

分散 KVS の概要と okuyama の紹介

スクエア free セミナー 第9回

株式会社リンク
ディベロッパーサポート
文屋 宏

自己紹介

○氏名

文屋 宏(ぶんや ひろし)

○所属

株式会社リンク ディベロッパーサポート

○業務

プロジェクトマネージャっぽいこと

○興味あること

分散データベース, クラウドコンピューティング, ウェブ系の技術

○活動

日本 Red5 ユーザー会メンバー

会社紹介(at+link とは)

株式会社リンクは
at+link の営業窓口

LINK, INC.

株式会社リンク

お問い合わせやお申し込みの受付窓口、
営業担当による訪問、広報・宣伝など
を担当しています。

ディベロッパーサポート

- ・開発者のためのサービス開発
- ・開発者の悩み相談

営業・契約窓口

技術サポート・
ハードウェア構築

at+link

オンサイト保守

netforce

株式会社ネットフォース

データセンターに常駐し、ネットワーク
管理とオンサイト保守を行っています。


A.T.WORKS

The Next Quality

株式会社エーティーワークス

ハードウェア製造・ソフトウェア開発
のほか、サーバ運用に関する技術サポ
ートを提供しています。

講演内容




- ・自己紹介 & 会社紹介
 - ・NoSQL について
 - ・KVS について
 - ・memcached のデモ
 - ・様々な KVS
 - ・okuyama について
- 

分散処理 の必要性


サービスが成長してきたとき、どうする？

スケールアップ



- ・ハードウェア的な限界がある
- ・ネットワーク集中
- ・コストパフォーマンスが悪い
- ・障害に弱い

スケールアウト



- ・ハードウェア的な限界がない
- ・ネットワーク分散
- ・コストパフォーマンスが高い
- ・障害に強い(高可用性)

Web サーバだけでなく、DB サーバも分散させたい！

データベースソフトウェアの分類

RDBMS

- ・Oracle
- ・MySQL
- ・PostgreSQL
- etc.

一貫性重視
スケールアップ


NoSQL

- ・カラム指向型
- ・ドキュメント指向型
- ・**キー・バリュー型**
- etc.

パフォーマンス重視
スケールアウト


KVS は NoSQL の一種
NoSQL = Not Only SQL

RDBMS と NoSQL は互いに補完し合う存在
どちらが優れている、ということはない



どんなシステムでも、何かを
犠牲にしなければいけない・・・

CAP 定理による NoSQL の分類



[参考]

・Visual Guide to NoSQL Systems
<http://blog.nahurst.com/visual-guide-to-nosql-systems>

・NoSQL登場の背景、CAP定理、データモデルの分類
<http://www.publickey1.jp/blog/10/nosqlcap.html>

・WEB+DB PRESS Vol.58
Cassandra 実践入門

Key-Value Store


Key-Value Store とは

- ・[Key, Value] のセットでデータ保存
- ・Key を指定して Value を取得
- ・処理を簡単にしてパフォーマンス向上

用途

- ・キャッシュ
- ・パフォーマンス重視のデータベース
- ・分散ファイルストレージ
- ・解析用のログ保存

KVS のデモ



キャッシュの代表 memcached
をさわってみよう



デモをご覧ください



memcached だけだと...

キャッシュサーバはすごく大事
でも...

○あくまでもキャッシュに特化

⇒永続型 KVS も必要

○分散多重保存できない

⇒分散型 KVS が必要

KVS には得意・不得意が

■分散多重保存が得意

Flare, kumofs

■データ永続化が得意

Tokyo Tyrant, Flare, kumofs

■データの一貫性を保つのが得意

memcached, Tokyo Tyrant

「何でも得意」な KVS は無い！

分散アルゴリズム

データをどのサーバに保存するか

ハッシュ法 (Mod 法)

MD5などでキーからハッシュ値を計算

→ 得られたハッシュ値をサーバー台数で割った余り




サーバ追加時にデータ移動が大量発生

コンシステントハッシュ法

コンシステントハッシング

ノード増減によるデータ移動を最小限にできる！



- ・ノードやキーを仮想リング上に配置
- ・ノードの IP や、Key 値をハッシュ関数に通す
- ・それぞれ、リング上の該当位置に配置
- ・時計回りで最初に遭遇するノードが担当

国産 KVS

国内だけでも、こんなにたくさんの開発者が

分散型

○Tokyo Tyrant 平林幹雄 氏(当時 mixi)

○Okumofs 古橋貞之 氏(筑波大)

○Flare 藤本真樹 氏(GREE)

○ROMA 西澤無我 氏(楽天)

○Okuyama 岩瀬高博 氏(神戸デジタル・ラボ)

素晴らしい！！

国産 KVS

分散型

○Tokyo Tyrant 平林幹雄 氏(当時 mixi)

○Okumofs 古橋貞之 氏(筑波大)

○Flare 藤本真樹 氏(GREE)

○ROMA 西澤無我 氏(楽天)

○Okuyama 岩瀬高博 氏(神戸デジタル・ラボ)

at+link でサービス化！



分散型 KVS「okuyama」

okuyama の特徴

■分散多重保存できるか

⇒ 得意！！


■データを永続化できるか

⇒ 4段階レベルを選択可能！！


■データの一貫性を保てるか

⇒ 3段階レベルを選択可能！！


okuyama って、CAP 定理だどこ？



okuyama って、CAP 定理だどこ？



okuyama の構成イメージ




Client → Master Node → Data Node(×3)

(以降 okuyama 関連資料
神戸デジタル・ラボ 岩瀬高博 氏 提供)

okuyama クライアント

okuyamaへの問い合わせを実現
専用クライアントはJavaと、PHPを実装



okuyama マスターノード

・クライアントからのI/F ・データノード管理

・サポートプロトコル

>オリジナル

>Memcached

・set ・get ・add

・delete

・gets ・cas

>HTTP

・GET

>データ入出力

サポート分散アルゴリズム


1. Mod

2. ConsistentHash

>生存監視


起動時のデータリカバリ

・制限台数なしに冗長化可能



okuyama データノード

- ・データの保存を実現
- ・データ保存方式を選択可能
- ・最大3ノードにデータを保存
- ・アクセスバランシング
- ・連鎖的ダウンの予防



データ保存方式の選択

1.全てのデータをメモリに保存

>非永続型 (key=メモリ、value=メモリ)

2.データ操作履歴のみファイルに保存

>永続型 (key=メモリ、value=メモリ) + 操作記録ファイル

3.データ本体をファイルに保存


>永続型 (key=メモリ、value=ファイル) + 操作記録ファイル

4.全てをファイルに保存

>永続型 (key=ファイル、value=ファイル) + 操作記録ファイル

データの一貫性について

複数のノードに同一の値を保持していると、
データに異なる時間が発生する



データ一貫性レベルの選択

1. 弱一貫性

> 全てのデータノードにランダムにアクセス

2. 中一貫性


> 常に最後に保存したデータノードからアクセス

3. 強一貫性

> データノードの値を検証

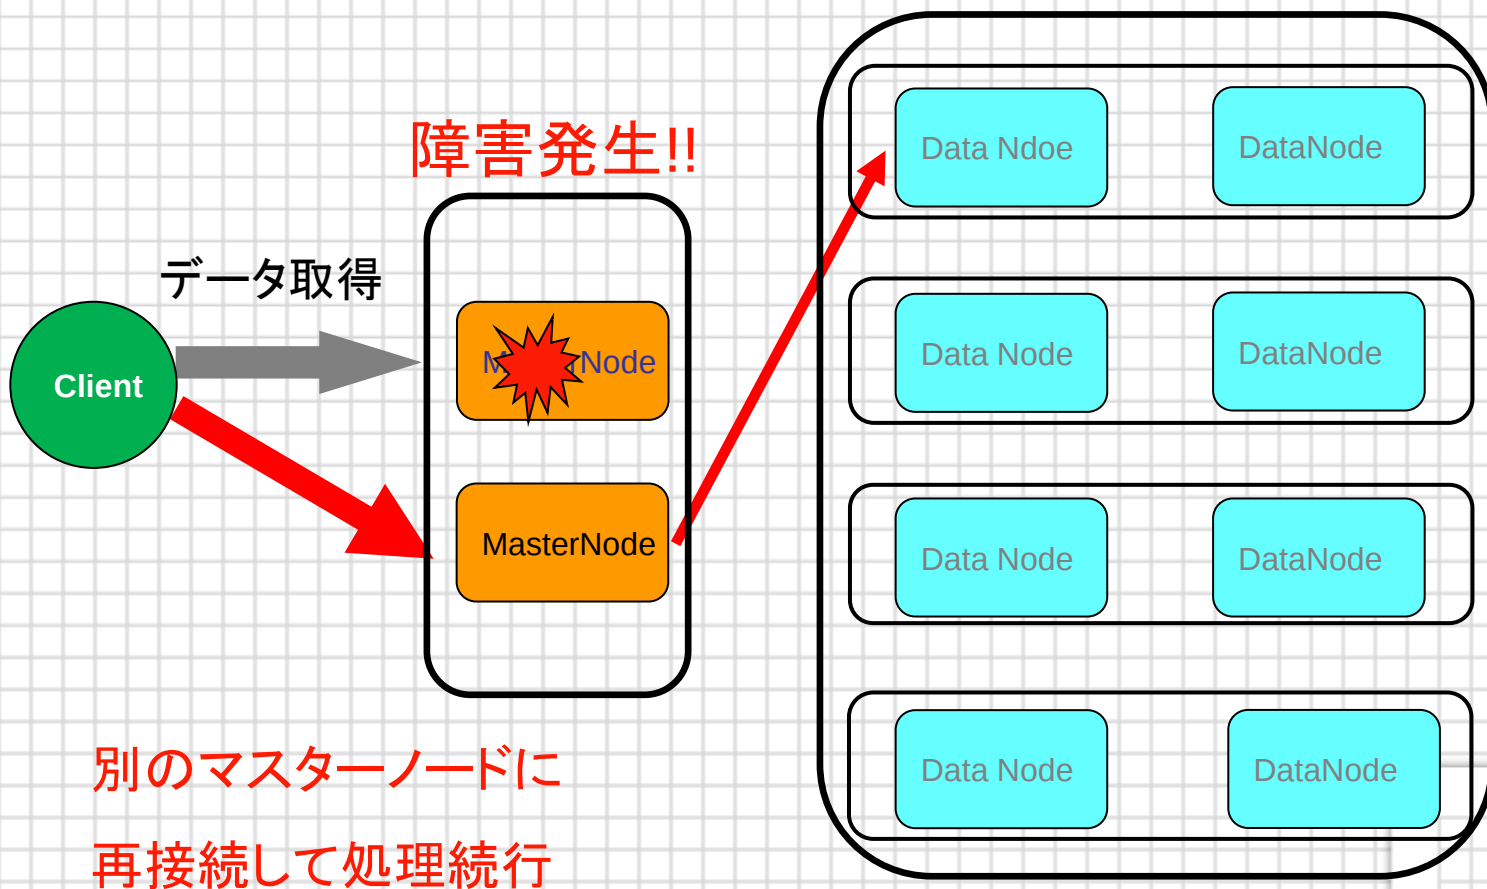
okuyama に単一障害点はない！

データノード障害発生



okuyama に単一障害点はない！

マスターノード障害発生





詳しくは、岩瀬氏の資料をご覧ください


○Think IT 連載記事

<http://thinkit.co.jp/story/2011/02/03/1990>


○講演資料

<http://www.slideshare.net/okuyamaoo/20110517-okuyama-8035077>

まとめ



- ・拡張性、可用性の面から KVS (NoSQL)
 - ・KVS (NoSQL) も色々
 - ・得意・不得意がある
 - ・用途によって使い分けよう
 - ・国内にも素晴らしい技術者がいっぱい
 - ・okuyama オススメ
- 



ご清聴ありがとうございました



では、KVS サービス化の話へ

