

性能、信頼性を大幅に向上した pgpool-II 最新バージョンについて

PostgreSQLカンファレンス2015
2015/11/27

SRA OSS, Inc. 日本支社
pgpool-II 開発者
長田 悠吾

自己紹介

- 長田 悠吾 (ナガタ ユウゴ)
 - SRA OSS, Inc. 日本支社
 - マーケティング部 OSS技術グループ
 - OSS の技術サポート
 - pgpool-II 開発者
 - PostgreSQL 関連の技術調査・開発



SRA OSS, Inc. 日本支社

- 1999年よりPostgreSQLサポートを中心にOSSビジネスを開始
- PostgreSQL、Hinemos、Zabbix などのOSSサポート
- PowerGresファミリーの開発、販売
- トレーニング、導入、設計コンサルティングサービス



pgpool-II とは

- アプリケーションとPostgreSQLの間に入って、クラスタリング機能を提供するミドルウェア
 - アプリケーションからは普通のPostgreSQLに見える
- オープンソースソフトウェア (BSDライセンス)
 - メジャーバージョンアップは年1回
 - 今年の冬に 3.5.0 がリリース予定
- 多彩な機能
 - コネクションプーリング
 - 参照負荷分散
 - クエリキャッシュ
 - ヘルスチェック
 - 自動フェイルオーバー
 - オンラインリカバリ




PostgreSQLのクラスタ技術

- HAクラスタ
 - Pacemaker+DRBD、共有ストレージなどを利用
 - 待機側はサービス停止
- ストリーミングレプリケーション
 - PostgreSQL自体が持つ、非同期レプリケーション機能
 - プライマリ(更新可能) + 複数のスタンバイDB(検索のみ)
 - 簡単、確実、速い
- pgpool-II
 - クライアントとPostgreSQLの間に入ってレプリケーション機能を提供
 - コネクションプーリング、負荷分散、自動フェイルオーバなど他の機能もある
- Postgres-XC/XL
 - PostgreSQLを改造したクラスタシステム
 - 書き込み性能の負荷分散

PostgreSQLのストリーミングレプリケーション

- ストリーミングレプリケーション (PostgreSQL 9.0 ~)
 - マスタからスレーブにトランザクションログ (WAL) を転送することによりデータの複製を実現



ストリーミングレプリケーションの課題

負荷分散はどうすればよい?
更新クエリ、参照クエリの振り分けは?
アプリケーションを書き換えなきゃだめ?



更新クエリ
参照クエリ

参照
クエリ


参照クエリ

DBサーバに障害が発生したら?
手動で対応するの?


プライマリ



レプリケーション



スタンバイ




スタンバイ

プライマリがダウンしたら更新ができなくなる?!
サービスが停止してしまう!?

新しいスタンバイの追加は?


pgpool-II の導入

- アプリケーションからは1つの PostgreSQL のように見える
- クエリ振り分け
- 負荷分散
- 自動フェイルオーバー
- ...



参照負荷分散


- クエリの自動振り分け
 - 更新クエリはプライマリサーバへ
 - 参照クエリはサーバ間で振り分け



振り分けの重みを指定可能
レプリケーション遅延が大きいサーバには振り分けない
3.4.0 からはよりきめ細やかな振り分けが可能に!

きめ細かな負荷分散 (3.4~)

- アプリケーション名、DB名によって接続先が指定できる



負荷分散の設定例

```
# PostgreSQL のホスト名、ポート番号、ロードバランスの重みを設定

backend_hostname0 = 'host1'
backend_port0     = 5432
backend_weight0   = 1

backend_hostname1 = 'host2'
backend_port1     = 5432
backend_weight1   = 1


backend_hostname2 = 'host3'
backend_port2     = 5432
backend_weight2   = 0

# 接続アプリケーションによって、接続先DBを変更

app_name_redirect_preference_list = 'analyze_app:2'
```


自動フェイルオーバー

- DBサーバの障害を自動検出（ヘルスチェック機能）
 - ダウンしたPostgreSQLを切り離す
 - 負荷分散の対象から外れる




自動フェイルオーバー

- プライマリサーバに障害が発生した場合は？
 - そのままでは更新ができなくなってしまう！




自動フェイルオーバー

- プライマリサーバに障害が発生した場合
 - そのままでは更新ができなくなる
 - 負荷分散からの切り離し
 - スタンバイをプライマリに自動昇格




オンラインリカバリ

- ダウンしたスタンバイをプライマリに同期させる
- 同期中でも更新が可能



オンラインリカバリ


- ダウンしたスタンバイをプライマリに同期させる
- 同期中でも更新可能
- 同期完了後、自動的に負荷分散対象となる



オンラインリカバリ時の処理もスクリプトで定義
(サンプルあり)


オンラインリカバリ

- 新しいスタンバイサーバの追加
 - pgpool-II に新しいサーバの情報を
読み込ませてから、オンラインリカバリ
 - 同期完了後、負荷分散対象に



オンラインリカバリ

- スタンバイの増設も容易
 - 検索性能のスケールアウト!




ここまでのまとめ

- 参照性能の負荷分散
 - 更新クエリと参照クエリの適切な振り分け
 - アプリケーション名やデータベース名での振り分け
- 自動フェイルオーバー
 - データベース障害の自動検出&切り離し
 - プライマリがダウンしたら、スタンバイが新プライマリに昇格
- オンラインリカバリ
 - サービスを止めずにダウンしたサーバを復帰
 - 新しいスタンバイの追加も簡単


pgpool-II の単一障害点回避

- もし、pgpool-II に障害が発生したら?!
 - 単一障害点 (Single Point of Failure) ?




watchdog

- pgpool-II 組み込みのHA機能
 - pgpool-II を Active/Standby 構成にする
 - 仮想IPでpgpool-IIにアクセス




watchdog

- Active pgpool-II に障害発生すると・・・
 - Standby pgpool-II が Active に昇格
 - 仮想IPでの付け替えが行われる



インメモリクエリキャッシュ


- SELECTクエリの結果をメモリ内にキャッシュする機能
 - 同じクエリが来たときに再利用する
 - DBへのアクセスが減り、応答速度が向上



pgpool-II 機能まとめ


- 性能向上
 - 参照負荷分散
 - インメモリキャッシュ
- 信頼性向上
 - 自動フェイルオーバー
 - Watchdog (= pgpool-II 自体の高可用化)
- その他クラスタ管理など
 - クエリの自動振り分け
 - オンラインリカバリ

第一法規株式会社様 事例



- 大量の判例などを検索するシステム
- PostgreSQLのストリーミングレプリケーション + pgpool-II で、負荷分散による性能向上、可用性向上
- インメモリクエリキャッシュ機能を活用して検索性能を向上
- 一度発生したDB障害でも pgpool-II の自動フェイルオーバー機能により、サービスは停止することなく継続できた。

株式会社 Gengo様 事例




- 翻訳サービスのクラウドソーシング企業
- AWS上でシステム構築
- 3万トランザクション/日
- 同時にPostgreSQLのバージョンアップ。オンラインリカバリ機能を活用しダウンタイムを最小限に。
- AWSによる強制インスタンス再起動メンテナンスも自動フェイルオーバ機能で乗り切った

pgpool-II 3.5.0


- 12月にリリース予定
- 主な変更点
 - 性能改善
 - watchdog 機能の改善
 - PostgreSQL 9.5 対応
 - その他

拡張問い合わせプロトコル性能改善(1)

- 単純問い合わせ



- 拡張問い合わせ



- 複数の段階に分けて処理
 - SQLの解析
 - パラメータ値の結び付け
 - 実行
- Java アプリケーションの JDBC ドライバで使用される


一部やり取りを省略しています

拡張問い合わせプロトコル性能改善(2)


- 今の pgpool-II は拡張問い合わせ使用時の性能が悪い
 - 最悪単純問い合わせ使用時の半分位の性能になってしまう

複数 PostgreSQL
の状態を
確認するために
Flush が必要


- 性能劣化の原因
 - Flush の発行回数が多い
 - PostgreSQL との通信が増えてしまう



拡張問い合わせプロトコル性能改善(3)



拡張問い合わせプロトコル 性能改善の結果



20% ~ 250%
の性能向上!

AWS m4.large instance
CentOS 6
PostgreSQL 9.4 x2
(streaming replication)
pgbench -S

Thundering herd 問題への対応


- Thundering herd (獣群の暴走) 問題とは
 - あるイベントを待機している多数のプロセスが、イベントの発生により一度に起こされる
 - プロセスが起こされた後に、その後の処理を続けるプロセスが1つだけ決められる
 - 残りのプロセスは再び眠りにつく
 - 多くのプロセスが、一斉に目覚めては眠ることの繰り返し...
- CPU 資源の無駄遣い!

pgpool-II の場合


- 起動時に fork した複数の子プロセスがクライアントの接続を待ち受けている
 - Thundering herd 問題が発生

1. 接続待ち状態


pgpool-II の
子プロセス達



2. 接続発生



3. リクエスト処理開始




pgpool-II 3.5 で解決


- 接続待ち受けをシリアライズを有効にする新パラメータを追加
 - `serialize_accept = on`
 - Thundering herb 問題を回避

1. 接続待ち状態


pgpool-II の
子プロセス達




2. 接続発生



3. リクエスト処理開始



Thundering herd 問題対応 性能改善の結果



Note PC with 16GB Mem,
CORE i7 x2, 512GB SSD
Ubuntu 14.04
PostgreSQL 9.4 x2
(streaming replication)
pgbench -S -C -T 300


Watchdog 機能の改善

- 内部コードの改善
 - よりデバッグ、メンテナンス、機能拡張がしやすいコードへ
 - 「状態マシン」モデルで全面的に書き換え
- スプリットブレイン対策
 - Quorum のサポート
- プロセス間通信方式の変更
 - UNIXドメインソケット、JSON の採用
 - 外部ツールを使った死活監視
- ノードの優先度
 - pgpool-II が「アクティブ」に選ばれる「優先度」を設定可能

スプリットブレイン問題への対応


• スプリットブレイン問題

- ネットワークが分離された時に、どの pgpool-II がアクティブとなるべきか決められなくなる問題
- Quorum (定足数) の充足を常に保証
 - クラスタに参加している全ノードのうち半数以上が自分と同じネットワークに属しているかどうか、をチェックする



プロセス間通信の改善

- watchdog 内部で行われる、プロセス間通信方式の変更
 - UNIX ドメインソケット & JSON 形式データ
- これにより、外部のサードパーティツールとの連携が可能に
 - 外部ツールを使った死活監視モード (external) を追加




その他のWatchdog 機能改善

- ノードの優先度
 - 各ノードに異なる優先度を付与できる
 - wd_priority パラメータを追加
 - 高い優先度のノードは、マスターに選ばれやすくなる
- ノード間で設定パラメータの一貫性を検証
 - pgpool-II 間で重要なパラメータの値に一貫性を持たせる
 - 設定ミスに起因する問題を軽減

PostgreSQL 9.5 対応

- pgpool-II 3.5 では PostgreSQL 9.5 の SQL パーサを移植



- 参照負荷分散、クエリキャッシュが、新しい SELECT 構文に対応
 - GROUPING SET, CUBE, ROLLUP
 - TABLESAMPLE
- レプリケーションモード時のクエリ書き換えが、新しい INSERT/UPDATE 構文に対応
 - INSERT ... ON CONFLICT
 - UPDATE tab SET (col1,col2,...) = (SELECT ...), ...

その他の変更

- PCP コマンドの改善

- 引数の与え方の改善: オプションとして指定可能に

```
旧) $ pcp_node_info 0 localhost 9898 admin_user admin_pass 0
```

```
新) $ pcp_node_info -h localhost -U admin_user 0
```

- パスワードをコマンドラインで渡さなくても良いようになった
 - ~/.pcppass ファイルに書いておけばよい
- 複数pcpコマンドの同時実行
 - たとえば時間のかかる pcp_recovery_node (オンラインリカバリ)の実行中に他のpcpコマンドを実行できる

- パラレルクエリモードの廃止

- ユーザが少なく、その割にメンテナンスの手間が大きかった


pgpool-II 3.5 まとめ

- 性能改善
 - 拡張プロトコル使用時
 - Thundering herd 問題対応
- 信頼性向上
 - Watchdog の改善
 - スプリットブレイン対策
- その他
 - PostgreSQL 9.5 コマンド, pcp コマンド, ...
- 今年の冬(12/15)にリリース予定
 - 現在、リリースに向けテスト中
 - alpha1 版が 11/16 にリリース済

参考URL

- pgpool-II オフィシャルサイト
 - <http://www.pgpool.net/>
 - <http://www.pgpool.net/jp/>
- SRA OSS, Inc. 日本支社
 - セミナー資料、事例情報、技術情報
 - <http://www.pgecons.org/>
- Let's Postgres
 - PostgreSQL 情報のポータルサイト
 - <http://lets.postgresql.jp/>


ご静聴ありがとうございました!



付録


ネイティブレプリケーション

- PostgreSQL のストリーミングレプリケーションを用いずに同期レプリケーションを実現するモード
 - 更新クエリを全てのDBに送信
 - 必要に応じて、**クエリの書き換え**
 - now() などを含む更新クエリ



Watchdog 改善: 状態マシン

- watchdog のクラスタ管理を行うコア部分のコード
 - 「状態マシン」モデルで全面的に書き換え



- 抽象化
 - コードが理解しやすく、デバッグが容易に → 保守性の向上
 - 将来の機能拡張が容易に → 拡張性の向上