オールインワンの PostgreSQL クラスタ管理ツール Pgpool-II で何ができる？

OSC2022 Online/Osaka
2022-1-29

SRA OSS, Inc. 日本支社
彭 博 (ペン ボ)

自己紹介

ペン ボ

- 名前： 彭 博 (Bo Peng)
  pengbo@sraoss.co.jp
- 所属：SRA OSS, Inc. 日本支社
  基盤技術グループ
- 職務：
  - OSS技術サポート、ミドルウェア構築
  - PostgreSQLクラスタ管理ツールPgpool-IIの開発者

本日の流れ

- Pgpool-IIとは
- Pgpool-IIの紹介
- 新バージョン4.3の機能紹介

Pgpool-II とは

- クライアントとPostgreSQLの間で動作するミドルウェア
- ユーザは複数PostgreSQLサーバを意識せず、1台のように見える

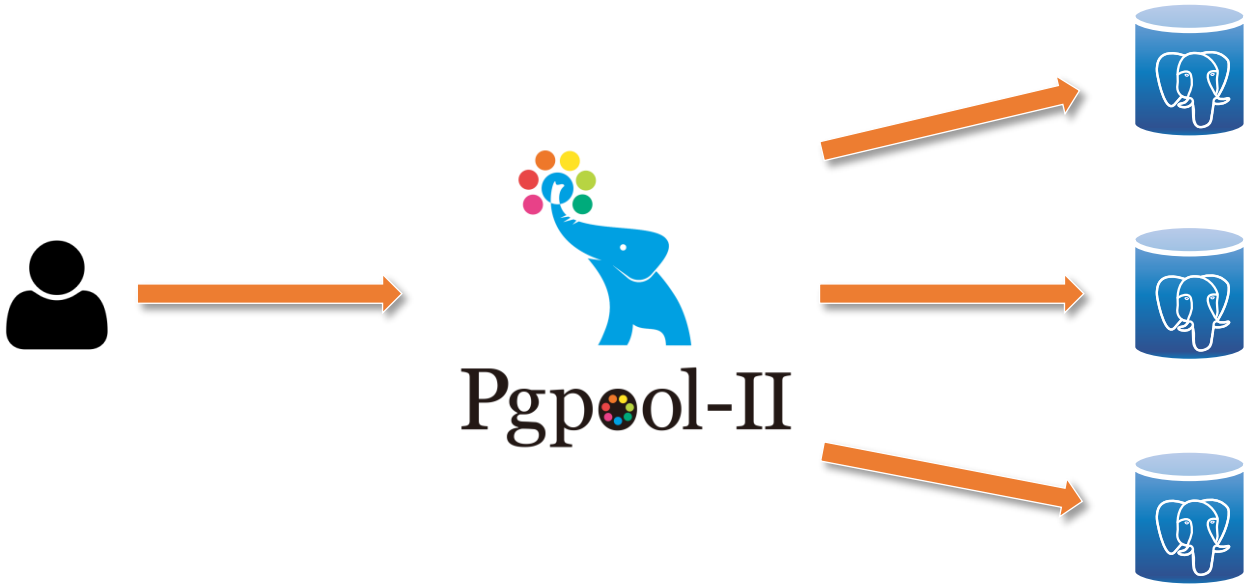

Pgpool-IIの機能

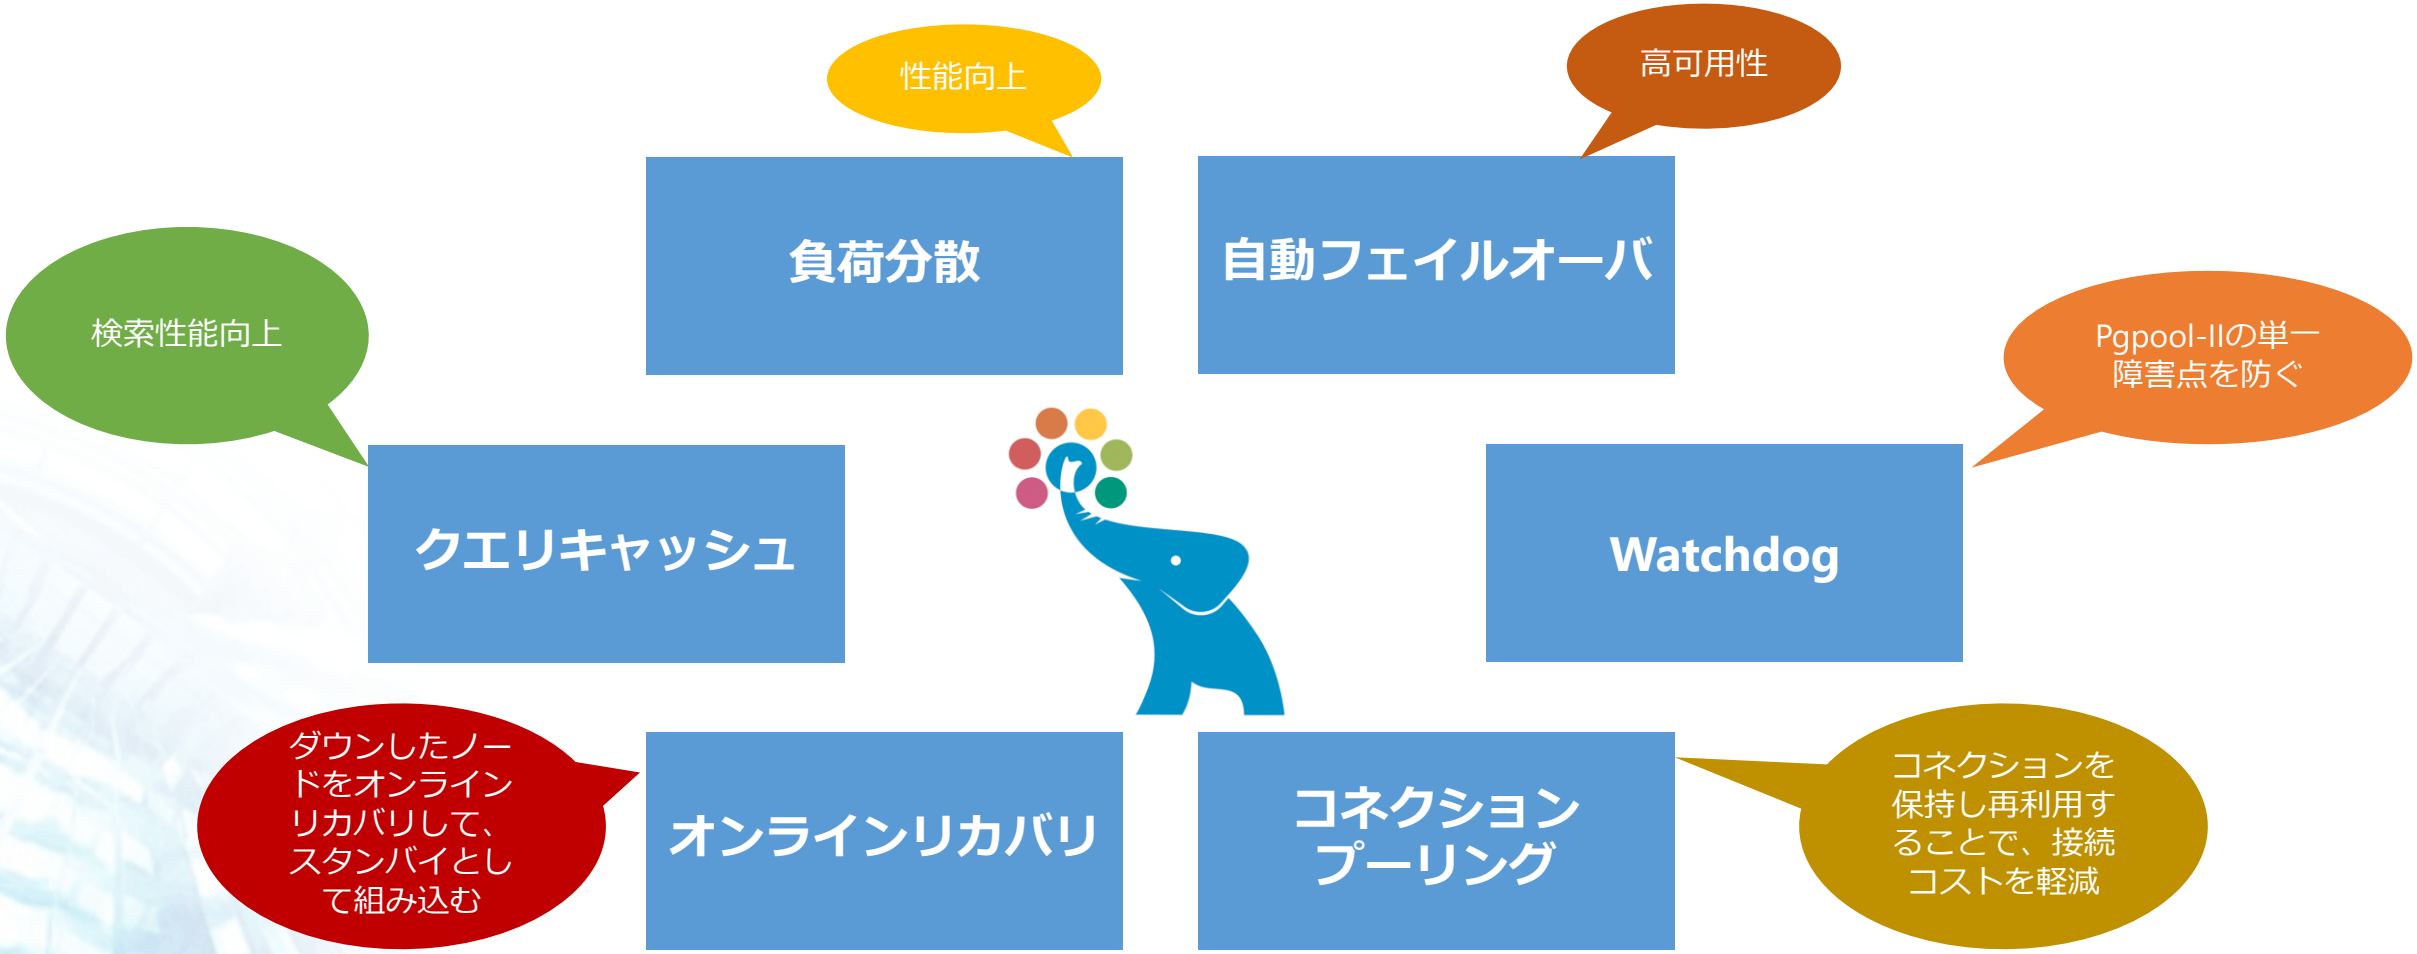

Pgpool-IIの基本構成

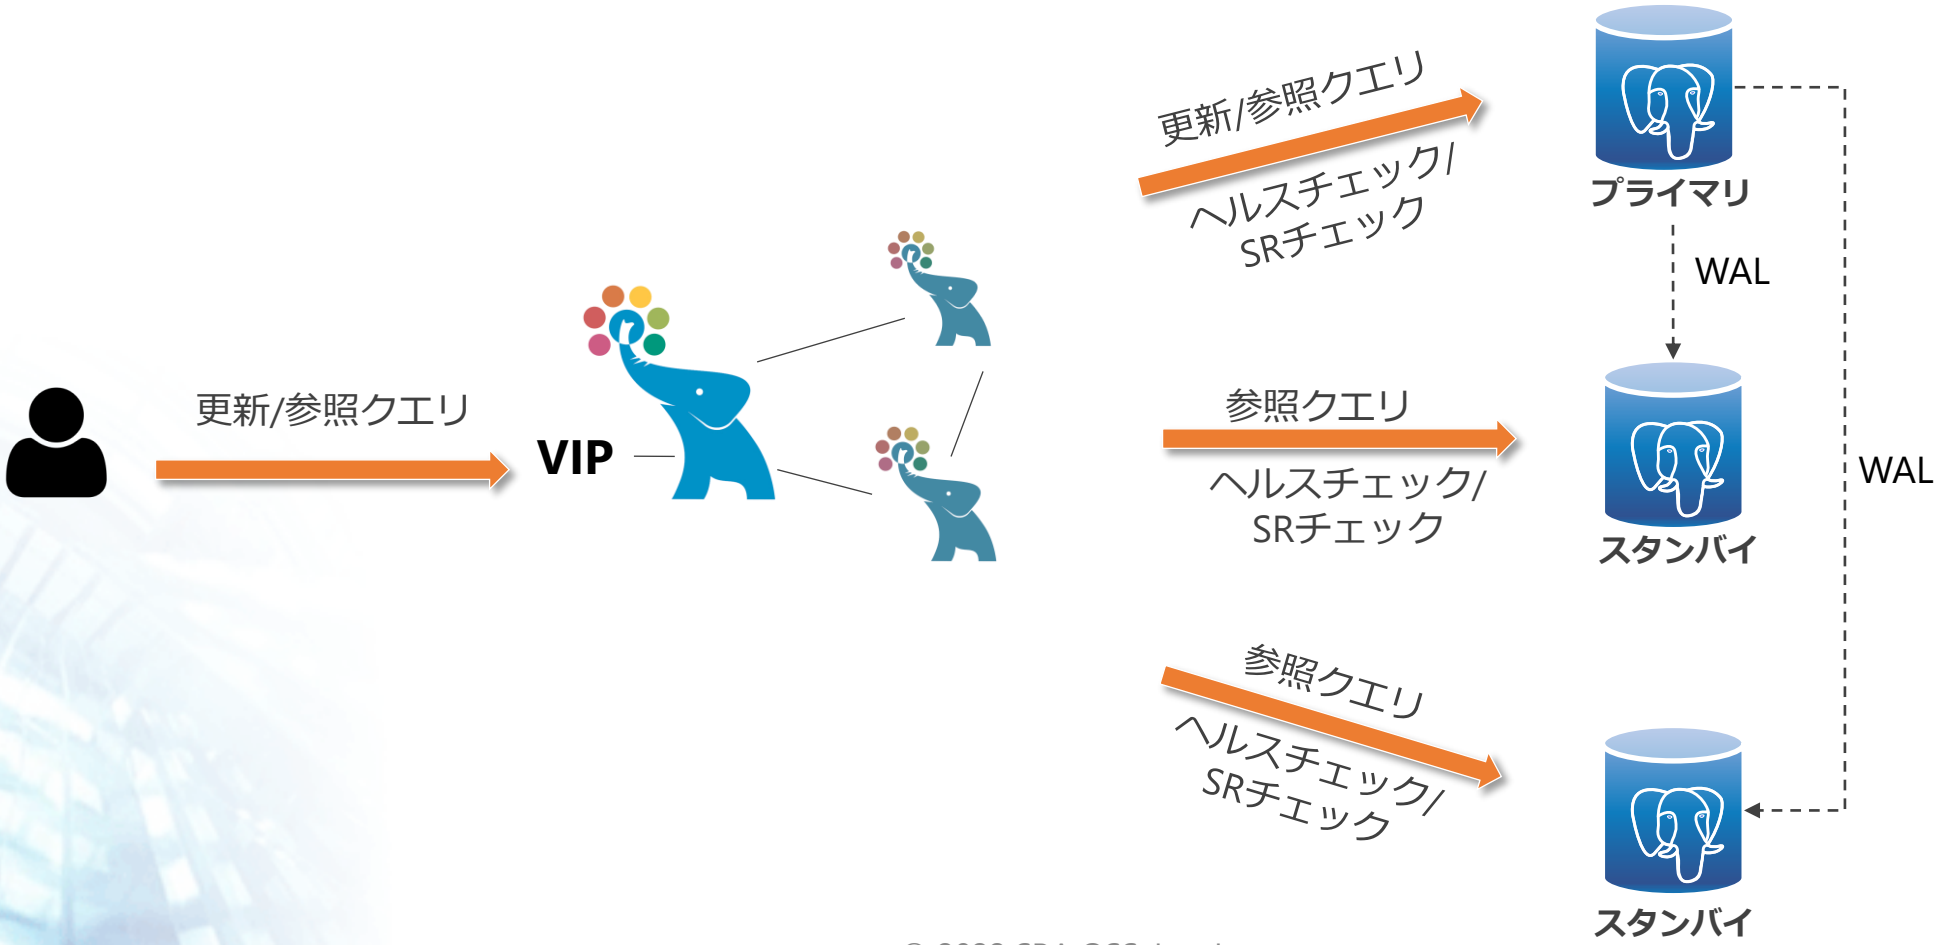

自動フェイルオーバ

- フェイルオーバの契機
  - ヘルスチェックでダウンと判定された場合
    - ヘルスチェック： 各PostgreSQLノードの状態を監視するプロセス
    - 実行間隔、最大リトライ回数などを設定可能
  - ノードへの接続、および接続中にエラーが発生した場合
    - failover_on_backend_error = on の場合
- フェイルオーバ処理
  1. failover_command
     - スタンバイの昇格
     - カスタムスクリプトを指定できる
  2. follow_primary_command
     - 残りのスタンバイの同期先を新しいプライマリに変更
     - カスタムスクリプトを指定できる

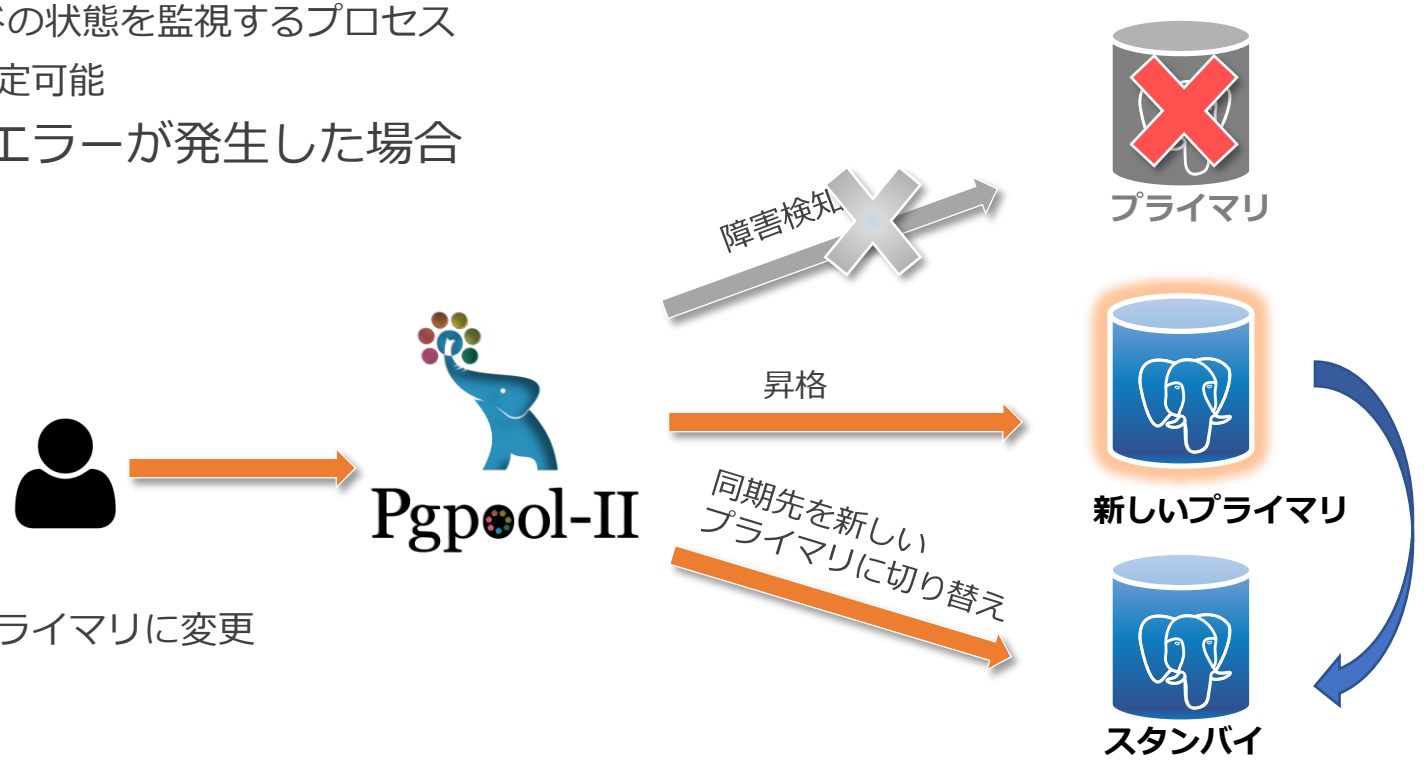

負荷分散

- SQLパーサを搭載しており、クエリを解析できる
- 更新クエリをプライマリに送り、参照クエリを複数のPostgreSQLノード間で分散
- 負荷分散モード
  - セッションレベル (デフォルト)
  - ステートメントレベル
- 負荷分散の比率が設定可能

  例えば、プライマリを更新処理専用にし、すべての参照クエリをスタンバイに振り分けたい

  backend_weight0 = 0
  backend_weight1 = 1
  backend_weight2 = 1

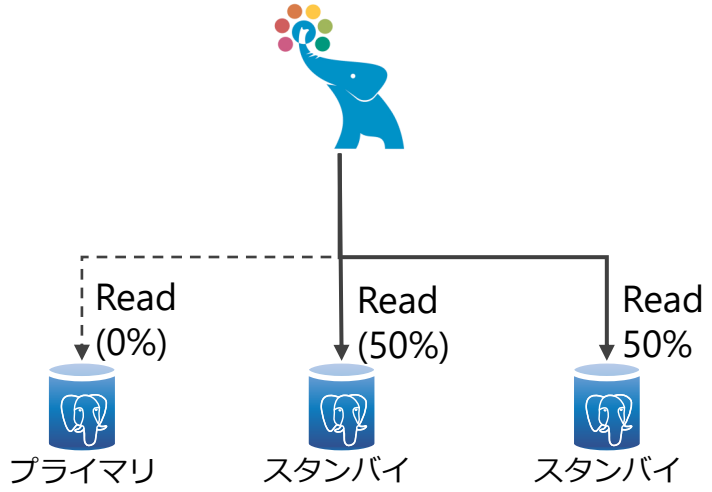

Watchdogとは

- Pgpool-IIの単一障害点を回避
- 複数のPgpool-IIがお互いに監視することで、Pgpool-IIを冗長化するための機能
- 定期的に他のPgpool-IIノードにハートビート信号を送信
- Pgpool-IIノードの障害が検出された際に、Watchdogは投票によって新しいリーダーを決定し、切り替える
- 仮想IPの自動切り替え
- バックエンドノードのフェイルオーバの動作を制御

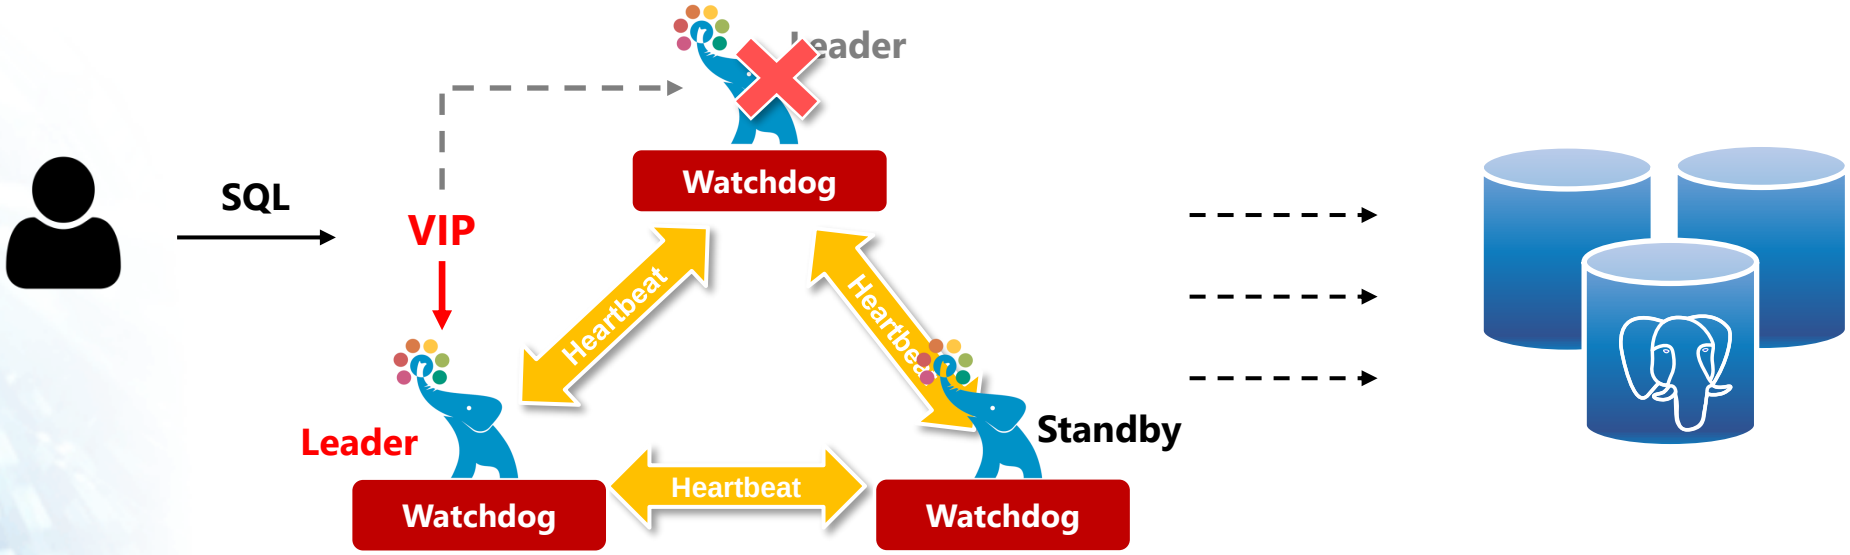

Pgpool-II 4.3の新機能紹介

v4.3の主な新機能・改良

- 設定ファイルの大幅な改善
  - pgpool.confから他の設定ファイルの読み込みが可能
  - すべてのパラメータのコメントアウト化
- Watchdogに動的クラスタメンバーシップ機能の導入
- フェイルオーバの機能強化
  - 予期しないフェイルオーバを回避
  - スイッチオーバ
- Pgpool-IIの独自の統計情報出力コマンドの改善
  - コネクションの統計情報の出力
  - SHOW POOL_NODESの新しいフィールドの追加
- PostgreSQL 14のSQLパーサの移植

v4.3新機能: pgpool.confから他の設定ファイルの読み込み

- pgpool.confファイルにincludeを書くことができるようになった
- pgpool.confファイルを機能ごとに複数の小さなファイルに分割することが可能

pgpool.conf

```
...

include = 'watchdog.conf'
include = 'query_cache.conf'
```

watchdog.conf

```
use_watchdog = off
hostname0 = ''
wd_port0 = 9000
pgpool_port0 = 9999
...
```

query_cache.conf

```
memory_cache_enabled = off
memqcache_method = 'shmem'
...
```

v4.3新機能: すべてのパラメータのコメントアウト化

- 4.2まで、コメントアウトされているパラメータとコメントアウトされていないパラメータが混在
- 4.3以降、すべてのパラメータがコメントアウト化される

```
...
#listen_addresses = 'localhost'
                                        # Host name or IP address to listen on:
                                        # '*' for all, '' for no TCP/IP connections
                                        # (change requires restart)
#port = 9999
                                        # Port number
                                        # (change requires restart)
#socket_dir = '/tmp'
                                        # Unix domain socket path
                                        # The Debian package defaults to
                                        # /var/run/postgresql
                                        # (change requires restart)
#reserved_connections = 0
                                        # Number of reserved connections.
                                        # Pgpool-II does not accept connections if over
                                        # num_init_chidlren - reserved_connections.'
```

スプリットブレインとは

- ネットワークの障害によって、Pgpool-II同士が相手と通信できなくなり、お互いがダウンしていると思って、両方ともLeaderになってしまう

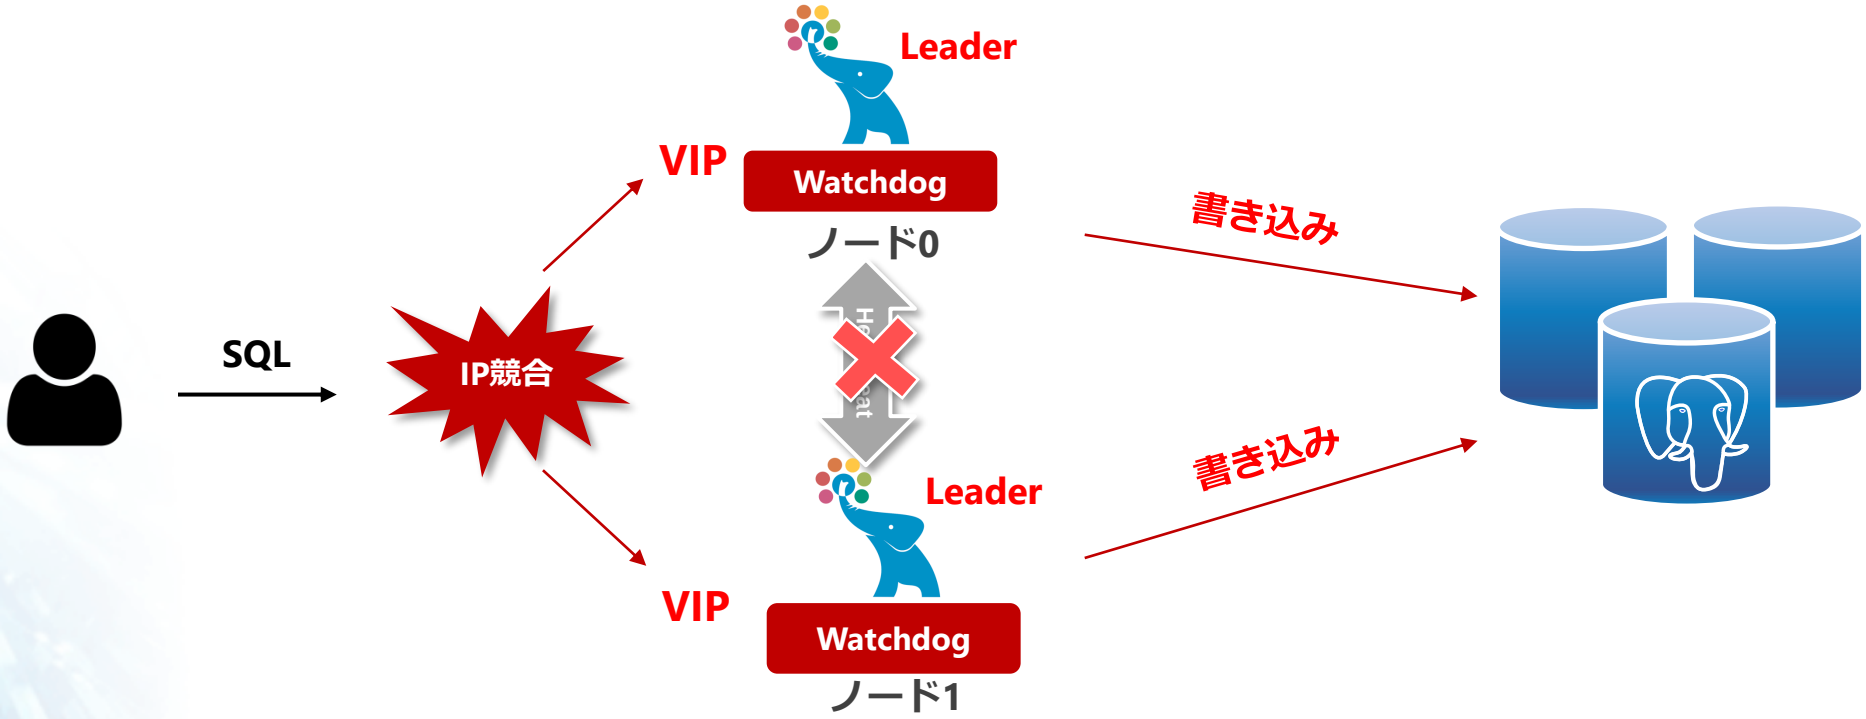

Watchdogのクォーラムによるスプリットブレイン対策

- Pgpool-IIを奇数台(3台以上)用意することによって、多数決で少数派がLeaderになるのを防ぐ

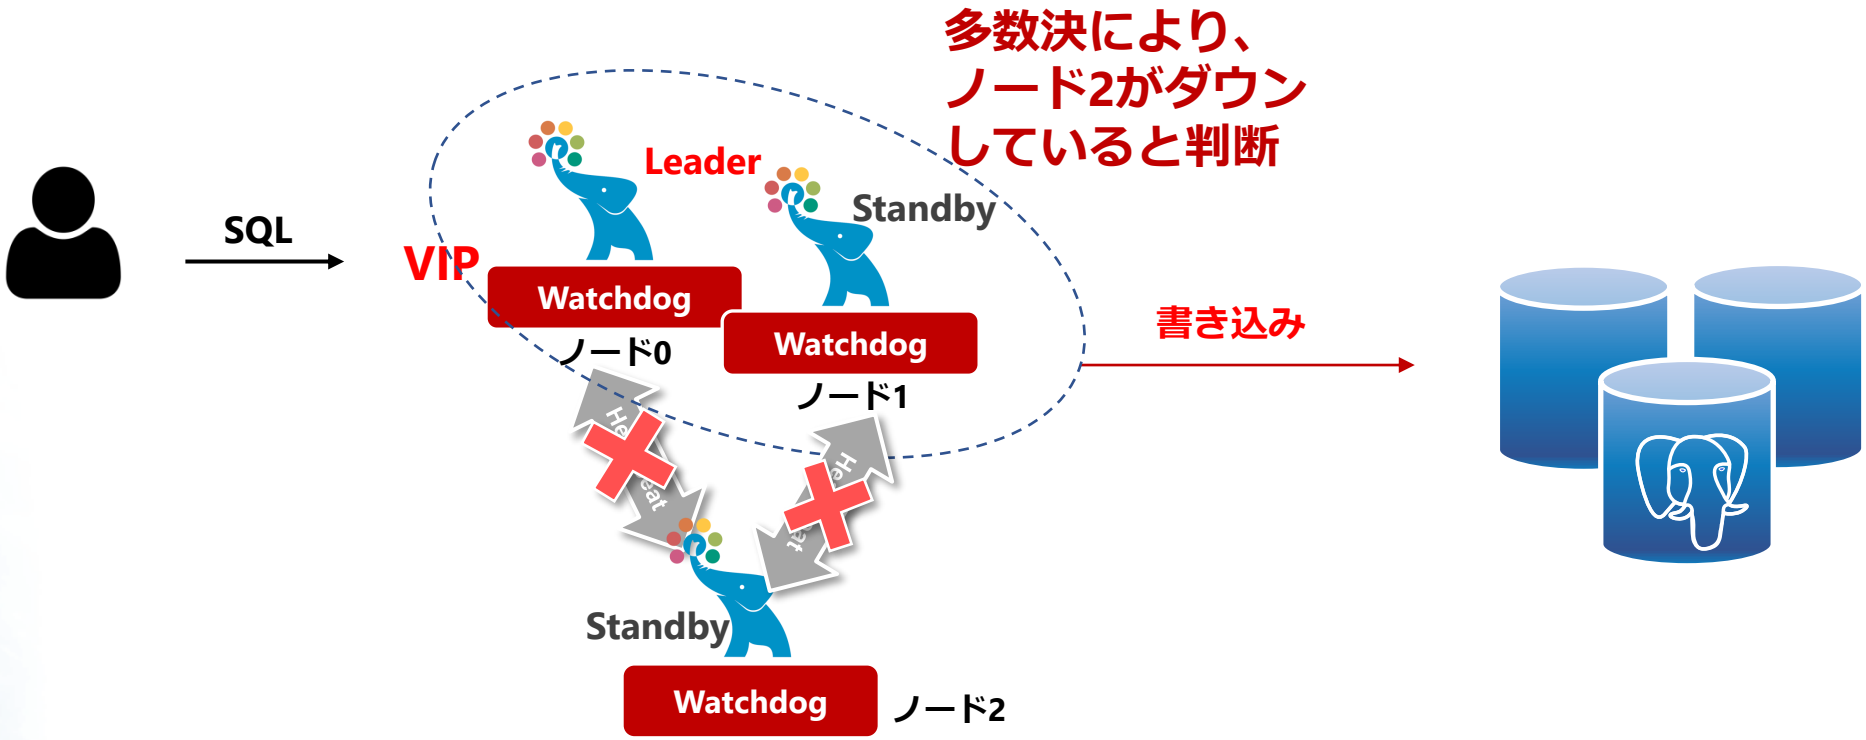

問題点

- スプリットブレイン対策
  - 3台中2台がダウンしている場合、クォーラムが存在しないため、VIPが起動しない
  - サービスが止まってしまう

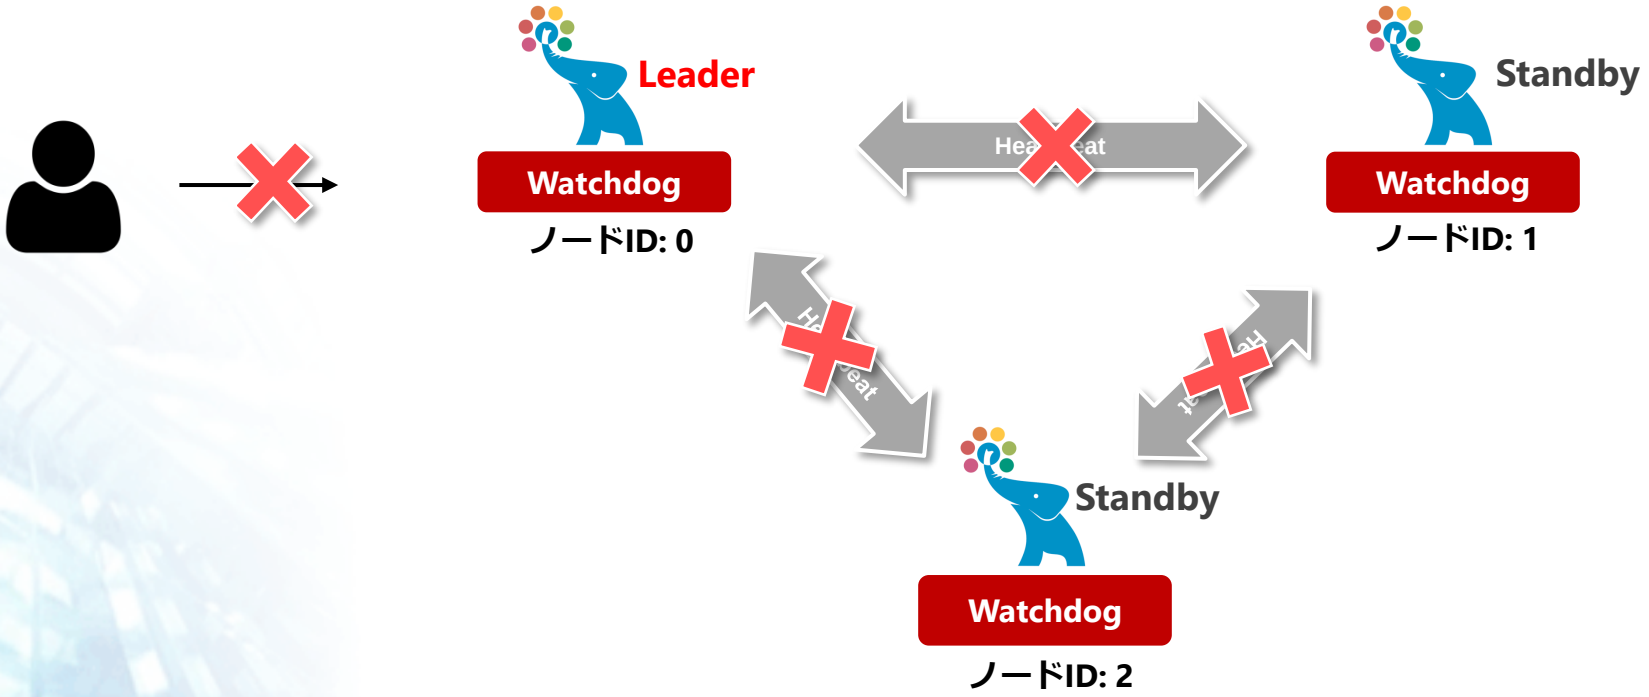

v4.3新機能: 動的クラスタメンバーシップ

- メンバーと非メンバーの概念を導入
- 動的にクラスタの定義を変えることが可能
- 非メンバーであると印をつける
  - wd_remove_shutdown_nodes
    - SHUTDOWNノードは直ちに非メンバーであると印を付けられ、クラスタから削除される
  - wd_lost_node_removal_timeout
    - LOST状態のwatchdogノードに非メンバーであると印を付けて、クラスタから削除するまでのタイムアウト時間
  - wd_no_show_node_removal_timeout
    - クラスタ起動時にノードが現れない(NO-SHOW)場合に、非メンバーであると印を付けるまでのタイムアウト時間

注意点：
- **動的クラスタメンバーシップを使うことにより、スプリットブレインが起こるリスクがある**
- **動的クラスタメンバーシップが必要かどうか慎重に検討することを強く推奨する**

v4.3新機能: failover_on_backend_shutdown

接続中のセッションを切断した場合の問題点:

予期しないフェイルオーバが発生してしまう可能性がある

以下①と②の場合は、PostgreSQLが同じエラーコードを送る

① クライアントがpgpoolに接続している間に、PostgreSQLが管理者によってシャットダウンされた場合

② pg_terminate_backend()またはSIGTERMを使って接続中のセッションを切断した場合

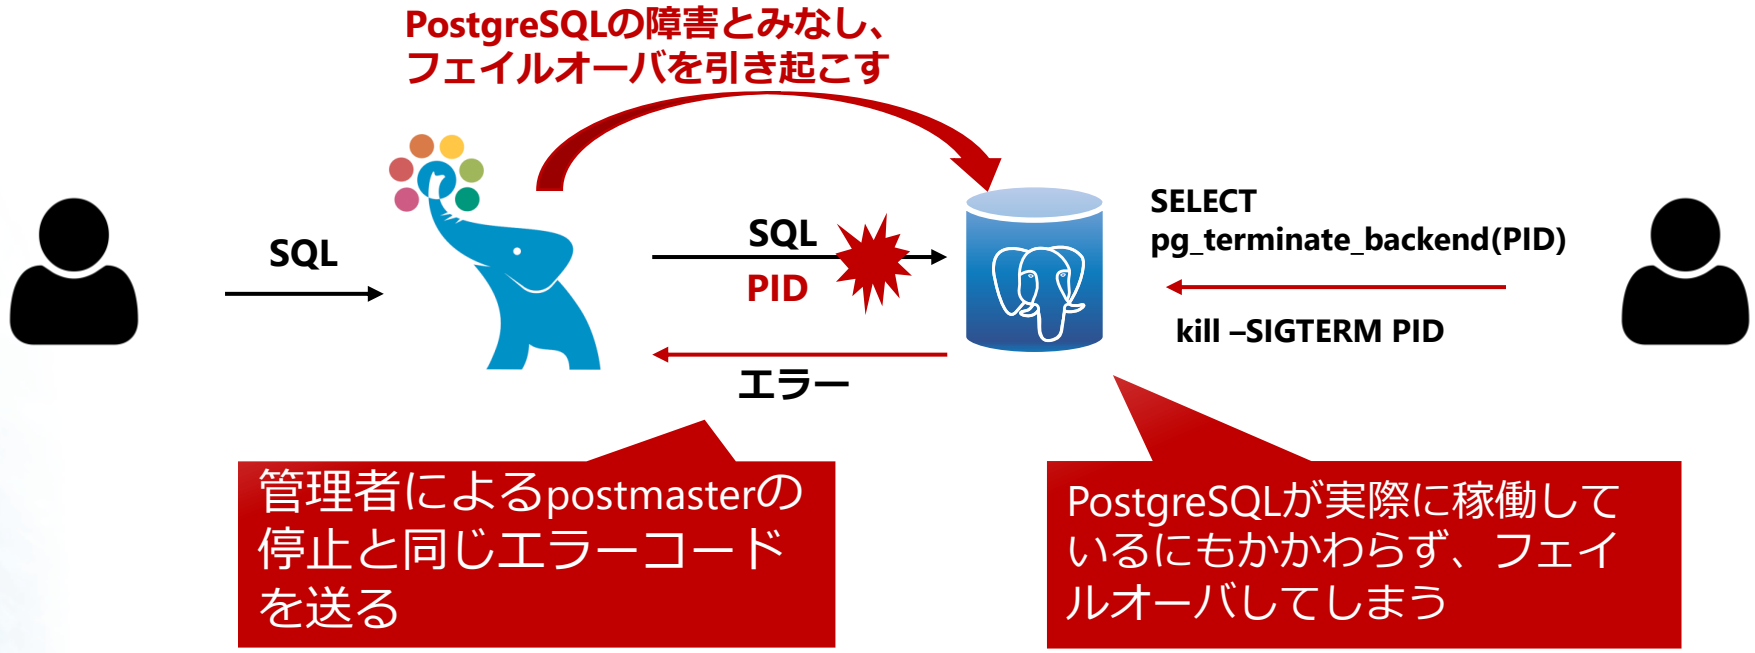

v4.3新機能: failover_on_backend_shutdown

failover_on_backend_shutdown =off (default) v4.3~

- 管理者によってpostmasterが停止する際に、**フェイルオーバの無効化**が可能に
- デフォルトでは、v4.2までと**異なる**挙動
- 予期しないフェイルオーバを回避したい時に便利
  - pg_terminate_backend
  - killコマンド

自動フェイルオーバ処理の流れ

- Pgpool-IIフェイルオーバ処理の流れ
  - ① プライマリで障害が発生/手動でPgpool-IIからプライマリを切り離す（pcp_detach_nodeにより）
  - ② 新しいプライマリを選定
    - 生きているデータベースノードの中から**一番若いノードID**を選ぶことが多い
  - ③ failover_commandを実行
    - ②で選定されたPostgreSQLノードを昇格させる
  - ④ follow_primary_commandを実行
    - 新しいプライマリからスタンバイをリカバリする

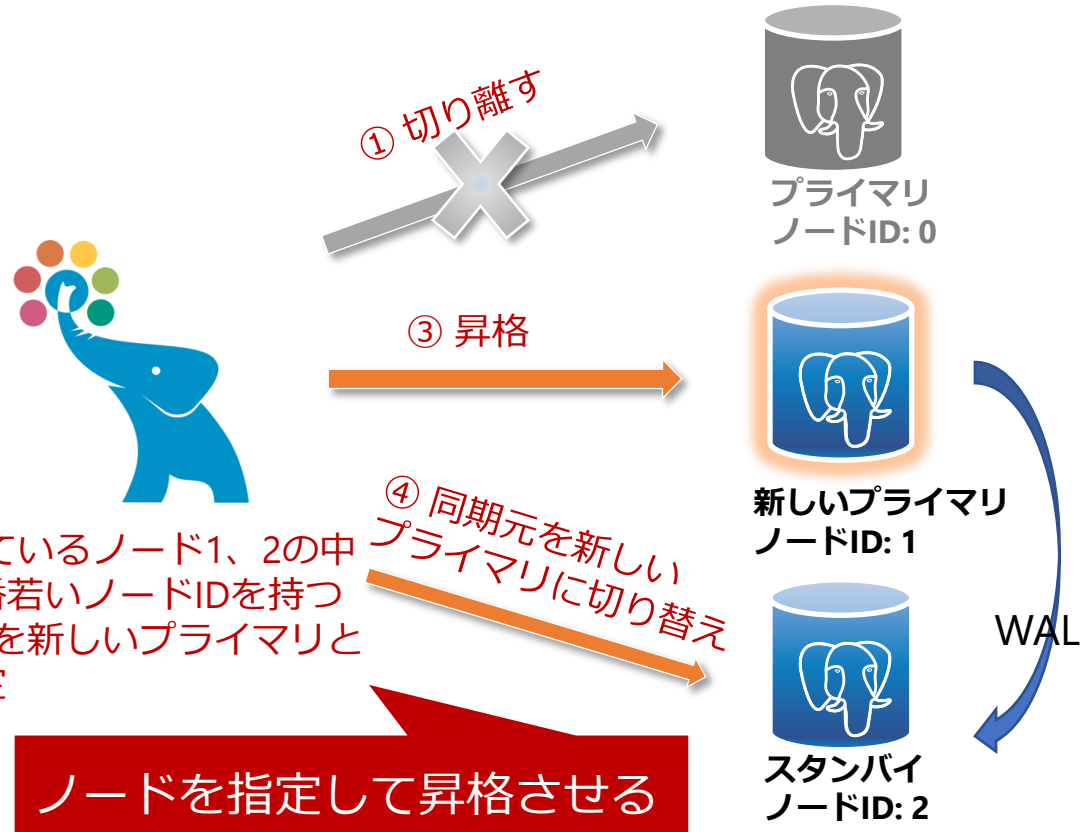

v4.3新機能: ノードを指定してスイッチオーバー

pcp_promote_nodeコマンドに新しいオプション:

-s, --switchover V4.3~

ノード2を昇格させる

```
# pcp_promote_node --switchover --node-id=2
```

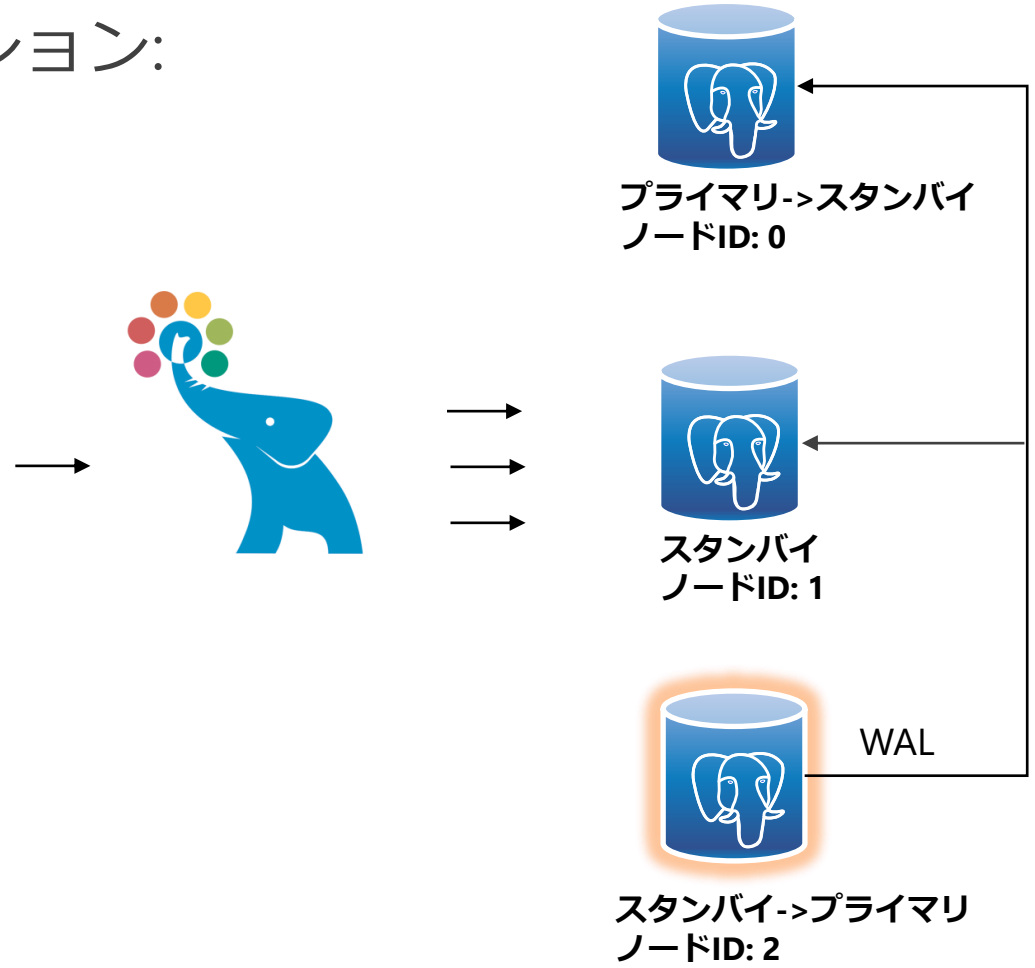

v4.3新機能: SHOW POOL_NODESの新しいフィールドの追加

- Pgpool-IIは共有メモリにバックエンドのステータス(status、role)を保存している
- Pgpool-IIが管理しているバックエンドのステータスは実際のバックエンドのステータスと一致しない場合がある
  - 例えば、pcp_detach_nodeにより、バックエンドノードがクラスタから切り離されて、ステータスが「DOWN」になるが、実際は稼働している
- 4.3以降、実行時にバックエンドの情報を取得し、表示できるようになった
  - pg_status: 実際のバックエンドノードのステータス (up/down)
  - pg_role: 実際のバックエンドノードのロール (primary/standby)

v4.2~

```
postgres=> show pool_nodes;
 node_id | hostname | port | status | lb_weight |  role   |
---------+----------+------+--------+-----------+---------+-
 0       | pgpool1  | 5432 | up     | 0.333333  | primary |
 1       | pgpool2  | 5432 | up     | 0.333333  | standby |
 2       | pgpool3  | 5432 | up     | 0.333333  | standby |
```

v4.3~

```
postgres=> show pool_nodes;
 node_id | hostname | port | status | pg_status | lb_weight |  role   | pg_role |
---------+----------+------+--------+-----------+-----------+---------+---------+-
 0       | pgpool1  | 5432 | up     | up        | 0.333333  | primary | primary |
 1       | pgpool2  | 5432 | up     | up        | 0.333333  | standby | standby |
 2       | pgpool3  | 5432 | up     | up        | 0.333333  | standby | standby |
```

v4.3新機能: コネクション統計情報の出力

1. 接続先のデータベース名
2. 接続ユーザ名
3. Pgpool-IIプロセスの起動時刻
4. **プロセスの利用カウンタ** v4.3~
5. プロトコルのメジャーバージョン
6. プロトコルのマイナーバージョン
7. バックエンドへの接続時刻
8. **クライアントが最後に接続開始した時刻** v4.3~
9. **接続がidleとなっている時間(秒)** v4.3~
10. **クライアントが最後に接続終了した時刻** v4.3~
11. 接続の再利用カウンタ値
12. PostgreSQLバックエンドプロセスのプロセスID
13. フロントエンドが接続中なら1、そうでなければ0
14. pgpool子プロセスID
15. PostgreSQLバックエンドID
16. **プロセスの状態** v4.3~

child_max_connectionsに到達する前にクライアントがPgpool-IIに接続した回数を知りたいときに役立つ

client_idle_limitが0でない場合、クライアントが切断されるまでの時間

プロセスの状態:
- Wait for connection
- Execute command
- Idle
- Idle in transaction

```
$ pcp_proc_info -h localhost -p 11001 -P 23493 --verbose
Database                  : test
Username                  : postgres
Start time                : 2021-10-21 14:16:00
Client connection count   : 1
Major                     : 3
Minor                     : 0
Backend connection time   : 2021-10-21 14:16:16
Client connection time    : 2021-10-21 14:17:25
Client idle duration      : 21 (0:39 before client disconnected)
Client disconnection time : 2021-10-21 14:17:23
Pool Counter              : 2
Backend PID               : 23500
Connected                 : 1
PID                       : 23493
Backend ID                : 0
Status                    : Idle
...
```

PostgreSQL 14のSQLパーサの移植

- Pgpool-IIはSQLパーサを持っている
  - 複雑なSQLを正確に解析するため
  - クエリの書き換えを行うため
- メジャーリリースを行うたびに、PostgreSQLの最新パーサを移植
- Pgpool-II 4.3はPostgreSQL 14のパーサを移植

参考情報

- Pgpool-II Webサイト
  - https://pgpool.net/
- ドキュメント
  - https://www.pgpool.net/docs/latest/ja/html/
- リポジトリ
  - https://git.postgresql.org/gitweb/?p=pgpool2.git;a=summary
- ML
  - https://pgpool.net/mediawiki/index.php/Mailing_lists
- バグ報告
  - https://www.pgpool.net/mantisbt/

ご清聴ありがとうございました。