PL/Proxy と PgBouncer

広島オープンセミナー2009(2009年11月28日)

講師:桑村 潤

日本PostgreSQLユーザ会

PostgreSQLのしくみ分科会

PL/Proxy, PgBouncer とは

- Skype™のバックエンドのために培われた技術
- 将来の10億ユーザ認証を目標とした高可用性重視の設計
- PostgreSQLを活用し、軽量かつ簡単
  - PgBouncerはコネクションプーラー
  - PL/ProxyはリモートDB呼び出し用プロキシー言語 で、レプリケーションやパーティショニングの記述が可能
- PostgreSQLコミュニティへの返礼として公開(BSDライセンス)
- PostgreSQLが稼動するプラットホームをサポート（Windowsにも対応）

開発背景

- 検索性能

  大規模テーブル・データの分散と接続のプールにより応答速度の向上

- 運用保守

  データの分散によってvacuum、backup、restoreの効率化

- 障害対策

  障害の影響範囲を局所化、システム全体の運用を継続。また、単純な仕組みで迅速な対応を可能に

運用概念図

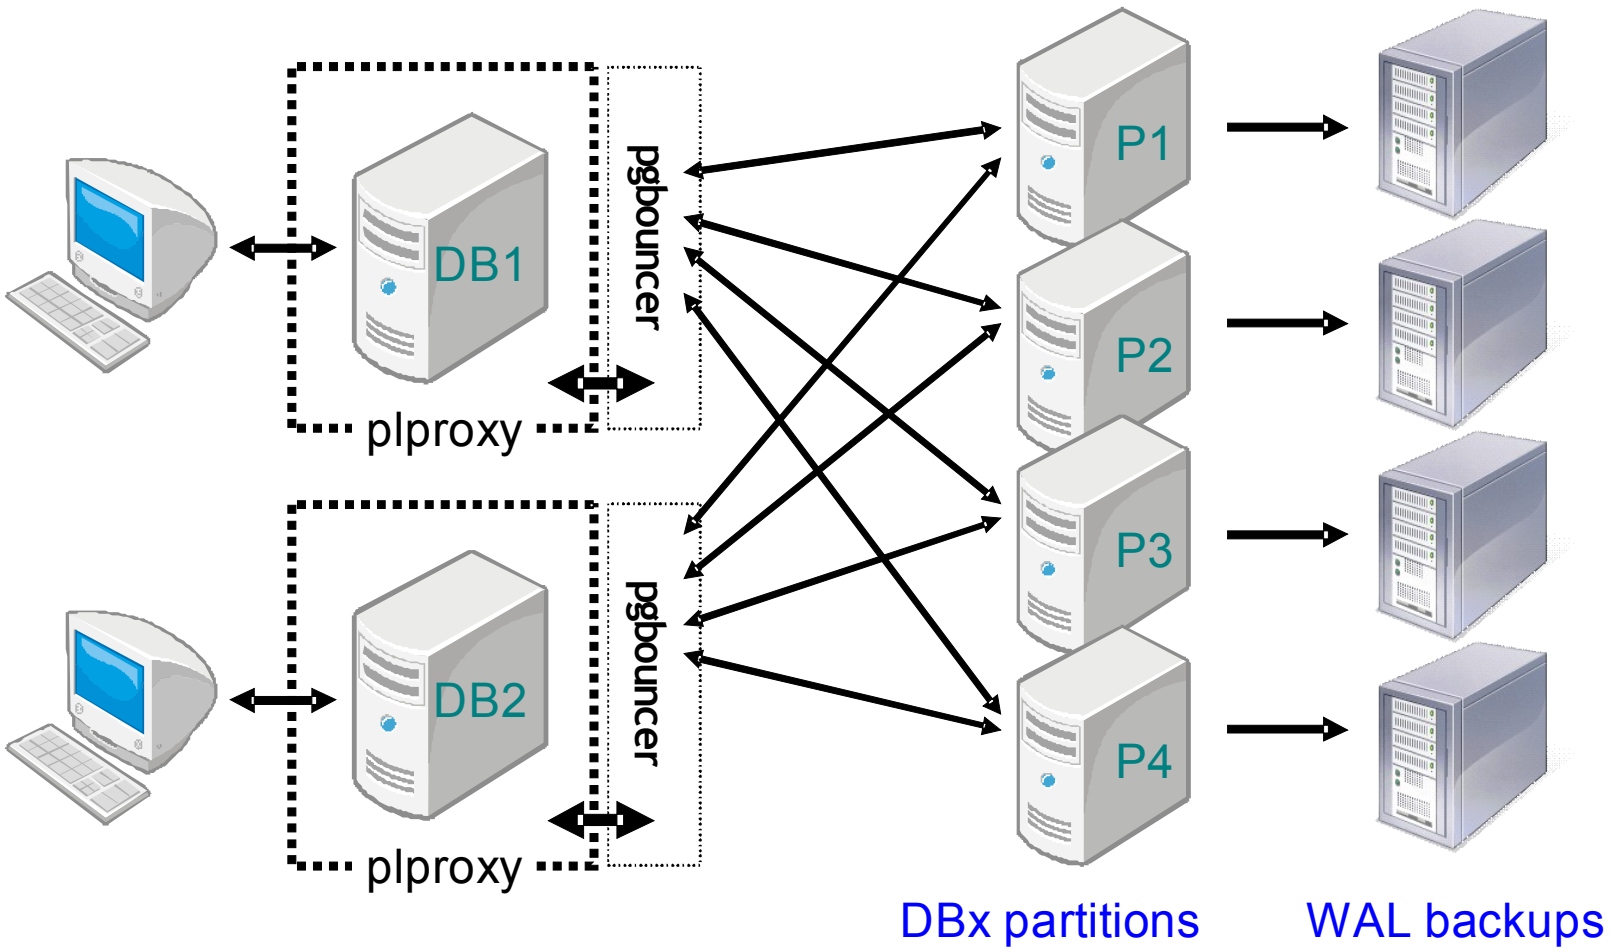

「plproxy+pgbouncer を使ってみよう!」 オープンソース カンファレンス 2009 Okinawa 2009.09.26(土)
(独立行政法人 情報処理推進機構 (IPA) オープンソフトウェア・センター 斉藤 浩)より引用

PgBouncer の特長

- 軽量かつ強固なconnection pooler、必要なメモリ量は、概ね接続当たり2kb
- 複数のPostgreSQLサーバを対象
- 全て、もしくは、特定のPostgreSQLサーバに対して接続を中断可能
- 殆どの環境設定項目をオンラインで変更可能
- クライアント接続の切断なく、オンラインでリスタート／アップグレードが可能
- 処理中SQLを解析しないため、CPUへの負荷は小さい

- https://developer.skype.com/SkypeGarage/DbProjects/PgBouncer

pgbouncerのモジュール構成

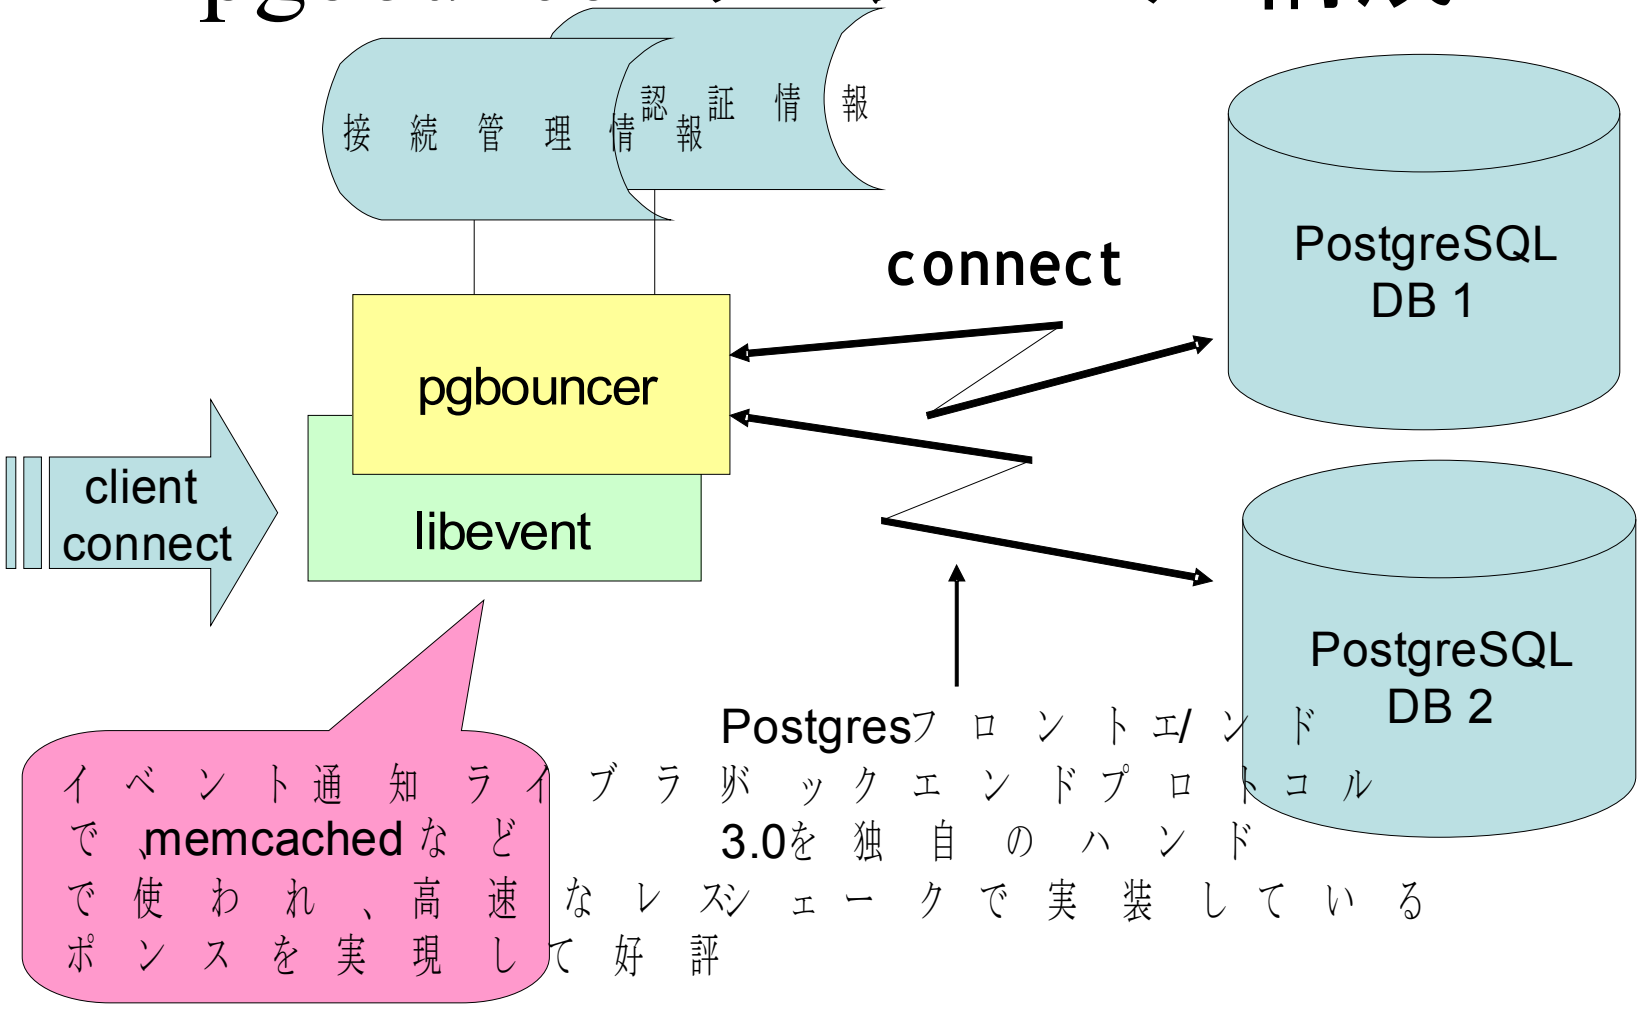

「pgproxy+pgbouncer を使ってみよう!」オープンソース カンファレンス 2009 Okinawa 2009.09.26(土)、(独立行政法人 情報処理推進機構 (IPA) オープンソフトウェア・センター 斉藤 浩)より引用

pgbouncer ：インストール

- 提供サイトの http://pgfoundry.org/projects/pgbouncer から安定版をダウンロード(pgbouncer-1.3.1 2009-07-06)
- ビルドは、所定の作業ディレクトリにpgbouncerを展開し, configure –with-libevent=/prefix; make; make install;を実行(libevent-1.3b以降が必要

  http://www.monkey.org/~provos/libevent からダウンロードしてインストール　libevent-1.4.12-stable 2009-7-24)
- pgbouncer 構成ファイルを編集する

バイナリパッケージ

- RHEL5用には、PGDG PostgreSQL yum リポジトリもある

  http://yum.pgsqlrpms.org/howtoyum.php
- Windows版バイナリはさいとうひろし氏のサイト

  http://winpg.jp/~saito/pg_work/plproxy/pgbouncer/

pgbouncer：プーリング方式

Session Pooling

最も堅実な方法。クライアントが接続すると、1つのサーバ接続が、接続の間、持続して割り当てられる。クライアントの接続が切れたとき、サーバ接続はプールに戻される。レガシーアプリではこの方式が有用。

Transaction pooling

サーバ接続が、1つのトランザクションの間だけ割り当てられる。pgbouncer がそのトランザクションが終了したことを認識した時点で、サーバ接続はプールに戻される。バックエンド接続したアプリケーションの例外で壊す恐れがあるので要注意。アプリケーションと協調をとって使い方を注意し、クライアントを壊す恐れのない機能のみを使うべき。

Statement pooling

最も活性的なプール方法。マルチステートメントのトランザクションには使えない。すなわち、“autocommit”モードをクライアントに強制し、PL/Proxyとの連携が主な目的。

PL/Proxyの特長

- PostgreSQLのストアドプロシージャ言語(PL/pgsql)で書かれた拡張モジュール
- リモートデータベースのプロシージャを呼び出すためのプロキシー言語
  - 例えば、フィールド値のハッシュをもとにデータベース間にデータを分割（構成関数で定義）
- リモート関数と同じ名前のプロキシー関数を作成し、行き先の情報はプロキシー関数の中で指定

- https://developer.skype.com/SkypeGarage/DbProjects/PlProxy

plproxyのモジュール構成

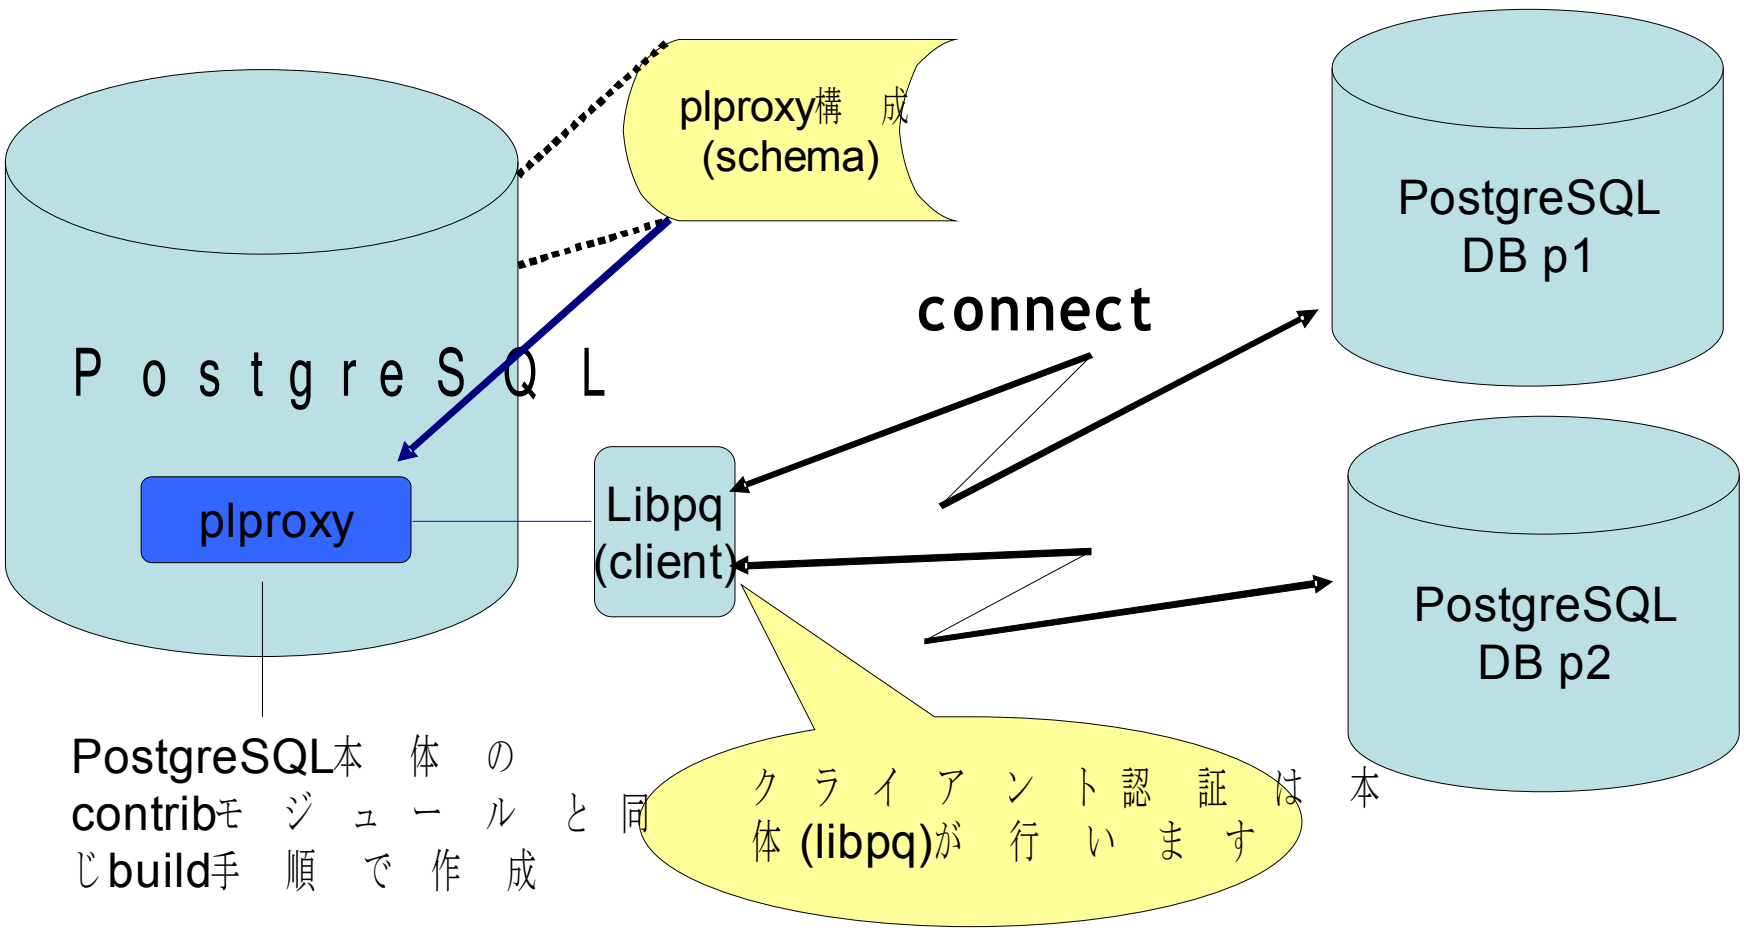

「plproxy+pgbouncer を使ってみよう!」オープンソース カンファレンス 2009 Okinawa 2009.09.26(土)、
(独立行政法人 情報処理推進機構 (IPA) オープンソフトウェア・センター 斉藤　浩)より引用

plproxy：インストール

- 提供サイトの http://pgfoundry.org/projects/plproxy から
- 安定版をダウンロード(plproxy-2.0.8　2009-01-16)
- ビルドは、所定の作業ディレクトリにplproxyを展開して、

  make;　make install; を実行(問題が起きる場合は、pg_config等PostgreSQL の実行バイナリディレクトリにpathが通っているか確認
- ターゲットのデータベースへplproxy機能をインストールするために、plproxy.sqlファイルをロードする

  # psql　-f　$PGSHARE/contrib/plproxy.sql　mydb
- plproxyの動作確認のために、テスト機能を作成

バイナリパッケージ

- RHEL5用など、PGDG PostgreSQL yum リポジトリもある

  http://yum.pgsqlrpms.org/howtoyum.php
- Windows版バイナリはさいとうひろし氏のサイト

  http://winpg.jp/~saito/pg_work/plproxy/

plproxy : Language

- 定義言語は、PL/PgSQLと類似
  - ストリングの引用、コメント、行末のセミコロン
  - ステートメントは4つだけ
    - CONNECT, CLUSTER, RUN, SELECT
- 各々の機能は、どのデータベースでSQLを実行させるべきかを決定するために、CONNECTか、CLUSTERステートメントと RUNステートメントのペア構成が必要
- CONNECT 'libpq connstr'; クエリを接続し実行するために、場所を指定。複数機能が同じconnstrを持てば、同じ接続を使用
- CLUSTER 'cluster_name'; 実行するcluster nameを指定 cluster nameは、plproxy.get_cluster_*機能でpassされたもの
- CLUSTER cluster_func(..); proxy機能引数と同時にクラスタ名 をダイナミックに決定。cluster_funcはクラスタ名文字列を返す

plproxy : Configuration

スキーマ：以下の3つの構成機能は、plproxyのために必須
（これらはPL/pgsqlで記述する関数）

plproxy.get_cluster_partitions(cluster_name text)
リモートのデータベースへ接続する際、指定されているplproxyの接続文字列で初期化。

plproxy.get_cluster_version(cluster_name text)
plproxyの構成が変更された場合、再読込みが必要。全ての機能がplproxyを経由するため、できる限り早く呼ばれるべき。

plproxy.get_cluster_config(
in cluster_name text, out key text,out val text)
接続が確立している間、plproxyパラメータを変更することができる。

plproxy :Language RUN ON...

RUN ON ALL;　クエリをcluster内の全パーティションで並列実行

RUN ON ANY;　ランダムにいづれかのパーティションで実行

RUN ON <NR>;　パーティション番号<NR>の上で実行

RUN ON partition_func(..);

1つ以上のハッシュ値(int4)を返すpartition_func()に指定した関数を実行。

RUN ON argument;　変数(例 $1)でパーティション番号を指定

※ クエリは、タグ付けされたパーティションで実行される。複数のパーティションにタグ付けされれば、クエリはそれらのパーティションで並列実行される

plproxy+pgbouncerの実装例

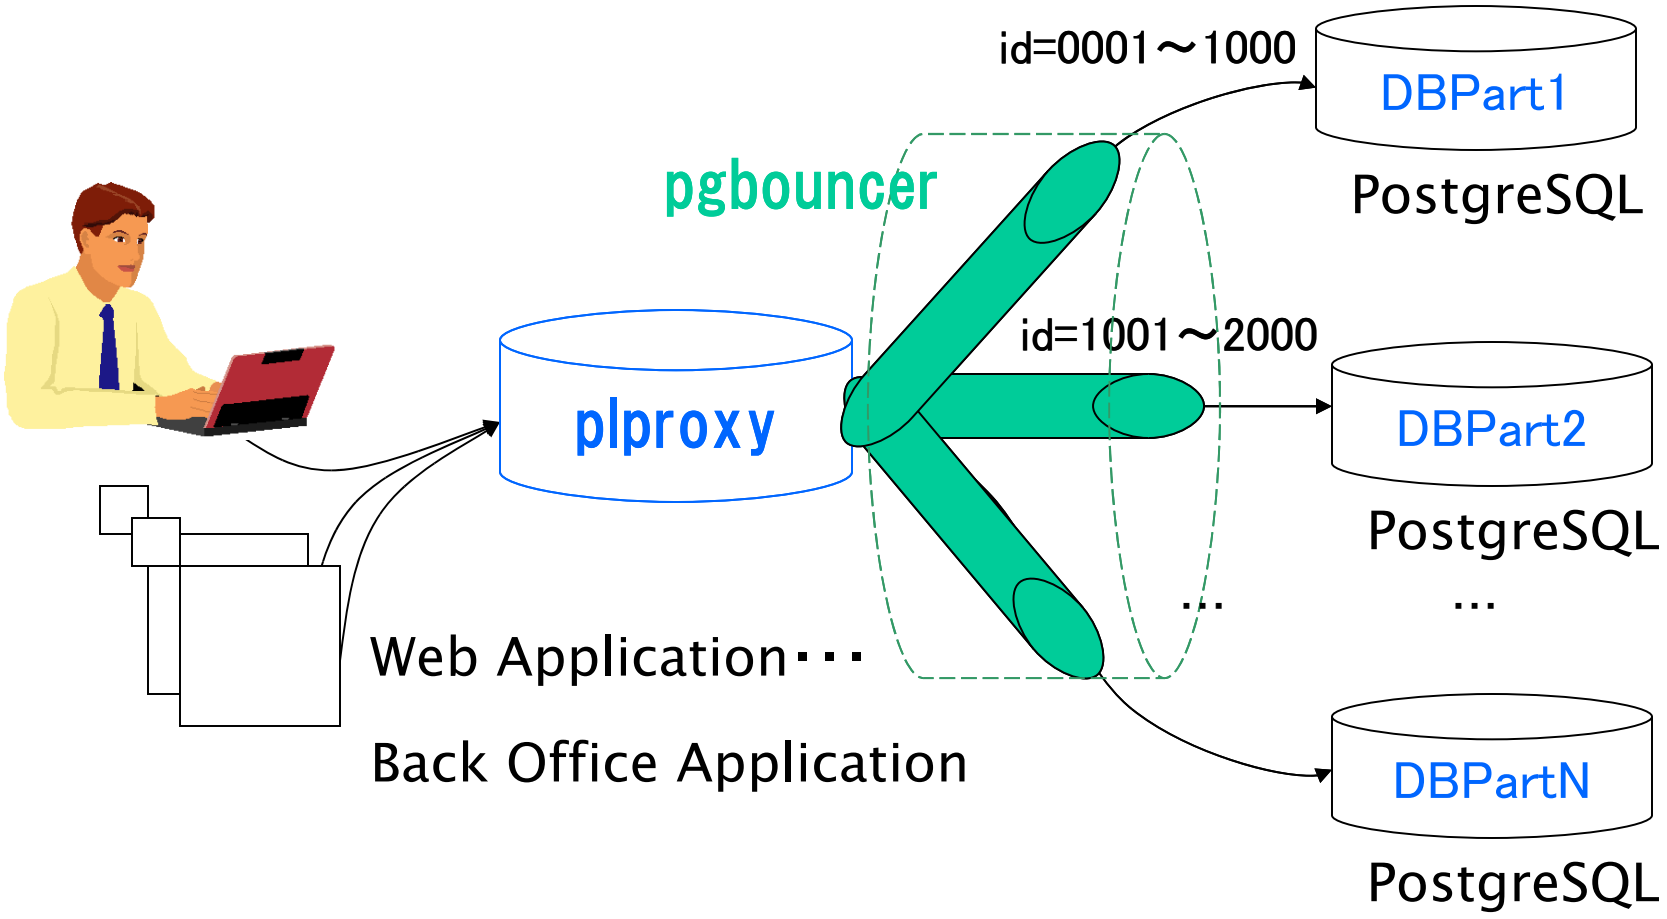

pgbouncer 構成例

```
;; database name = connect string
[databases]
proxy = host=127.0.0.1 port=54320 dbname=jpug user=jpug password=pass
part1 = host=127.0.0.1 port=54321 dbname=jpug user=jpug password=pass
part2 = host=127.0.0.1 port=54322 dbname=jpug user=jpug password=pass

;; Configuation section
[pgbouncer]
admin_users = admin
stats_users = stat_collector

logfile = /home/jpug/pgsql/log/pgbouncer_test.log
pidfile = /home/jpug/pgsql/log/pgbouncer_test.pid

listen_addr = 127.0.0.1
listen_port = 6666

auth_type = trust                              ; any, trust, plain, crypt, md5
auth_file = /home/jpug/pgsql/pgbouncer_test_u.txt

pool_mode = session
;   session      - after client disconnects
;   transaction  - after transaction finishes
;   statement    - after statement finishes
...
```

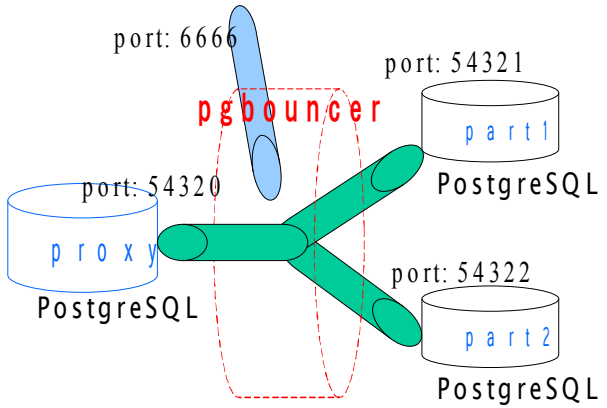

plproxy: 構成例

ユーザ名とメールアドレスからなるテーブルに、plproxyを使ってデータを格納してみる。わずかな設定変更で格納方法を変更できること、格納の仕方による振る舞いの違いを確認する。

RUN ON hashtext(名前)

- hashtext()関数の戻り値(int)によって、複数の格納先パーティションへ振り分ける

※ 次ページ以降のサンプル参照

RUN ON ALL

- 値のセットを返す関数が必要となる(RETRUNS SET OF TEXT)
- すべてのパーティションに格納される

サンプル1：各バックエンドDBでの登録

クラスタ化するデータベースのそれぞれにテーブルの実体と関数を作成する。
関数名は、プロキシ上で登録するものと同じ名前、型、引数型にする。

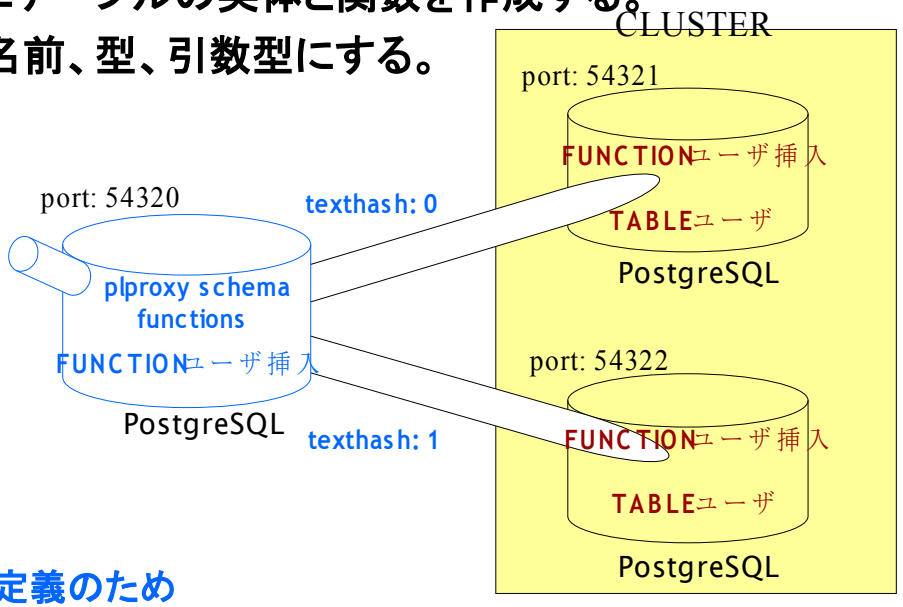


```
CREATE TABLE ユーザ (
 ユーザ名 text,
 メール text
);
-- 各リモート側データベースに定義する挿入関数
create language plpgsql;        --- 関数定義のため
CREATE OR REPLACE FUNCTION ユーザ挿入(ユーザIN text, メールIN text)
RETURNS integer AS $$                                    --- 型に注意
  INSERT INTO ユーザ (ユーザ名, メール) VALUES ($1,$2);
  SELECT 1;                                              --- 型に注意
$$ LANGUAGE SQL;
```

サンプル2a：フロントエンドDBに登録するplproxy構成(plpgsql関数)

(plproxy.get_cluster_partitions)

クエリをリモートデータベースに送る必要があるとき、plproxyは plproxy.get_cluster_partitions(cluster)関数を呼び出し、各パーティションに送るための接続文字列を取得する
（パーティションの数は2の階乗でなくてはならない）

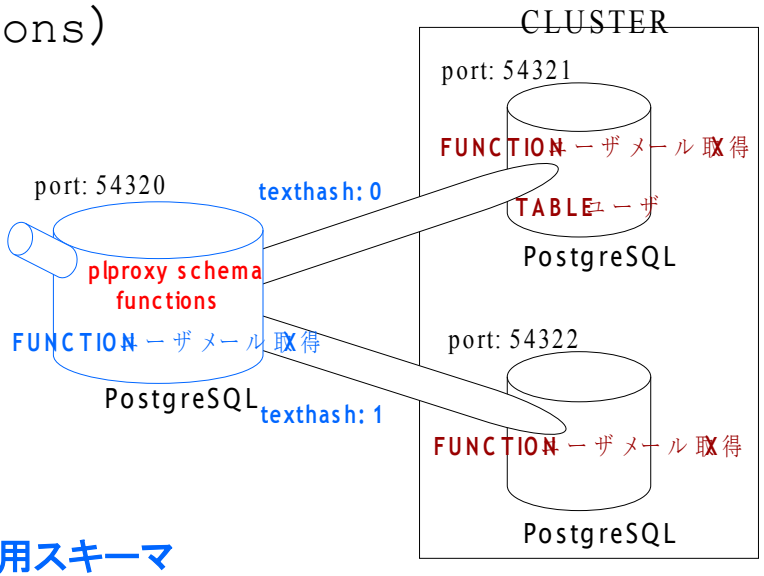


```
CREATE LANGUAGE plpgsql;
CREATE SCHEMA plproxy;          --- plproxy関数用スキーマ
CREATE OR REPLACE FUNCTION plproxy.get_cluster_partitions(cluster_name
text)
RETURNS SETOF text AS $$
BEGIN
  IF cluster_name = 'クラスタ' THEN
    RETURN NEXT 'port=54321 host=127.0.0.1 dbname=jpug user=jpug';
    RETURN NEXT 'port=54322 host=127.0.0.1 dbname=jpug user=jpug';
    RETURN;
  END IF;
  RAISE EXCEPTION 'クラスタ名が見つかりません';
END;
$$ LANGUAGE plpgsql;
```

サンプル2b：フロントエンドDBに登録するplproxy構成(plpgsql関数)

(plproxy.get_cluster_version)

plproxy.get_cluster_version(cluster_name) 関数は、リクエスト毎に呼び出され plproxy.get_cluster_partitions() の結果キャッシュを出力として再利用できるかどうか決定する

```
CREATE OR REPLACE FUNCTION plproxy.get_cluster_version(cluster_name text)
RETURNS int4 AS $$
BEGIN
  IF cluster_name = 'クラスタ' THEN
    RETURN 1;
  END IF;
  RAISE EXCEPTION 'クラスタ名が見つかりません';
END;
$$ LANGUAGE plpgsql;
```

サンプル2c:フロントエンドDBに登録するplproxy構成(plpgsql関数)

(plproxy.get_cluster_config)

plproxy.get_cluster_config() 関数はパラメータを調整する。ここでは接続の持続時間を設定している。他のパラメータについては本体付属文書を参照のこと。

```
CREATE OR REPLACE FUNCTION plproxy.get_cluster_config(
  in cluster_name text,
  out key text,
  out val text)
RETURNS SETOF record AS $$
BEGIN
  -- lets use same config for all clusters
  key := 'connection_lifetime';
  val := 30*60; -- 30min.
  RETURN NEXT;
  RETURN;
END;
$$ LANGUAGE plpgsql;
```

サンプル3：フロントエンドDBに登録する（plproxy関数）

ここでは、ユーザ・テーブルは、ユーザ名のハッシュ値によっていくつかのデータベースに分散されていることを前提としている。パーティショニングされるデータベースへの接続文字列は get_cluster_partitions() 関数の中にある。次の関数は、プロキシーサーバで実行され、適切にパーティショニングされたリモートデータベースから、指定ユーザのメールアドレスを取得。

```
CREATE LANGUAGE plproxy;        --- plproxy言語登録
-- プロキシ側データベースに定義する挿入関数
CREATE OR REPLACE FUNCTION ユーザ挿入(ユーザIN text, メールIN text)
RETURNS integer AS $$           --- 型に注意
  CLUSTER 'クラスタ';
  RUN ON hashtext(ユーザIN);
$$ LANGUAGE plproxy;
```

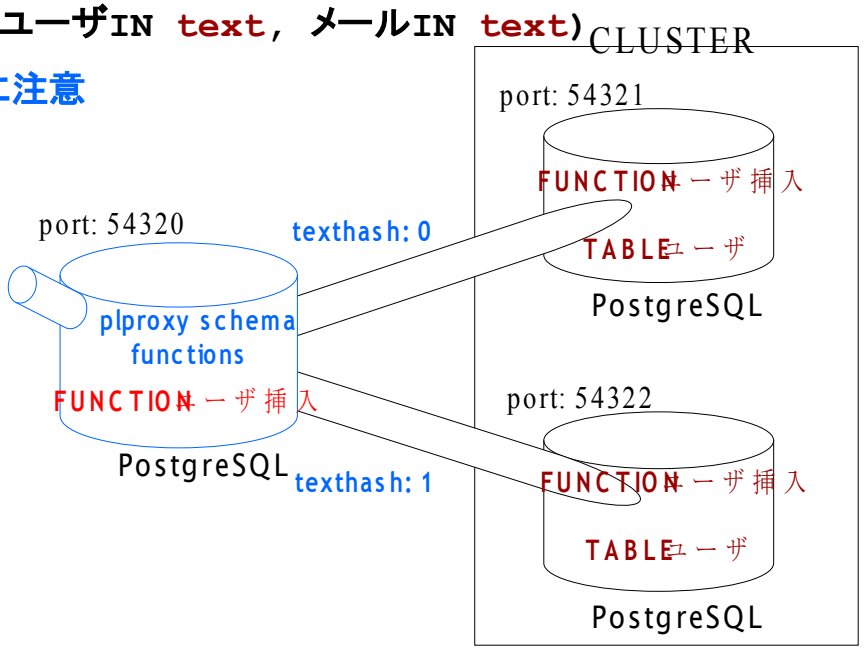

まとめ

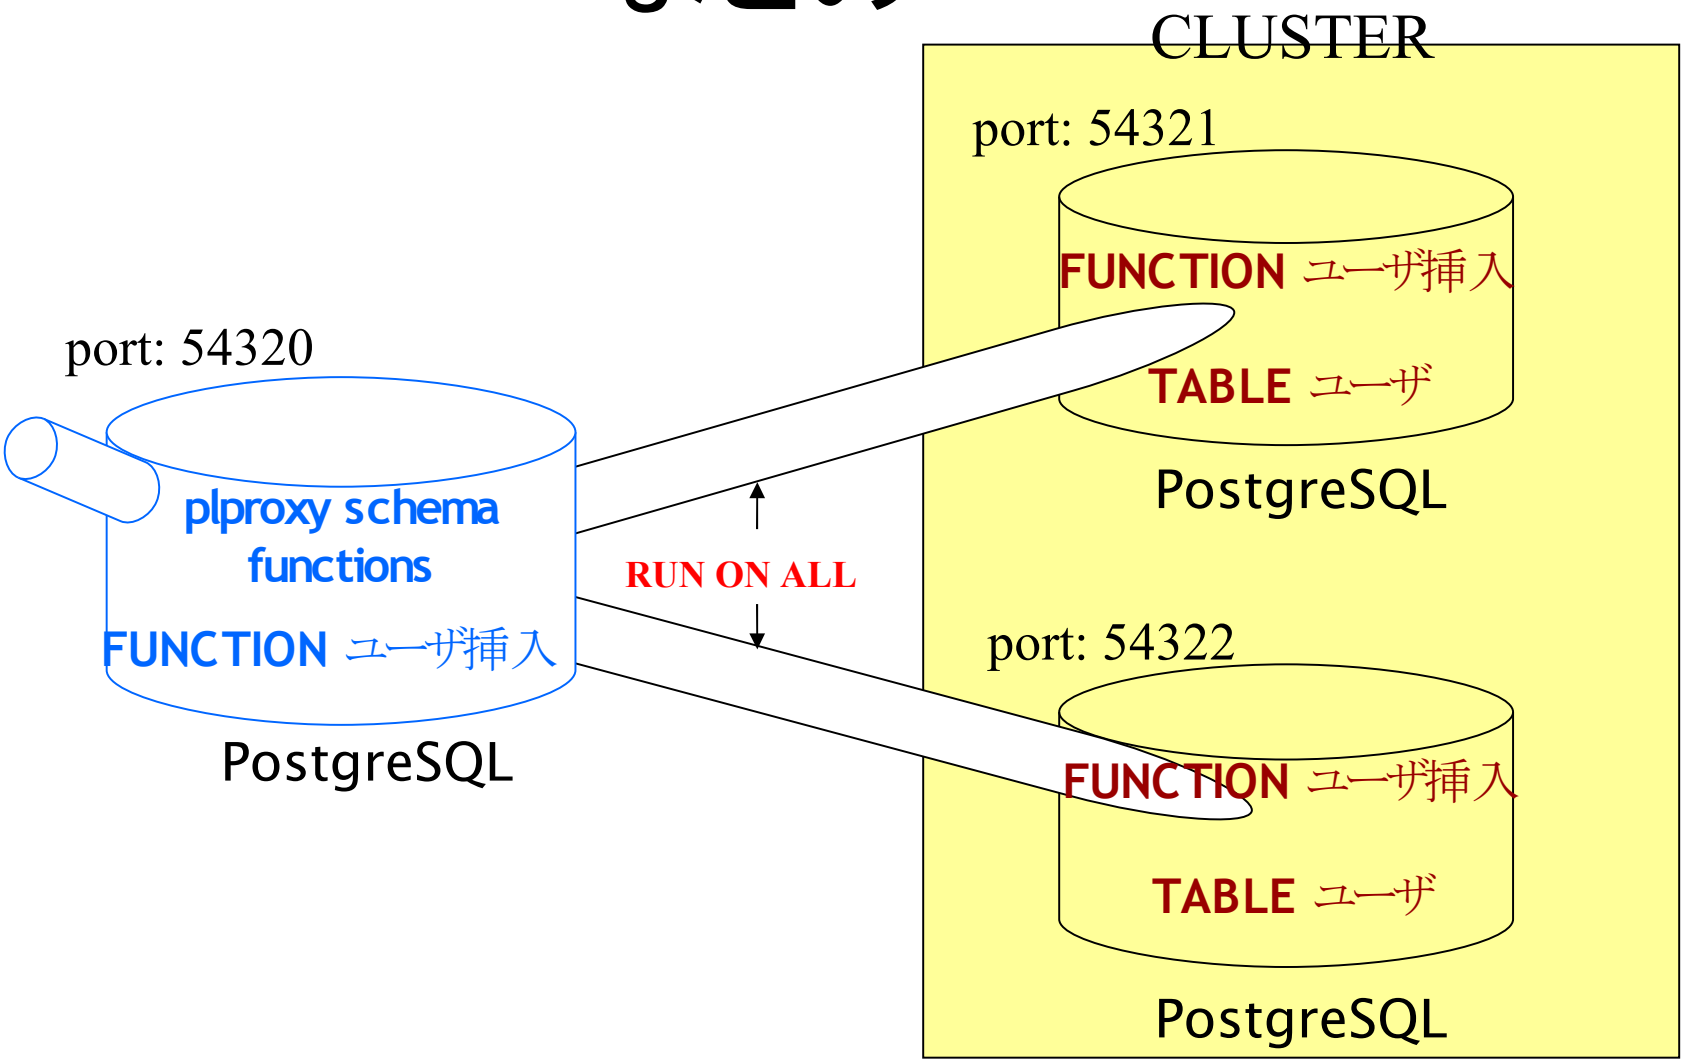

謝辞

- オープンソースに興味を持ち、集まってくださった皆様に感謝いたします。
- 本セミナーのために資料をご提供くださった独立行政法人　情報処理推進機構(IPA)　オープンソフトウェア・センターの斉藤浩様に感謝いたします。
- PL/Proxy, PgBouncerの動作について、情報を提供下さったSkype™社のMarko Kreen氏、JPUGのさいとうひろし氏に感謝いたします。
- PostgreSQLならびにPL/Proxy, PgBouncerの開発に貢献くださった人々に感謝いたします。

ありがとうございました

お疲れさまでした。

JPUG 10th Anniversary Conference

無事終了！

のべ来場者数約380名

主催： 日本PostgreSQLユーザ会
運営： PostgreSQL Conference 2009 Japan 実行委員会