強い，抜群だ，必要だ，便利だ，満足だ，等	悪い，良い（否定），暗い，異常だ，割高だ，苦しい，最悪だ，最低だ，弱めだ，心配だ，不安だ，不十分だ，不調だ，危険だ，苦しい，酷い，少な目だ，心細い，辛い，大変だ，難しい，悲惨だ，不要だ，無理だ，異様だ，等

出典：「テキストマイニングによる国土政策評価手法の研究」国土交通省

テキストマイニング

テキストマイニングをすることで、テキスト情報から何らかの有用な情報を得ることができます。

例 ・自社の評判と他社の評判を分析、比較する。
→トピックの傾向を把握したり、新たな気づきを得たりできる。

・売上やキャンペーンデータについて、時系列で比較する。
→マーケティングなどに有用な情報を得られる。

第６章

ビッグデータとAI、機械学習

クラウド、IoT

AIの発展

AI（artificial intelligence）とは

コンピュータ上などで、人工的に人間と同様の知能を実現させようという試み、あるいはそのための一連の基礎技術のことを言います。

・エキスパートシステムとルールエンジン
エキスパート（専門家）がルールをつくりプログラムに実行させ、推論機能を適用することで結論を得る。
エキスパートシステムは大量の既知情報を処理し、関係性を導ける。

・事例ベース推論（CBR）
類似した過去の事例を基準に、修正をしながら試行を行い、結果と事例を事例ベースに記憶する。

・ベイジアン・ネットワーク
因果関係を確率により記述する。
複雑な因果関係の推論を有向非巡回グラフ構造により表しながら、個々の変数の関係を条件つき確率で表す確率推論のモデルである。

機械学習

機械学習と深層学習

2005年以降は機械学習と深層学習による第3次AIブームとなっています。

機械学習

データから反復的に学習し相関を見つけ出すことです。また、その結果を元にして将来を予測することができます。
予測分析におけるモデル構築の自動化ができるため、データサイエンティストの人材不足を補うものとして期待されています。

深層学習

ニューラルネットワークの多層化、1990年代の視覚野の研究や、ブルーノ・オルスホーゼンによるスパース・コーディング理論を基にしたアルゴリズムが実装されたものを指します。
情報が第1層からより深くへ伝達されると、各層で学習が繰り返され、特徴量(問題の解決に必要な本質的な変数であったり、特定の概念を特徴づける変数)が計算されます。

教師あり学習と教師なし学習

機械学習の手法として、教師あり学習と教師なし学習があります。

「教師あり学習」のイメージ
入力データに対応する出力を予測

① 入出力のペアで訓練データを用意し、入出力の関係を学習させる

② 未知データを正しく判断できるようにする

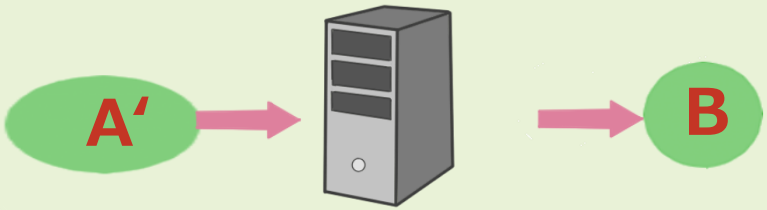

→ 迷惑メール判定、株価予測などに使われている

「教師なし学習」のイメージ
入力データの特徴を学習して分類

① 入力データのみを与え、データの特徴をつかみ、分類を行うもの

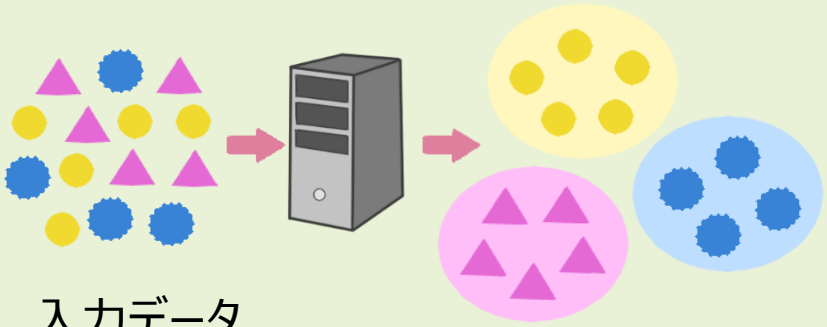

→ クラスタリングなどを用いて、同じ集合の持つ特性などから結果を予測する

機械学習アルゴリズム

機械学習アルゴリズムの分類

・Classification/Class probability estimation
既存のデータをクラスに分類し、未知の新規データの分類を予測する。
新規データに対しては、属する特定のクラスを示したり、各クラスに属する期待値も計算したりする。
例 商品の買い替え時に、もともと使っていた製品から購入を予測する

・Regression（回帰分析）
既存データの関係を示す、数的な「関数」を推測し、定量的な予測をたてる。
例 広告費と売り上げの相関を見つける

・Similarity matching
新規データの、既存データへの類似性を予測する。

機械学習アルゴリズム

機械学習アルゴリズムの分類

・Clustering
具体的な指標を示さず、既存データを自然に分類できるグループを見つける。
分類後、各グループの特性を別のアルゴリズムで分析する。
　例 顧客をグループ化し、それぞれに別のサービスを提供する

・Co-occurrence grouping
既存データから、同時にまたは付帯的に起こる事象を推定する。
　例 Aを買った人は、Bも買っている

・Reinforcement learning(強化学習)
環境との相互作用を元に、データを収集し分析する。
例 囲碁プログラムがコンピュータ同士の対局から有効な手筋を発見する

機械学習アルゴリズム

クラスタリング (clustering)

データの集合を、具体的な指標を使わず性質が近い部分集合にすることです。

統計解析や多変量解析の分野ではクラスター分析 (cluster analysis) とも呼ばれ、基本的なデータ解析手法としてデータマイニングでも頻繁に利用されています。

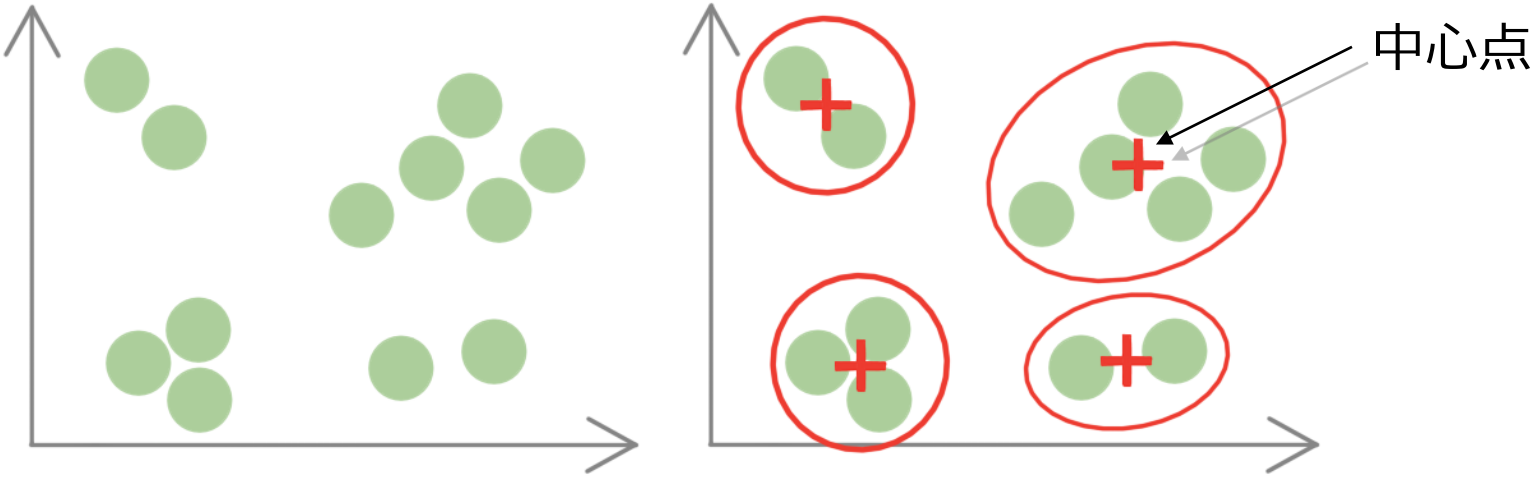

機械学習アルゴリズム

協調フィルタリング

商品の閲覧と購入のデータから、人同士の類似性や商品間の共起性をアソシエーション分析（相関分析）で解析し、対象者の行動履歴と関連づけることで、パーソナライズされた商品を提示する手法です。

協調フィルタリングは、商品スペックの関連性や商品閲覧の共起性だけではなく、購買データを基に人と人の類似性も重要視します。それにより、対象者に似ている集団が持つ特徴の中から、意外性のある商品を提示すること（セレンディピティ）もでき、コンバージョンレートのアップが期待できます。

画像分析手法

画像データを解析し、顔認識や、画像の分類などを行う事が可能となります。

・SIFT
特徴点周りの輝度から最も輝度変化が大きいベクトルを調べ分類することにより、細かい特徴を把握することができる。

・Haar-like
形状やパーツが固定的なものに対し、平均的に示される特徴から画像を解析する。カメラの顔認識などに用いられる。

・畳み込み深層学習（CNN）
画像をピースごとに比較して、位置や形状の特徴が類似する箇所を検出する。
その上で、色、明度、エッジなどの多層において学習を繰り返す。
顔認証などに用いられる。

地図情報システムとの連動

GIS

地理空間情報を
データ毎に管理

地図レイヤーと
分析対象データを

位置関係の把握
データ検索、表示、
関連分析

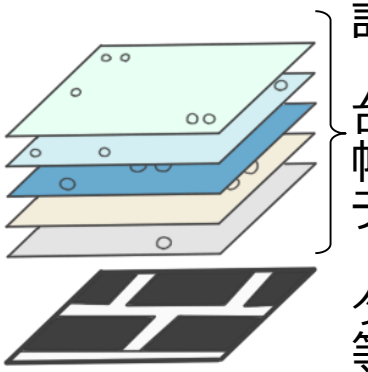

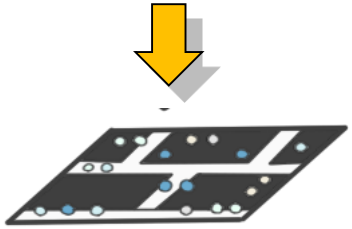

GISの特徴

- 地図データとビッグデータを重ね合わせ、新たな発見を得ることができます。
- 地理的な位置情報との情報の関連性を視覚的に理解することができたり、図面上で情報の集約、整理をしたりできます。

GISの利用シーン

- 災害時の、正確で素早く効果的な行動決定などに利用されています。