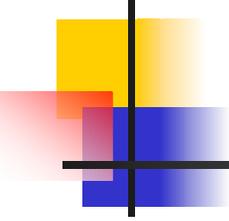


MySQLによる ミッションクリティカルサービスの 設計と運用

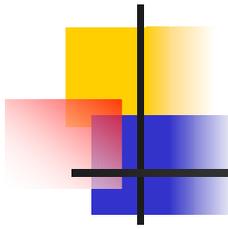
飯坂 剛一 / Office ISK

渡辺 隆志 / (株)Infoseek



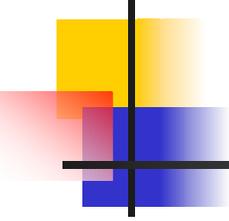
進行予定

- 自己紹介と項目説明 3分
 - 「場」になれるための時間。リラックス～
- MySQLとInfoseek 3分
- 設計関連 12分
- 運用関連 15分
- チューニング関連 12分
- 質疑応答 5分



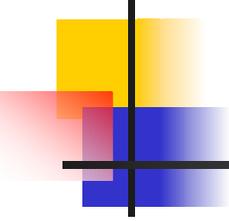
設計関連 (TOC)

- ソフトウェア構造
- Barista / Tea
- Java からのMySQLアクセス mm.mysql
- Auto Reconnectionの設定方法
- Connection Poolingについて
 - DBConnectionBroaker
- DB構造
- ロールバック



運用関連 (TOC)

- 機材選定
- OSの選択
- クラスタ
- 設備投資の内訳
- 機材構成概要
- バックアップ
- アクセス集中について

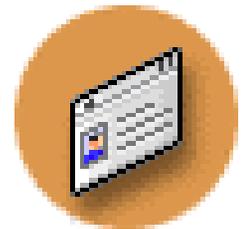
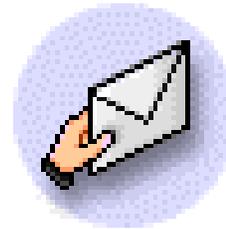
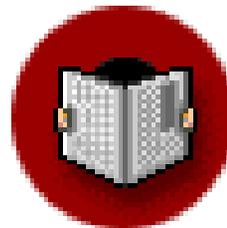


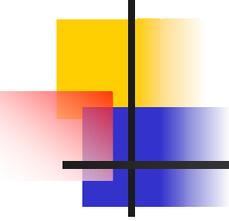
チューニング (TOC)

- Linux
- Java
- MySQL

MySQL と infoseek

- プロフィール
- メール
- ニュース検索
- 不動産検索
- スクール検索

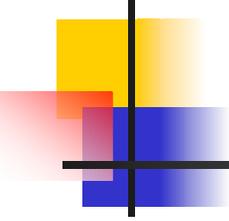




MySQLを使った理由



- MySQLの長所にある
 - コスト
 - サーバサイドでのData Replication
 - ハイパフォーマンス（速い）
 - 保守がしやすい



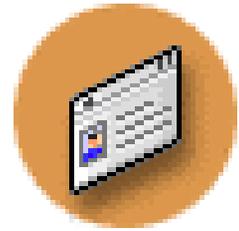
MySQLに不満はある？MySQL™

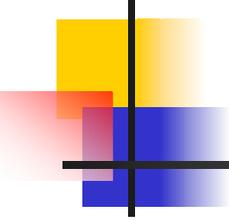


- 短所もやはり...
 - Cursor や View などがなくSQL仕様で劣る
 - 結局は使い方で回避できる
 - それを実装することで遅くなるのなら不要！
 - Larry Wallも言っている
“There’s More Than One Way To Do It!”
 - Raw I/O ができない
 - やっぱりORACLEは良い

infoseek ではどうしたか

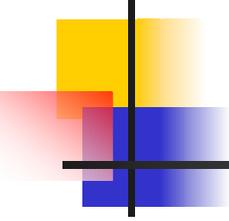
- こうしたことをふまえて、プロフィールを例にとり、どう対応していったかを話そう





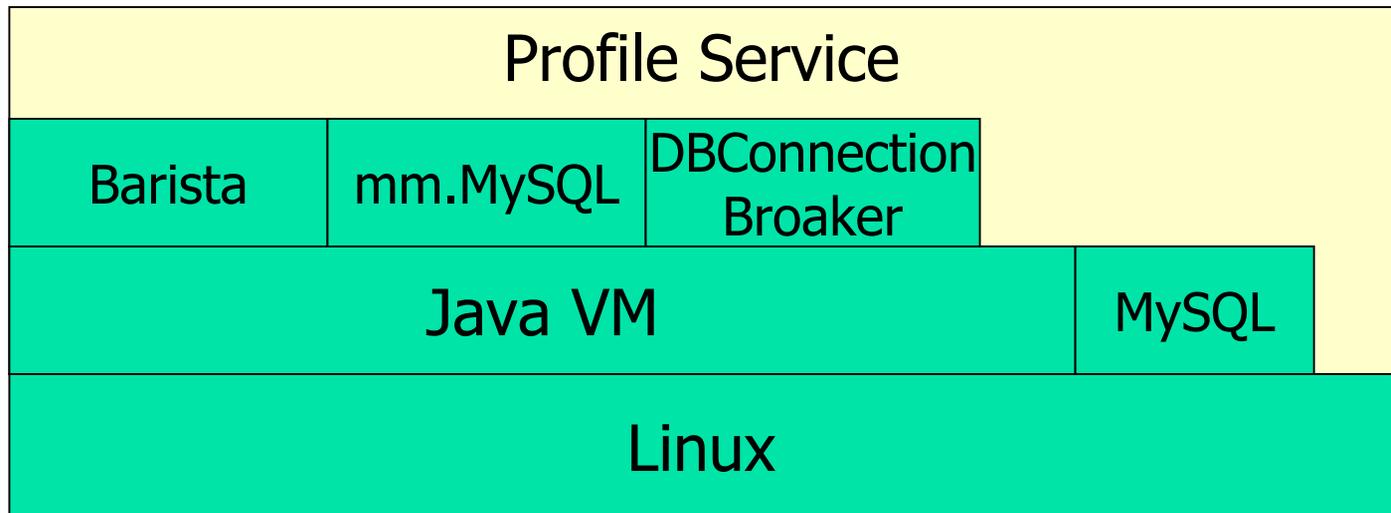
設計関連 (TOC)

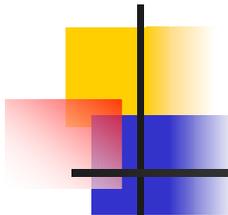
- ソフトウェア構造
- Barista / Tea
- Java からのMySQLアクセス mm.mysql
- Auto Reconnectionの設定方法
- Connection Poolingについて
 - DBConnectionBroaker
- DB構造
- ロールバック



ソフトウェア構造

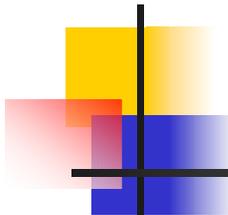
- プロフィールサービス





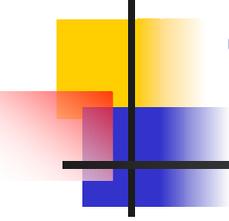
Barista

- WDIG(旧Go.com)が開発した、Pure Java Servlet Engine (Servlet 2.3 対応)
- 強力なLog機能 (Trove log API)
 - <http://opensource.go.com/>
- 高パフォーマンス
- Servlet EngineごとIDE上で起動できるので、Servletの開発が容易
- 残念な事に、外部には非公開。



Tea (1)

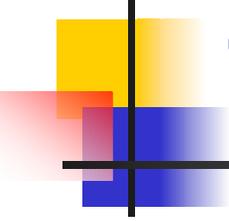
- WDIG(旧Go.com)が開発した、JavaVM用 Template言語
- ESPN.com, Movies.com, ABCNews.com and Disney.com.等で使用されている。
- 現在は、オープンソースで配布
 - <http://opensource.go.com/>
- O'REILLY Java Servlet Programming 2nd Editionで、一章を割いて解説されている。



Tea (2)

■ 特徴

- 平易な文法
- JAVA BEANSにより、データを分離できる
- class ファイルへ、直接Compileされる
- IDEが用意されている(日本語では不具合あり)
- Servlet以外にも、汎用のTemplate言語として使用可能

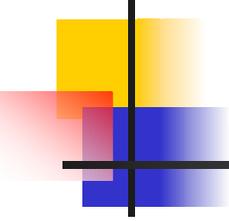


Tea (3)

■ コード例

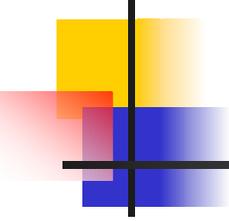
```
<% template HelloSample() * >
<HTML><BODY>
<%
request = getRequest("EUC_JP")
myName = request.parameters("name") %>

Hello <%myName%> <HR>
<%
if myName == "OSDN"{
    "Nice !!(^ ^)"
}
%>
</BODY></HTML>
```



Java からのMySQLアクセス

- MM.MySQL
 - GPLな、Type4 (Pure Java) JDBC1/2 Driver
 - 入手先
 - <http://mmmysql.sourceforge.net/>
- *最新版は、このページには書いていないので注意



MM.MySQLの設定方法

- 設定方法

- 配布アーカイブ内の、README内に記述

- 日本語を使う際には

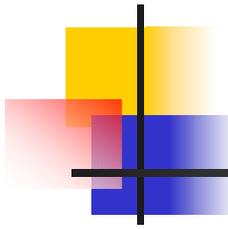
- useUnicode

- characterEncoding

の指定が重要

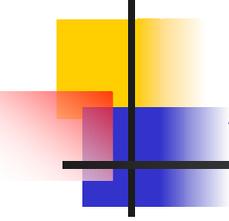
- JDBC URLの例

```
jdbc:mysql://dbhost:3306/test?user=isj&password=jsi&useUnicode=true&characterEncoding=EUC_JP
```



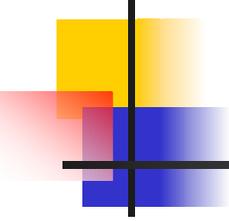
Auto Reconnection機能

- MM.MySQLには、Auto Reconnection機能がある。
- Statementを実行する際などに、Connectionが切れていた場合、自動的に、Connectionの再接続を行う。



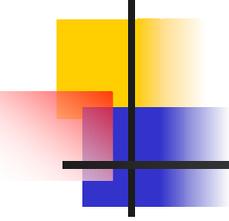
Auto Reconnectionの設定方法

- JDBC URL パラメータで指定
 - autoReconnect
 - Auto Reconnection を行うかどうか (true or false)
 - maxReconnects
 - 何回Reconnectを試行するか
 - initialTimeout
 - Reconnectを試行する間隔 [sec]



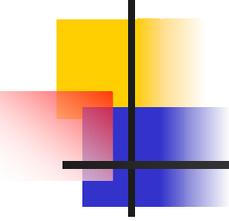
Connection Pooling

- Infoseek では、
DbConnectionBroker
(<http://javaexchange.com/>)
を使用。
- MM.MySQL単体でも、ver 2.0.9より
PooledConnectionDataSource
で、ConnectionPoolingを行うことができる。
(Infoseekでは、使用を検討中)



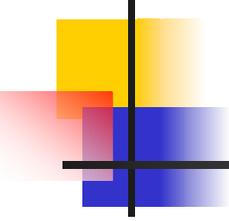
DBConnectionBroaker

- 汎用の、Connection Poolingライブラリ
- 長所
 - フリーである
 - 設定が簡単
 - Auto Reconnection機能
- 欠点
 - JDBC 2.0 Optional Packageとは異なるAPI



DB構造

- KEYの設定は重要
 - パフォーマンスに非常に影響する
- デフォルト値を利用する
- Mod Timeには特性(癖)がある

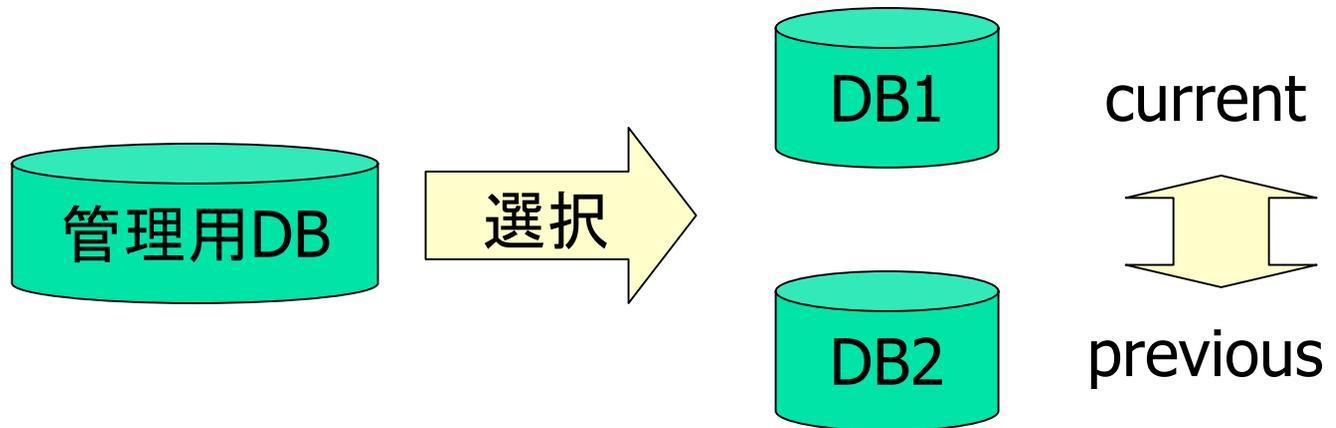


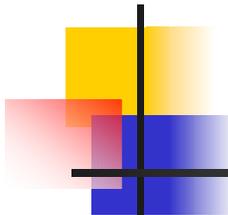
ロールバック (1)

- プロフィールではやっていないが...
- データ更新を意識して利用すべき
 - 元データが「いつも正しい」とは限らない
 - ダンプによりデータを戻すのは非現実的

ロールバック (2)

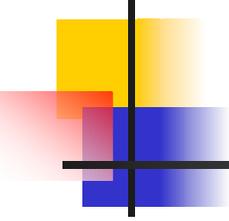
- 同じ構造のDBを複数定義





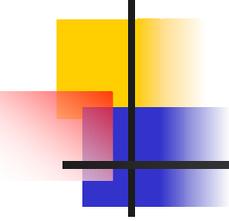
設計で気をくばった点

- プロフィールサービスについて
 - JOINを避けるために、一覧表示に必要なデータは、On MemoryでCache
 - Lockを減らす為に、頻繁に追加、更新がかかるデータ(Counter, FootPrint等)は別Tableに移す
 - 不必要なデータは、On timeでなく、Off timeでBatch処理により削除



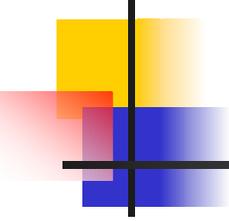
運用関連 (TOC)

- 機材選定
- OSの選択
- クラスタ
- 設備投資の内訳
- 機材構成概要
- バックアップ
- アクセス集中について



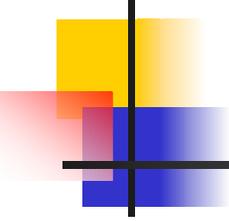
機材選定 (1)

- 機材選定はとても重要
- 速いものは良い
- 速くても不安定は困る
- パフォーマンス VS コスト
- 誰も保守できないのは困る
- 誰もが知っているのも困る



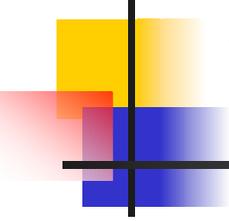
機材選定 (2)

- マシンが落ちると信用も落ちる
 - 常時接続の普及
 - サービスはますます落とせない
- 連続稼働率
 - 1年で30分のサービス停止しかないとき？
 - 1年 = 525,600分
 - 99.9942%



OSの選択

- [SysAdmin](#) 2001年7号より
- メール処理能力は：
 - Linux > Solaris > FreeBSD > Windows2000
- ファイルのリード・ライトでの処理能力
 - Linux > Windows2000 > FreeBSD > Solaris



Web ApplicationとLinux

- 低い投資コスト
- 非常に相性がよい
- パフォーマンスが良い
- セキュリティには気を配る必要あり
 - 必要なデーモンのみ起動
 - プライベートネットワークに押し込む

並列Cluster System (1)

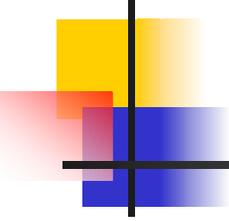
■ 長所

- スケラビリティ
- ハイパフォーマンス
- 冗長性が高い

■ 短所

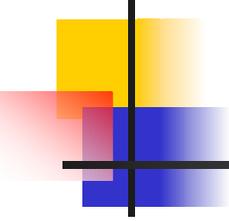
- 占有スペース
- 保守が煩雑
- 性能を引き出すためにはMPI





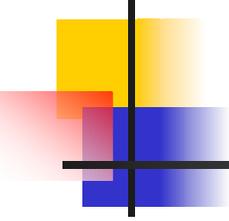
並列Cluster System (2)

- Linuxもなかなかやる
 - Clusters@Top500
<http://clusters.top500.org/>
- Dolphin Interconnect LLC社 
 - WulKit3
- SCALI社 : ScaMPI 
 - ノード間300MB/sec超のインターコネクト



HA Cluster System (1)

- HA = High Availability
 - フォルトトレランス
- High Availability Linux Project
 - <http://linux-ha.org/>



HA Cluster System (2)

- Open Sources
 - Ultra Monkey
 - LVS
- コマーシャルプロダクト
 - SteelEye: LifeKeeper
 - Mission Critical Linux: Convoloc
 - SGI: FailSafe
 - SUN: Sun Enterprise Cluster
 - Fujitsu: SafeCluster

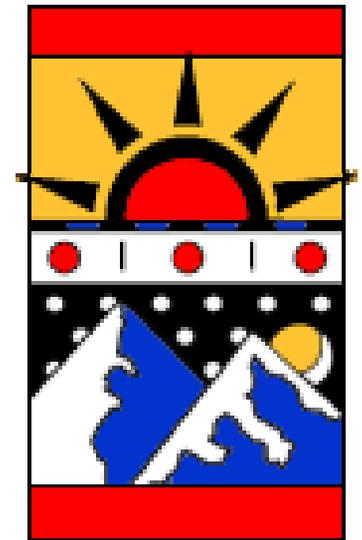
Blade Cluster System

- 収容性
 - 32 Server in 3U
- 保守性
 - 交換が容易
 - ダイナミックリソース管理
- 運用コスト
 - 低い電源消費量

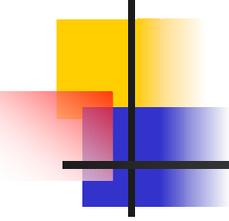


Blade Cluster System

- SC2001でも存在感
 - これからの大きな流れに？
- 増えるベンダー
 - HP
 - Compaq
 - NEXCOM
 -

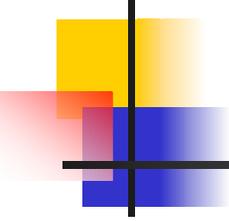


SC2001



Load Balancing (1)

- ロードバランスを行う利点
 - 負荷分散
 - 冗長性
 - 保守性
 - スケーラビリティ
 - 段階的な設備投資

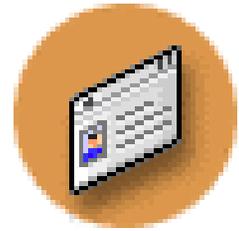


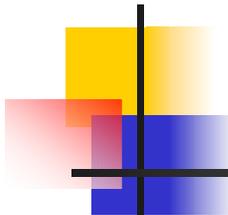
Load Balancing (2)

- ロードバランスでの欠点は？
 - 追加機材が必要
 - 投資コストの増大
 - 保守管理の対象が増加 = 運用コスト大

infoseek ではどうしたか

- こうしたことをふまえて、プロフィールを例にとり、どう対応していったかを話そう

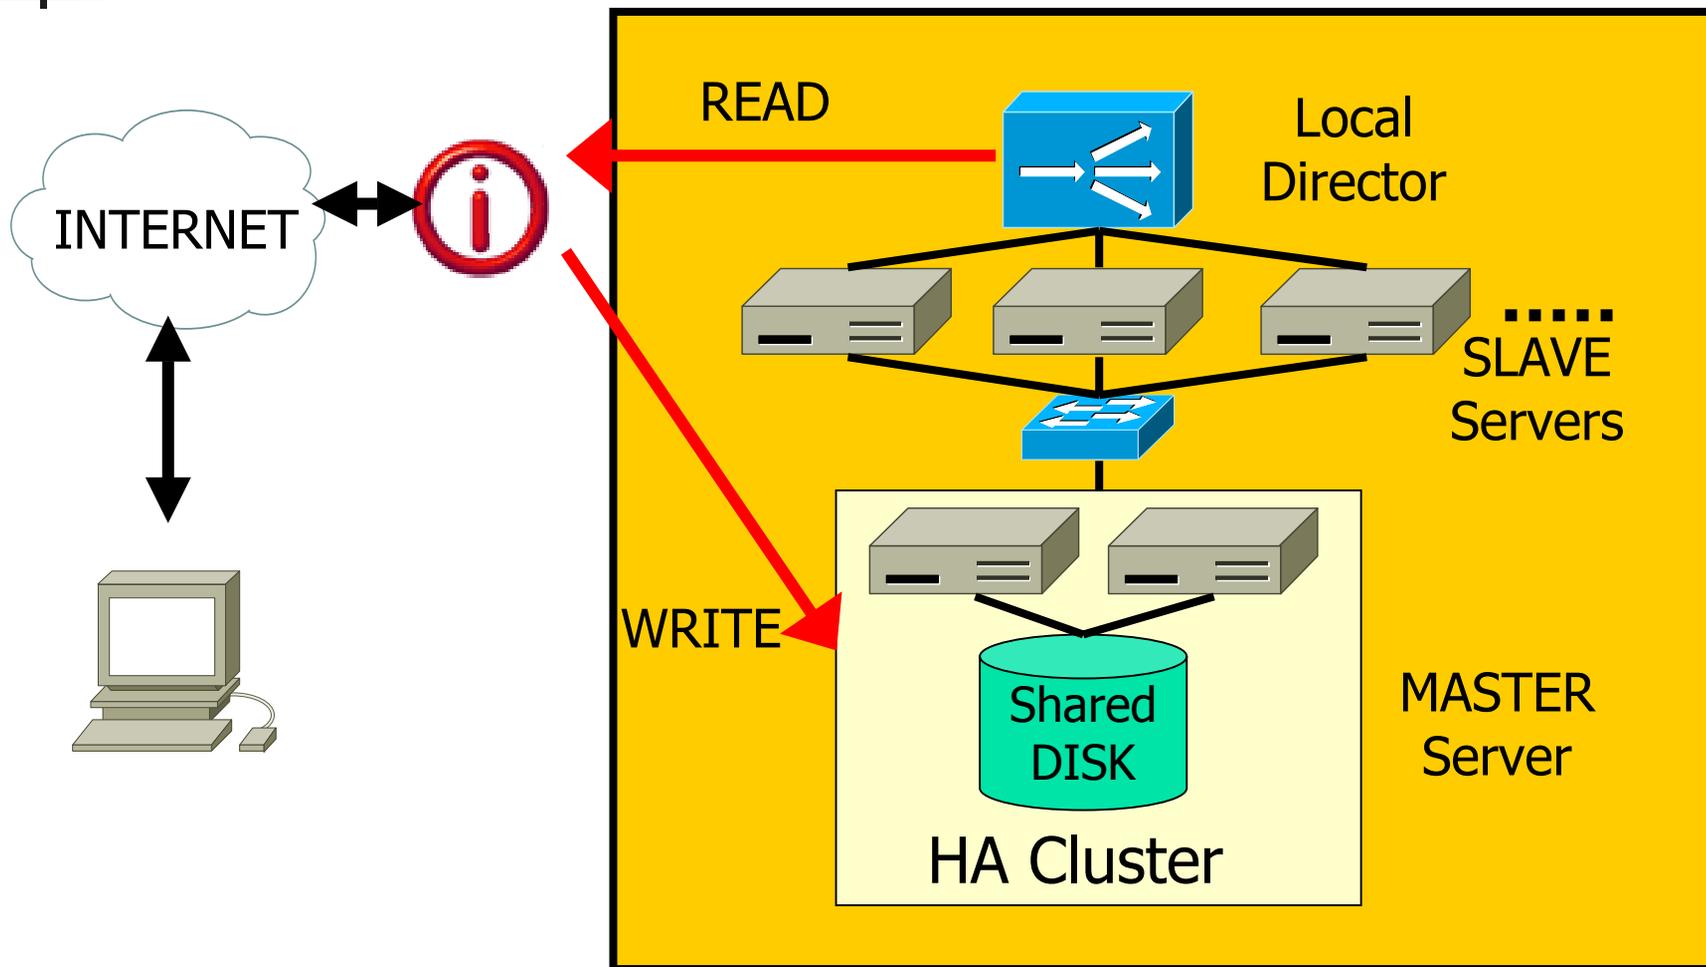


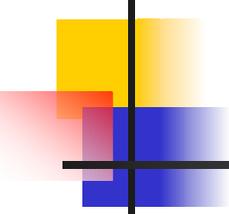


設備投資の内訳

- 設備投資額
 - $HW + SW + \text{保守} + \text{運営} = \text{TotalCost}$
- 陳腐化の速度
 - $HW > SW$
- リソース管理
 - 需要予測と設備投資との同調
- 最高性能は不要
 - 現実的な性能をターゲット

機材構成概要

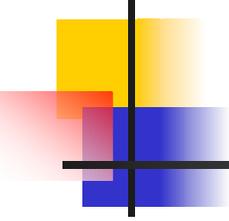




LifeKeeper

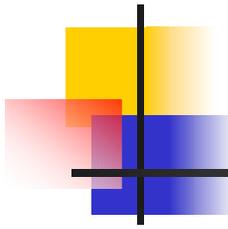


- LifeKeeper
 - ダウンロードして評価できる
 - サポートOSが多い
 - Linux, WindowsNT/2000, Solaris(Intel)
 - サポートアプリケーションが多い
 - 投資コストが低い
 - 日本での代理店
 - テンアートニー
- <http://www.10artni.co.jp>



バックアップ

- バックアップの対象
 - 機材
 - データ
- MySQLのData Replicationを利用



MySQLのData Replication (1)

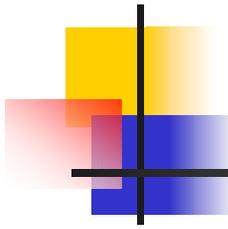
- マスター側の設定 (my.cnf)

[mysqld]

log-bin=/var/spool/mysql/profilebinlog

server-id=xxxx

bin-log=on



MySQLのData Replication (2)

- スレーブ側の設定 (my.cnf)

```
[mysqld]
```

```
server-id=xxxx
```

```
master-host=マスターサーバのホスト名
```

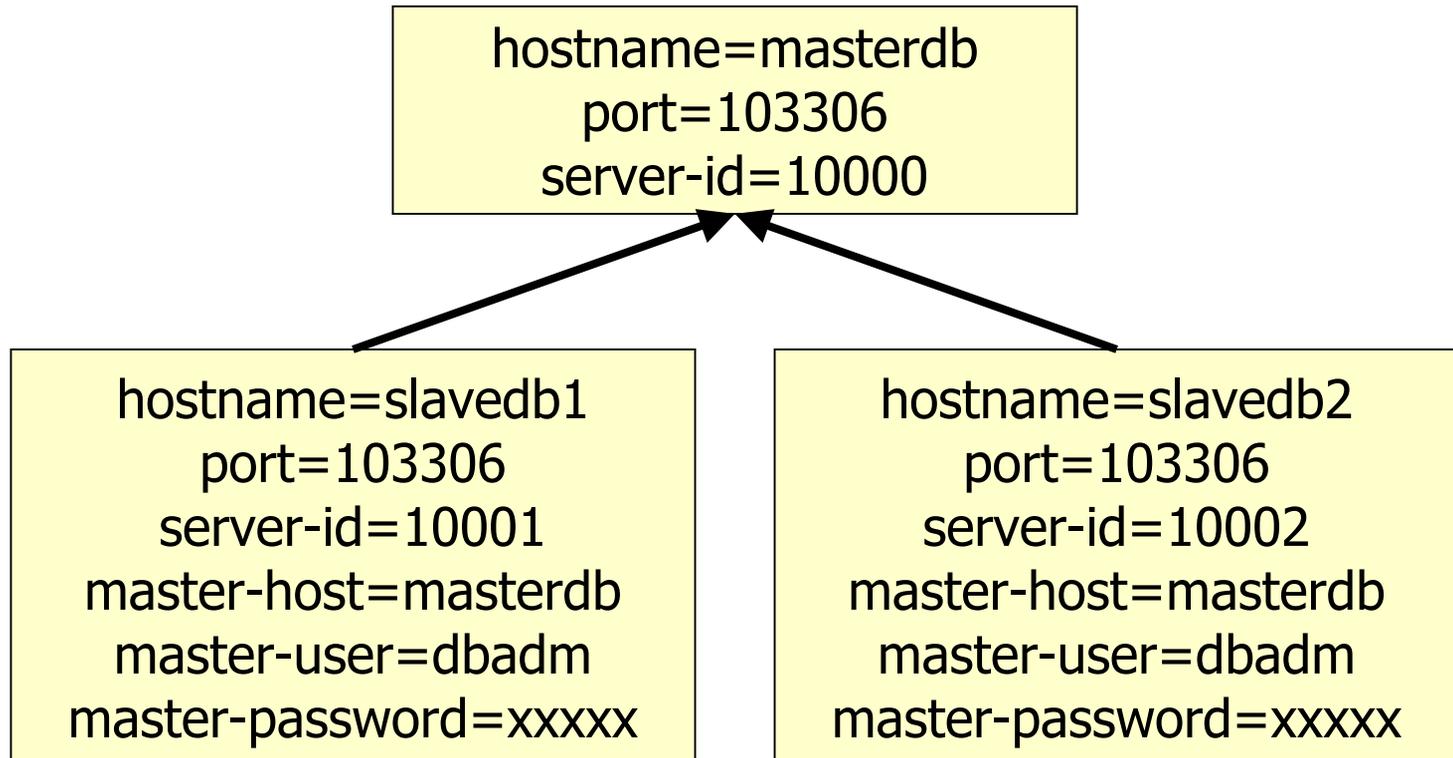
```
master-user=Replicationを行うMySQLユーザ名
```

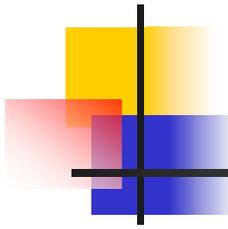
```
master-password=Master-userのパスワード
```

```
master-port=マスターサーバのポート番号
```

MySQLのData Replication (3)

■ 設定例

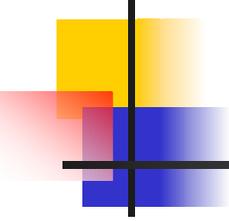




MySQLのData Replication (4)

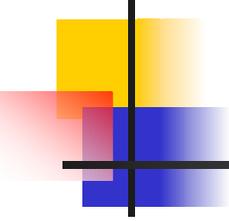
■ 注意すべき点

- Replication開始時点でマスターとスレーブのDBの内容を同期させる必要あり
- Bin-logのケアが必要
 - max-binlog-size で設定した値でローテーション
 - ローテーションさせたくない場合はlog-binで指定するファイル名に拡張子以降を記述しない
 - $1\text{KB} < \text{max-binlog-size} < 1\text{GB}$ (1GB default)
- RAND()は同じにならない



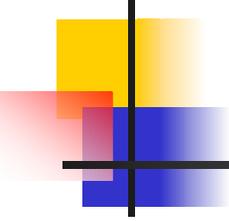
チューニング (TOC)

- Linux
- Java
- MySQL



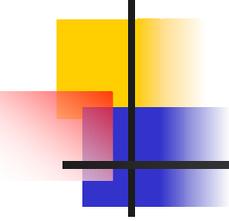
Linuxをチューニング

- Mountの方法
- ファイルシステム
 - tune2fs
 - ジャーナルフファイルシステム



Mount (1)

- /etc/fstab にDISK Labelを書かない
 - 便利ではあるが該当するDISKを探すことに
 - 起動の際の時間短縮



Mount (2)

■ /etc/fstabにDISKラベルを書いた例

LABEL=/	/	ext3	defaults	1 1
none	/dev/pts	devpts	gid=5, mode=620	0 0
LABEL=/home	/home	ext3	defaults	1 2
LABEL=/opt	/opt	ext3	defaults	1 2
none	/proc	proc	defaults	0 0
none	/dev/shm	tmpfs	defaults	0 0
LABEL=/tmp	/tmp	ext3	defaults	1 2
LABEL=/var	/var	ext3	defaults	1 2
/dev/hda3	swap	swap	defaults	0 0
/dev/cdrom	/mnt/cdrom	iso9660	noauto, owner, kudzu, ro	0 0
/dev/cdrom1	/mnt/cdrom1	iso9660	noauto, owner, kudzu, ro	0 0
/dev/fd0	/mnt/floppy	auto	noauto, owner, kudzu	0 0

ファイルシステム (1)

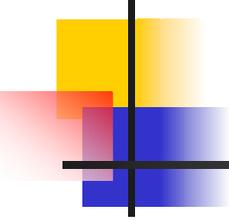
■ Maximum mount counts

- ext2などではパーティションやDISKが複数マウントしているときは、それぞれのこの値を異なる数値に変える
- 起動時のfsckの時間短縮

```
# tune2fs -l /dev/hda1 | grep -i Mount
Last mounted on:      <not available>
Last mount time:      Tue Feb  5 11:48:05 2002
Mount count:          4
Maximum mount count:  -1
```

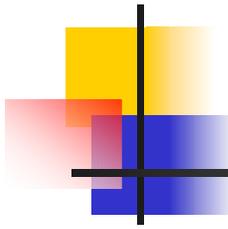
```
# tune2fs -c 7 /dev/hda1
```





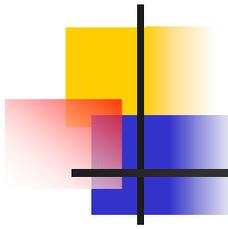
ファイルシステム (2)

- ジャーナリングファイルシステム
 - Write Fast, Read Slow
 - fsckが不要
 - RedHat 7.2ではext3が標準
 - SGIのXFSも“使える”
 - <http://www.oss.sgi.com/projects/xfs/>



JavaのVMをチューニング(1)

- JavaVMの起動パラメタ
 - メモリ割り当てプールの設定は必須
 - サーバアプリケーションにおいては、デフォルトの最大値である64MBでは、小さすぎる。

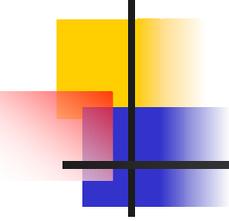


JavaのVMをチューニング(2)

- JavaVMの起動パラメタ
 - インクリメンタルガーベジコレクタの使用の是非、一概には言えないので、実際に試してから決定するのが良い。

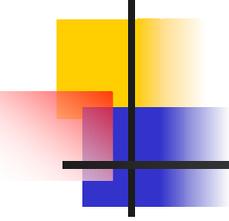
Infoseekでは、

- 使用：ニュース検索, 株価検索 など
- 未使用：プロフィール など



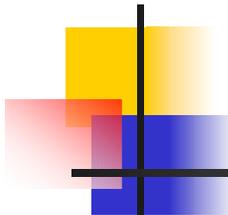
MySQLをチューニング (1)

- MySQLのパフォーマンスに依存するもの
 - CPU性能
 - メモリサイズ
 - DISK性能(転送速度)
 - mysqldのオプションパラメタ



MySQLをチューニング (2)

- メモリに関するもの
 - key_buffer_size
 - table_cache
 - record_buffer
 - sort_buffer

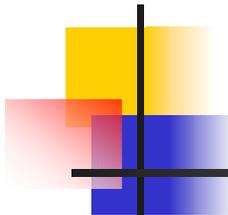


MySQLのチューニングを評価

- SHOW STATUSでヒット率を評価
 - $100 - ((\text{Key_reads} / \text{Key_read_requests}) * 100)$
 - 90以上が目標

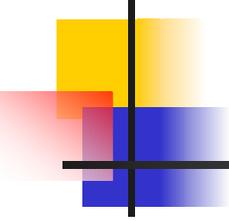
```
mysql> SHOW STATUS LIKE 'Key%';
```

Variable_name	Value
Key_blocks_used	7793
Key_read_requests	1589396597
Key_reads	356247
Key_write_requests	6675835
Key_writes	6502631



チューニングでの注意点

- テストサーバで十分評価する
 - MySQL 3.x ではデーモンの再起動が必要
 - サービスが停止することになる
 - MySQL 4.x ではダイナミックに変更できる
- 1度にいくつもパラメタを変更しない
- パラメタが与える影響を確かめる

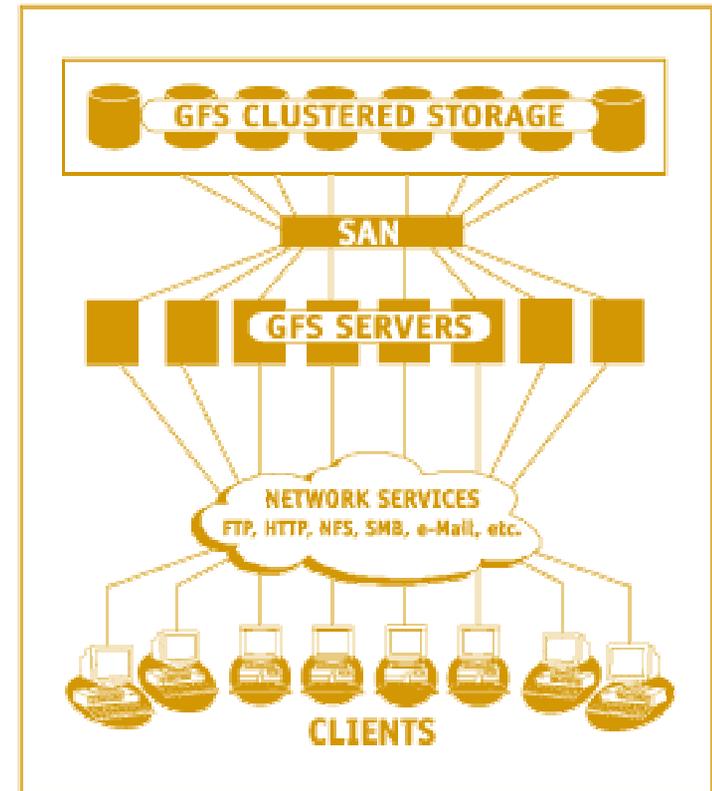


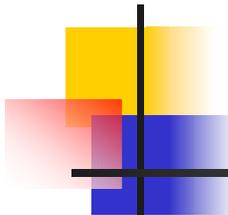
TODO

- SAN
- MySQL 4.x

SAN(Storage Area Network)

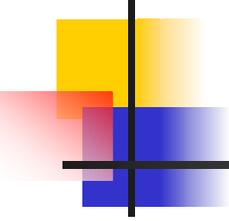
- GFS: Global File System
 - Open Source (だった)
 - DISK増強が容易
- ミネソタ大学が母体
 - Sistina Software
1313 Fifth Street Southeast
Suite 111
Minneapolis, MN 55414





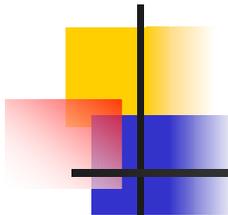
参考資料 (1)

- Which OS is Fastest for High-Performance Network Applications?
Jeffrey B. Rothman and John Buckman
SysAdmin - July 2001 Volume 10 Number 07
<http://www.samag.com/documents/s=1148/sam0107a/0107a.htm>
- Which OS is Fastest -- FreeBSD Follow-Up
Jeffrey Rothman and John Buckman
SysAdmin - August 2001 Volume 10 Number 8
<http://www.samag.com/documents/s=1147/sam0108q/0108q.htm>



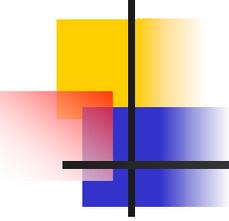
參考資料 (2)

- High Availability Linux Project:
<http://linux-ha.org/>
- Dolphin Interconnect LLC
 - <http://www.dolphinics.com/>
- SCALI
 - <http://www.scali.com/>
- SteelEye : LifeKeeper
 - <http://www.steeleye.com/>
- SC2001
 - <http://www.sc2001.org/>



參考資料 (3)

- MySQL Manual:
Tuning Server Parameters
http://www.mysql.com/doc/S/e/Server_parameters.html
- MySQL Manual:
SHOW VARIABLES
http://www.mysql.com/doc/S/H/SHOW_VARIABLES.html
- MySQL Manual:
SHOW STATUS
http://www.mysql.com/doc/S/H/SHOW_STATUS.html



參考資料 (4)

- mytop:

A “TOP” Clone for MySQL

<http://public.yahoo.com/~jzawodn/mytop>