PostgreSQL最新情報
～ 9.2バージョンほか ～

WebDB Forum 2012

2012-11-20　10:35～11:00

SRA OSS, Inc. 日本支社

高塚 遥 harukat@sraoss.co.jp

PostgreSQL のこれまでと現在

改めて・・・ PostgreSQL とは

- 代表的なオープンソースRDBMS
- Ingres(1970～ UCB) を先祖に持つ
  - PostgreSQL 6.0 (1996 ～) から 15年以上の歴史
- BSDタイプのライセンスで配布
  - PostgreSQL Global Development Gruop と University of California が著作権を持つ
- ひとつのオーナー企業、オーナー個人を持たない
  - PostgreSQL開発に時間を割く技術者を提供している企業がいくつかある／その企業群も少しずつ変遷している

PostgreSQL開発体制

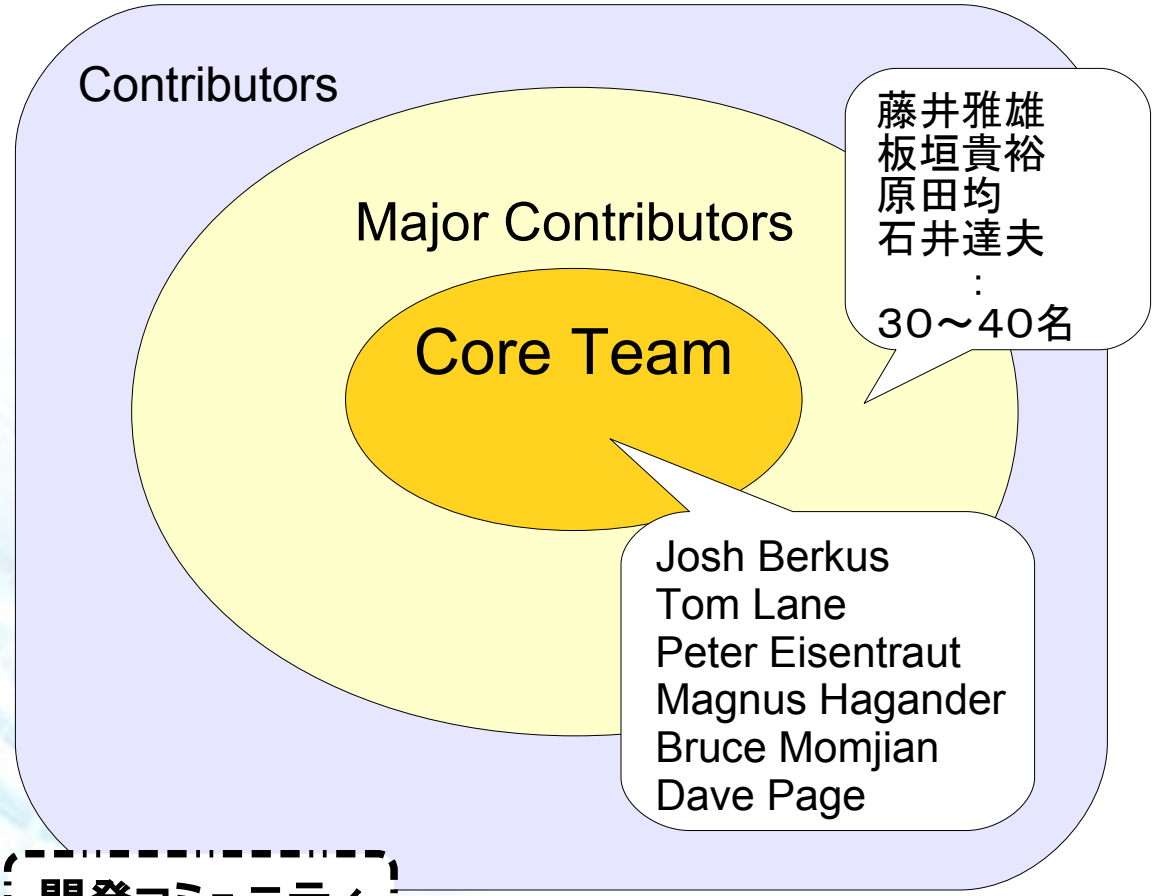

支援企業

FORCIA
NTT
EMC²
where information lives
SRA OSS, INC.
redhat
PGX
POSTGRESQL EXPERTS, INC.
Redpill Linpro
F-Secure
EnterpriseDB
etc...

1年 1バージョン
を
10年以上！

PostgreSQLの歩み

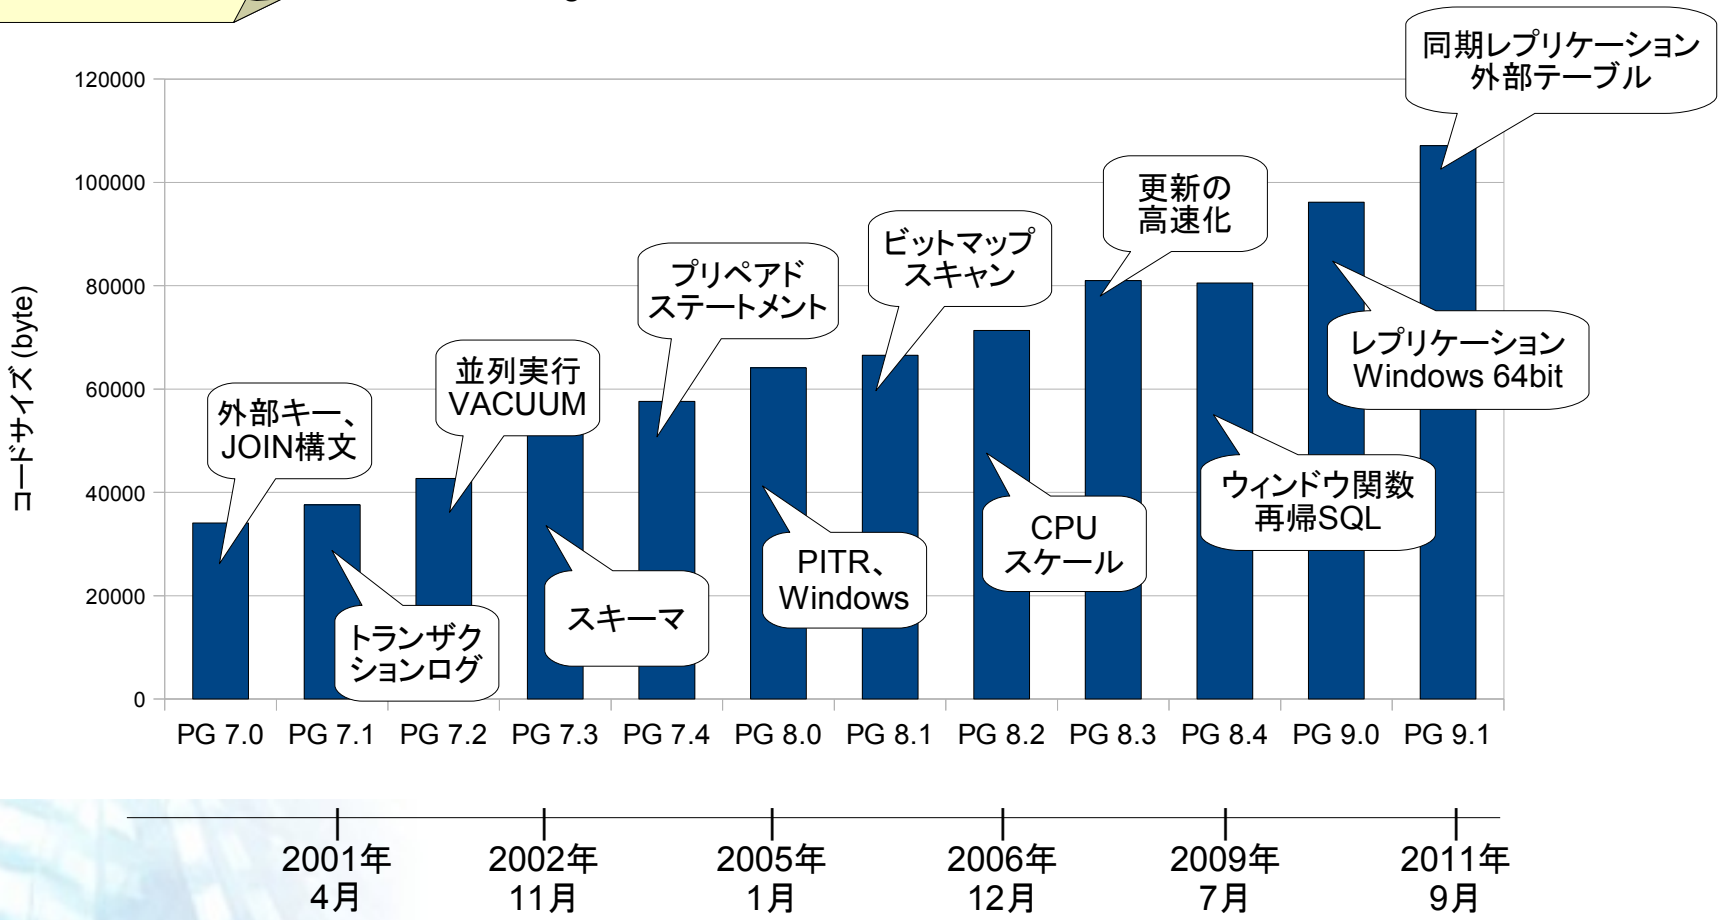

PostgreSQL 9.2 リリース

- 2012/9/10 に無事リリースされました

- しかし、さっそく 9.2.1 リリース （2012/9/24）
  - レプリケーション先でデータ破損の可能性・・・特に index-only scan で問題となる
  - その他、プランナまわりの修正

PostgreSQL 9.2 の拡張

CPUスケール対応

- PostgreSQL 9.2 で コア数32～64までスケール
  - ⇒ PostgreSQL 8.2 で改良 コア数 8～12 まで

64コアマシンで参照pgbench

※PGCon 2012
EnterpriseDB社 Robert Haas の
発表資料より引用

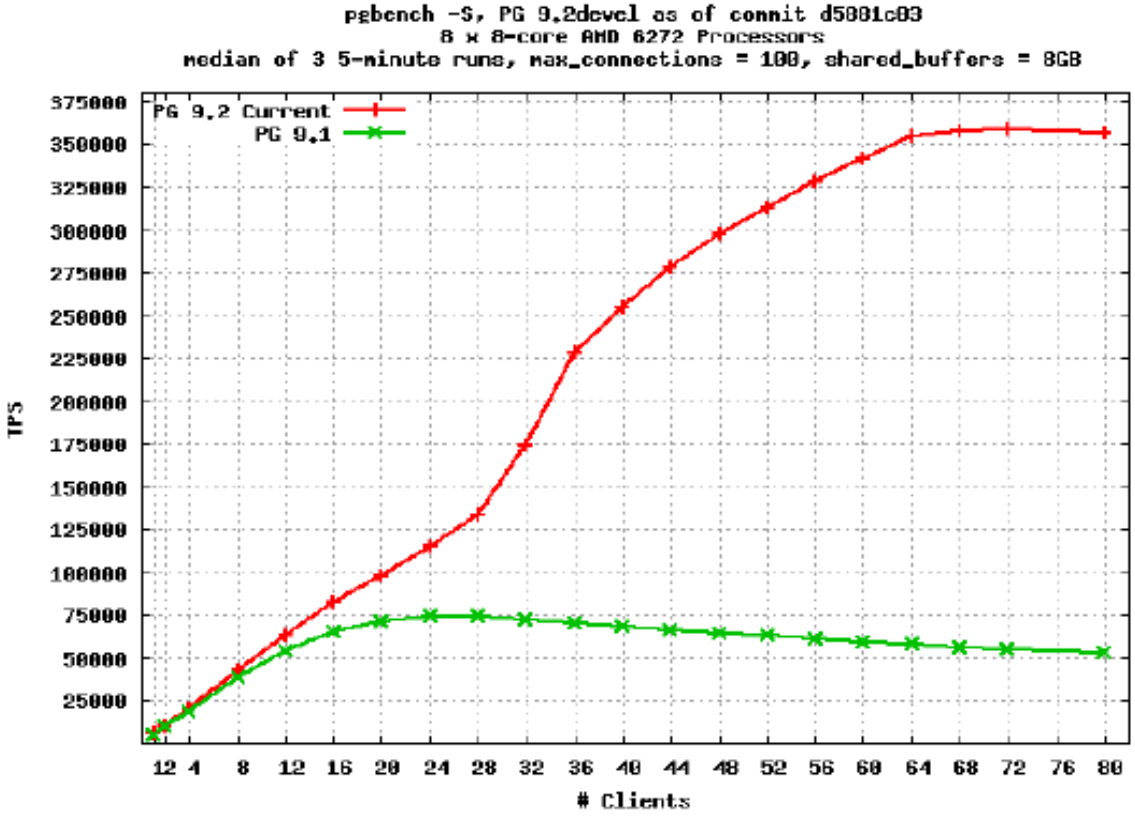

・Fast Pathロック
・直列化部分を短時間に
・WALディスク同期を改善

書き込みトランザクション改善

- 小規模性能サーバ（2コアマシン）
  - 標準 更新pgbenchでは差は僅か

多接続で５～１０%程度の改善がみられるのみ。

ストレージ律速になるとバージョン差が出ない。

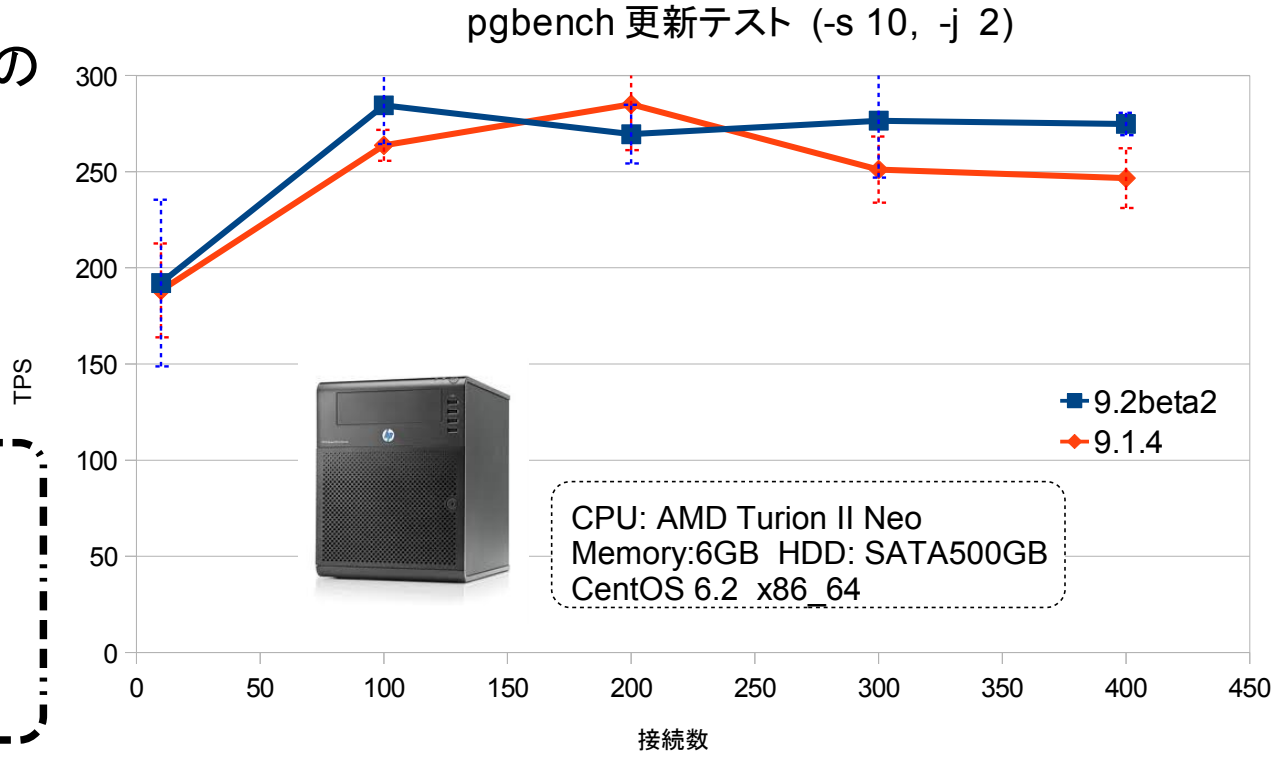

・Fast Pathロック
・直列化部分を短時間に
・WALディスク同期を改善

COMMIT遅延の改善

- 2コアマシンでもテスト内容によっては大幅性能向上

独自シナリオでpgbench実行
（休止を入れた更新処理）

COMMIT遅延が解消

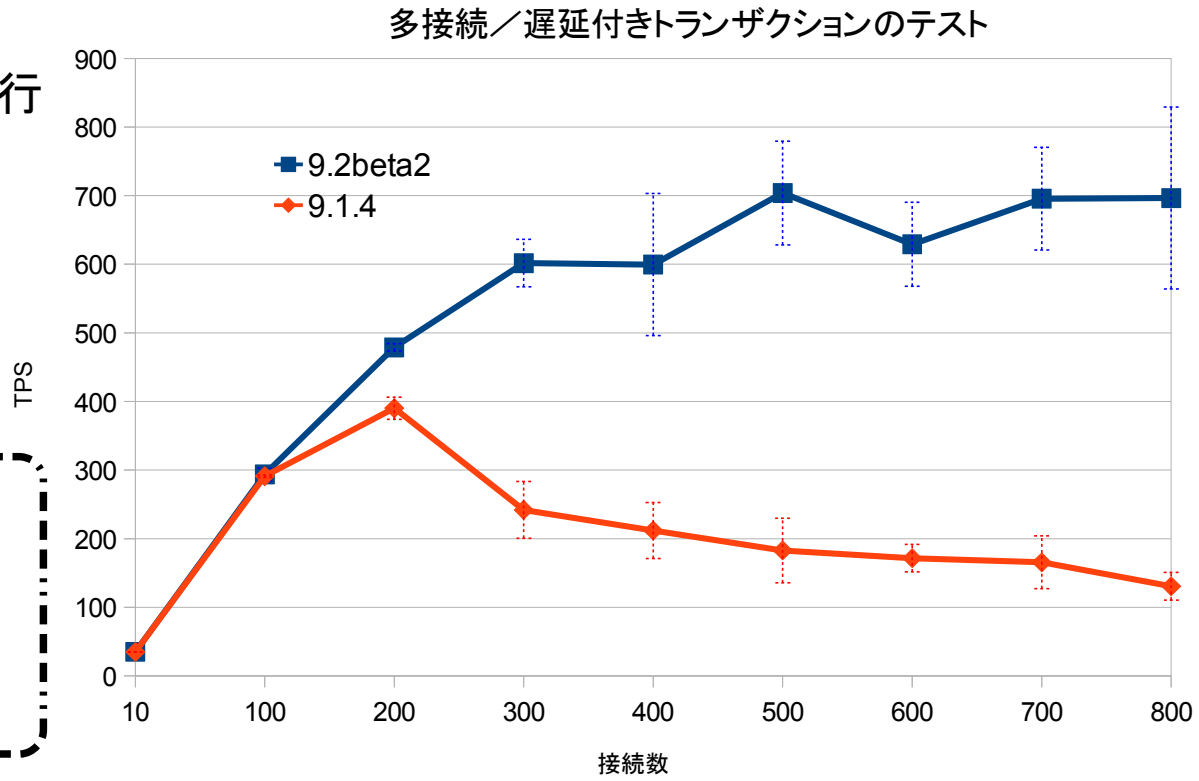

・Fast Pathロック
・直列化部分を短時間に
・WALディスク同期を改善

Index Only Scan（1）

- インデックスだけを読んで処理できる
  - 行バージョンがあるため難しかったが Visibility Map を参照して「可能なときには行う」ことで対応

```
=# EXPLAIN select min(i) from t;

                  QUERY PLAN
-------------------------------------
 Result
  InitPlan 1 (returns $0)
   -> Limit
   -> Index Only Scan using tix on t
      Index Cond: (i IS NOT NULL)
```

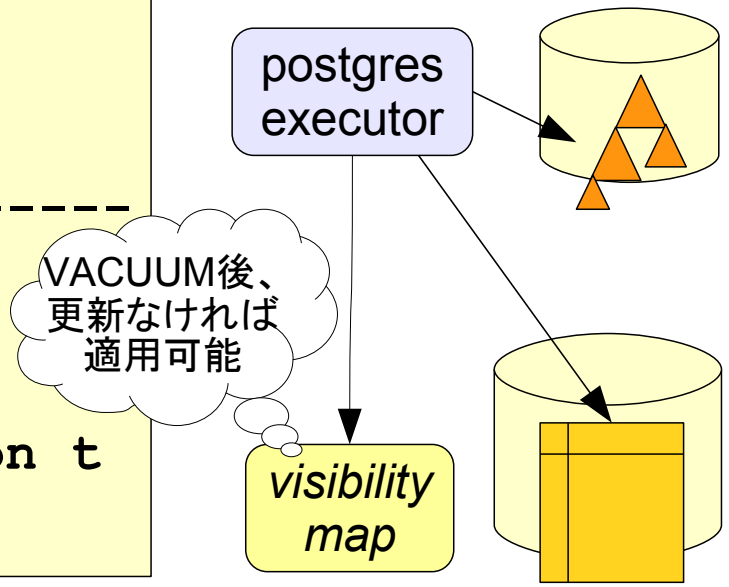

Index Only Scan（2）

- 適用されれば大きな効果
  - 読み込みブロック減
  - バッファヒット率向上
  - min, max, count などに有効

《全50万行から30万行を参照》

```
=> SELECT aid FROM
   pgbench_accounts
   WHERE aid < 300000;
```

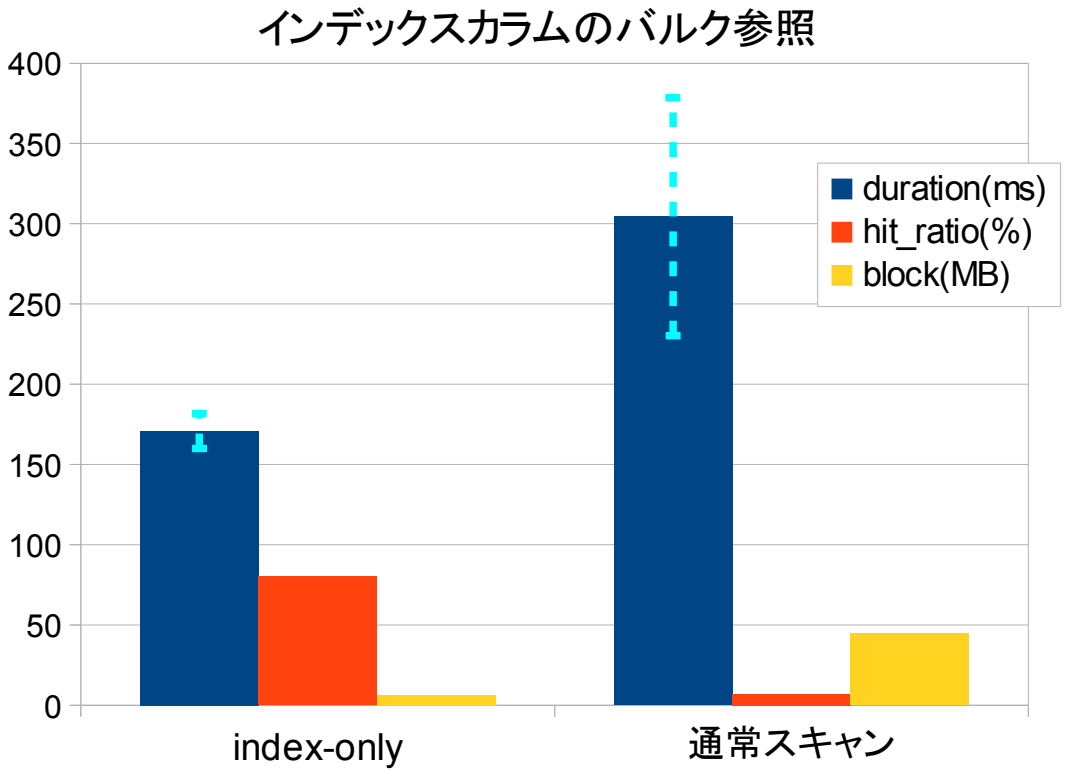

IBM Power780 による測定結果(1)

参照pgbench -s 100, -S -c 64 -j 32 -T 300

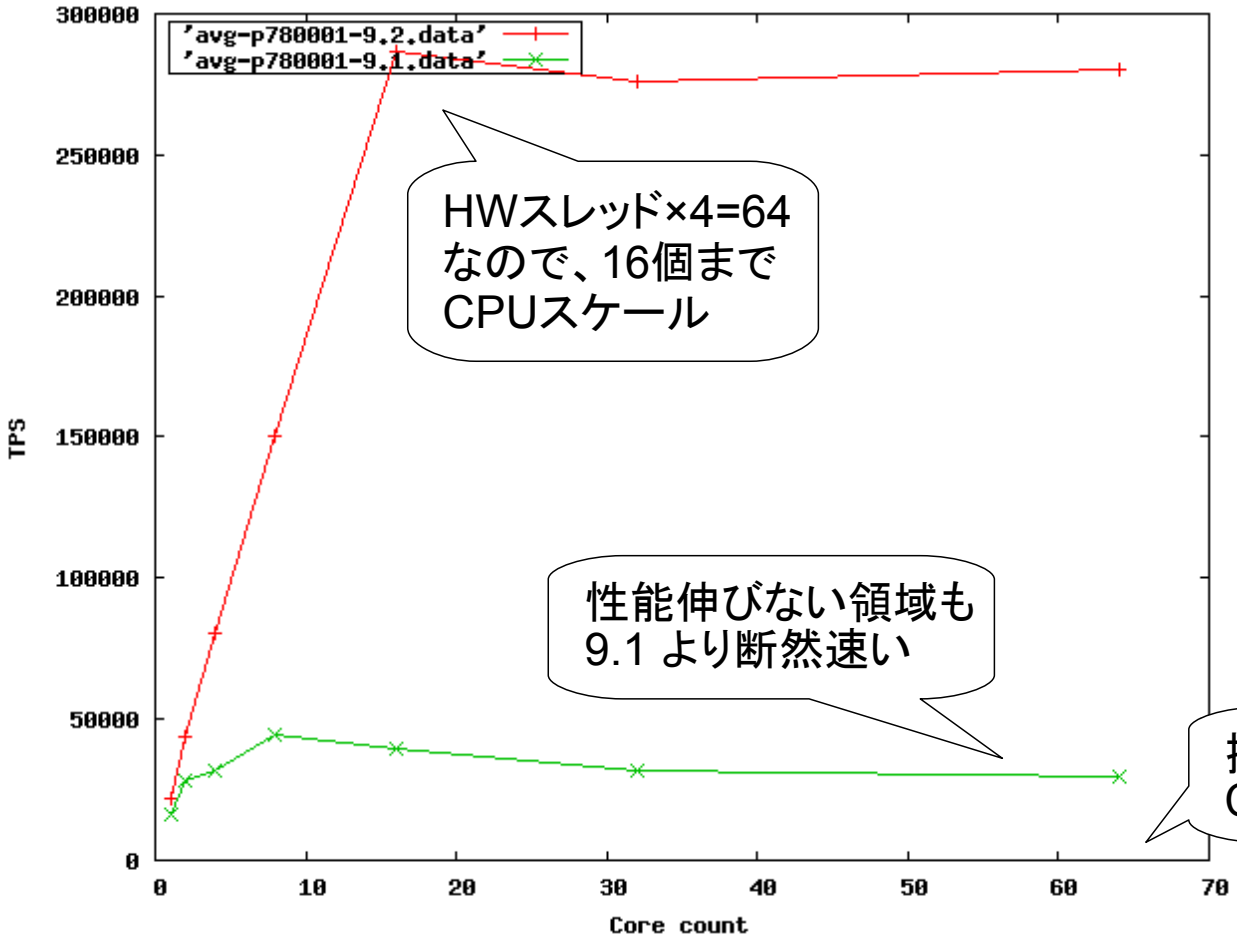

HWスレッド×4=64
なので、16個まで
CPUスケール

性能伸びない領域も
9.1 より断然速い

接続数でなく、
CPUコア数を増やす

CPU: POWER7 64core × HW4thread
Memory:64GB Storage: Fibre/RAID

64コアスケールを確認。

9.2 で POWERチップむけ
固有の改修あり

IBM Power780 による測定結果(2)

Index Only Scan を pgbench -s 10000, -S -c 64 -j 32 -T 300 でテスト

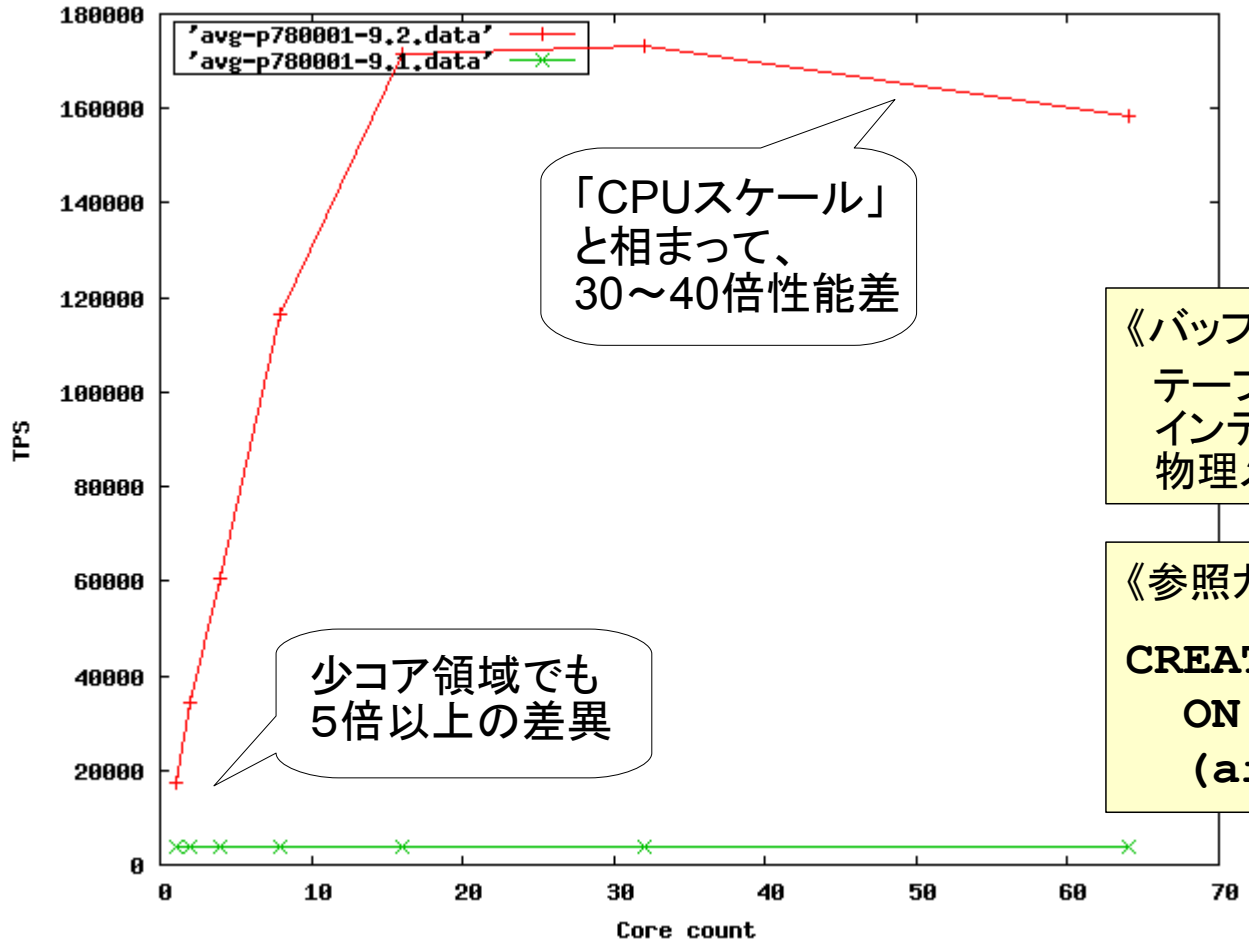

Index Only Scan のある 9.2 が圧倒的な性能優位を示す。

《バッファに載らないデータ規模》

テーブル	125 GB
インデックス	42 GB
物理メモリ	64 GB

《参照カラムにインデックス作成》

```
CREATE INDEX
  ON pgbench_accounts
  (aid, abalance);
```

レプリケーション拡張（1）

- カスケード構成に対応
  - マスターサーバの負荷軽減策に
  - オンライン物理バックアップをスタンバイ側から取れる

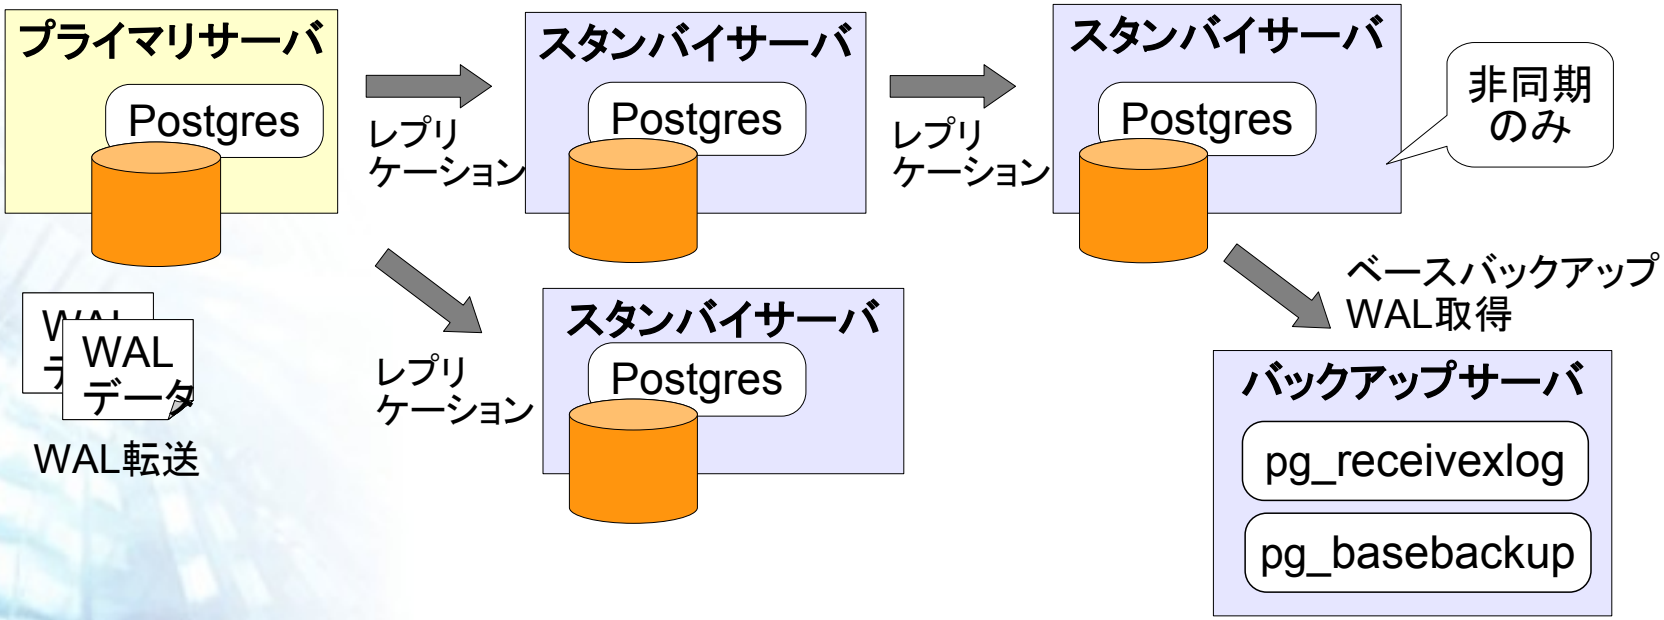

レプリケーション拡張（2）

- remote_write モードが追加
  - より軽量、低信頼な同期レプリケーション

同期レプリの
オプション

```
synchronous_commit = 'remote_write'          #  'off', 'local', 'remote_write' or 'on'
```

高速

	COMMIT時のWAL書き込み動作
off	ディスク同期を待たない
local	自機のディスク同期を待つ
remote_write	自機のディスク同期を待つ レプリ先への書き込み完了を待つ
on	自機のディスク同期を待つ レプリ先のディスク同期を待つ

安全

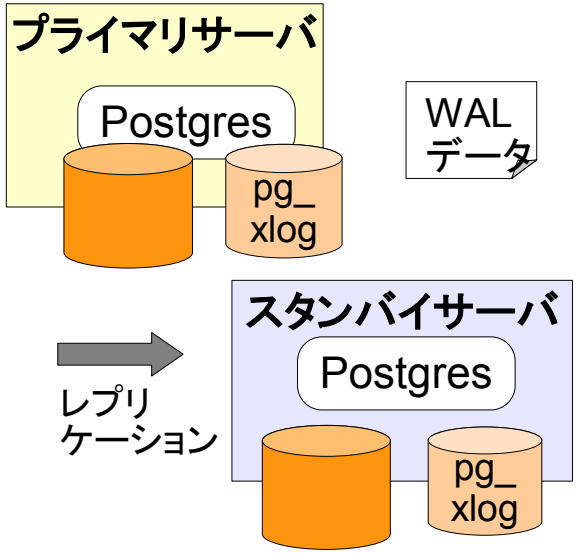

レプリケーション拡張（3）

- pg_receivexlog ユーティリティが追加
  - 接続してWALを受領して保存するユーティリティ

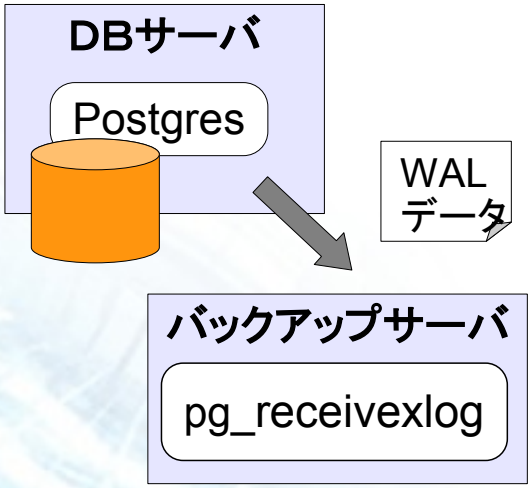

	archive_command	pg_receivexlog
特性	プッシュ型	プル型
単位	ファイル単位	ストリーム
経路	cpコマンド等	ネットワーク経由
サーバ側の動作	アーカイブに失敗している限り pg_xlog から消えない	pg_xlog 内のWALは構わず消える。要求した古いWALが無いとエラーになる。

組み合わせ指定例:

```
archive_command = 'sleep 5 && test -f /mnt/server/archivedir/%f'
```

Range data type (1)

- 範囲を表現するデータ型
  - 重なり検出する演算子 && など
    - gist インデックスが利用可能
  - 8.4 で導入された排他制約と組み合わせ
    - 重なりがあったら制約違反
    - これまでは BOX型くらいしか使える対象がなかった

データ型	要素データ型
int4range	int
int8range	bigint
numrange	numeric
tsrange	timestamp
tstzrange	timestamptz
daterange	date

演算子	意味
<@	含まれる
&&	重なりがある
*	共通範囲
+	合併範囲
>=	範囲の大小比較

《排他制約の定義例》

```
ALTER TABLE reservation
  ADD EXCLUDE
  USING gist (during WITH &&);
```

Range data type (2)

- ユーザ定義の範囲型を利用可能

大小比較ができる型

```
=> CREATE TYPE float4range AS RANGE (SUBTYPE = float4);
```

- 境界値を含む／含まないを指定できる

```
=> SELECT '(1.5, 2.1]'::float4range;
 float4range
-------------
 (1.5,2.1]

=> SELECT 1.5::float4 <@ '(1.5, 2.1]'::float4range;
 ?column?
----------
 f
```

空範囲 '(,)'
開範囲 '(0, NULL)'
なども表現可能

境界値を含まない
ので False になる

JSONデータ型

- JSON構文チェック
  - 配列や行からJSON型への変換関数がある

逆向きの変換手段は乏しい

```
=> SELECT * FROM t;
 id | name |        tags
----+------+--------------
  1 | 犬   | {従順,賢い}
  2 | 猫   | {自由}
  3 | 虎   | {強い,恐い,希少}

=> SELECT row_to_json(t) FROM t WHERE id = 3;
                    row_to_json
-----------------------------------------------
 {"id":3,"name":"虎","tags":["強い","恐い","希少"]}
```

これは文字列の配列型

JSONの配列になっている

セキュリティ関連

- セキュリティバリア ビュー
  - 関数を通してアクセス不可のカラム内容が漏れることがありえたのをガード

```
=> SELECT * FROM v1 WHERE f_leak(passwd);
NOTICE:  f_leak => passwd12345
```

```
CREATE VIEW v1 WITH (security_barrier) AS...
ALTER VIEW v1 SET (security_barrier=true)
```

デフォルト false

  - LEAKPROOF 関数定義オプション
    - 「この関数は安全」を宣言
- SE-pgsql の対応範囲拡大

CREATE、DROP なども

プリペアドステートメント
であっても、必ずしも
プラン固定しない

Parameterized Plan

```
=> PREPARE p1 (bigint)
  AS SELECT * FROM pgbench_accounts WHERE aid < $1;

=> EXPLAIN (COSTS OFF) EXECUTE p1(100000);
            QUERY PLAN
---------------------------------
 Seq Scan on pgbench_accounts
   Filter: (aid < 100000::bigint)

=> EXPLAIN (COSTS OFF) EXECUTE p1(10);
                QUERY PLAN
-------------------------------------------
 Index Scan using pgbench_accounts_pkey
     on pgbench_accounts
   Index Cond: (aid < 10::bigint)
```

9.1 では
プラン固定

行数が多ければ
Seq Scan

行数少なければ
Index Scan

スナップショットのエクスポート、インポート

- パラレルスキャンのための基盤機能

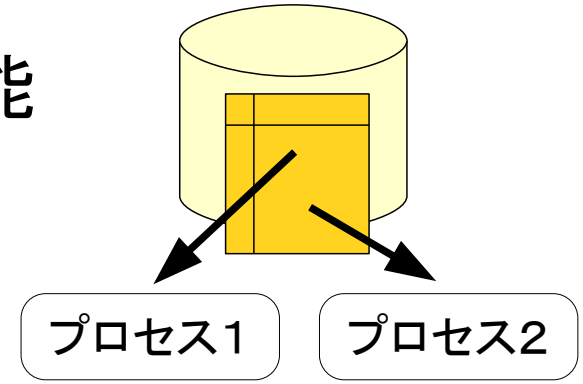


```
=# BEGIN TRANSACTION ISOLATION
   LEVEL REPEATABLE READ;

=# SELECT pg_export_snapshot();
 pg_export_snapshot
--------------------
 000008F2-1
(1 row)

=# SELECT * FROM t1
   LIMIT 100000
   OFFSET 0;
```

```
=# BEGIN TRANSACTION ISOLATION
   LEVEL REPEATABLE READ;

=# SET TRANSACTION SNAPSHOT
  '000008F2-1';

=# SELECT * FROM t1
   LIMIT 100000 OFFSET 100000;
```

その他の拡張(1) - 内部実装

- 省電力
  - 補助プロセスが動作する回数を減らすことで、処理が無い時間帯においてサーバ省電力機能が効果的に働く

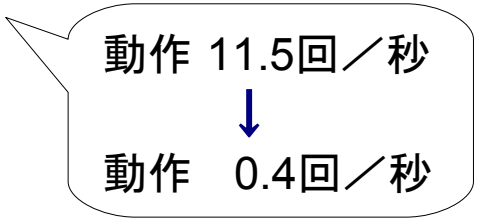

- 各種プランナ、executer改善
  - 高速ソート
  - 配列のコスト見積もり改善
  - 入れ子ループ＋インデックススキャンのプラン改善
- SP-GiST (空間分割GiST) 対応
- libpq で URL表記に対応

その他の拡張(2) - 管理機能など

- contrib/pg_stat_statement
  - SQL集約が改善、I/O 情報収集
- 実行時統計情報の拡充
  - pg_stat_bgwriter チェックポイント動作の情報
  - pg_stat_database デッドロックカウンタ
- ALTER TABLE .. ALTER TYPE の改善
  - 必要なければ全レコード書き込みしない
- DROP INDEX CONCURRENTLY
  - 強いテーブルロックを取らない

SQL実行統計を収集する機能

その他
多数の改良があります

インデックス再構築のオンライン実行を助ける機能

PostgreSQL 9.3 にむけて

- 或いは 9.2 に漏れた機能
  - 配列に外部キー制約
  - contribモジュール pgsql_fdw
  - パラレル pg_dump
  - 外部キー用の行ロック SELECT ... FOR KEY SHARE
  - ページチェックサム
  - 並列スケーリング XLOG挿入
  - コマンドトリガ
  - etc...

PostgreSQL の周辺

9.2 に対応した pgAdmin 1.16

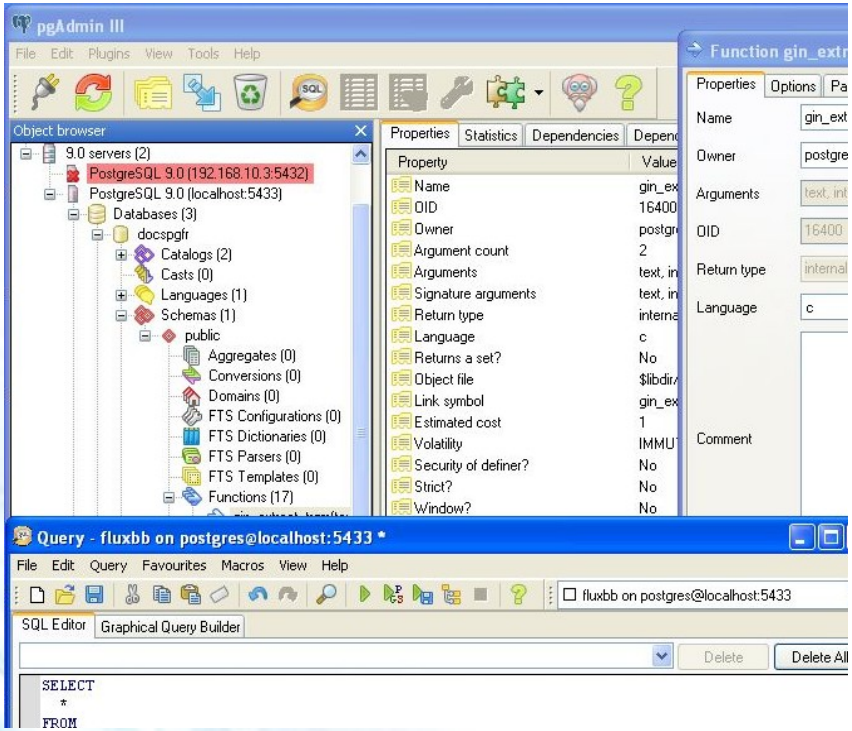

- DB管理とデータアクセス、ストアド開発などに対応するGUIツール
- 各種新オプションに追随
- SE pgsql ラベルなどにも対応

pgpool-II が自身の HA化対応

- PostgreSQL の多機能プロキシサーバ
  - SQL振り分け
  - レプリケーション
  - フェイルオーバー
- pgpool-II 3.2 ～
  - メモリ上クエリキャッシュ
    - memcached 連携
  - 仮想IP管理とpgpoolプロセスの死活監視

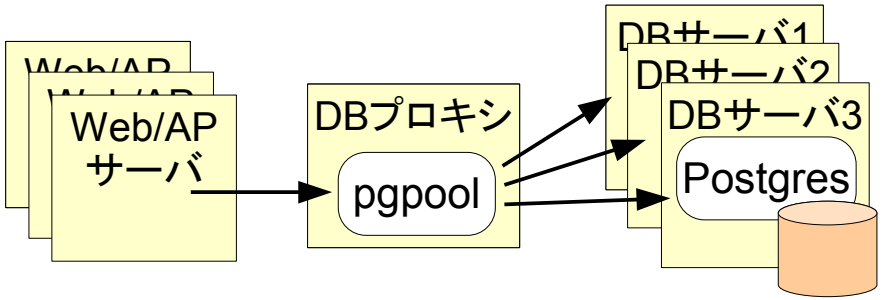

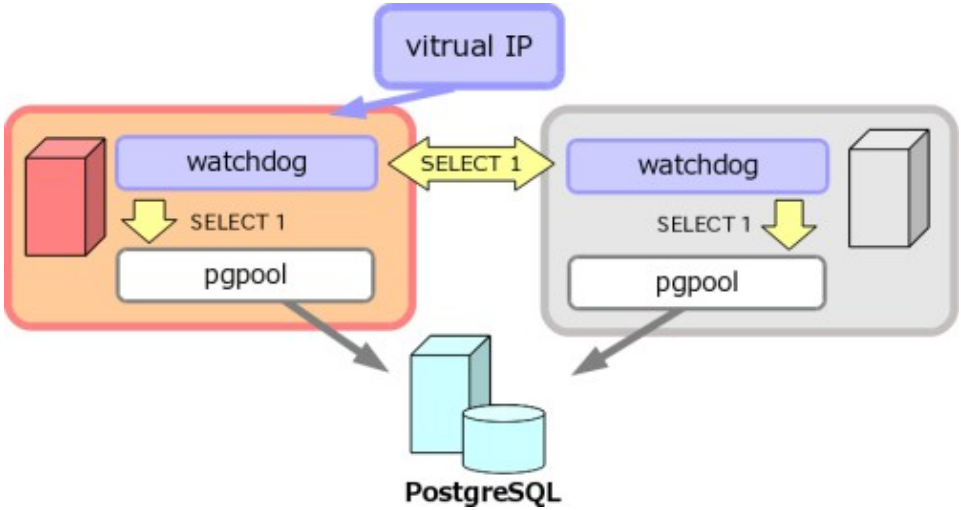

Postgres-XC 1.0 ～1.0.1 リリース

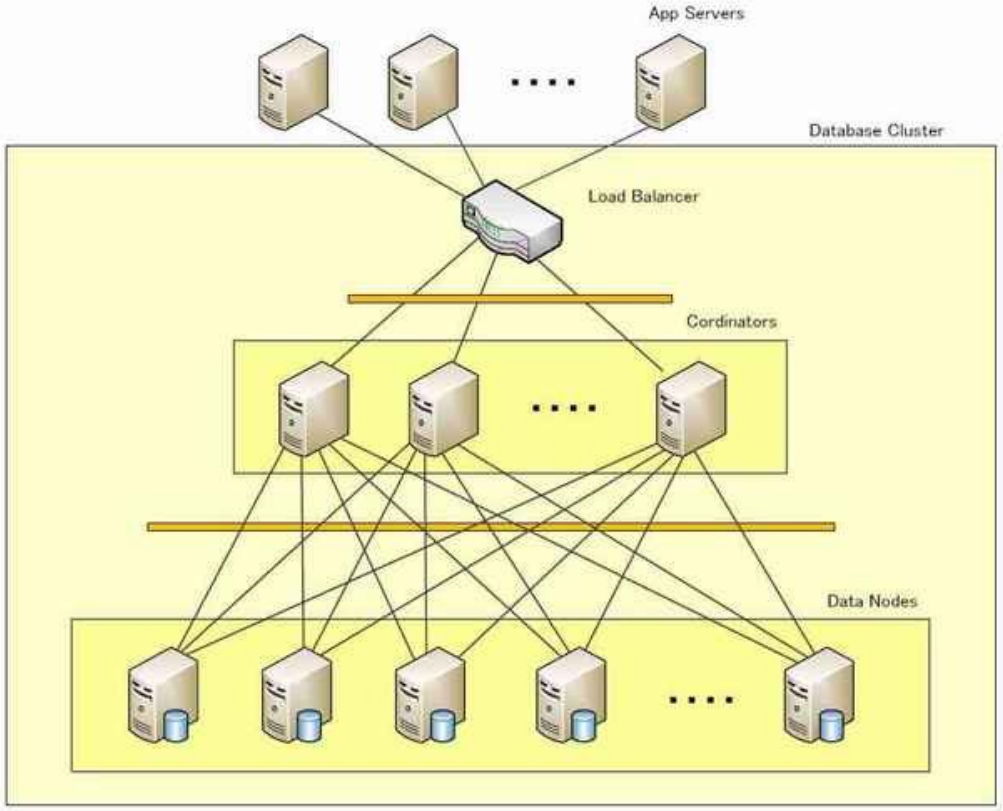

- 分散格納クラスタ
  - 書き込みの負荷分散を実現する
  - レプリケーションも可能
  - 以前から発表、公開されていたが、2012年6月に 1.0 となった
  - 実用はこれから

PGECons が発足しました

PostgreSQLエンタープライズ・コンソーシアム

日本PostgreSQLユーザ会

任意団体	⇔	特定非営利法人
法人の集まり	⇔	(主に)個人の集まり

力点は違えど「PostgreSQLの普及を推進」というのは同じ