オープンソースカンファレンス 2013 Nagoya

Cassandra , HBase で学ぶ NoSQL 入門

2013年6月21日

盛　宣陽
y-mori@sraoss.co.jp

SRA OSS, Inc. 日本支社
マーケティング部

NoSQLとは

- NoSQL(Not only SQL)とは
  RDBMS以外のデータベースを示す総称

- なにかしらの点でRDBMSより性能がよいデータベース

  性能とは？
  レスポンス、スループット、対障害性、スケーラビリティ

- RDBMSの機能を犠牲にして
  要件に合わせた性能を満たすデータベース

RDBMSのデータモデルと特性

- RDBSMではリレーショナルモデルを採用
  - 正規化によりデータを一元管理
  - リレーションの結合により論理データを扱う
- RDBMSではACID特性を満たす
  - A(原始性) トランザクションは成功 or 失敗で終わる
  - C(一貫性) データに矛盾が生じない
  - I (独立性) 他のトランザクションから影響されない
  - D(耐久性) 障害が発生しても、更新結果は保持される。

一般にNoSQLでは、リレーショナルモデルとACIDを排除することで、性能を満たす

NoSQLのデータモデル

NoSQLの種類とデータストアの種類

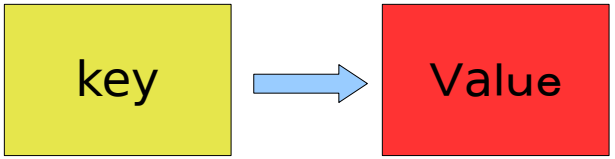

- **key-value型**

  ユニークなキーに対してバリュー(値)を持つ。

  NoSQLデータベースの基本的なデータ構造

  例) memcached,Redis

- **カラム指向型**

  キーに対してカラム(名前と値)を複数持つことができる

  HBase, Cassandra

- **ドキュメント指向**

  XMLやJOSNと言ったスキーマレスでデータ構造を持てる

  MongoDB

NoSQLとBASE

- トランザクションの性質 [BASE]

  - BA (Basically Available)
    可用性が基本 (サービス維持が基本)
    部分障害への対応
  - S (Soft State)
    厳密ではない状態遷移
  - E (Eventual Consistency)
    結果整合性

NoSQLの特性

- key-valueによってKey単位で分散処理が可能
  スケールアウトに対応
  - 分散ハッシュテーブルの利用

- ACIDを排除
  - 性能を妨げる強いロックを削減
  - データ間の依存関係をなるべく削除
    (MVCC非採用)
  - 高速なレスポンス

  クラウド環境やビッグデータ時代にマッチ

分散データベースとCAP定理(ブリューワの定理)

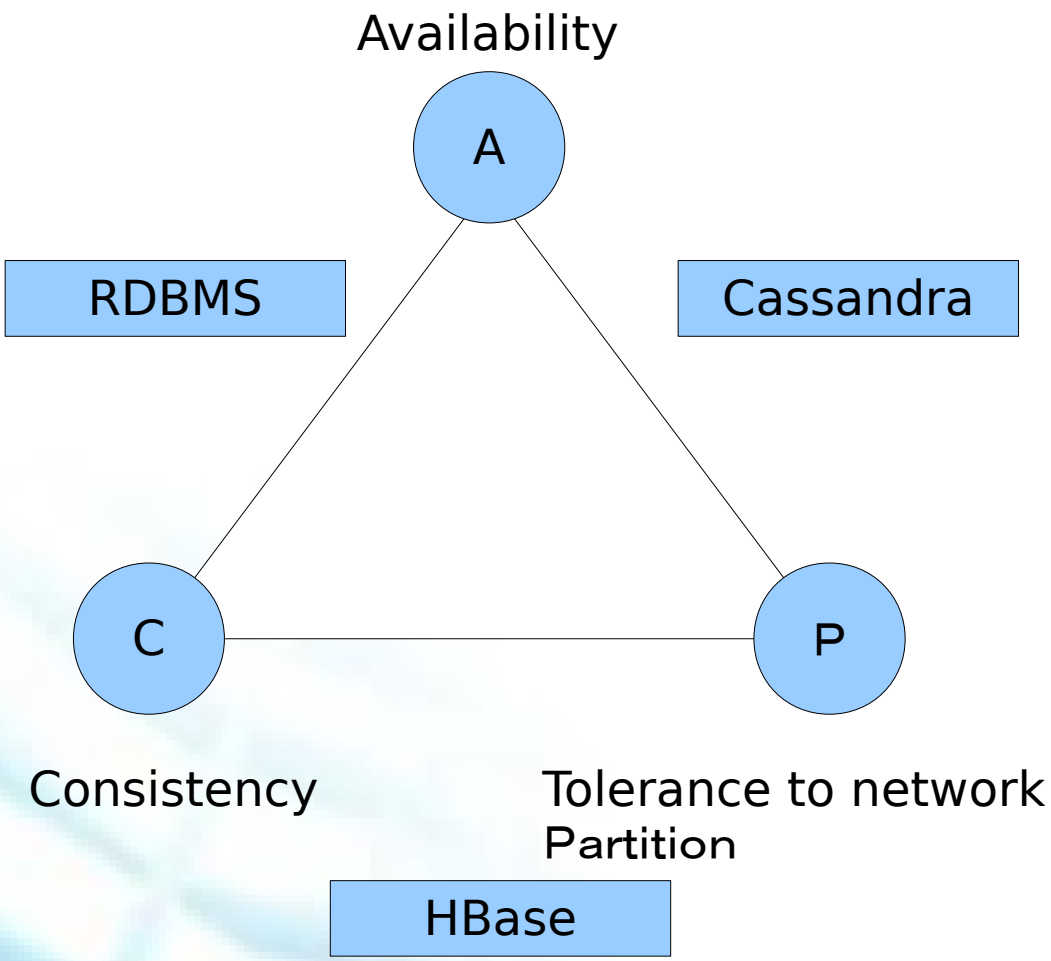

- Consistency

  すべてのクライアントから同じ結果が見える(整合性)

- Availability

  すべてのクライアントがシステムを常に利用できる(可用性)

- Tolerance to network Parition

  ネットワークが分断されても、システムが稼働する

CAP定理

CAPのうち同時に二つしか満たすことができない

HBase
http://hbase.apache.org/

HBaseとは

- 分散データストアシステム (カラム指向)
- ビッグデータ向け (テラバイト規模)
- Javaベース
- 行レベルの一貫性
- 線形スケーラビリティ
- 自動論理分割(シャーディング)
- Hadoop分散ファイルシステム(HDFS)上に構築
  レプリケーションはHDFSの機能に依存
- Apache License Version 2.0

HBase データモデル

データモデル

- カラム指向

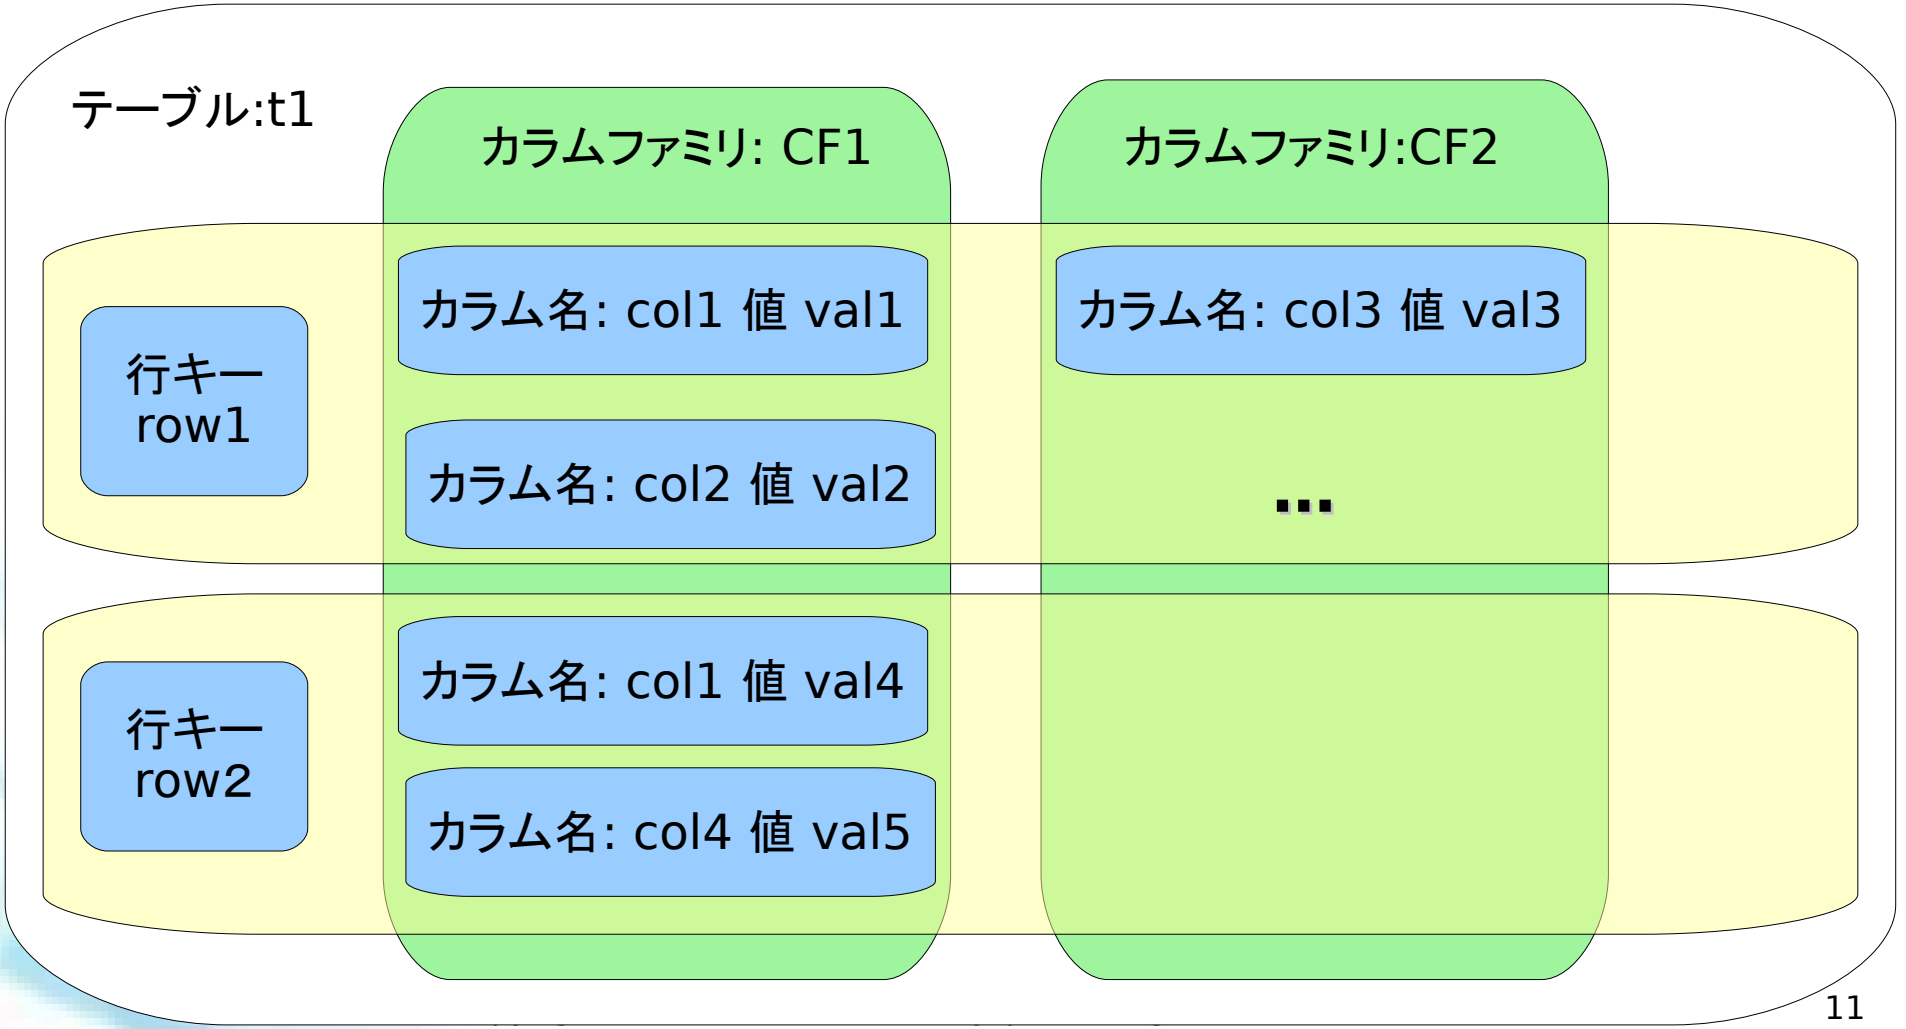

テーブルの作成

- 以下の図で表されるスキーマを定義する

テーブル:test		
行キー	カラムファミリ	カラム
row1	colfam1:	カラム:a
	colfam2:	カラム:b, c

- createコマンドを使用してテーブルを作成

```
hbase(main):002:0> create 'test', 'colfam1', 'colfam2'
0 row(s) in 1.2070 seconds
```

データの追加と取得

- putで行と新しい列を追加

```
hbase(main):003:0> put 'test', 'row1', 'colfam1:a', 'data1'
0 row(s) in 0.1200 seconds
hbase(main):004:0> put 'test', 'row2', 'colfam2:b', 'data2'
0 row(s) in 0.0110 seconds
```

高度な機能

- バージョン (タイムスタンプ)
  - セルごとにバージョン(タイムスタンプ)をもつ
- TTL (生存期間)
  - 列ファミリごとにTTL(生存期間)を決められる
- フィルタ機能
  - 文字列や数値の比較、正規表現などにより結果をフィルタリングできる

```
hbase(main):028:0> scan 'test', {FILTER => "(PrefixFilter ('row2')
 AND ValueFilter(=,'binary:data2'))"}
ROW                   COLUMN+CELL
 row2                 column=colfam2:b, timestamp=1342511049557, value=data2
```

HBase概要

HBaseを構成するサーバ

- HBase Master
- リージョンサーバ
- ZooKeeper
- Hadoop (HDFS)
  - NameNode
  - DataNode

HBaseの構成図

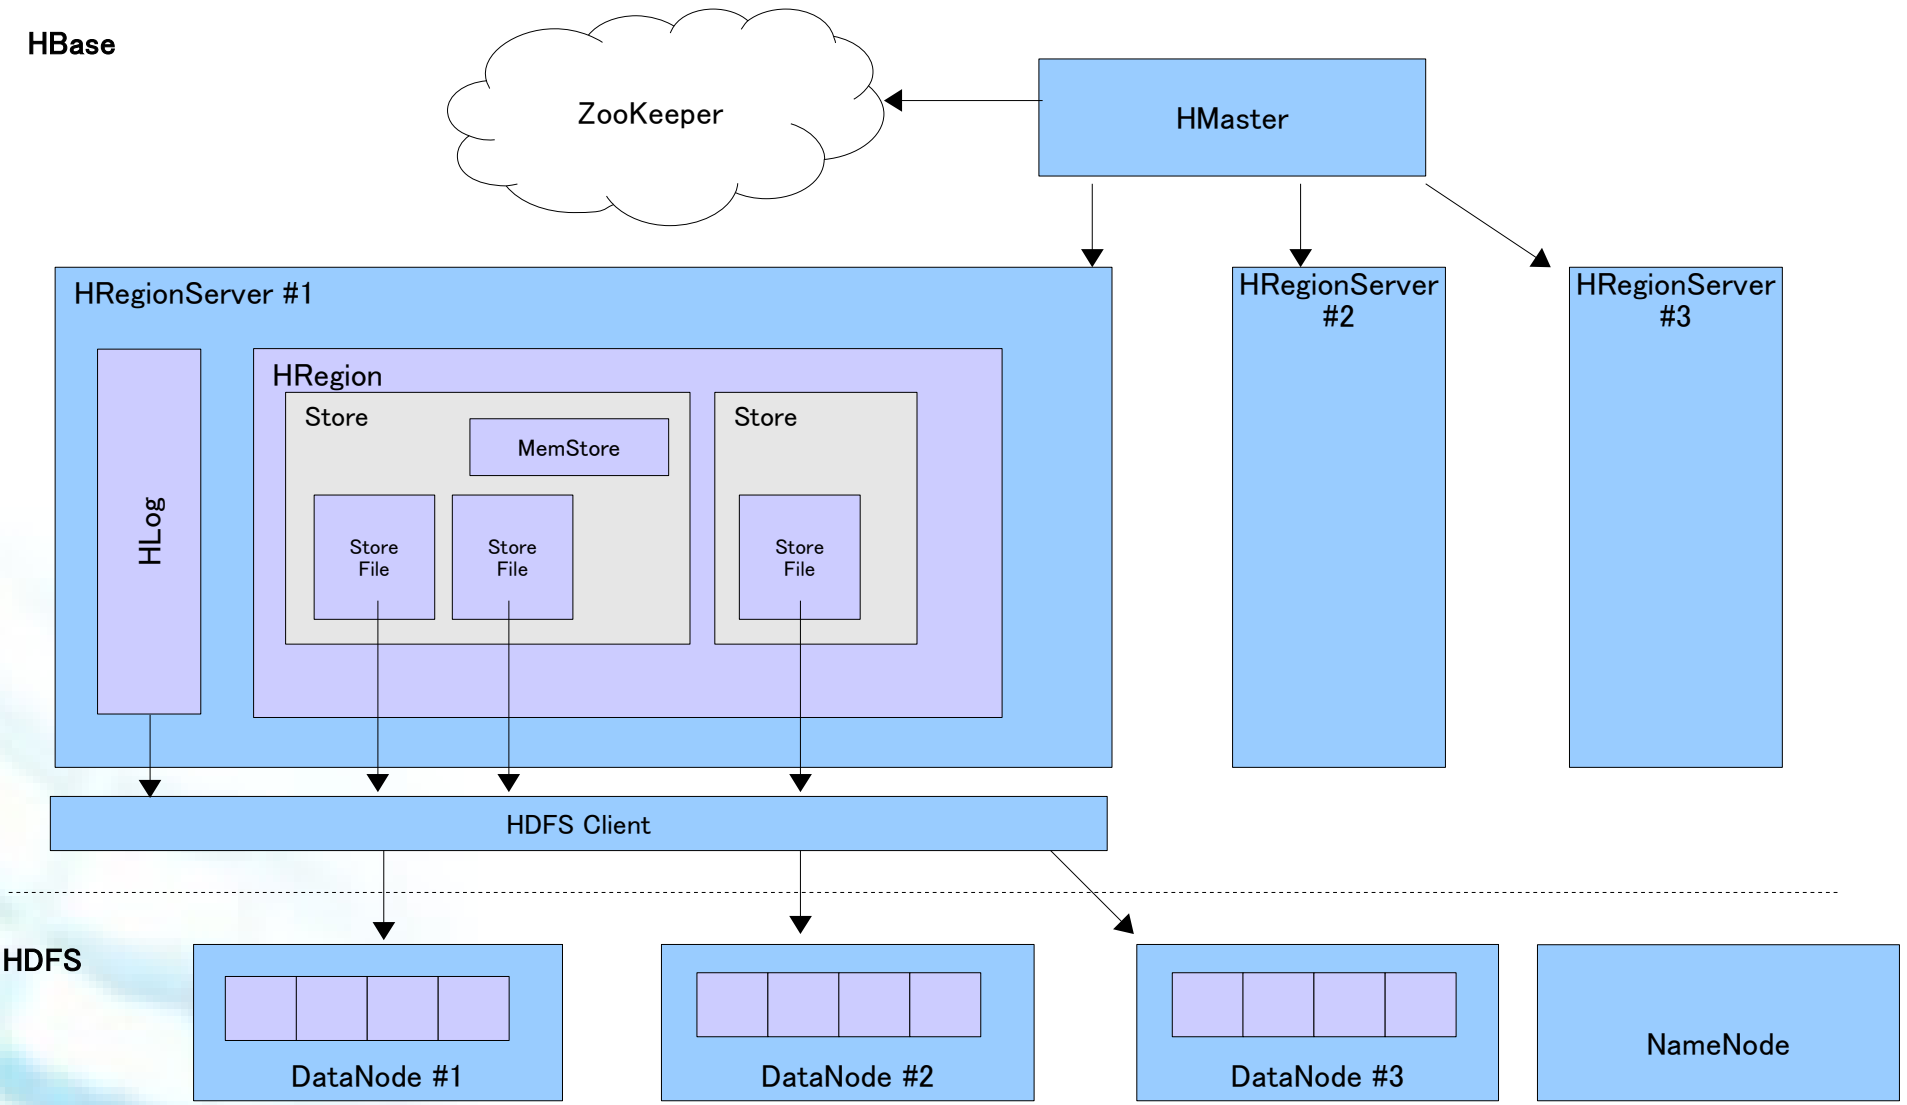

リージョン（概念図）

- 1つのテーブルは複数のリージョンに自動分割される
- 分割の単位は連続した範囲の行キー

  例) 行キーの先頭が A～M と N～Z で分ける
- リージョンは複数のリージョンサーバに分散される
- 1つのリージョンサーバは複数のリージョンを扱う
- リージョンサーバを増やすことで、処理はスケールする
- 行キーは特定のリージョンサーバで管理されるため、行キーレベルの一貫性を保つ

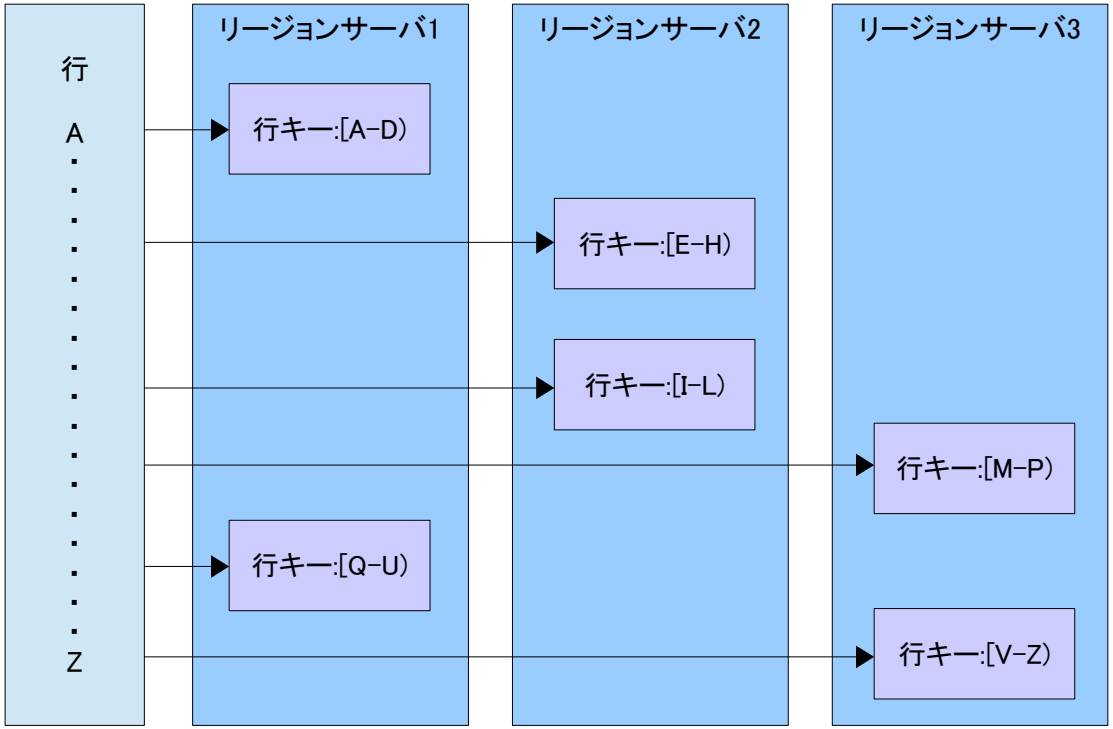

リージョンサーバ　書込み処理

- 書込み要求はHLog(トランザクションログ)に記述してからメモリ上のMemstoreに保存される
- Memstoreが溢れるとカラムファミリ単位でStoreFileに出力して永続化を行う

重要　書込みルール

- 既存ファイルは上書きしない
  同じキー、カラムファミリのデータは複数ファイルで管理(書込み直後にはマージされない)
- ファイルは行キーでソートされている

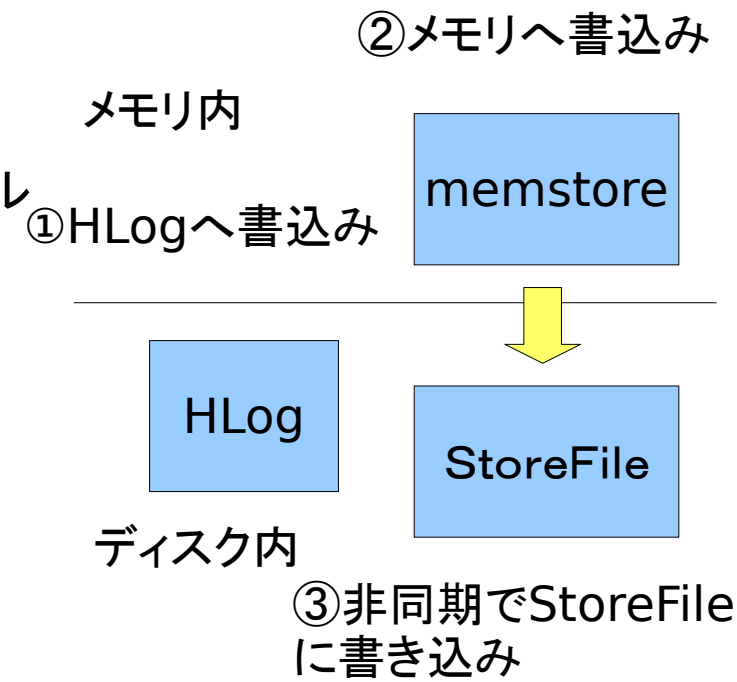

リージョンサーバ　読込み処理

- Memstoreに要求データがあればそのまま
  クライアントにデータを返却

- Memstoreに無ければ、StoreFileから対象データを探す

  - ここで、特定のキーのデータは複数のStoreFileから探すことになる
    (注)一つのカラムファミリのデータは各リージョンサーバ
    内の複数のStoreFileに存在する

HBase Masterの役割

- リージョンを各リージョンサーバに割り当てる
- 負荷分散 (リージョンのサーバ間移動)
- クラスタの状態の管理
  (リージョンサーバの自動フェイルオーバとリージョンの再割り当て)
- スキーマの作成、変更
- クライアントとは直接のやりとりは行わない

ZooKeeperの役割

- クラスタの各ノードの情報の管理
- 最初にクライアントからの接続を受け付ける
- 「-ROOT-」システムテーブル(メタデータ)を格納するリージョンの場所をクライアントに通知する

  リージョンの場所を受け取ったクライアントは、直接リージョンに接続を行い、通信を行う

Hadoopの役割

- HDFS (Hadoop 分散ファイルシステム)を提供
- HBaseで扱うデータは実際にはHDFS上に格納される
- HBase自体にはレプリケーションの機能はなくて、HDFSによってデータのレプリケーションが行われる
- HDFSは、バックグラウンドでノード間のデータ比較を行う

  破損しているデータがある場合には自動復旧される

障害ケース①

- HBase Master
  - 短時間の停止はシステム全体の停止に直結しない
  - 長時間の停止はクラスタの破綻につながる
  - 対策

    HBase Masterのホットスタンバイ構成

    =>Zookeeperと連動し自動フェイルオーバが行われる
- リージョンサーバ
  - 担当しているデータは一時的に利用不可となる
  - マスタノードによってリージョンのフェイルオーバが自動的に行われる
  - クライアントが障害を検知した場合には、マスタノードに通知を行い、マスタノードがリージョンをフェイルオーバさせる

    リージョンの移動後、クライアントはデータアクセスを行う

障害ケース②

- Zookeeper
  - 複数台で運用するためクライアント側で接続先を切り替える
- HDFS
  - NameNodeが単一障害点となる
  - 一般的にHAクラスタで冗長化

    Hadoop 2系でNameNodeがActive-Standby方式のHA機能が追加される(現在alpha版)
- ネットワーク分断

  ZookeeperがHBaseクラスタのノード情報を比較し、多数決によって稼働を続けるノードを決定する

  そのためZookeeperは奇数台が推奨される

http://cassandra.apache.org/

Cassandraとは

- マルチマスタ
  - 単一障害点がなく、すべてのノードが同じ役割をする
  - すべてのノードで読み書き可能
- スケーラビリティ
  - データを複数のノード間で分散管理(シャーディング)
- 高可用性と対障害性
  - 複数のノード間で同じデータを冗長管理
  - ラック間、データセンター間などでネットワーク障害が発生することを想定し設計されている
- 調整可能な一貫性レベル
  - Cassandraに接続を行うアプリケーションから、一貫性レベルを設定
- Apache License Version 2.0
- Javaベース

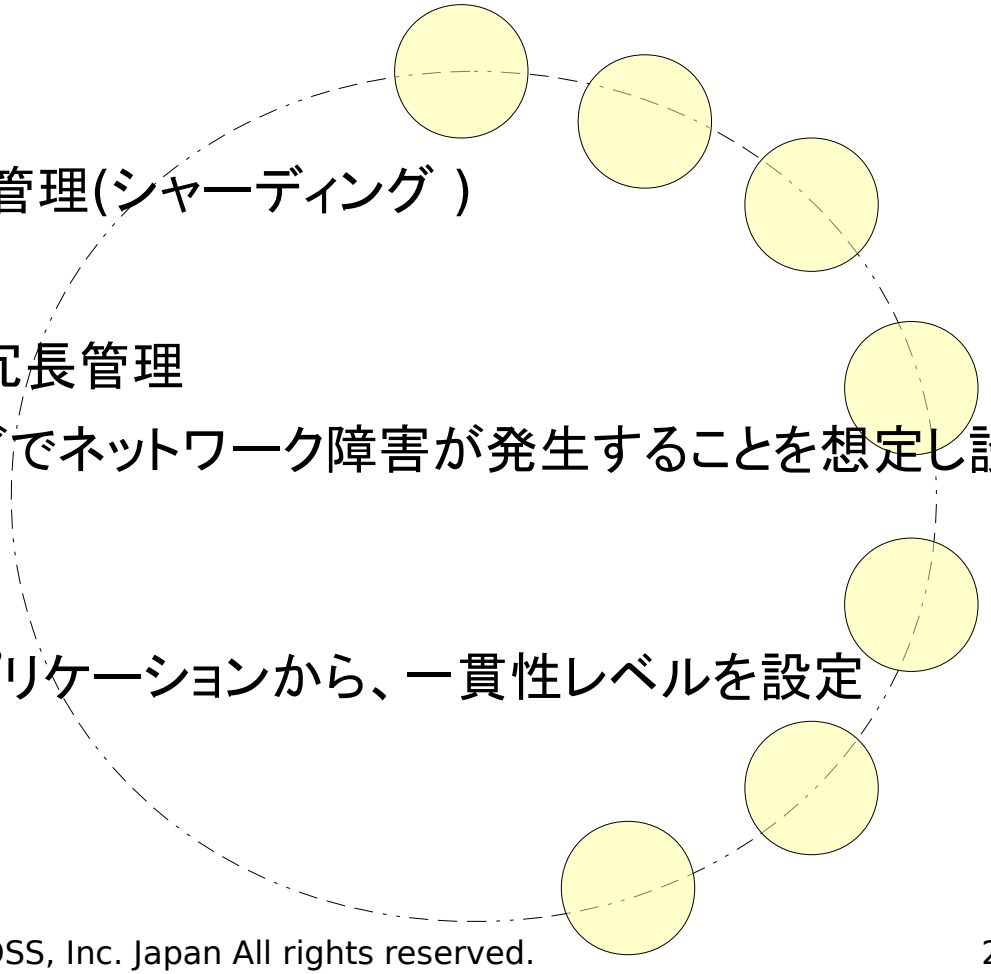

Cassandraデータモデル

Cassandra スキーマ

- keySpace
  もっとも外側のデータ格納領域
  RDBMSのデータベースに相当
  複数作成可

- カラムファミリ or スーパカラムファミリ
  論理データの集合
  RDBMSのテーブルに相当
  複数作成可

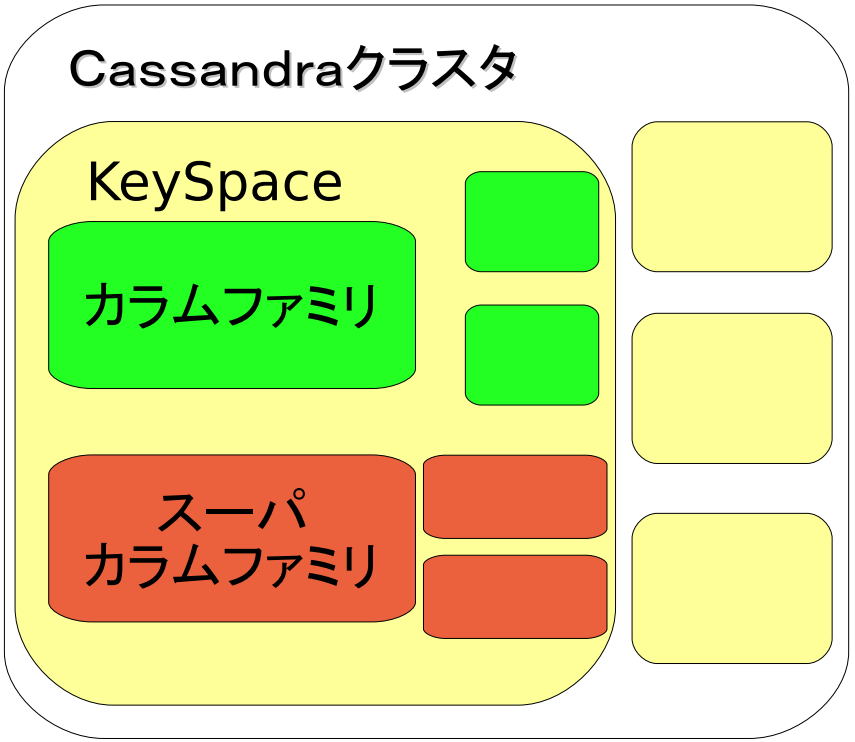

カラムファミリ

- カラムファミリは複数の「ロウ」で構成
- 各ロウには、ユニークな「ロウキー」を指定する
- 各ロウには、ロウキーに従属した複数の「カラム」により構成される
- カラムには「名前:値」が格納される
- [カラムファミリ名][ロウキー][カラム名]を指定して値にアクセス

(注)
各ロウに入っているカラムの名前は異なっていてもよくデータ格納時に名前を決定できる

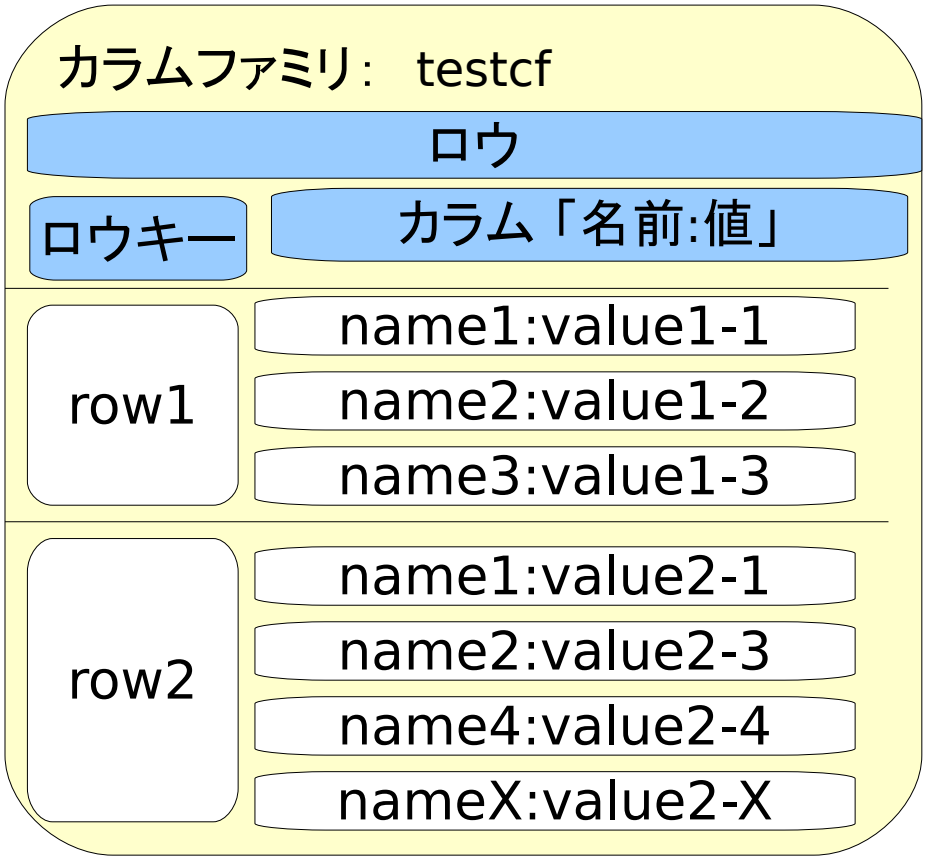

Cassandra概要

マルチマスタ

RDBMSで一般的な
マスタースレーブ構成

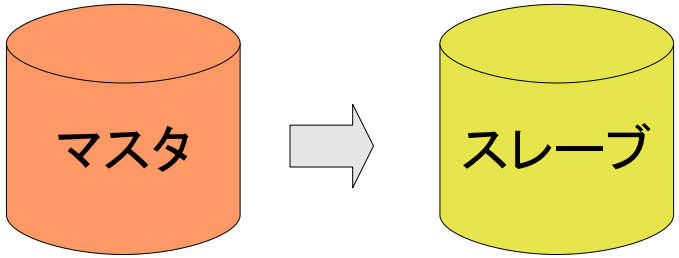

VS

Cassandraのマルチマスタ構成

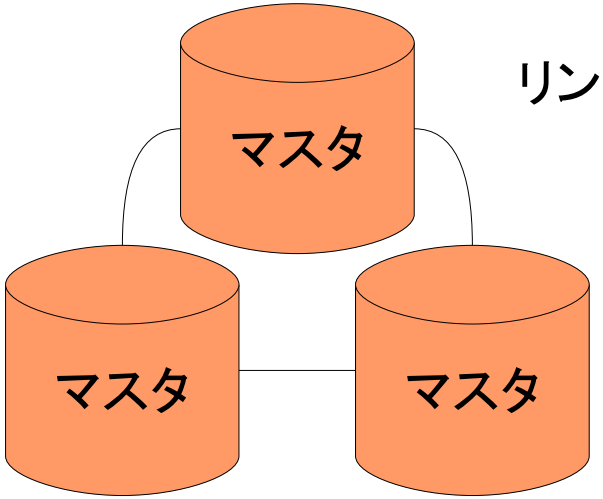

一般的なRDBMSにおける
クラスタ構成

書き込みはマスタで
読み込みはマスタ･スレーブ

書き込み、読み込みを
アプリケーションで切り替える.

Cassandraでは

すべてのノードが対等な関係で
読み書き可能

すべてのノードが振り分け先
を決める(proxyとして機能)

スケーラビリティ

- ダウンタイムなしにノードの追加が可能
- 各ノードに担当データ範囲(Token)を設定しデータを格納

  キーをハッシュ化して、Tokenと比較し担当ノードが決定される

  Partitionerも選択可　（ランダム or 値順）

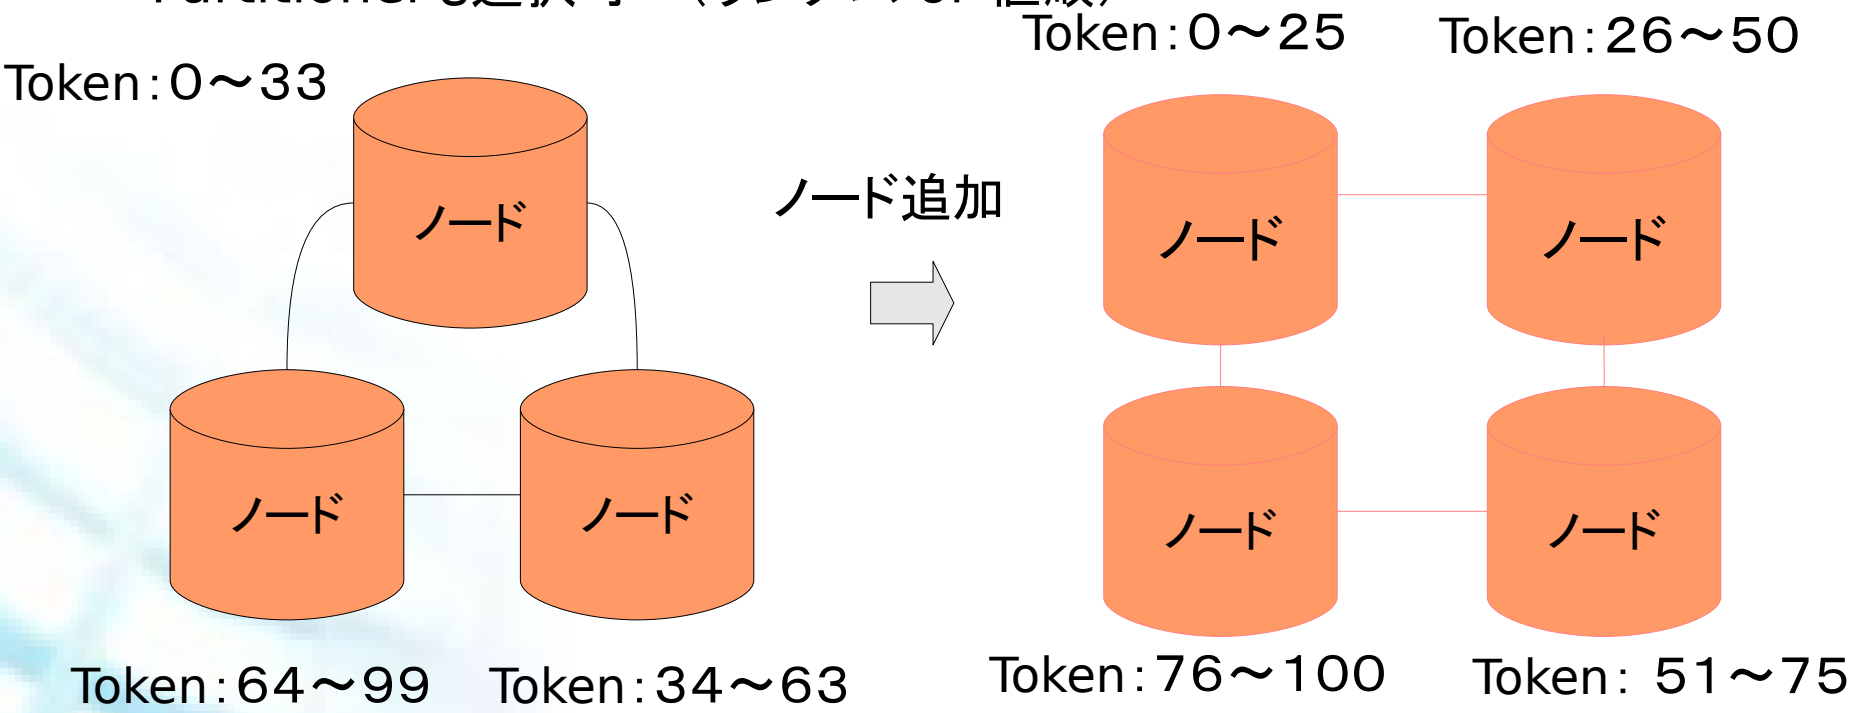

レプリケーション

- データの冗長化
  - キースペース単位でレプリカ数を決定
  - 隣のTokenを持っているノードがレプリケーション先となる
  - DCやラックを考慮したレプリカ戦略も可能

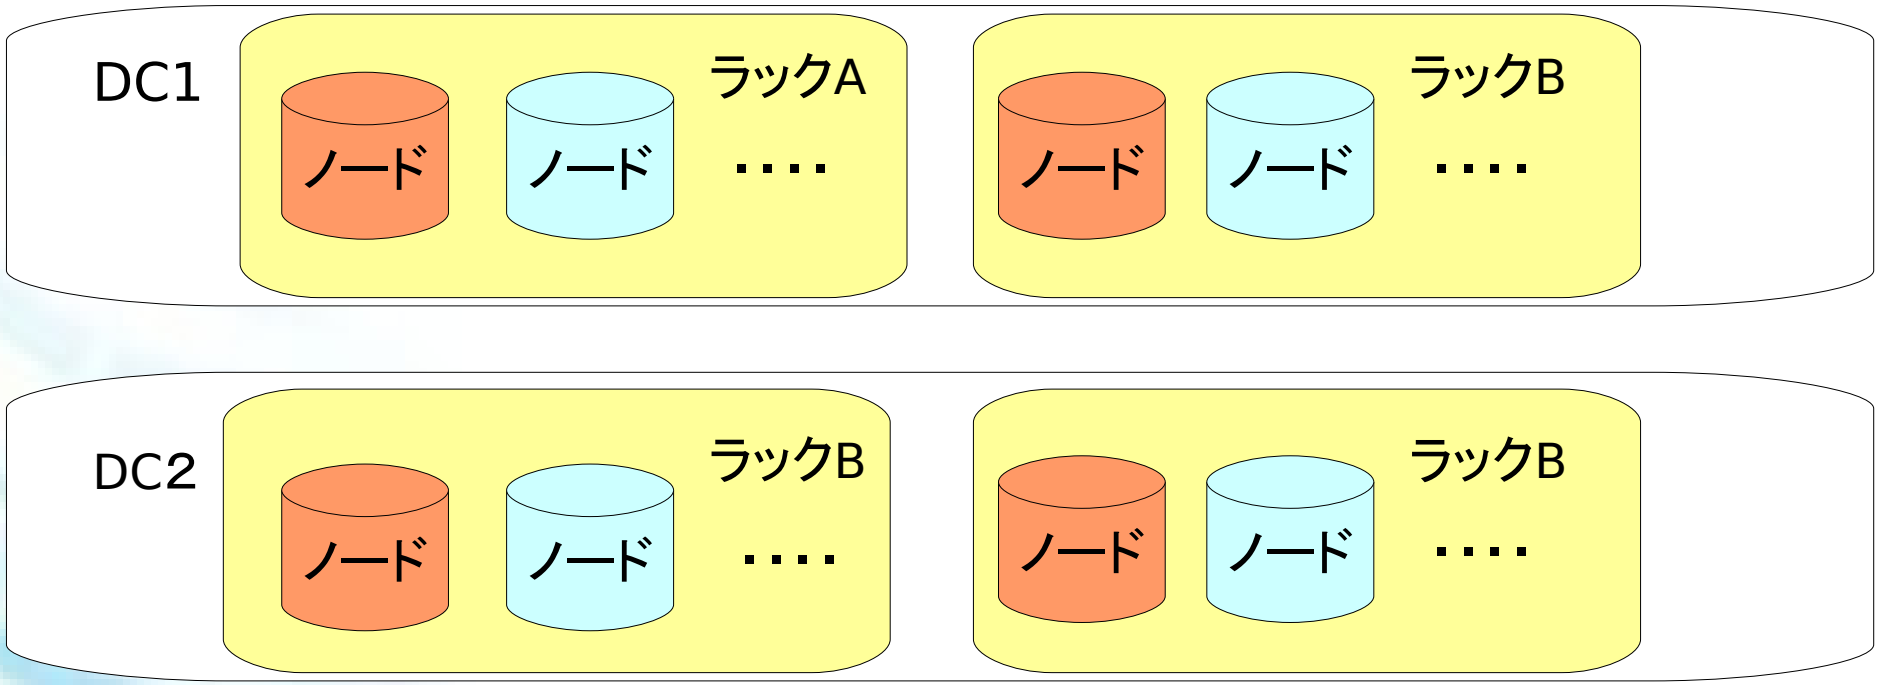

一貫性レベル①

- WRITE/READを行うときにアプリケーションで一貫性を調整

  指定するパラメータ

  ONE,TWO,THREE,QUORUM,ALL,LOCAL_QUORUMEACH_QUORUM

  ANY (WRITEのみ)

- WRITEのときに
  - レプリケーション数（N)に従って書込みを行うときに書込み完了を待つノード数を指定する。 書込み完了を待つノード数をWとする
  - 例) レプリケーション数 5　QUORUM(過半数）の場合には、3台の書込み完了を待ち、残りの2台は非同期でレプリケーションが行われる
- READのときに
  - レプリケーション数(N)以内で読み込みを行うノード数を指定する。

    読み込みを行うノード数をRとする。
- R ＋ W ＞ Nを満たせば最新のデータが読み込めて、一貫性が保てる

一貫性レベル②

N=5, W=3, R=3の場合には,R+W >N (R > N-W) を満たすので
最新データが読み込める

N:レプリケーションするノード数

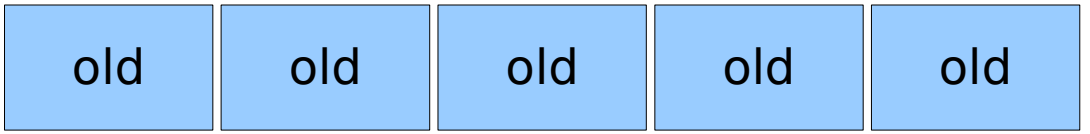

W:書込み完了を待つノード数

R:読込みを行うノード数

一貫性レベル③

- 注意事項
  - RDBMSのような”強い”一貫性は保てない
    - RDBMSでいうところのMVCCレベルでの一貫性は保てない
    - Cassandraでは複数のノード間で行データを取得し
      一貫性レベルに従って比較して返す
      （行レベルの操作ですらアトミックではない）
      トランザクションや、テーブル間にまたがる一貫性ももちろん
      保証されない
    - 各ノードの時刻に依存してデータを管理する。
      NTP以上の分解能は見込めない

高可用性と対障害性①

- ノード情報の伝播は Gossip プロトコル
  - 障害を検知したノードを起点に情報（噂）が広まるように伝播する
  - 低オーバヘッド

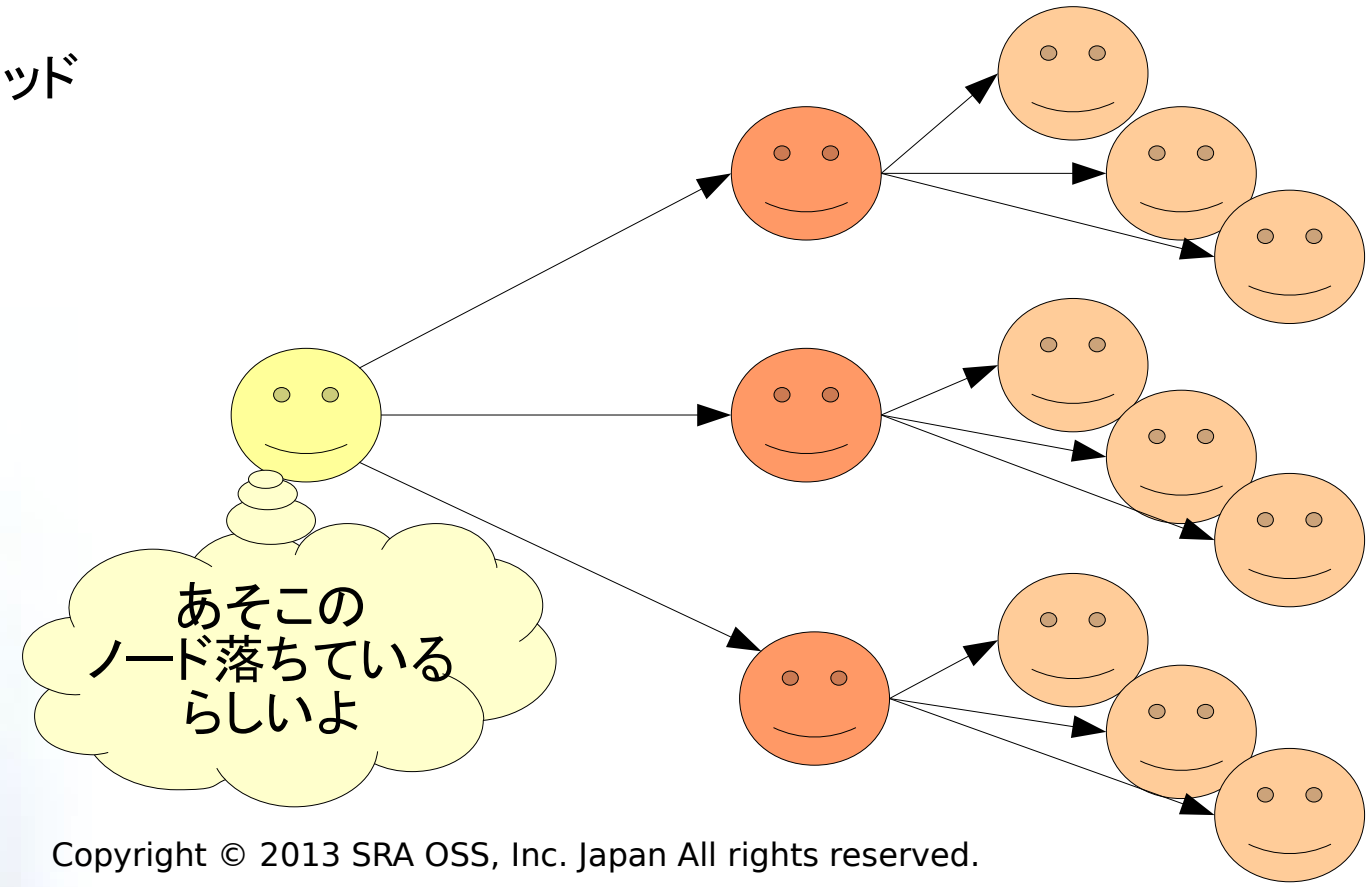

高可用性と対障害性②

- ネットワーク分断やノード停止を考慮
  - 障害回復時に、3つの処理によってデータ同期が行われる
    1. ヒントハンドオフ
    2. リードリペア
    3. アンチエントロピー

ヒントハンドオフ

- 担当ノードに障害が発生していたときに、処理を受け取ったノードが追加データを一定期間預かる仕組み
- 担当ノードが復帰時に自動的に同期が行われる
- ロウ単位の復旧

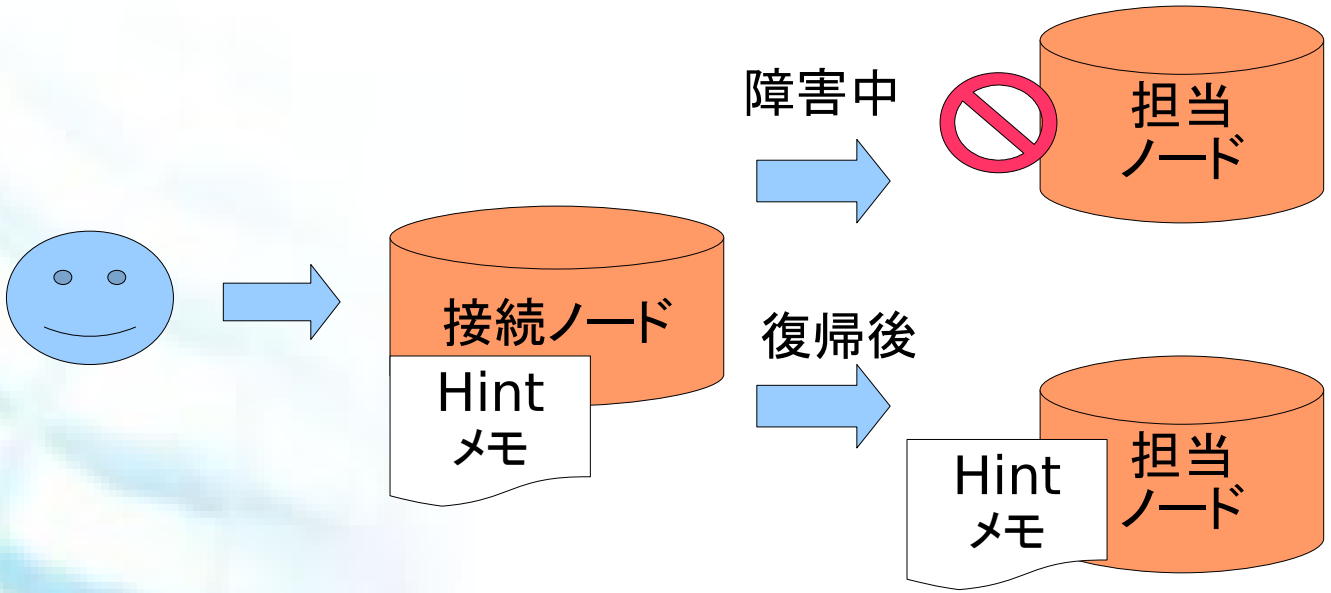

リードリペア

- READのときにデータ復旧

  複数の担当ノードから返却されたデータを比較して、異なっていた場合は最新のデータで更新する

- ロウ単位の復旧

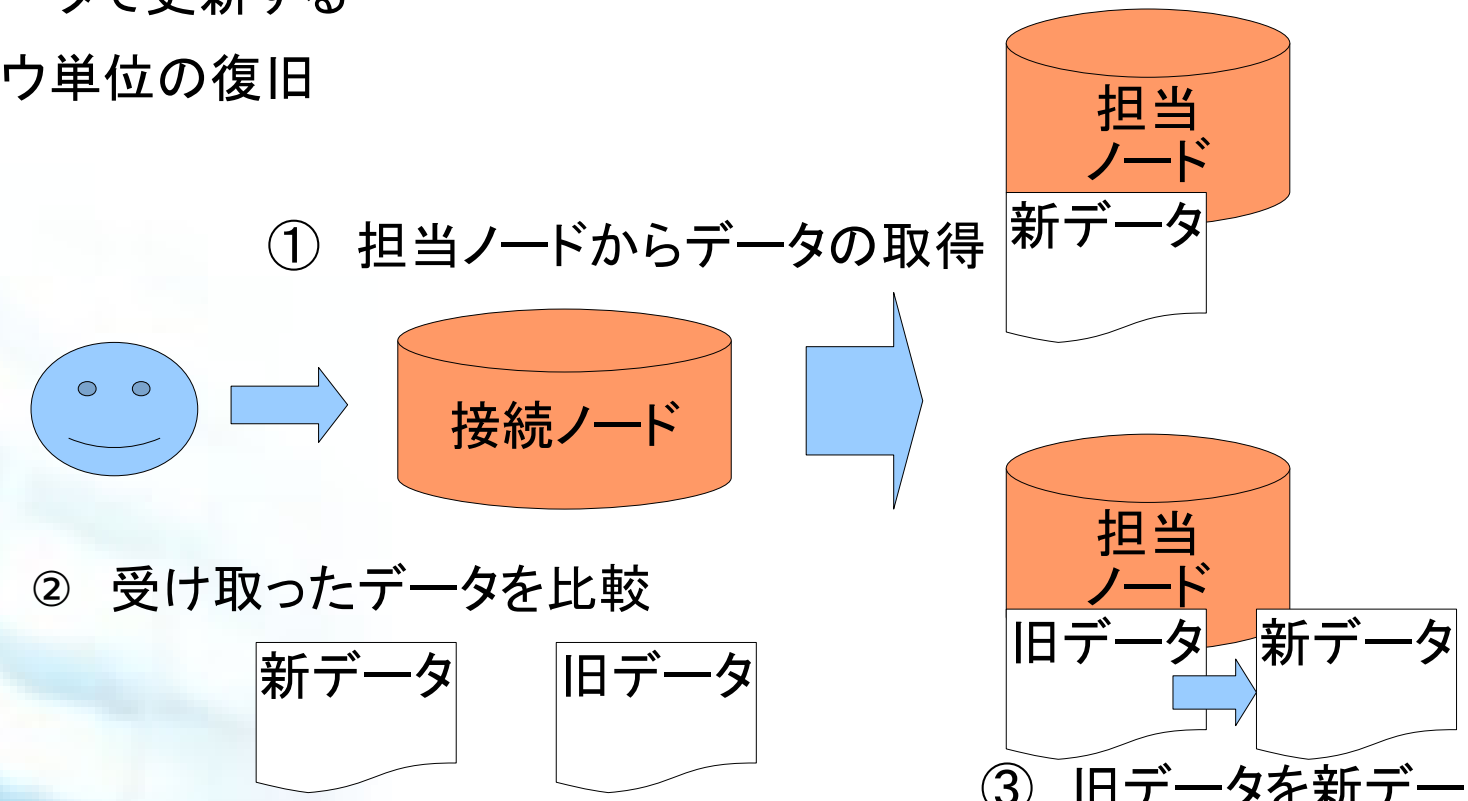

アンチエントロピー

- 各ノードがもっているデータの比較を行って結果が異なる場合にはデータ転送が行われる

  ハッシュ値(マークルツリー)を利用してデータ比較を行い転送コストを削減

- カラムファミリ単位の復旧

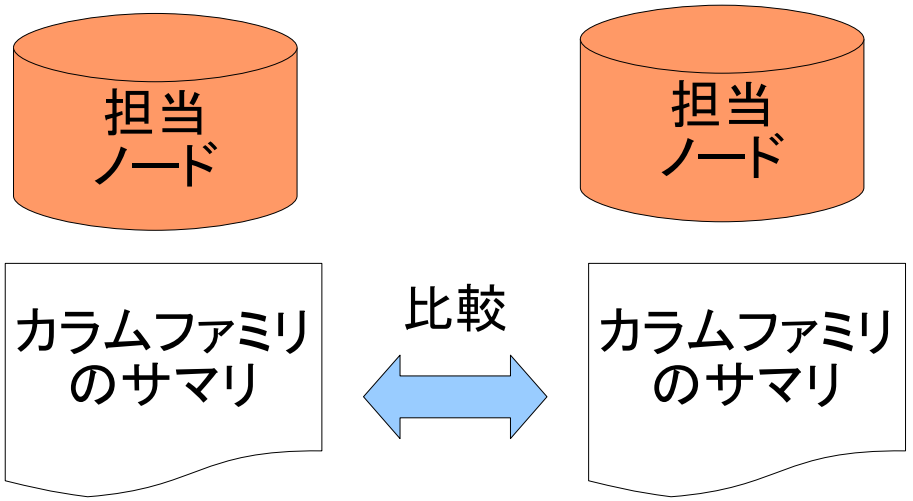

Cassandraの内部構造

- プロセス

  SEDAと呼ばれるステージ(処理)毎にイベントドリブン型のアーキテクチャ

  大規模なアクセスをさばけるイベントドリブン型　＋ リソースをステージ毎に設定可能

- データ構造

  commitlog　・・RDBMSでいうところのトランザクションログ(redo log)

  　　電源断などの復旧時はcommitlogからデータを復元

  memable　・・RDBMSでいうところの共有メモリ

  　　memtableが溢れるとDISKにフラッシュ

  sstable　・・DISKに書き出されるデータ

  　　(キーでソートされて書き出される)

書込み処理

① 受け取った書込み要求はCOMMITLOGに書き出される

② memtableにも変更内容を反映
ここでユーザに結果を返却

③ バックグランドでmemtableの内容をフラッシュして、sstableが生成される

sstableはコンパクションを除き変更されない

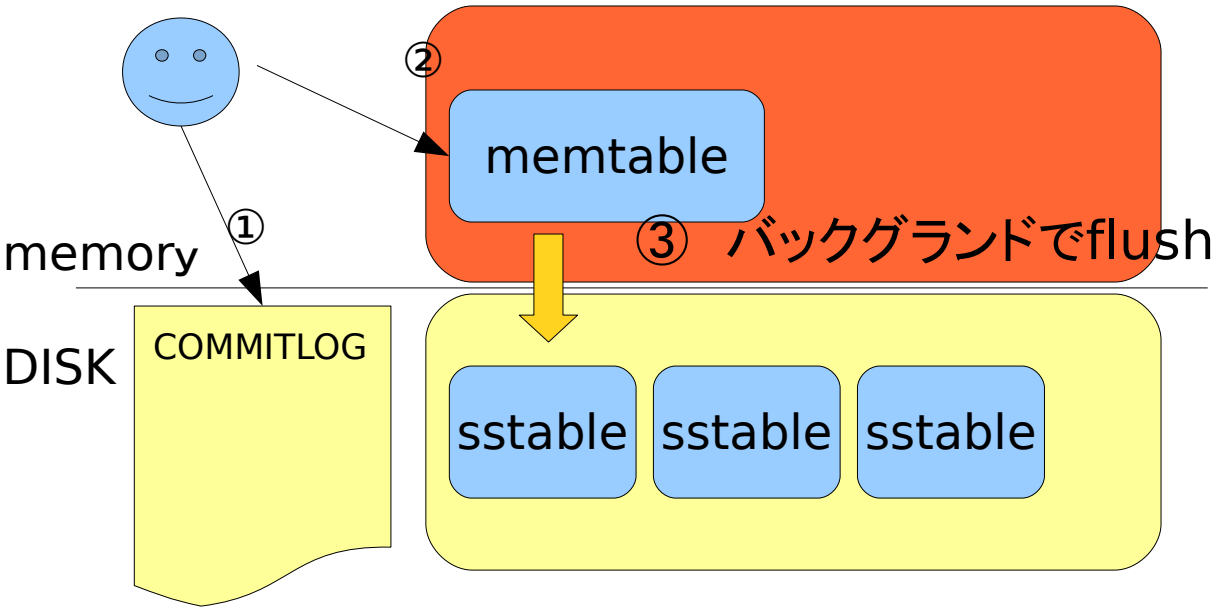

sstableはカラムファミリ単位で管理
memtableをフラッシュするとカラムファミリにつき一つ作成される

読み込み処理

- メモリ上のmemtableやcacheから探して返事を出す
- メモリ上にデータが無ければsstableから読み込む

  複数のsstableをスキャンする必要あり(indexやbloomfilterで効率化)

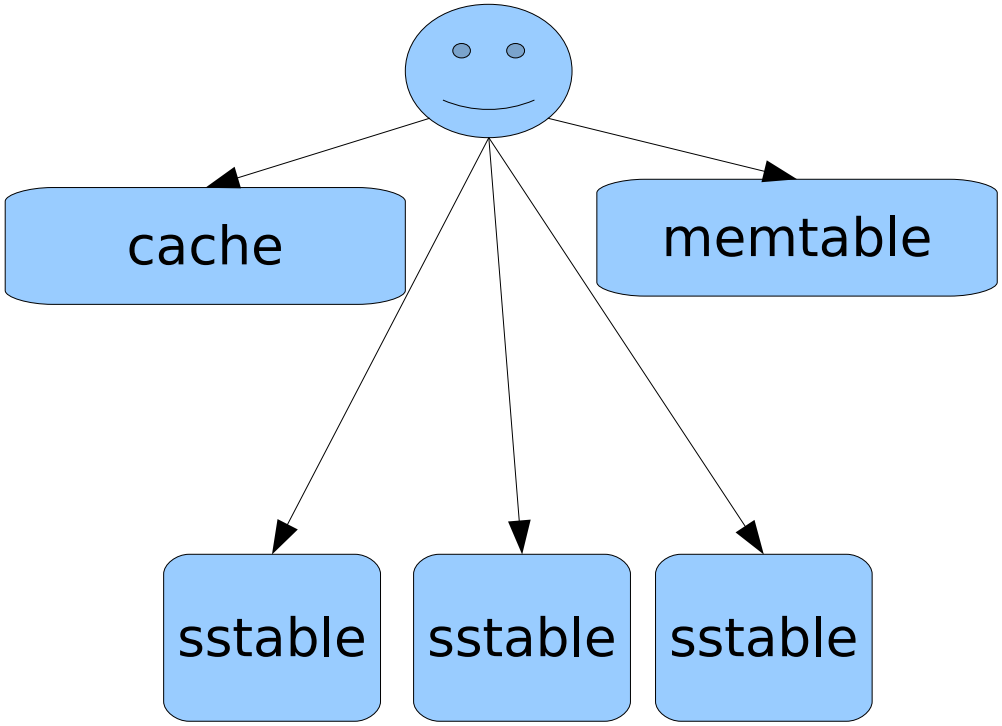

障害ケース

- Cassandraのノード障害

  ノードが1台でも動いていれば (一応) 動作は可能

  クライアントが発行するクエリに依存する

  例)

  クライアントがConsistency level ALLで書込みを行った場合には、レプリケーション先の全てのノードで書込みを行えない場合にはエラーを返す

  Consistencyを優先とすると、Availalivityを損なう

  クライアントAPIでは、複数のノード指定が可能なものがあり、障害があったノードを自動で切り離す

  例) Java　hectorライブラリ

  　　php　phpcassaライブラリ

HBase Cassandra 共通事項

コンパクション

- 複数の物理ファイルをまとめる処理

  サイズの縮小、リードの効率化

- 有効期限切れのデータやトゥームストーン(削除データ)の削除も

  同時行われる

- バックグラウンドで自動的に行われ、数個の物理ファイルが一つにまとめられる
  (マイナーコンパクション)

- 管理コマンドや定期的に一つの物理ファイルにまとめる

  (メジャーコンパクション)

  HbaseもCassandraもランダムアクセスを極力避けるために、

  直接物理ファイルを変更せずにコンパクションによって、無効データの削除

  を行い物理ファイルの統合が行われる

  このため、WRITEは追記のみであり、極めてWRITE性能が高い

ベンチマーク

- NoSQLベンチマーク比較

  http://www.networkworld.com/news/tech/2012/102212-nosql-263595.html

  A vendor-independent comparison of NoSQL databases

  pdfファイル

  http://gotocon.com/dl/goto-cph-2012/slides/big-data/Evaluating%20NoSQL%20performance.pdf

  Cassandra,HBase,MongoDB,Riak,Shared MySQL, MySQLクラスタの性能比較