PostgreSQL 9.0 とクラスタリングソリューション最新動向セミナー

2010年 7/14, 7/28, 8/4, 8/18

SRA OSS, Inc. 日本支社

高塚 遙 / harukat@sraoss.co.jp

はじめに

- 講演者について
- 本セッションの構成
  - PostgreSQL 9.0 のご紹介
  - PostgreSQL クラスタソリューションのご紹介
    - 高可用性クラスタについて
    - 負荷分散クラスタについて

PostgreSQL 9.0 について

PGCON 2010
developpers meeting
Arc the Hotel, Ottawa

PostgreSQL 9.0 までの軌跡

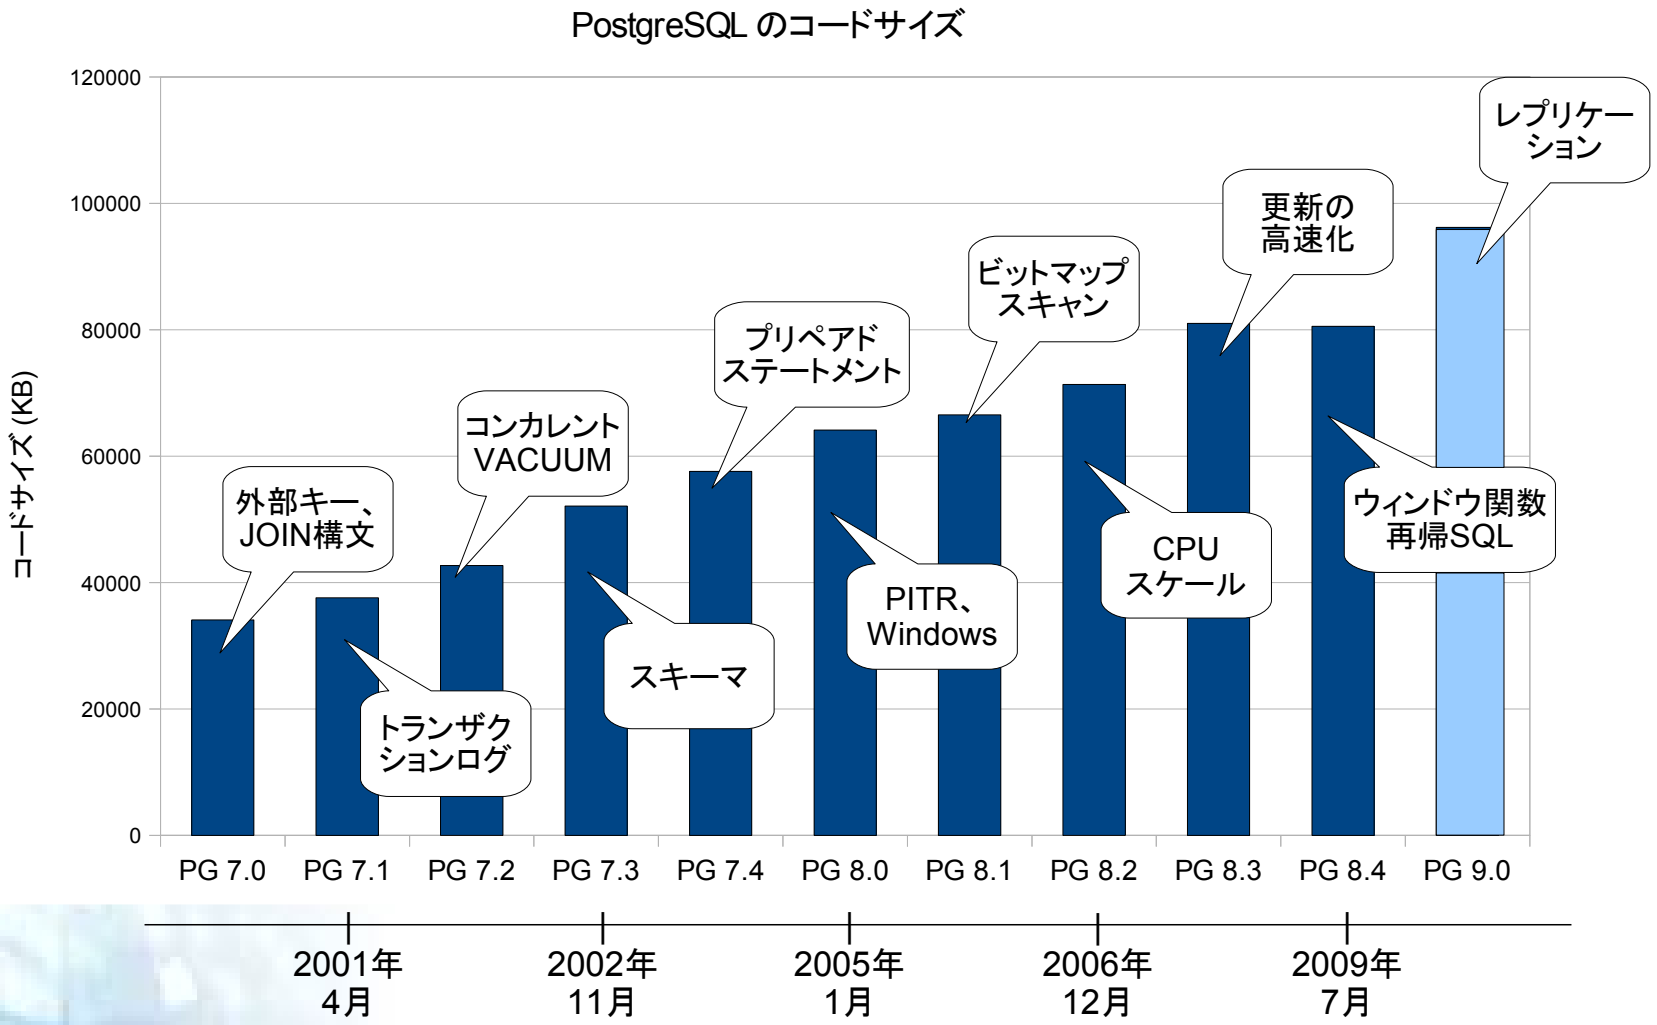

PostgreSQL 9.0 の拡張

- レプリケーション標準装備
- Windows 64bit 対応
- 遅延可能なユニーク制約 ／ 「排他制約」追加
- VACUUM FULL のリニューアル
- LISTEN/NOTIFY のリニューアル
- 手続き言語（ストアドプロシージャ）関連を拡張
- オブジェクト権限設定を拡張
- 上書きアップグレードツール（追加ツールの拡張）

レプリケーション標準装備
HS/SR（ホットスタンバイ/ストリーミングレプリケーション）

- シングルマスター
  - マルチスレーブ
  - カスケードは非対応
- トランザクションログ転送
  - block転送（DRBD）、行転送（Slony-I）より軽い
  - データベースクラスタ単位でのレプリケーション
  - WALファイル単位でなく、処理単位で転送する
- スレーブで参照アクセス

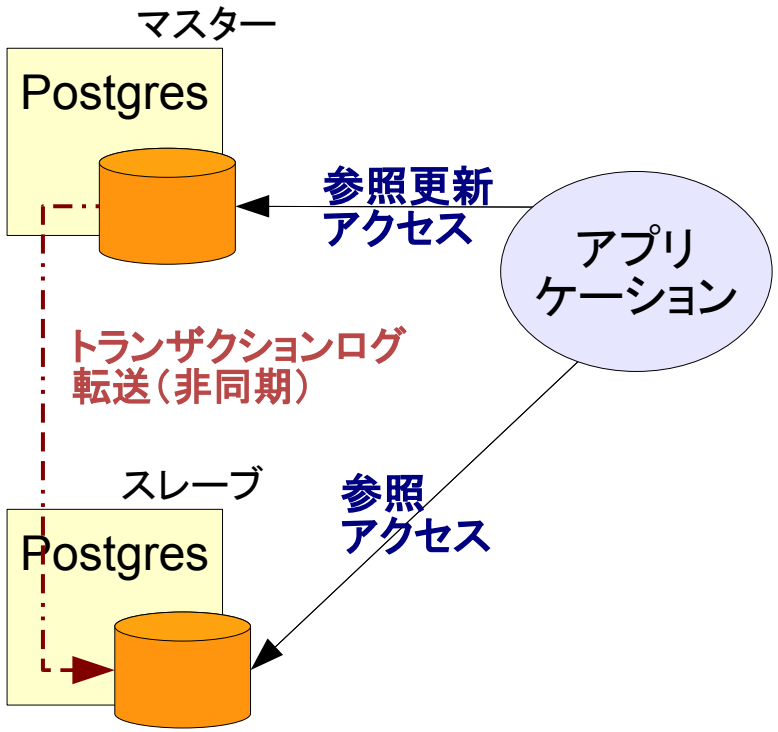

Windows 64bit 対応

- これまでは 32bitビルドのみ対応
  - 64bit版 Windows では WOW64 で動作
  - shared_buffers や work_mem に 2GB～4GB を超えるサイズを設定できなかった

- Visual Studio 2008 でビルド
  - PostgreSQL 8.3 までは Visual Studio 2005 が推奨ビルド環境（9.0 も 2005 でビルド可）
  - MinGW、cygwin では依然 32bit のみ

遅延可能なユニーク制約

- 以下のようなことができる（これまでできなかった）

```
db=# \d test
      Table "public.test"
 Column |  Type   | Modifiers
--------+---------+-----------
 id     | integer | not null
 v      | text    |
Indexes:
    "test_pkey" PRIMARY KEY, btree (id) DEFERRABLE

db=# BEGIN;
db=# SET constraints all DEFERRED;
db=# UPDATE test SET id = id + 1 ;
db=# END;
```

id	～
1 → 2	～
2 → 3	～
3 → 4	～

排他制約 EXCLUDE

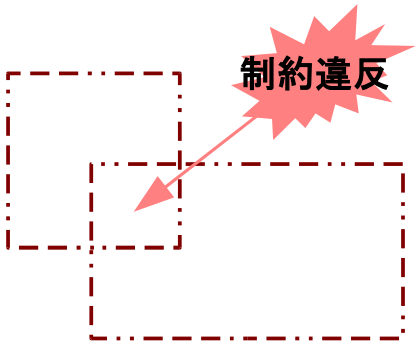

- 「ユニーク」概念を拡張したもの
  - 任意の演算子で排他制約を
  - gist インデックスのみ対応
    - 応用は様々だが既存データ型ではすぐ使えるものが少ない
    - 組み込み型では BOX などの幾何データ型に適用可能

```
CREATE TABLE real_estate_registration (
  regist_id       int8,
  land            geometry,
  term            period,
  owner           text,
  EXCLUDE USING gist
   (term WITH &&, land WITH &&));
```

「重なっているか？」の演算子／「＝」ならUNIQUE 制約と同じ

VACUUM FULL リニューアル

- 高速動作／実施後の REINDEX も不要に
  - 内部的にテーブルを作り直す動作になる
  - そもそも VACUUM FULL は
    - 不要領域を削除してデータ物理サイズを縮小する
    - 通常VACUUMをよく行い、使わずに済ますのが王道
  - これまでの VACUUM FULL は
    - 代替にCLUSTERコマンドを使う
    - 代替にダンプ／リストアを使う
    - パーティショニングをしてテーブルごと削除

  といった技法がしばしば使われるほどに、
  非効率な方式となっている

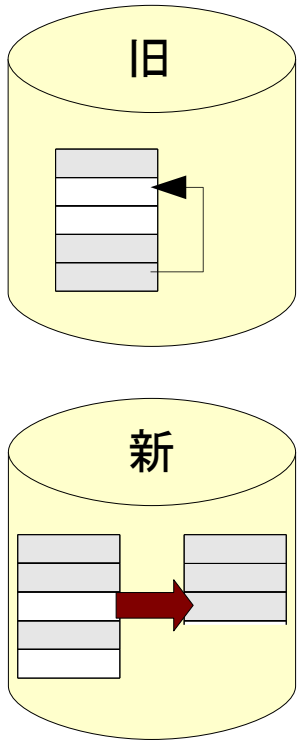

動作イメージ

LISTEN/NOTIFY のリニューアル

- 接続セッション間での通信手段
  - PostgreSQL独自の機能
  - 「ある件について通知が発生」を伝達
  - 各種接続ドライバで対応

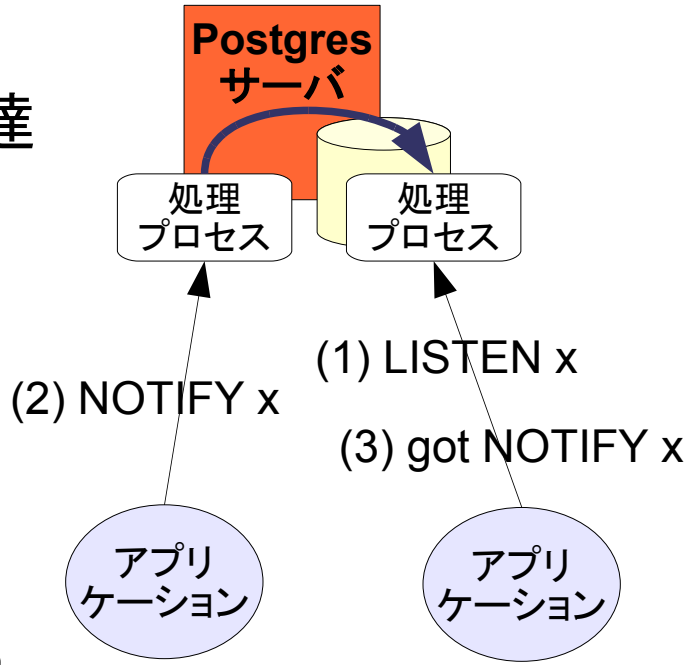

- 高速化
  - テーブルで実装していたものを、
    メモリ上のキューで実装
- 任意の文字列メッセージを渡せる

関数／手続き言語の拡張（1）

- DO文を使って匿名関数を作成

```
db=> DO LANGUAGE plpgsql
db-> $$ BEGIN FOR i IN 1..3 LOOP RAISE NOTICE 'hello';
db->            END LOOP; END;  $$;
NOTICE:  hello
NOTICE:  hello
NOTICE:  hello
```

・いきなり記述できる
・バッチ処理記述など

- 関数呼び出しにおいて自由な引数順序

```
db=> SELECT f(p3 := 12, p1 := 7);
```

これまでは末尾の引数にしかデフォルト値が利用できなかった

```
f(p1 int DEFAULT 0,
  p2 int DEFAULT 0,
  p3 int DEFAULT 0)
```

関数／手続き言語の拡張（2）

- カラム単位のトリガ
  - 特定カラムの変更に対して駆動するトリガ定義
- 条件付きトリガ
  - 処理対象行の値が特定条件のとき駆動するトリガ定義

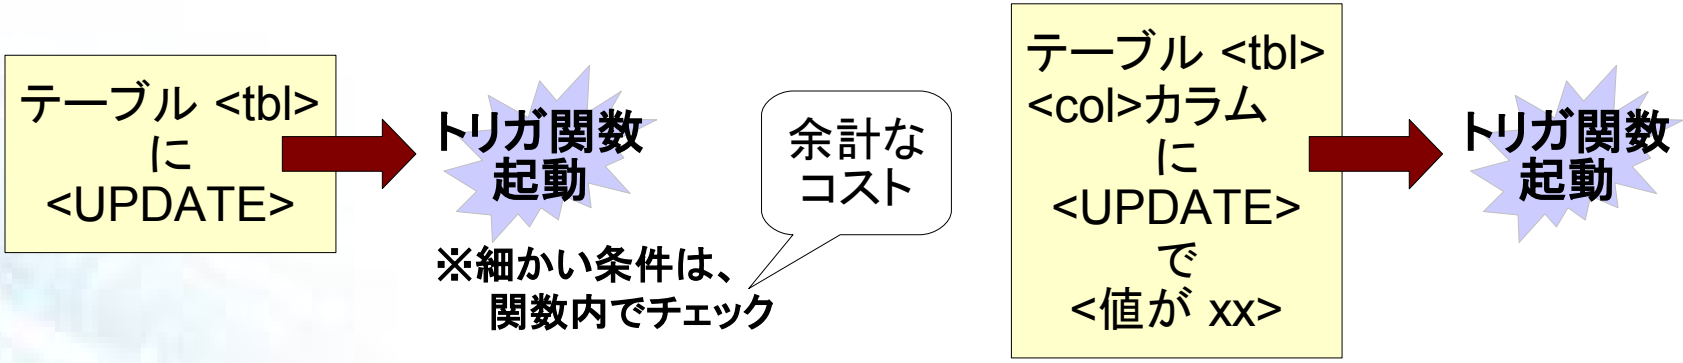

- PL/Perl が大幅に拡張、PL/Python も拡張

オブジェクト権限設定の拡張

- ラージオブジェクトにアクセス権限設定
  - これまで欠けていた機能
  - デフォルトでは他のユーザが所有するラージオブジェクトにアクセスできないようになる *（非互換注意）*

```
db=# GRANT SELECT, UPDATE ON LARGE OBJECT 16577 TO foo;
GRANT
```

- スキーマごとにまとめて権限の変更
  - 「このスキーマに属するテーブル全てに一度に権限設定」ができるようになります

```
db=# GRANT SELECT ON ALL TABLES IN SCHEMA scm1 TO role1;
GRANT
```

追加ツール（contrib）の拡張

- 上書きアップグレードツール pg_upgrade 新登場
  - 8.3.x、8.4.x からのアップグレードに使用可能
  - 内部データ書き換えを行う

以前は pg_migrator と呼ばれていた

- contrib/pgbench の拡張
  - マルチスレッド対応
  - シェルコマンド実行機能

マルチスレッド対応でないと、
クライアントマシン側が先に限界と
なって、性能計測仕切れないケース

- contrib/hstore の拡張
  - ハッシュデータ型（キーバリューの組）
  - キー長、バリュー長の制限が撤廃された
  - GROUP BY、DISTINCT が利用可能に

以前は、キーも値も、
65535バイトが最大長

PostgreSQL 9.0 いつリリース？

- 7/12 ～ 7/13 に beta3 が公開
  - 僅かながら beta2 に機能追加もされている
- その後に rc (release candidate) を 1つ 2つ出す
- 正式リリースは早くとも 8月

PostgreSQL 9.1 の展望

- 同期レプリケーション
- MERGE
- JSON型、各種Range型
- マテリアライズドビュー
- パラレル pg_dump
- テーブルパーティショニング構文
- SQL/MED（外部表参照）
- SE-PostgreSQL
- 書き込み再帰SQL
- プリペアドステートメントのプラン改善
- インデックスのみスキャン

PgCon 2010
Developer Meeting より

PostgreSQL の展望

- PostgreSQL開発は止まらない
  - 特定オーナー企業は無い
    （支援企業も一定ではない）
  - 世界に多数ある関連サービス企業が主力
  - 時に研究実証に使われる
  - 大規模ユーザから出てくる新機能

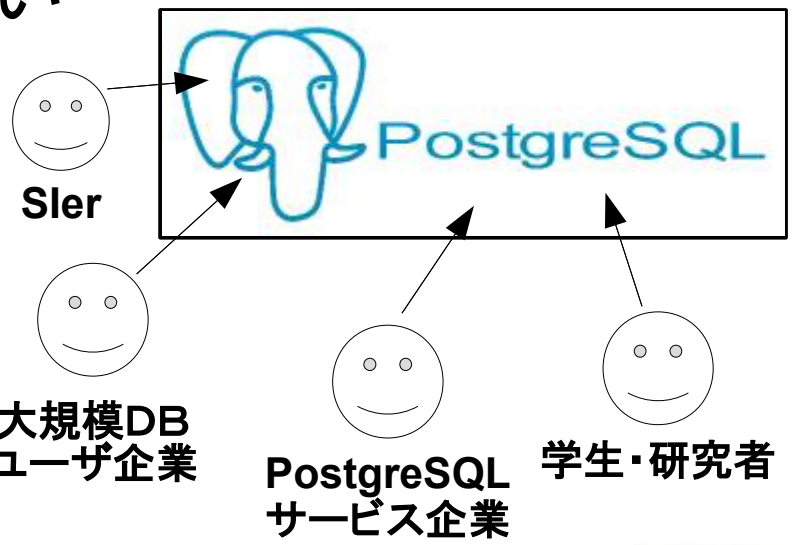

休憩

猫　Tokyo/Japan

PostgreSQL の クラスタソリューション一挙紹介

- 高可用性クラスタ
- 負荷分散クラスタ

目的あっての
クラスタリング

高可用性クラスタについて

カルタゴの武装した象
Parco de Mostri di Momarzo

データベース高可用性クラスタ

- 可用性の追求
  - サービス停止時間を短く
    - 避けえない HW/SW 障害
    - 復旧時間の短縮
      ↓
  - クラスタにする
    - 並行で別サーバを稼動させればよい
  - Single Point of Failure
  - DBMS は データを持つ

- クラスタソフト化に必要な要素は

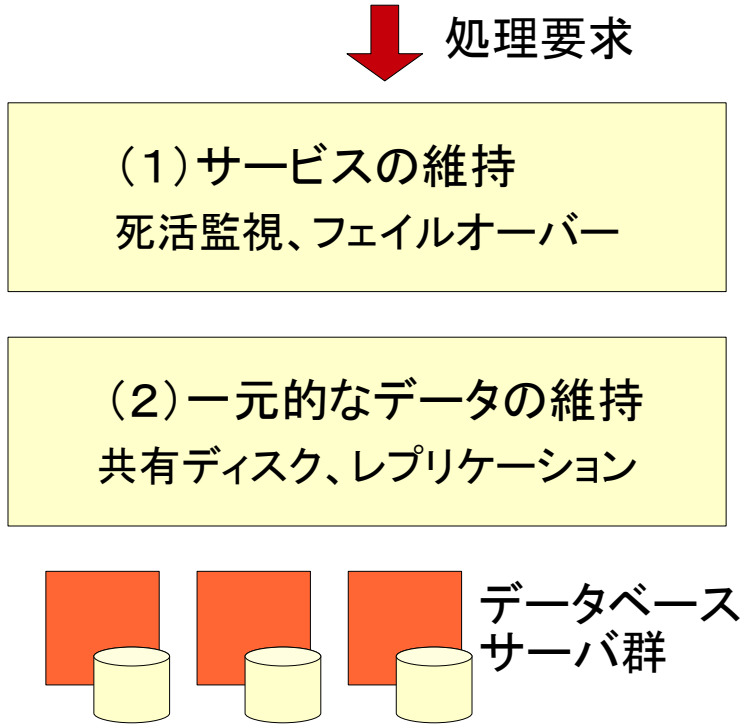

クラスタ以前（1）
ダンプによるバックアップリストア

- 障害の発生時にはバックアップ時点まで復旧

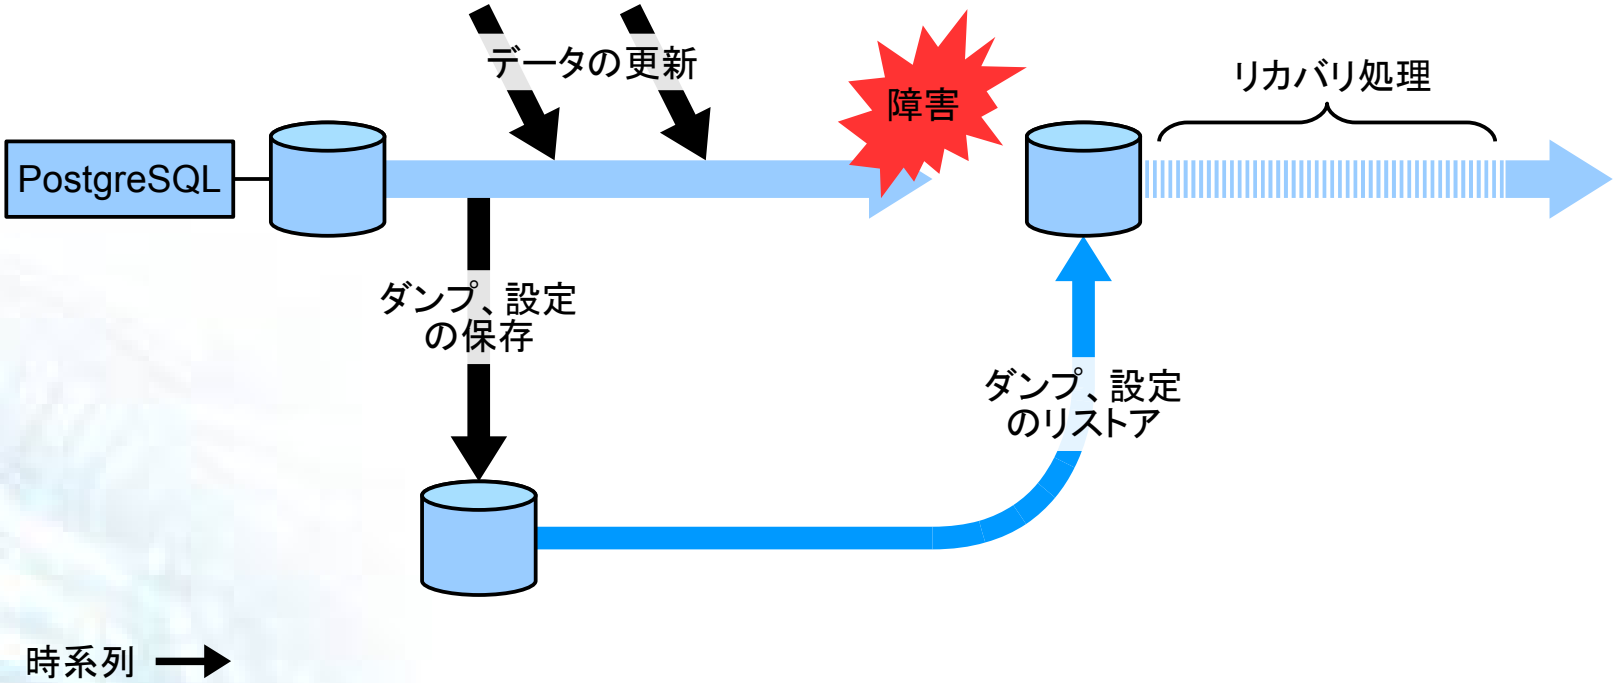

クラスタ以前（2）
PITR による バックアップリストア

- データの更新によって発生した差分を保存し、障害の発生時には差分を適用して直近の状態まで復旧

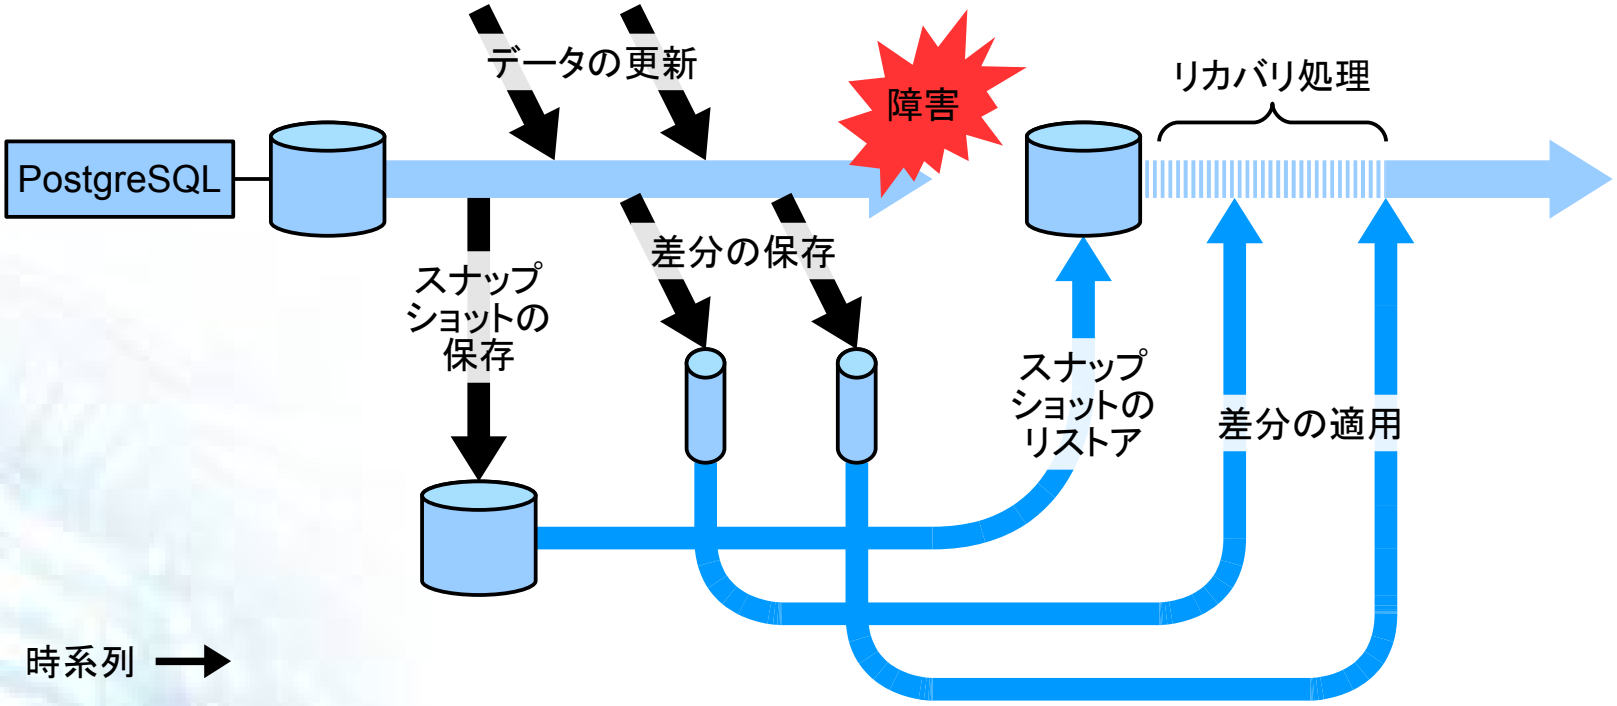

Single Point of Failure

- 全体の可用性は弱点の可用性にひっぱられる
- 現実には全2重化はしてないことが多い

単体可用率　　99.9 %

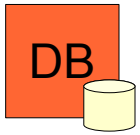

故障率 0.1%（8h/年）

クラスタ可用率　99.8999%　あれ？
=（1 - 0.001 x 0.001）x（1 - 0.001）

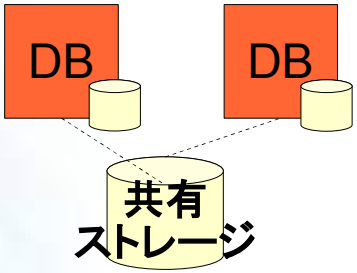

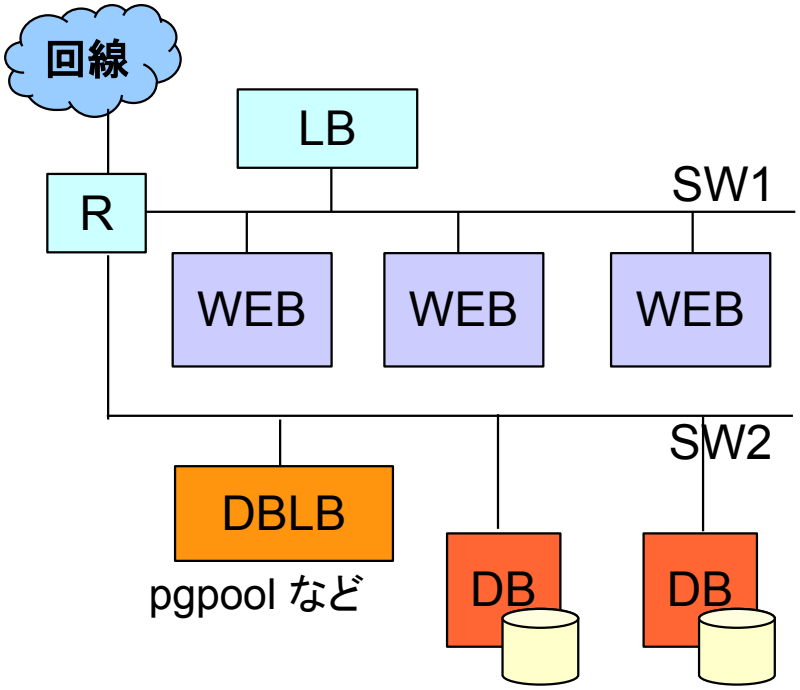

データベース管理システム（DBMS）はデータを持つ

- クラスタソフトウェアに重い課題
  - ノード間データ維持をどうするか？

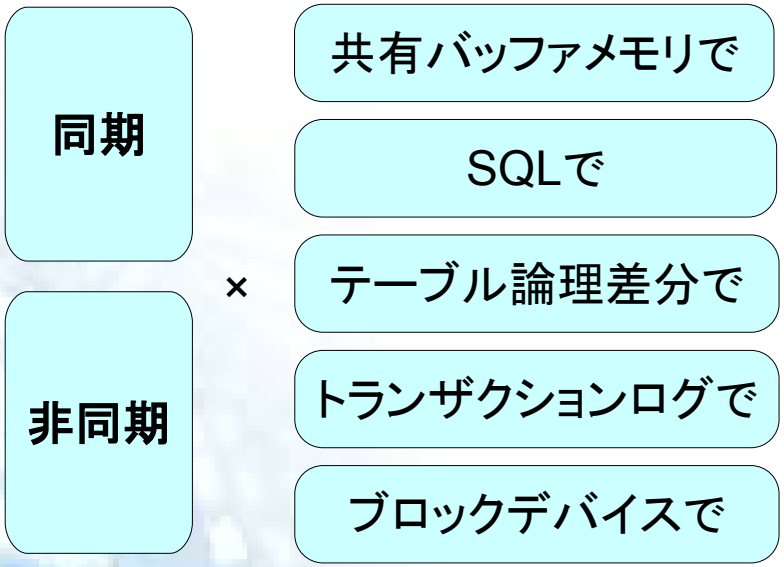

- 「データ保全」がサービス可用性よりも重いことがある

可用性が落ちる
レプリケーションにも
価値がある

PostgreSQL 高可用性クラスタ 構成例

HAクラスタ(共有ディスク)構成

- かつては PostgreSQL の実用的な唯一選択肢
- 相互アクティブスタンバイは可能だが、両アクティブに対応したミドルウェアはない
- SQL制約なし／処理オーバーヘッドなし

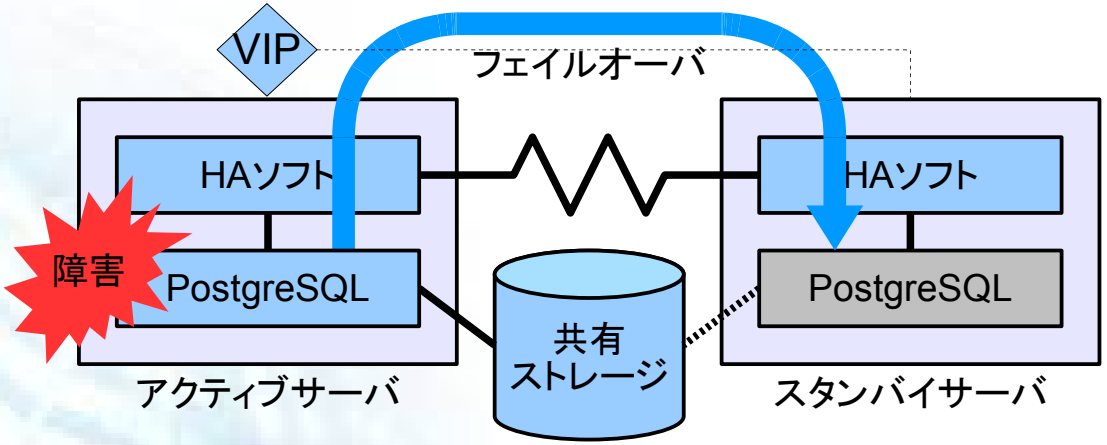

＜HAソフト＞

Heartbeat/Pacemaker
LifeKeeper
CLUSTERPRO
RHCS
Veritas CS
PRIMECLUSTER
etc..

PowerGres on Linux + Lifekeeperで
データベースサーバの業務継続を実現
PowerGres on Linux HA

HAクラスタ（DRBD）構成

- ネットワークRAIDによるレプリケーションを使う
  - DRBD、商用HAソフト付属のレプリケーションツール
- SQL制約なし、処理オーバーヘッドあり、

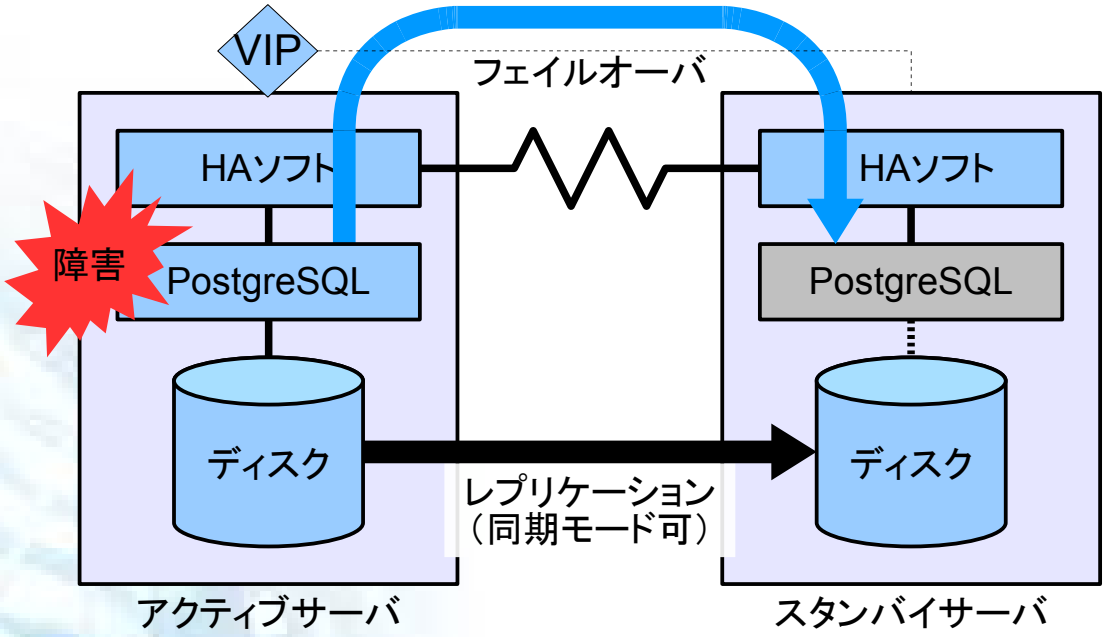

＜HAソフト＞

Heartbeat/Pacemaker
LifeKeeper
CLUSTERPRO
RHCS
Veritas CS
PRIMECLUSTER
etc..

PowerGres on Linux + Lifekeeperで
データベースサーバの業務継続を実現
PowerGres on Linux HA

HAクラスタ（その他）構成

- 各種レプリケータを使う
- HAソフトとの連携について、作りこみが必要
- SQL制約あるものも、処理オーバーヘッドあり

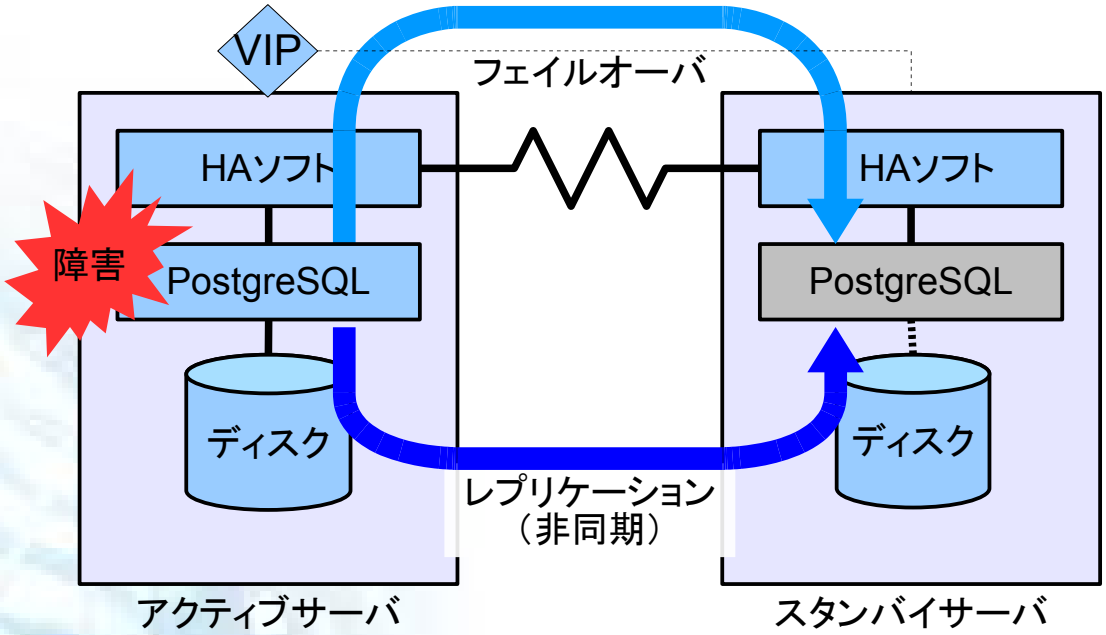

＜各種レプリケータ＞
ウォームスタンバイ
9.0 HS/SR
Slony-I
Bucardo
Londiste

Slony-I について

- 1つのマスタのみがデータの更新を受け付け、トリガによって差分を保存し、slonが複数のスレーブに差分を転送してレプリケーション
- 指示をうけて、スレーブのマスタ昇格ができる

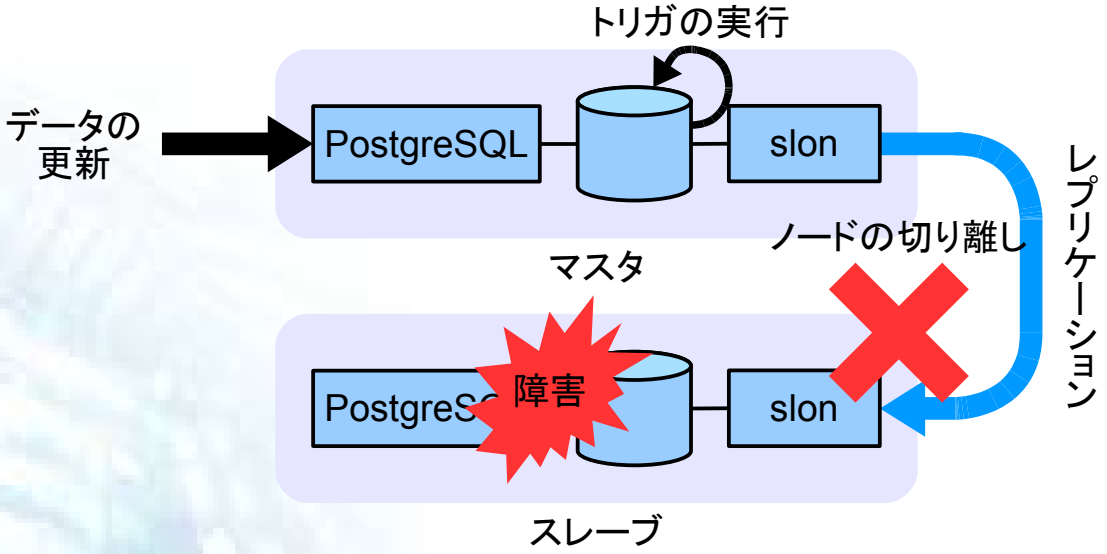

大量書き込みでは転送遅延が生じる

＜同類ソフト＞

Bucardo
　マルチマスター可

Londiste
　PgQでやや軽いか

VMware HA + プロセス監視

- 既に仮想化インフラが整備されているとき
- プロセス監視、再起動の仕組みが要る

ftServer等も得失は似ている

＜単体監視ソフト＞
CLUSTERPRO SSS monit
各種HAソフトの単体むけ使いまわしも可

＜仮想化ソフト（HA）＞
各種HAソフトの上に仮想化ソフトを載せるパターンがいくつか可

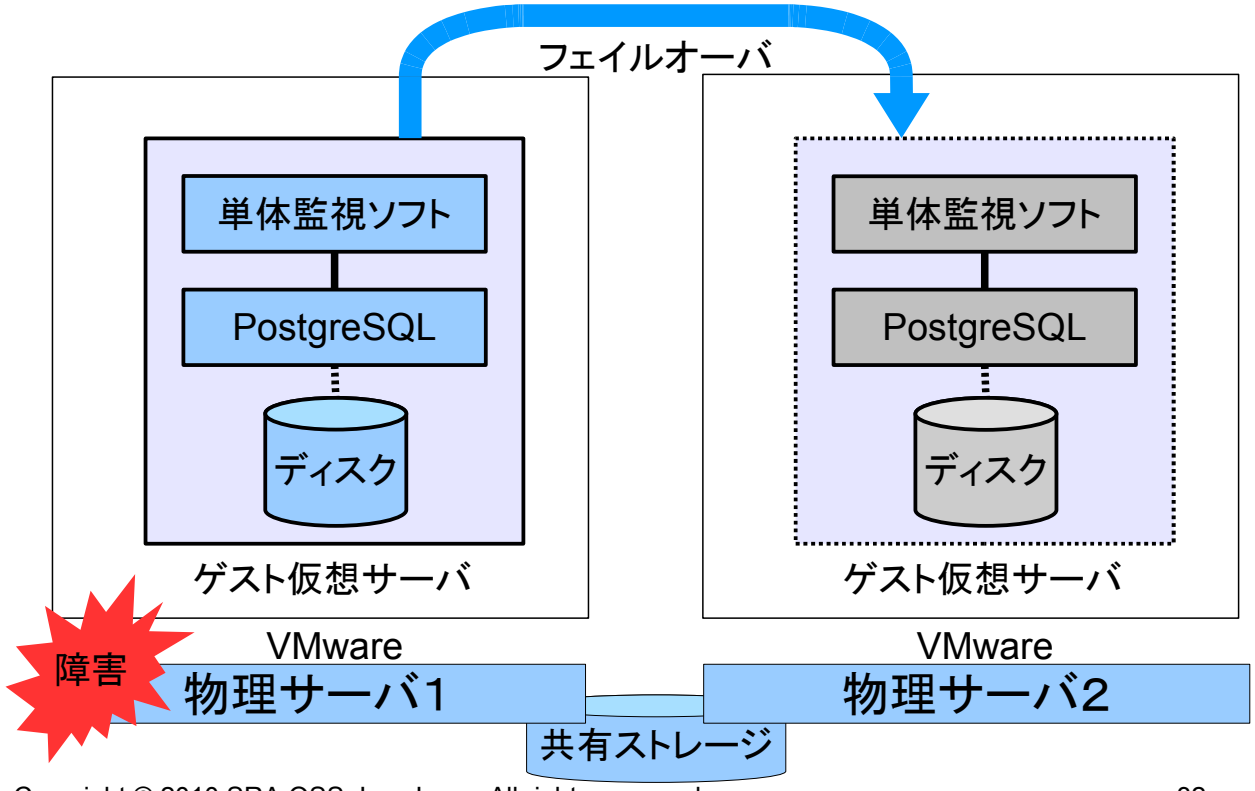

pgpool-HA 構成

- pgpool-II の読み取り負荷分散が併用できる
- SQL制限あり、書き込み処理オーバーヘッドあり

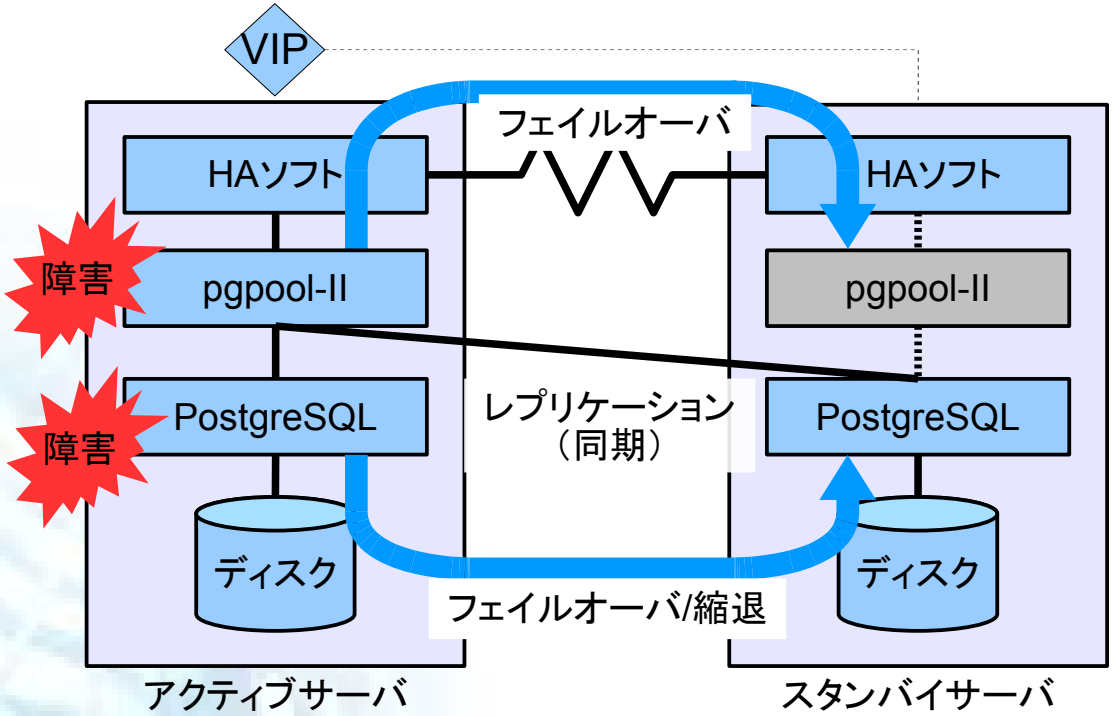

＜HAソフト＞

Heartbeat/Pacemaker
（pgpool-ha AS）

pgpool-II について

- PostgreSQLのプロキシサーバ
  - レプリケーション
  - フェイルオーバー
  - オンラインリカバリ
  - スクリプトを設定して、他のレプリケータと連携
  - 参照負荷分散
  - パラレルクエリー
  - クエリーキャッシュ

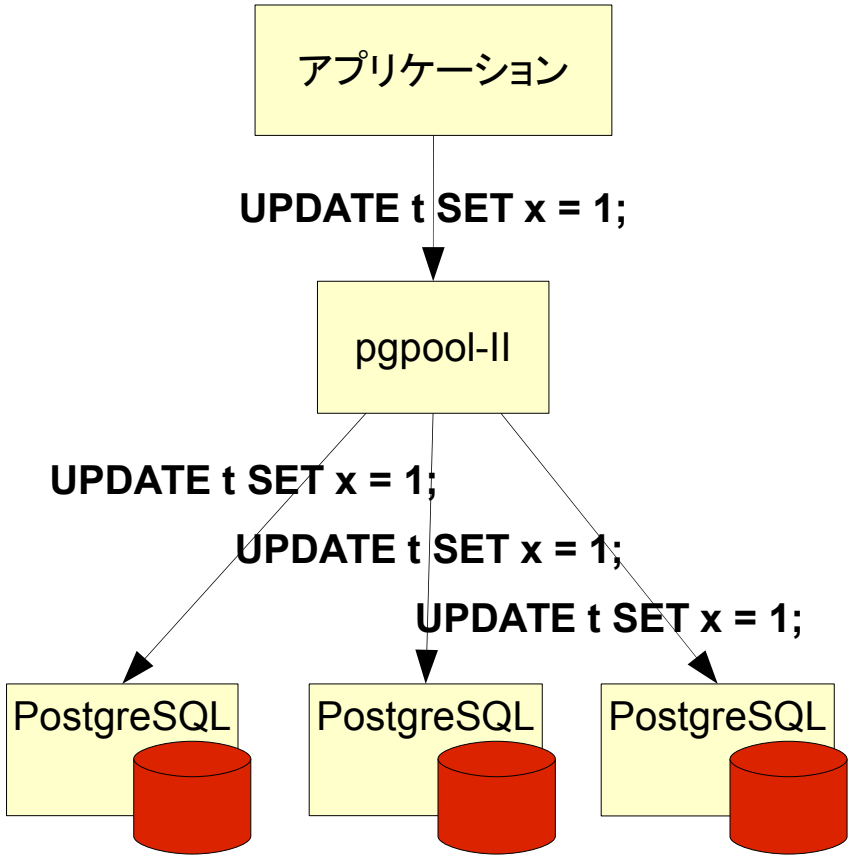

Feature	Shared Disk Failover	File System Replication	Hot/Warm Standby Using PITR	Trigger-Based Master-Slave Replication	Statement-Based Replication Middleware	Asynchronous Multimaster Replication	Synchronous Multimaster Replication
Most Common Implementation	NAS	DRBD	PITR	Slony	pgpool-II	Bucardo	
Communication Method	shared disk	disk blocks	WAL	table rows	SQL	table rows	table rows and row locks
No special hardware required		•	•	•	•	•	•
Allows multiple master servers					•	•	•
No master server overhead	•		•		•		
No waiting for multiple servers	•		•	•		•	
Master failure will never lose data	•	•			•		•
Slaves accept read-only queries			Hot only	•	•	•	•
Per-table granularity				•		•	•
No conflict resolution necessary	•	•	•	•			•

PostgreSQL 9.0 マニュアルより

負荷分散クラスタについて

Balance à tabac (wikipedia commons)

性能アップをめざしてスケールアウト

- RDBMSはデータを持つ
  - スケールアウトしにくい
  - スケールアップは有効
    - PostgreSQL: 8～16CPU
  - シェアードナッシングも適所では有効
    - OLAP分野むけソフト多数
    - アプリ巻き込みも有力

Key-Value型DB なら
スケールアウトする？

⇒ Key-Value 用途だけなら
RDBMSだって速いしスケールする

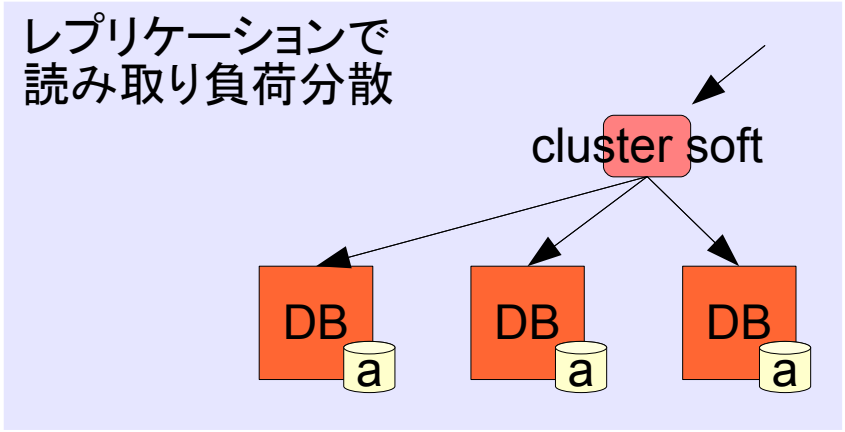

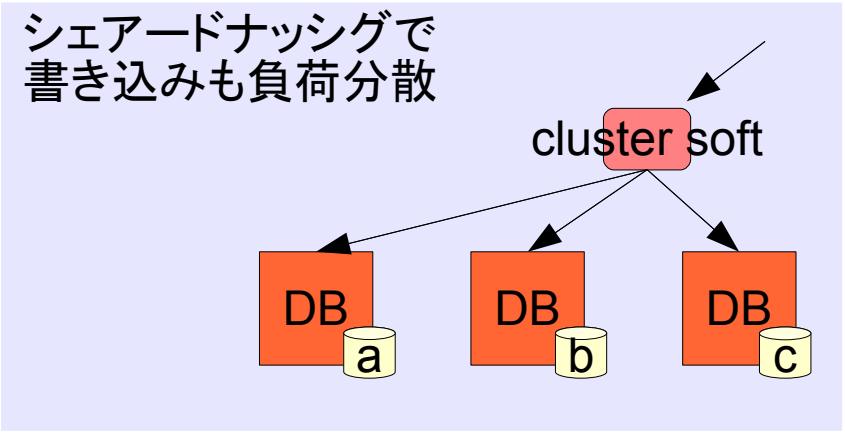

可用性も！ 負荷分散も！

- CAP定理
  - Consistency
    - 一貫性
    - データー致！遅延差異なし！
  - Availability
    - 可用性
    - 待たせない！ も含む
  - Partition-Tolerance
    - 分割透過性
    - 分散して動く！ 部分でも動く

3つを全ては満たせない!

- 「レプリケーション＋負荷分散型」なら「高可用性も」「負荷分散も」となりそうだが、易しくない
  - 形のうえでできても、たいていそれは「ノードを足すほどに『遅い』」
- 銀の弾丸は無い
  - 特定条件にマッチしたソリューションはあっても、万能構成は無い

システム全体としてあきらめどころを見つける

PostgreSQL 負荷分散クラスタ 構成例

pgpool-II 読み取り負荷分散

- SQL制限あり、書き込み処理オーバーヘッドあり
- アプリケーションから透過的に使える

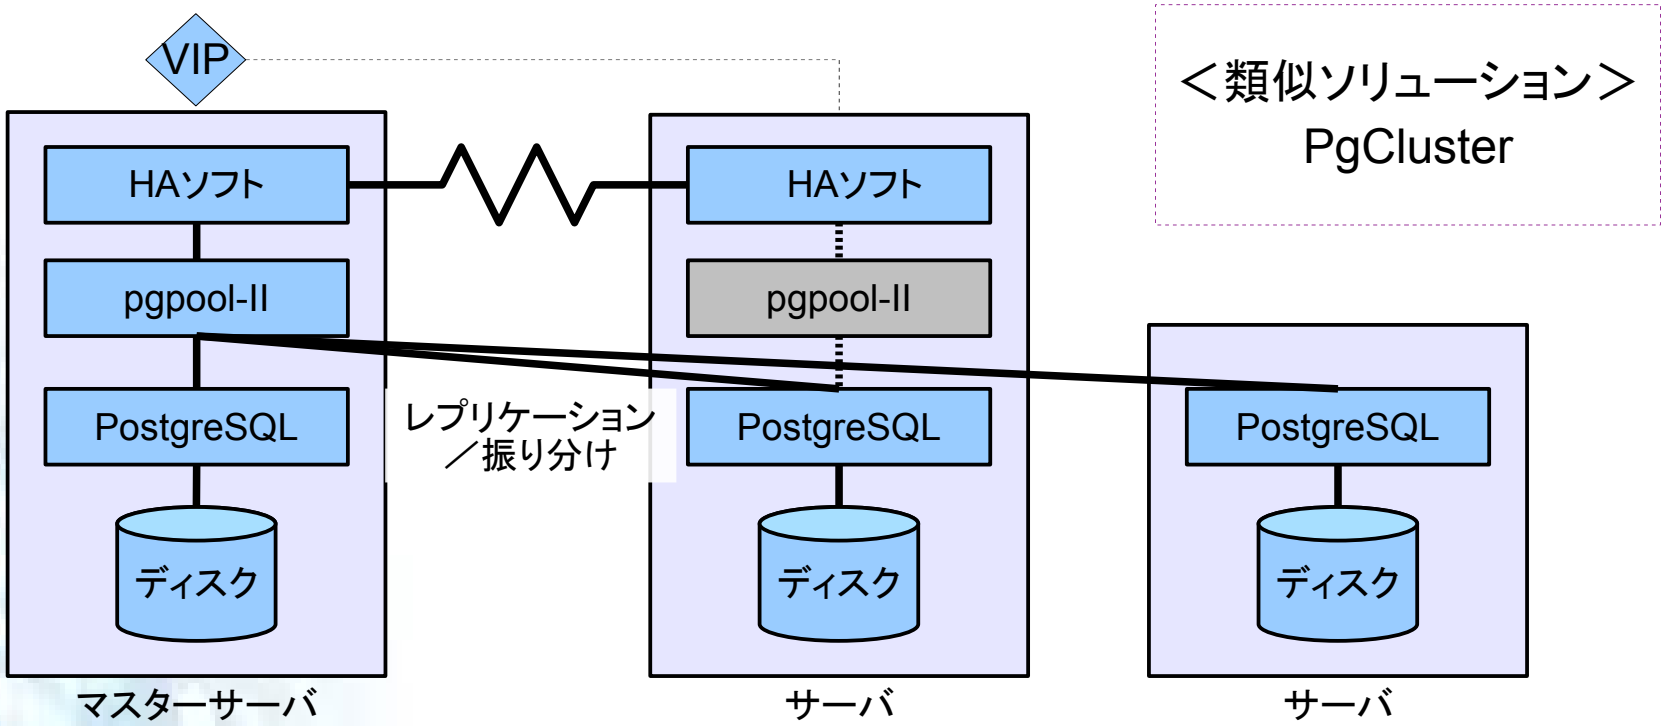

pgpool-II 2.3.x の世界

- タイムスタンプデータの挿入ができる

```
INSERT INTO t (ts)
 VALUES (CURRENT_TIMESTAMP);
```

  - ノードごとにサーバ時刻が異なるので従来はNG
  - マスターノードの時刻を使うように自動書き換え
- そのほか
  - フェイルオーバーする／しないの制御
  - pgpool-II 停止時に状態を記憶

pgpool-II 読み取り負荷分散 - Slony-I 等による非同期版 -

- pgpool-II のマスタースレーブモード
- スレーブサーバのデータは遅れる

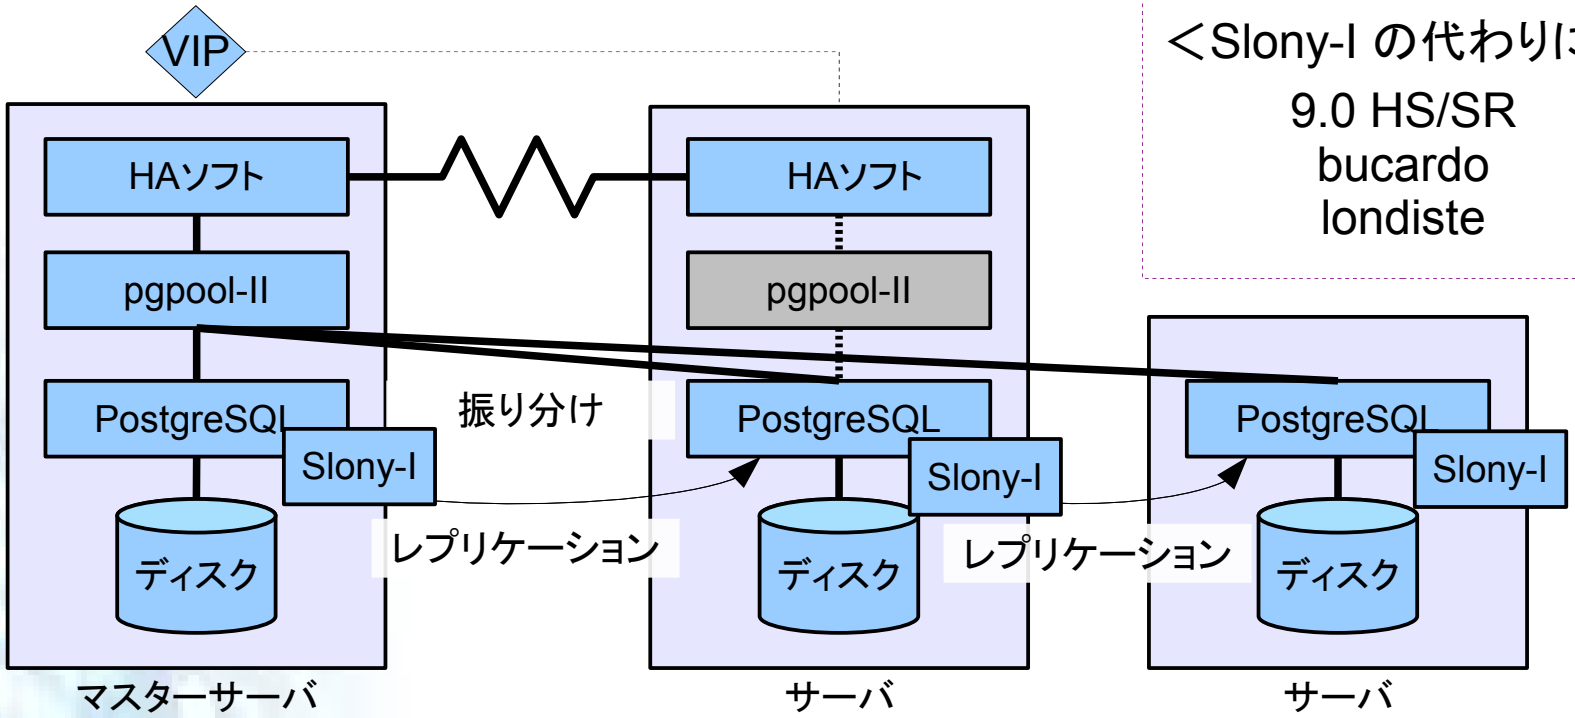

＜Slony-I の代わりに＞

9.0 HS/SR
bucardo
londiste

シェアードナッシング＋分散クラスタ

- 巨大テーブルを水平分割して各ノードに格納
- 透過的なアクセスを可能にする分散クラスタソフトウェア
- 読み取り中心、OLAP では実用多数
  - （単純な）書き込み主体も OK、複雑で不規則な書き込みは？

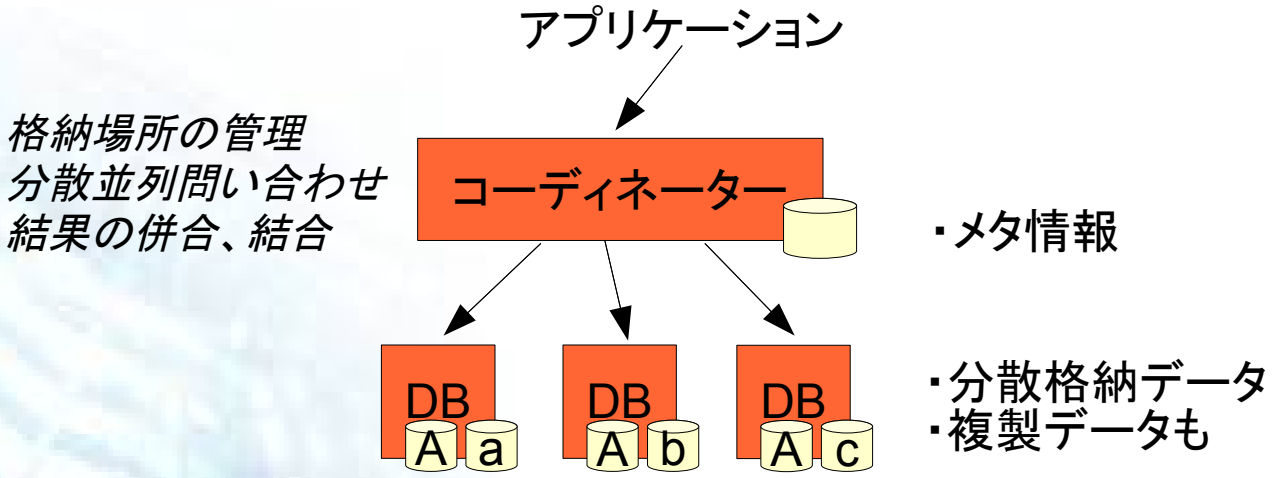

＜分散クラスタ＞
GridSQL
pgpool-II
Postgres-XC
GreenPlum
postgresForest
etc..

アプリケーション実装として・・・ 機能分割、利用単位分割

- サービスの機能ごとに分ける
- 利用単位（ASPなら契約顧客ごと等）に分ける

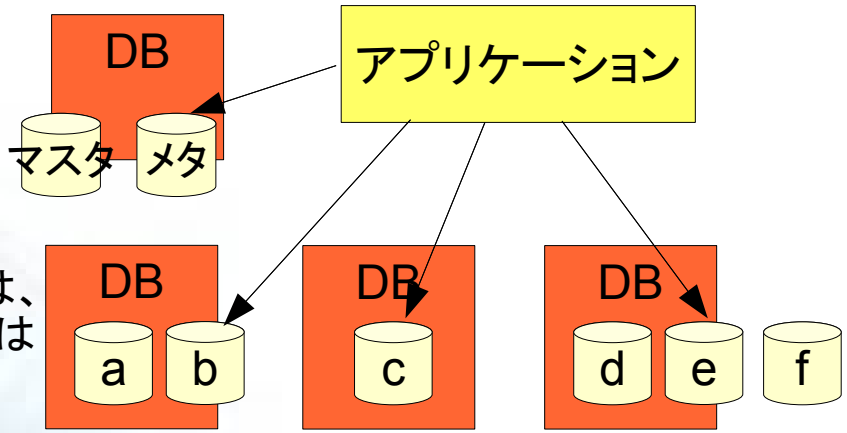

a, b, c, d .. は、機能、あるいは利用単位

JOINしたい共通データをテーブル単位でレプリケーションする

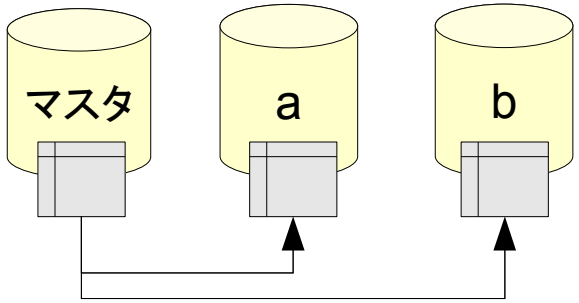

Slony-I など利用

DB分割しやすい設計か？

分散クラスタソフトを試してうまく書き込み性能をスケールできないなら手堅い方法

ご質問