Wonderful PostgreSQL!

SRA OSS, Inc. 日本支社
取締役支社長
石井　達夫

SRA OSS,INC.

自己紹介

- OSSの開発とビジネスに携わっています
  - OSS活動
    - PostgreSQLのコミッタ
    - PostgreSQL用のクラスタソフト Pgpool-II の開発
  - ビジネス
    - PostgreSQLなどのOSSのサポート
    - PowerGres製品の製造、販売
    - PostgreSQLトレーニング

本日のアジェンダ

- PostgreSQL前夜
- PostgreSQL誕生
- PostgreSQL現在
- PostgreSQL未来

PostgreSQL前夜

- PostgreSQLの先祖は、カリフォルニア大学バークレー校での研究プロジェクトで開発された“Postgres”まで遡ることができる
- Michael Stonebraker 教授が指導
- 1994年まで開発継続
- used by assorted “bold and brave” early users

  (様々な「大胆で勇気のある」初期ユーザに使われています)
  - “THE IMPLEMENTATION OF POSTGRES” より
- 最終バージョンは4.2

Postgresの特徴

- オブジェクト指向の考え方を取り入れた
  - クラス、継承、OID
- 抽象データ型、拡張可能な型システム、配列
- 独自の問い合わせ言語 POSTQUEL
  - ちなみに、”libpq” の ”pq” は ”Post” “Quel” のそれぞれ頭文字を取っている
- fast path
  - バックエンド関数の直接実行
- プログラミング言語中立
  - 今では当たり前だが、当時は新しい考え方だったようだ
- ルールシステム
- タイムトラベル
  - retrieve (EMP.salary) using EMPT['2017-11-03']
    where EMP.name = “Sam”

Postgresの実装(1)

- 追記型のテーブルとトランザクションステータスビットを格納したファイルのみ。トランザクションログなし
  - 動機は、「普通のトランザクションログを使ったDBMSでは面白くないから」
  - トランザクションログがないことによる性能の悪さは、不揮発性メモリでカバーできると考えていたようだ
  - VACUUMの性能問題に悩まされていたようだ

Postgresの実装(2)

- 実装言語の選択
  - SmallTalk: 遅いから却下
  - C++が良さそうだったが、安定したコンパイラがないので辞めた
  - CはINGRESで使っていたので別な言語にしたかった
  - で、結局Lispを選択
  - そしてすぐに後悔（バッファマネージャをLispで書くのは難しい）
  - そこでLispとCを併用することに(Lispで17,000、Cで63,000)
  - しかし、「Lispメモリ喰い問題」に直面
    - 「4MBも」メモリを使っている
    - また、デバッグも困難
  - 結局Lisp部分をCに書き直し、全部で90,000行のCコードになった

Postgresの実装(3)

- Postgresの性能
  - C実装とLisp実装の比較
  - 参考のためにINGRESとの比較も
- Cに書き換えてかなり性能が向上したが、それでも商用DB(INGRES)には遠く及ばない性能だった

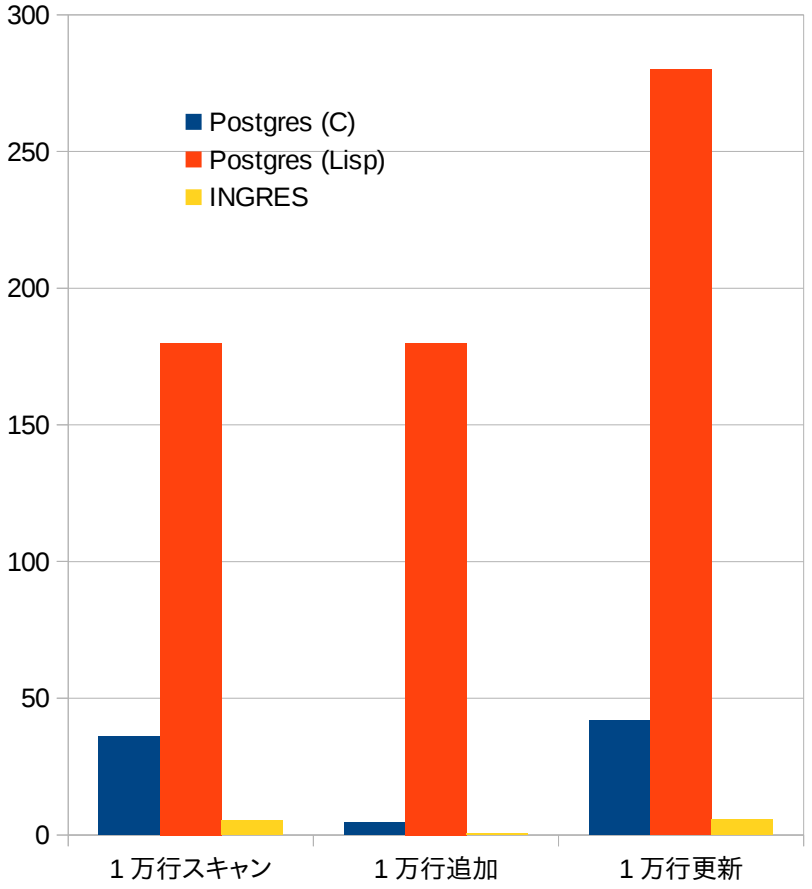

縦軸は、クエリ実行時間(秒)

当時私は何をしていたかと言うと...

- 1991-1993までハワイのホノルル大学で研究をサポートするエンジニアをしていた
- そこではじめてPostgresと出会う
- 最初に使ったRDBがPostgresで、最初に使った問い合わせ言語がPostquelだった

Postgres95へ

Jolly Chen

Andrew Yu

- Postgresプロジェクト1994年で終了
- Postgresプロジェクトに参加していたAndrew Yu氏とJolly Chen氏が、Postgresをベースに Postgres95を開発

Postgres95での変更点

- 問い合わせ言語を Postquel から、SQLに変更
- より洗練されたコードに書き直し、不要部分を削除して高速化
- 若干のSQL強化(Having句の追加)
- “monitor” に代わって、“psql” の実装

当時私は何をしていたかというと...

- 帰国してしばらくは遊びでPostgresをいじる程度
  - M68kアーキテクチャや、MIPSアーキテクチャのマシンへの移植
  - 当時PostgresはSparcアーキテクチャでしか動かなかった
  - そこへ、現在のJPUGの方から「Postgres95が出た」ということを教えていただき、Postgres95のメーリングリストとWebページを立ち上げた
    - これがのちの「pgsql-jp」メーリングリスト

PostgreSQL History

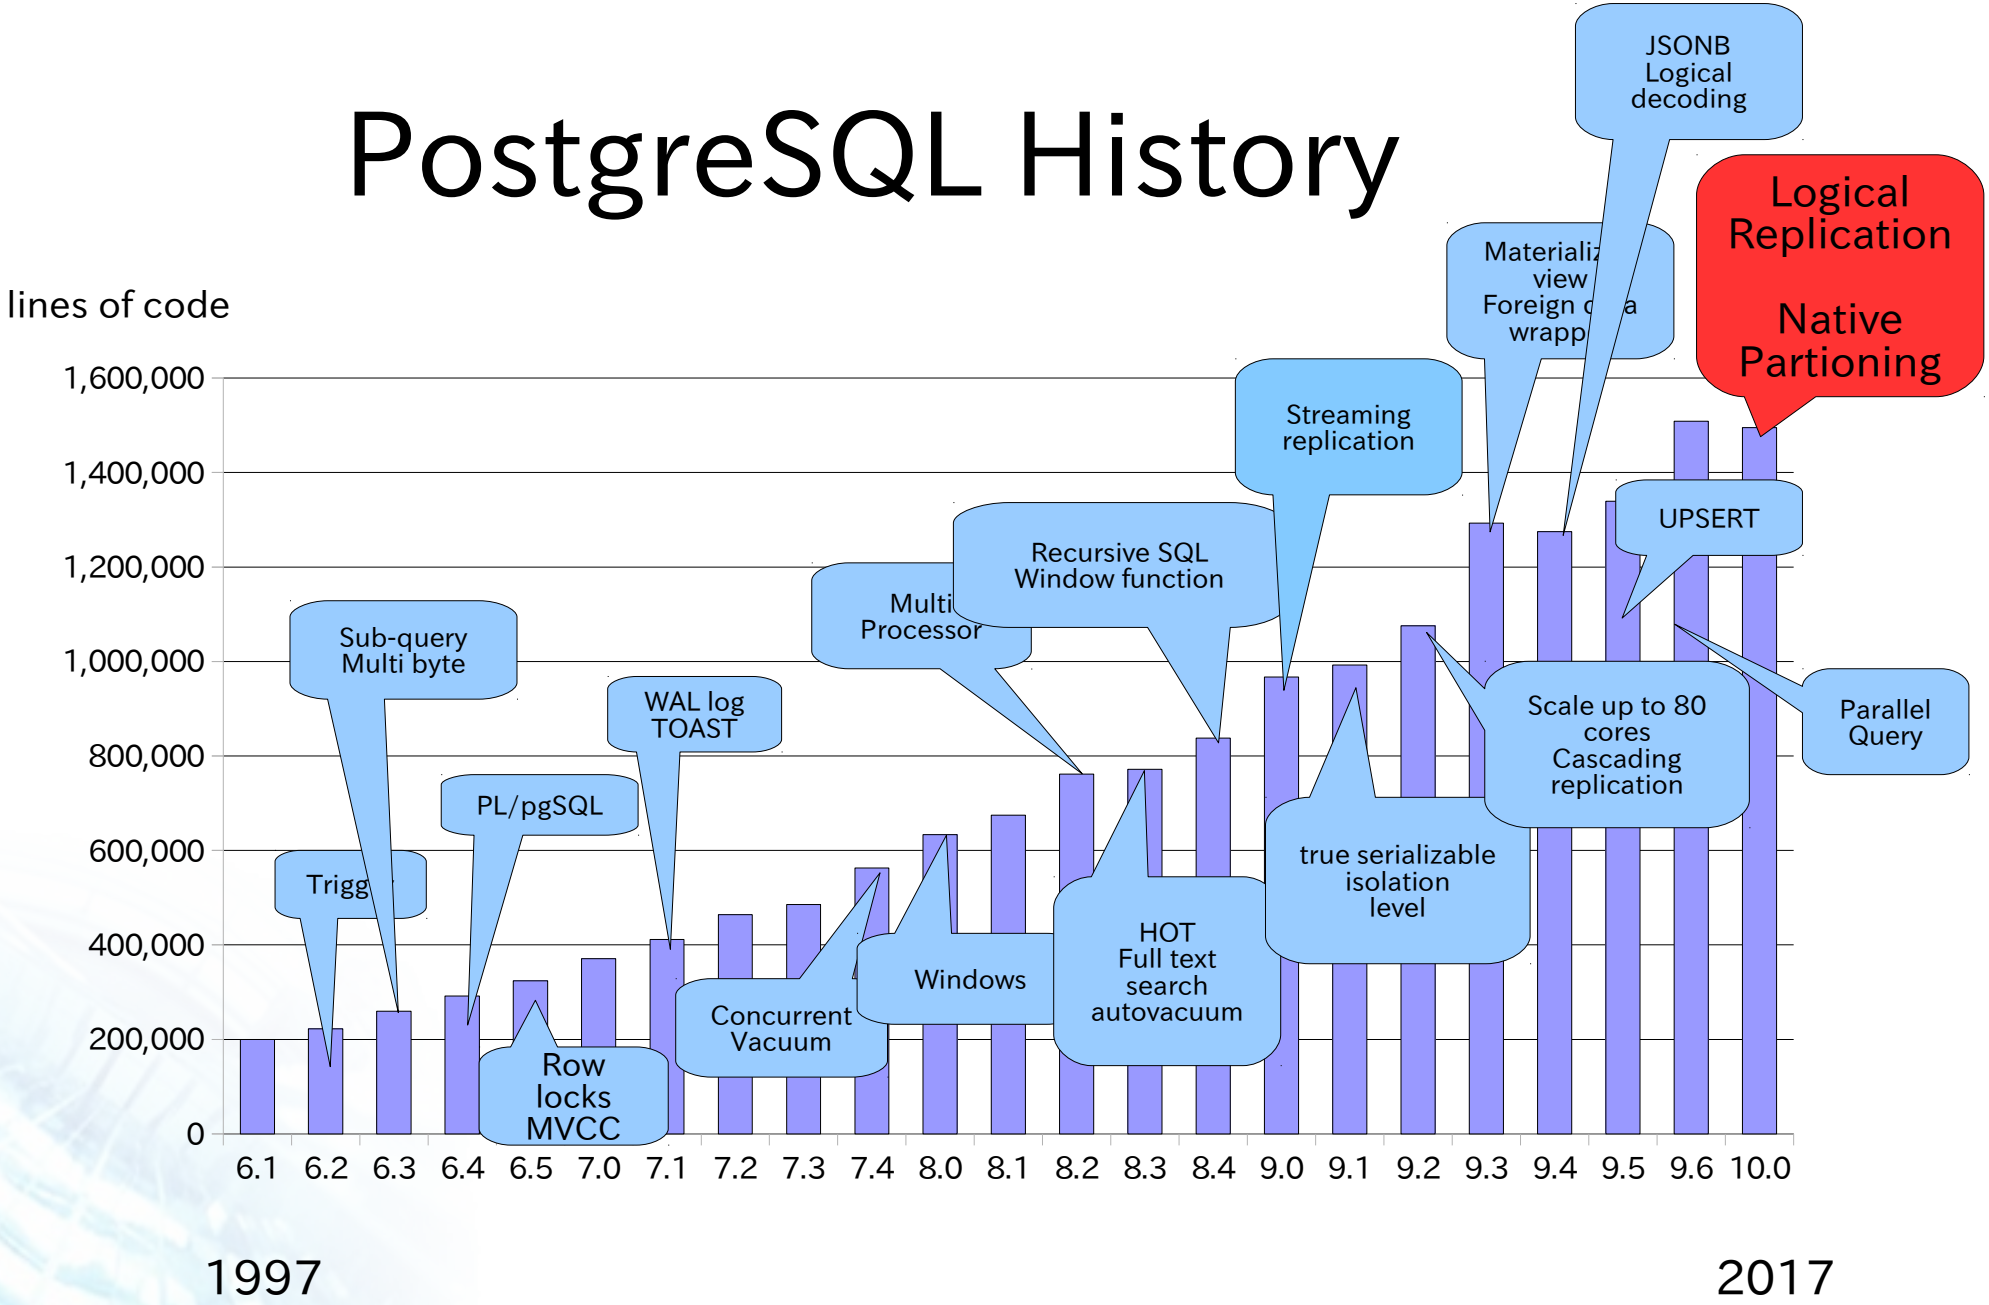

SRA OSS, INC.

1997年1月、PostgreSQL 6.0誕生

- リリースチームは、Marc G. Fournier, Bruce Momjian 氏など
- Berkely Postgres が 4.0、Postgres95を5.0と考えると、PostgreSQLは6.0から開始すべき、と考えた
  - 自分たちがオリジナルではなく、過去の資産の上に貢献を重ねていくという考え方の表れ
  - 後のPostgreSQLの発展の原動力となった方針

Postgres95チームと、初期のPostgreSQL コアメンバー

PostgreSQLの愉快なバグたち

- 修正パッチを送った中で、特に印象深いバグ
  - postmasterに無制限に接続できて、そのうち落ちてしまう
  - フロントエンドとバックエンドのendianが違うと、通信できない
  - ラージオブジェクトの途中にseekしてwriteすると、データがおかしくなる

当初のPostgreSQLになかったもの

- 日本語が使えない
  - パッチを当てて対応（6.3で対応)
- PL/pgSQLがない
  - PL/pgTCLで代用（PL/pgSQLが追加されたのは6.4）
- サブクエリがない
  - SQL関数で代用(6.3で対応)
- トリガがない
  - ルールを使う(6.2で対応)
- 行ロックがない(6.5で対応)
- MVCCがない(6.5で対応)
- トランザクションログ(WAL)がない(7.1で対応)
- Windowsで動かない(8.0で対応)

MVCCの導入

- それまでのPostgreSQLには「タイムトラベル」機能があった
  - 追記型のアーキテクチャを活かし、過去データを、時刻を指定してSELECTできる機能
- これを削除し、代わりにMVCCを実装。過去データはユーザからは見えなくなった
- MVCC導入によるメリット
  - 高いトランザクション並列性
  - 行ロックの導入
    - 当時商用DBでもエスカレーションなしの行ロックは少なかった
  - トランザクション分離レベルの導入
    - READ COMMITTED

トランザクションログの導入以前

- それまでのPostgreSQLは、トランザクションをコミットする度に、データファイルを同期書き込みしていた
- その結果、書き込み性能が非常に低かった
  - 1000万件のデータロードに12時間以上かかる
  - pgbenchで20TPS以下の性能
  - 2 CPUまでしかスケールしない。4 CPUではかえって性能低下

WALをたった一人で実装した伝説のプログラマ: Vadim

- Jim Grayの“Transaction Processing”を読んだだけでWALを実装した
- 議論は1998年からスタート。実装完了したのは7.1(2001年)
  - MVCC込で設計していた

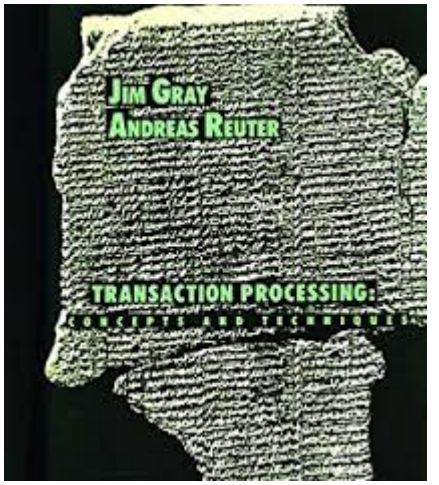

日本PostgreSQLユーザー会の誕生

- 1999年、世界で最初の大規模PostgreSQLユーザグループとして誕生
- pgsql-jpで集まった方を母体に結成
- セミナー、マニュアル翻訳、懇親会など、活発な活動を開始
- 個人的にもいろいろあった年
  - PostgreSQLユーザー会理事長就任
  - PostgreSQLコミッタに就任
  - 本業でもPostgreSQLを取り扱う

PostgreSQL Anniversary Summit

- 2006年カナダのトロントで、PostgreSQLの誕生10周年を記念して開催
- はじめてPostgreSQL開発者・ユーザがface to faceで集合
- この後、世界各地で開催される国際PostgreSQLカンファレンスの先駆け
- PostgreSQLの開発を加速した
- 参加レポートはこちら
  - http://itpro.nikkeibp.co.jp/article/COLUMN/20060727/244542/

PostgreSQLの開発体制

- 特定の企業がソースコードを管理しない集団管理体制
  - 特定企業の方針転換・栄枯盛衰に影響されないメリット
- 最終決定は数人の「コアメンバー」が行う
- gitリポジトリへのコミット権限を持つ「コミッタ」
- それ以外の「開発者」
- ほとんどの決定は、開発者間の議論で行う
  - 開発者は約100人ほど
  - それ以外にレビューに参加した人などを含めると、300人以上が開発に参加している
- ほとんどの議論は公開されているが、一部クローズドな議論を行うグループがある
  - セキュリティ、リリース日程など

PostgreSQLの開発は「みんなで徹底議論」が基本

- メーリングリストで機能仕様・設計について徹底議論
  - 時には1-2年も議論が続く
  - その機能は本当に必要か
  - その機能を追加して保守が困難にならないか
  - その機能を追加することにより性能が犠牲にならないか
  - 議論が長々と続いても、スレッドを容易に追えるような仕掛けがある

長い議論スレッドの例（ロジカルレプリケーション）

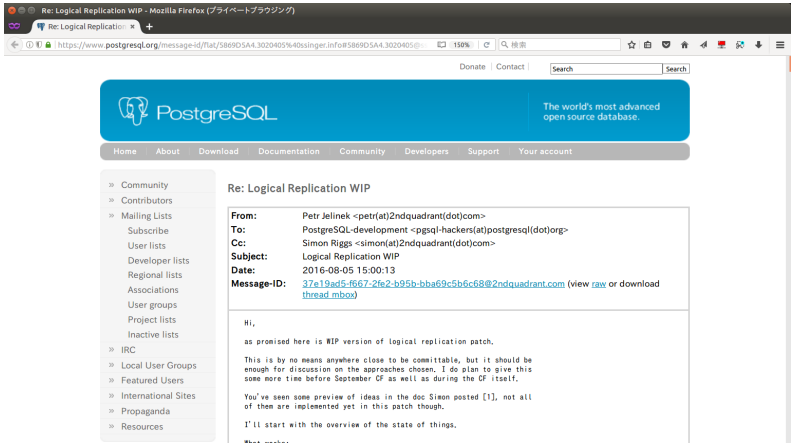

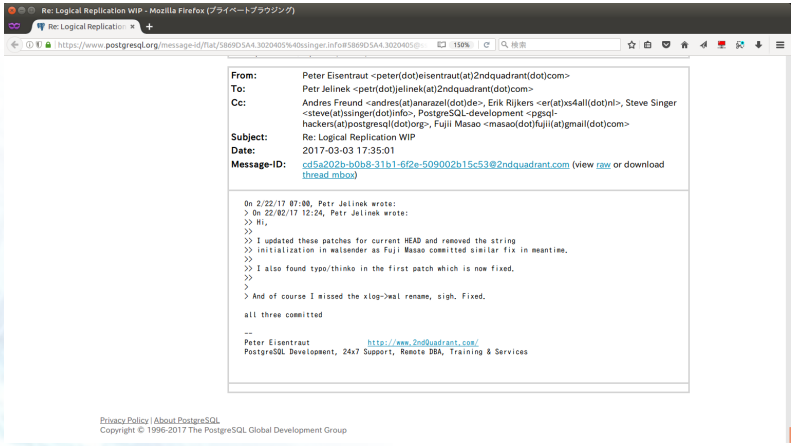

- 2016/8/5にWIPパッチ投稿
- 2017/3/3にパッチコミット
- この間222通のメールのやり取り

Commit Fest

- パッチの投稿、レビュー、コミットを管理する仕組み
- パッチが投稿されてもレビューされずに放置されることもある状態を改善するために2008年ころから開始
- 仕組み
  - 2ヶ月毎にCommit Festを開催、パッチの投稿、レビューを行い、可能ならばコミットする
  - コミットされなかったパッチは次回Commit Festに持ち越される
  - そのメジャーリリース用の最終Commit Fest(前回は2017/3)でコミットされなかったパッチは、次のメジャーリリースに持ち越し
  - 専用のWebアプリで管理

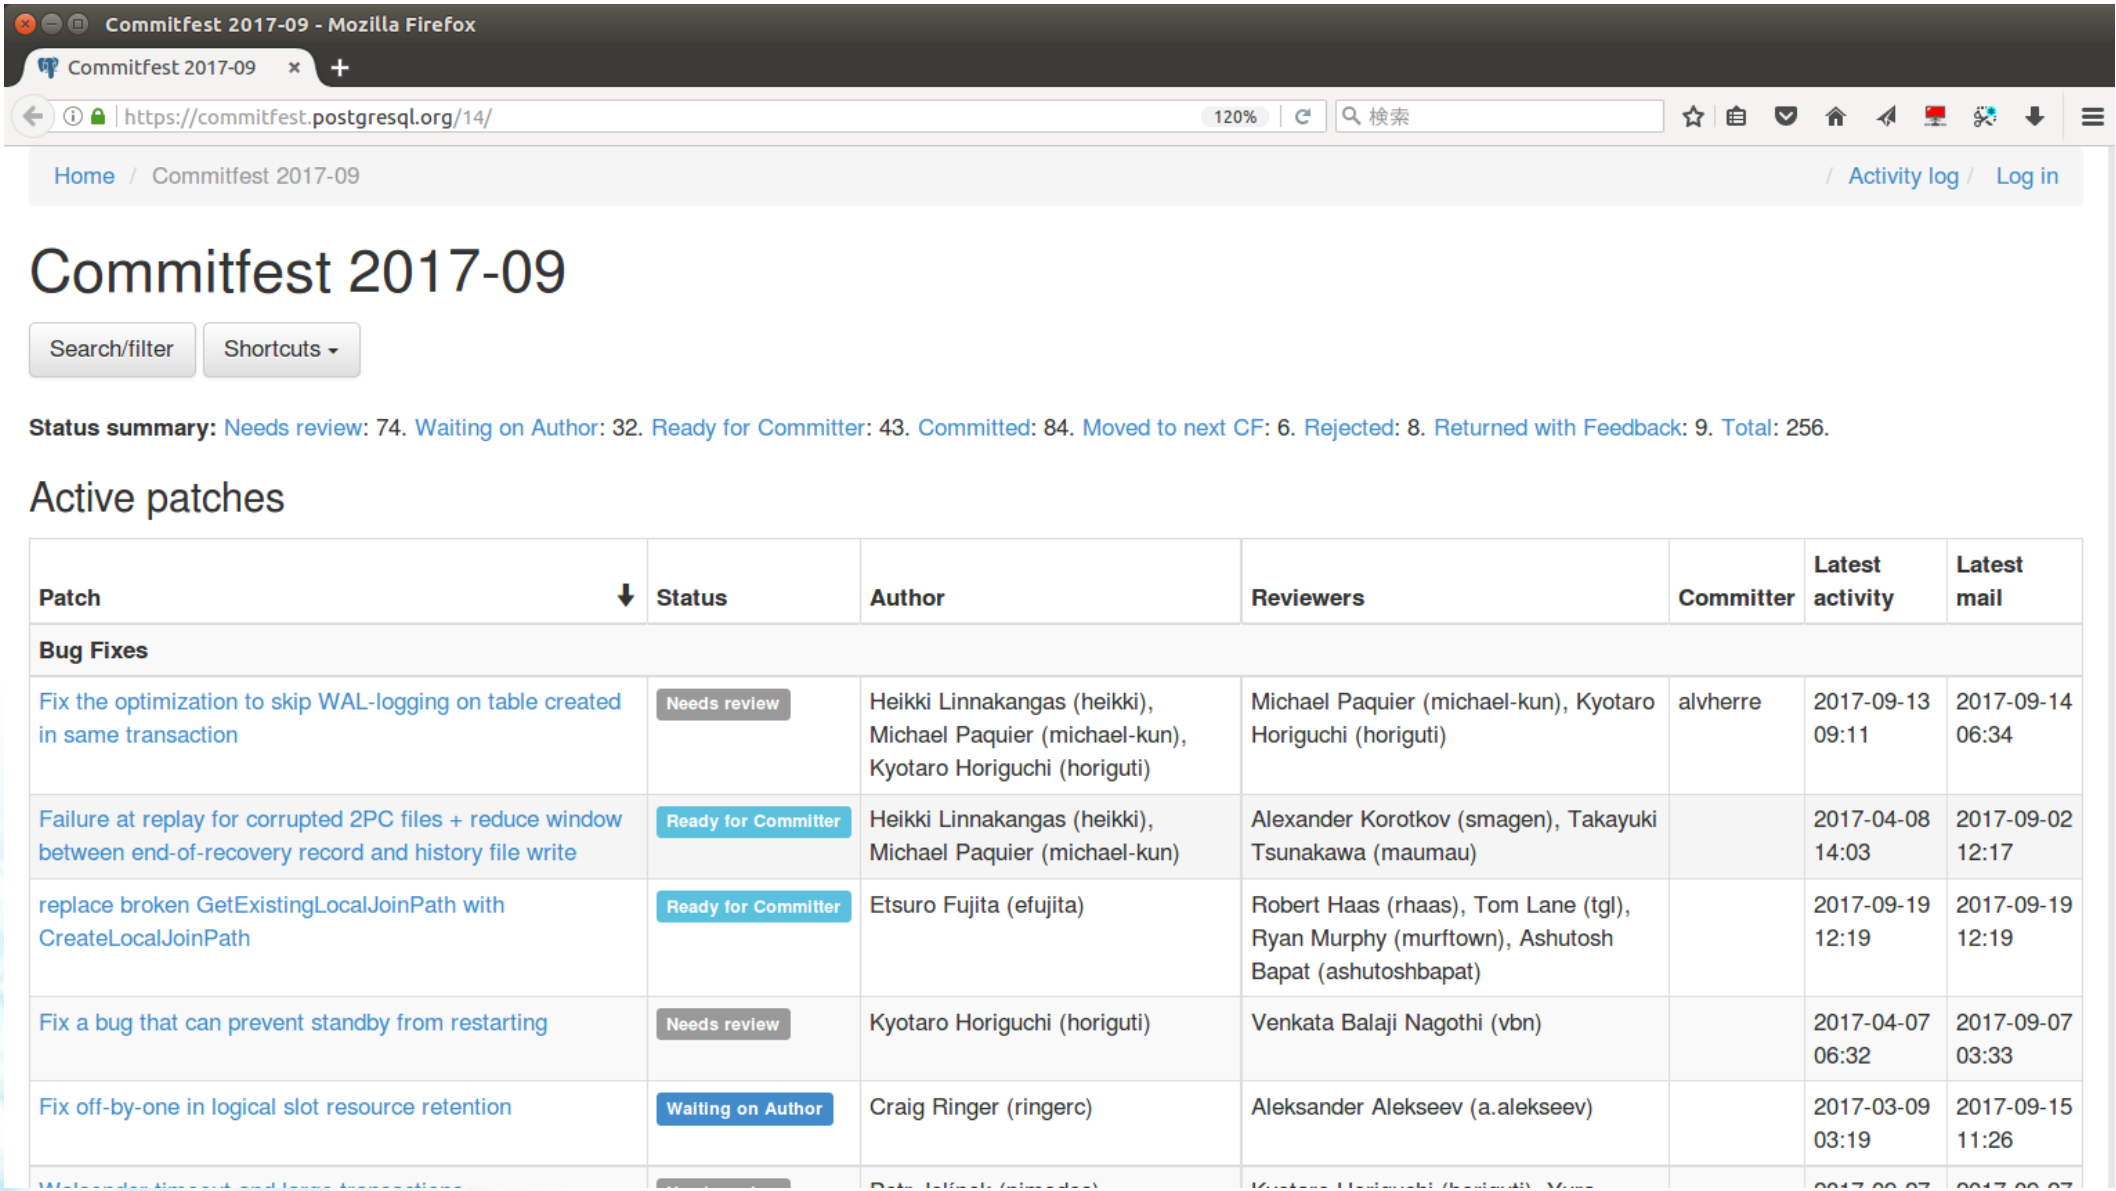

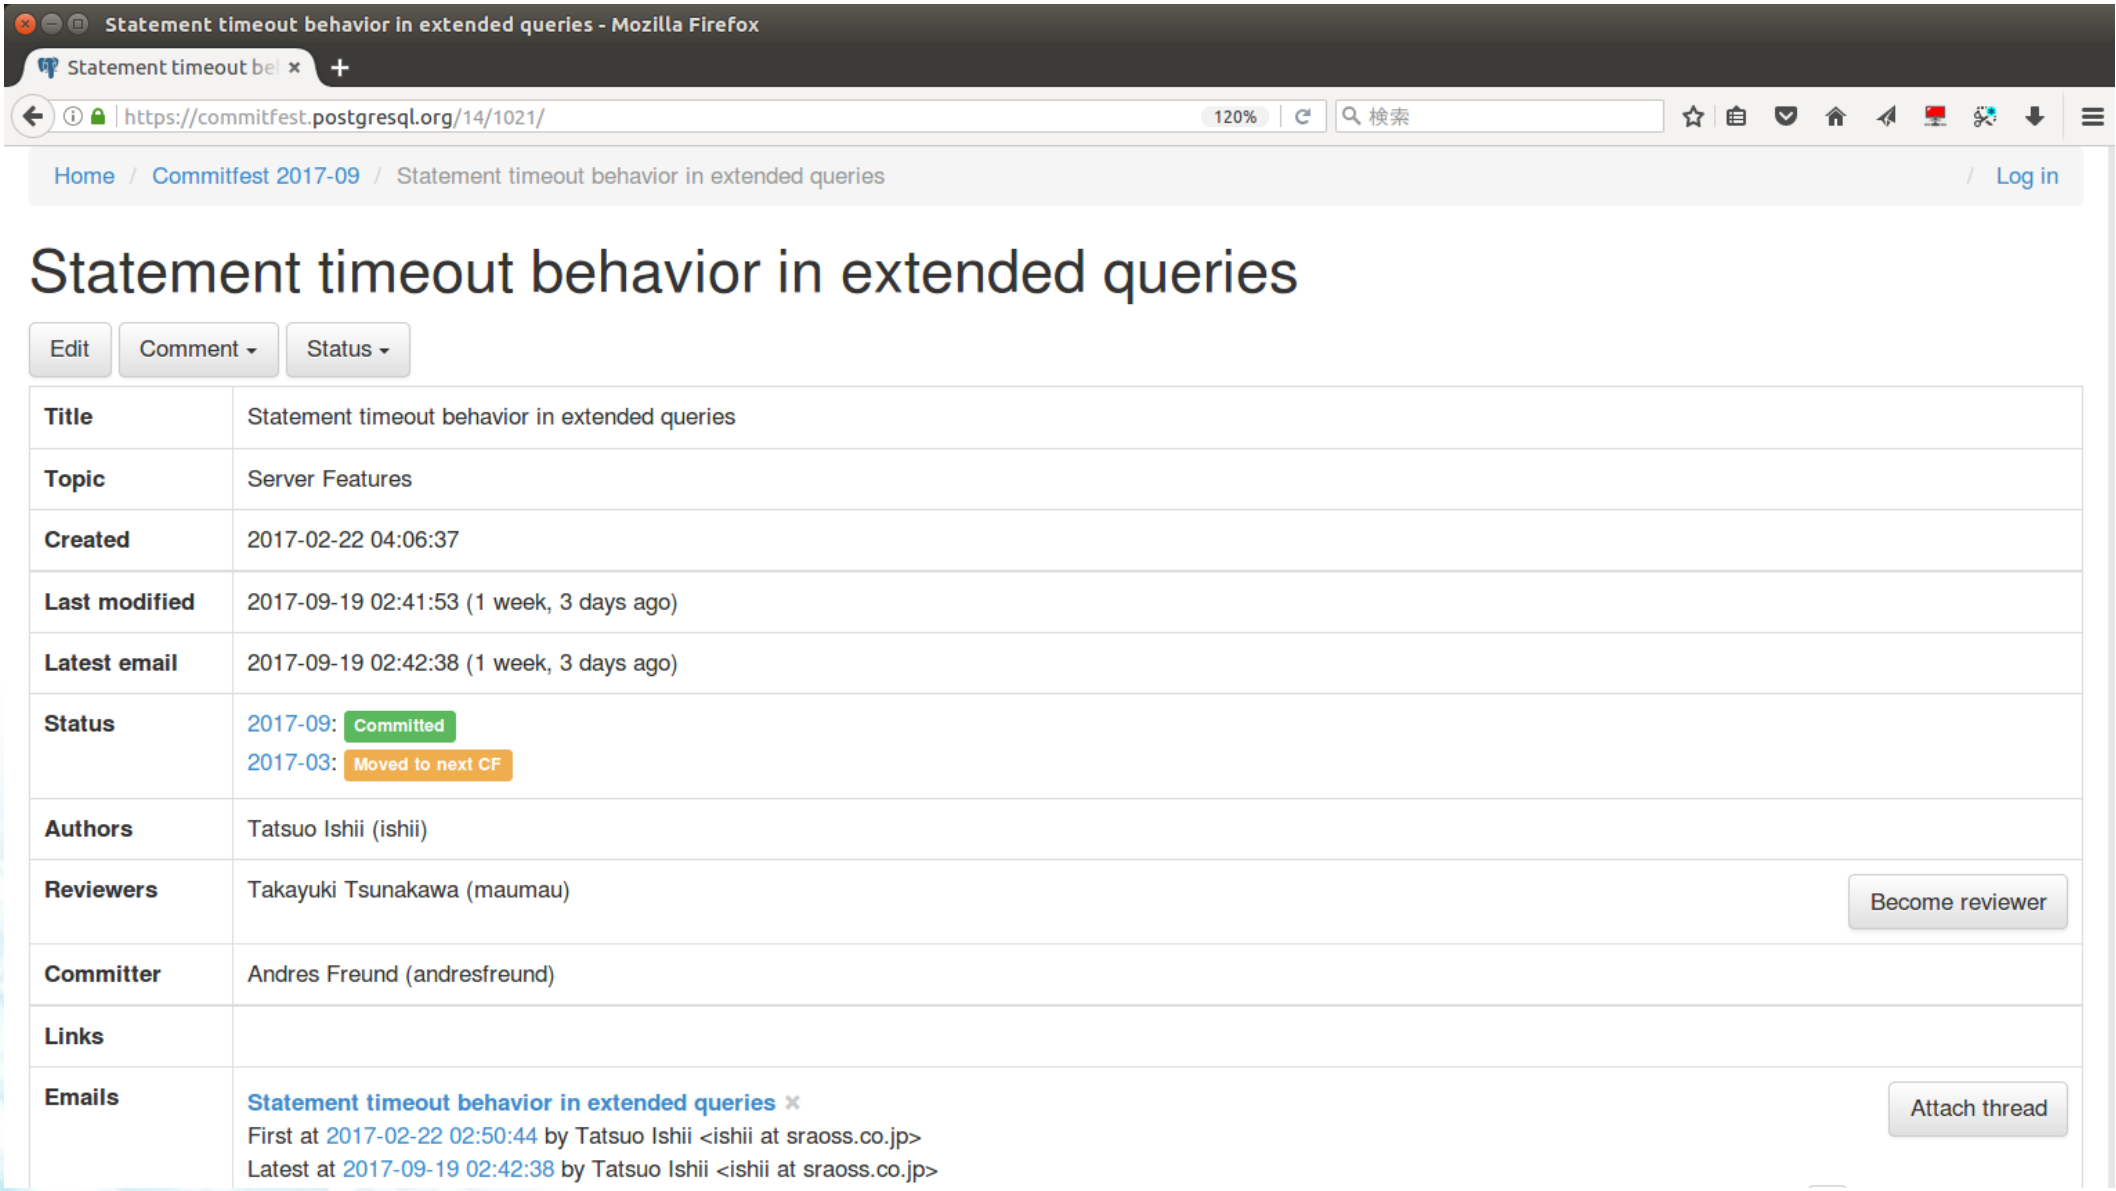

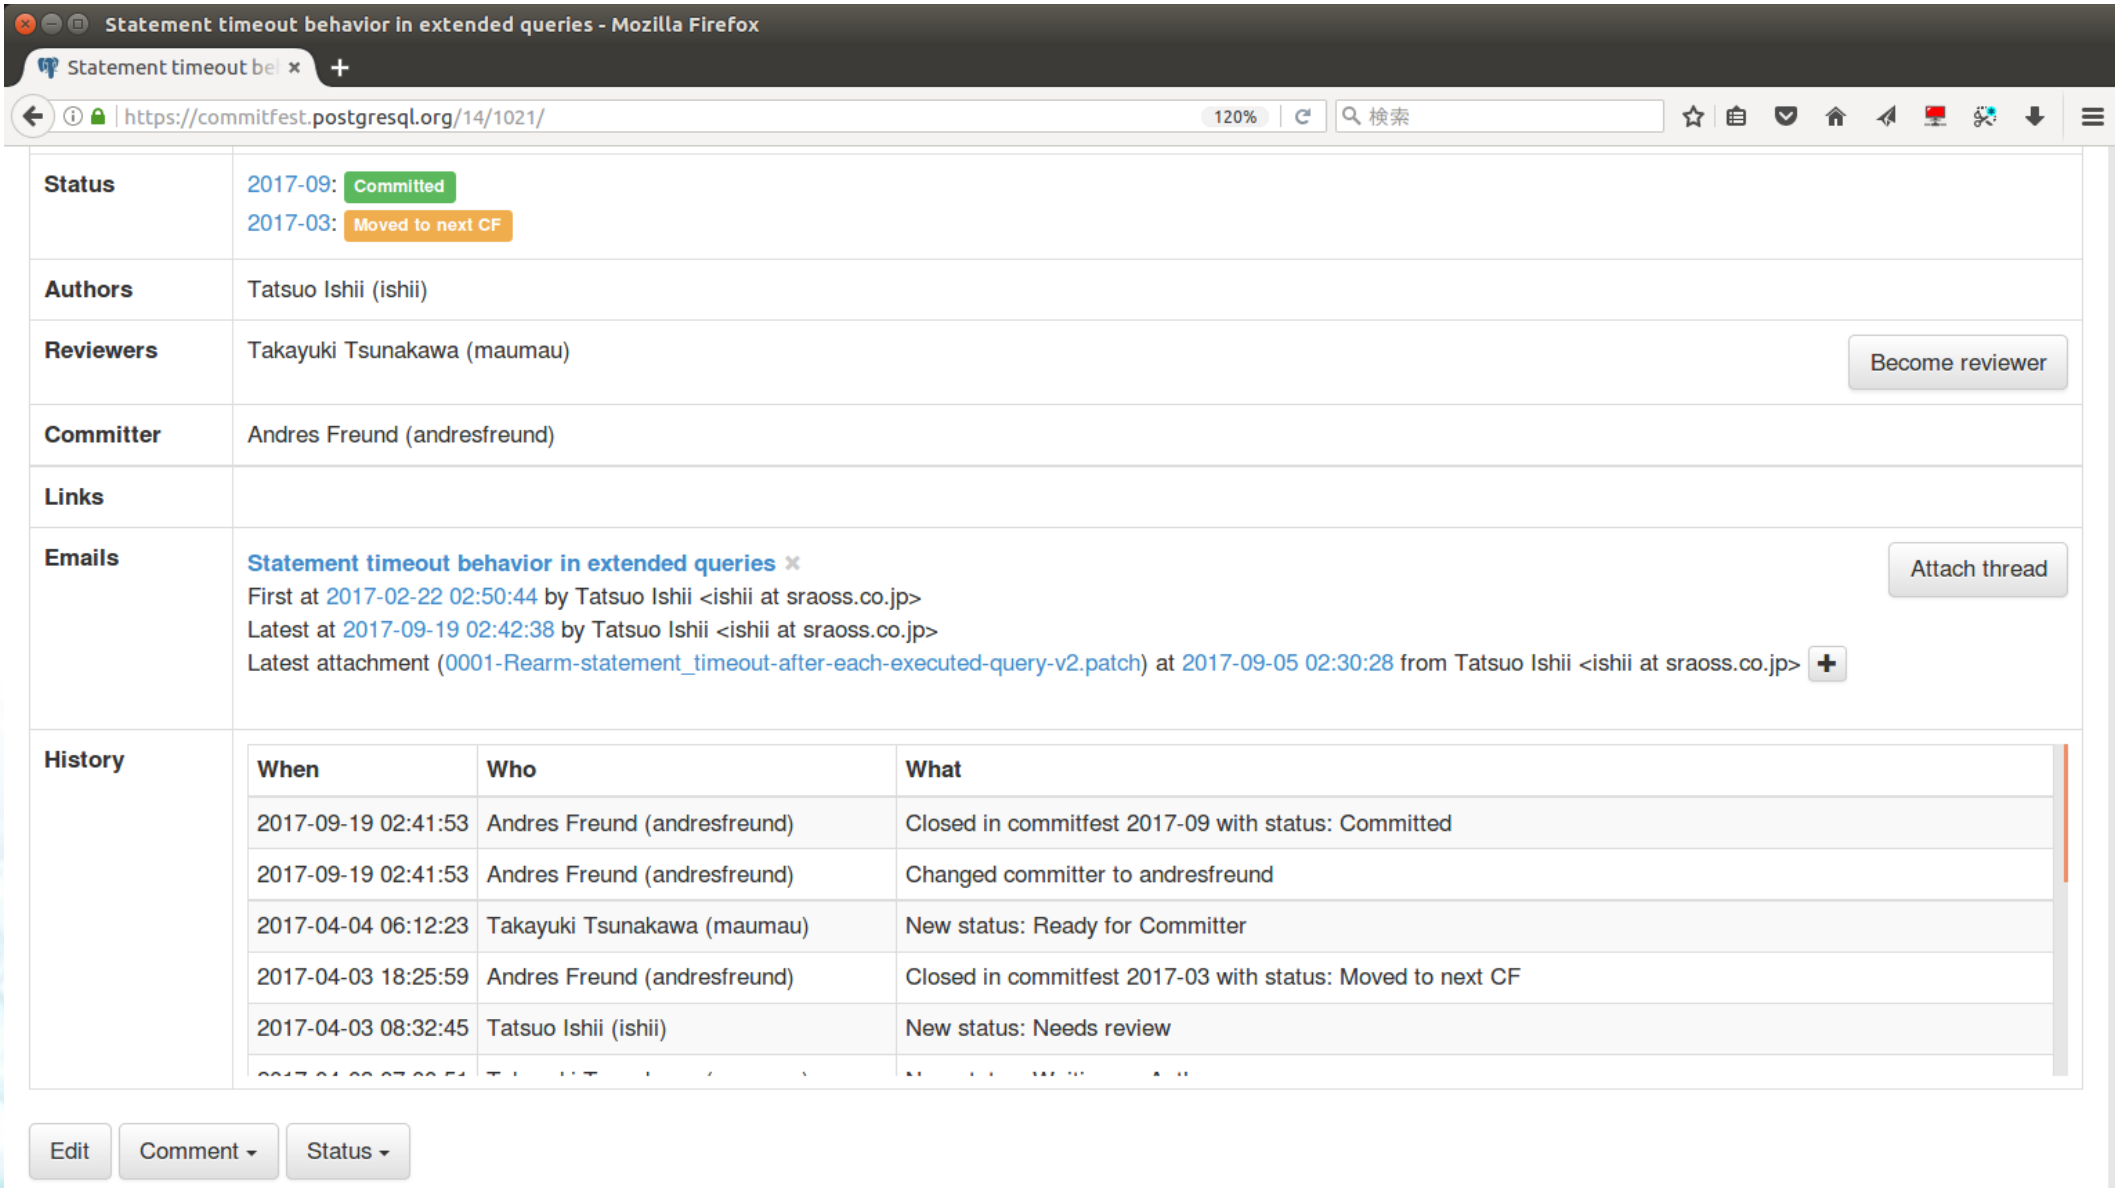

SRA OSS, INC.

PostgreSQLの現在：重要な機能追加

- ストリーミングレプリケーション
- パラレルクエリ
- 論理レプリケーション

レプリケーション、クラスタリングの必要性

- PostgreSQLサーバ1台の性能が上がってくると、人間欲が出てくるもの
  - DBクラッシュ時に業務が止まってしまうのは困る
    - かといって、バックアップから戻すのは、非常に時間がかかる
    - レプリケーションで解決→可用性の向上
  - DB性能が足りない
    - 複数台のDBサーバを束ねて性能を向上できないか

ストリーミングレプリケーション登場以前のレプリケーション技術

- Pgpool-IIのネィティブレプリケーション
  - SQL文を複数サーバに投げることによってレプリケーションする
- Slony-I
  - 更新トリガを利用して更新差分を転送してレプリケーションする
- dblink
- 問題点
  - 性能が出ない
  - すべてのデータオブジェクトをレプリケーションできるわけではない
  - PostgreSQL組み込みのレプリケーション技術ではない

ストリーミングレプリケーションの登場

- PostgreSQL 9.0 (2010)で実装
- 既存のレプリケーション技術に対する優位性
  - 組み込みレプリケーション技術
  - 性能的に優れている
  - ほとんどすべてのオブジェクトをレプリケーションできる

ストリーミングレプリケーションの継続的な改良

- スタンバイ昇格の際に、データを失わない
  - 同期レプリケーションの実装
- レプリケーション遅延のコントルールと一貫性の保証
  - synchronous_commit = 'remote_apply'

パラレルクエリの登場

- 単一プロセスでクエリを実行するアーキテクチャから、複数のワーカーがクエリを並列に実行するアーキテクチャへの変更
- 十分なメモリとCPUがある環境での検索クエリに威力を発揮

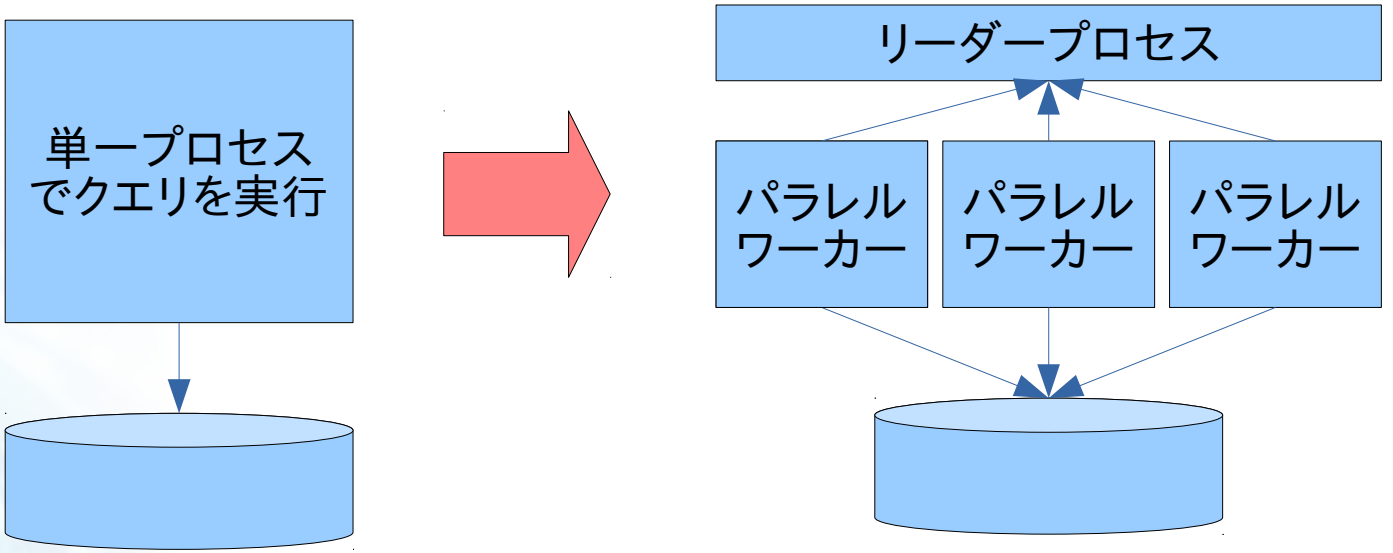

論理レプリケーションの登場

- 変更内容を論理的に後から操作できる形でログとして保存し、そこから特定の変更を取り出して適用する

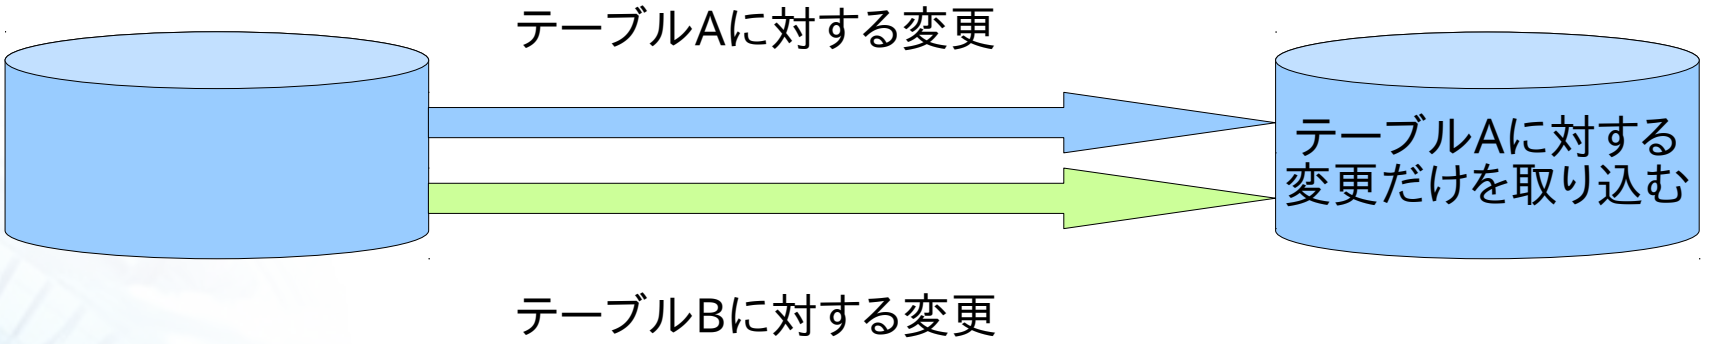

論理レプリケーションの ユースケース

バージョンアップ

ストリーミングレプリケーション との併用

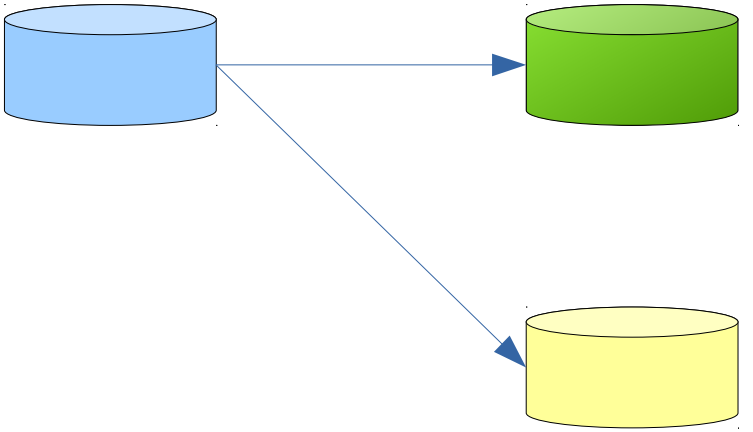

データの集約

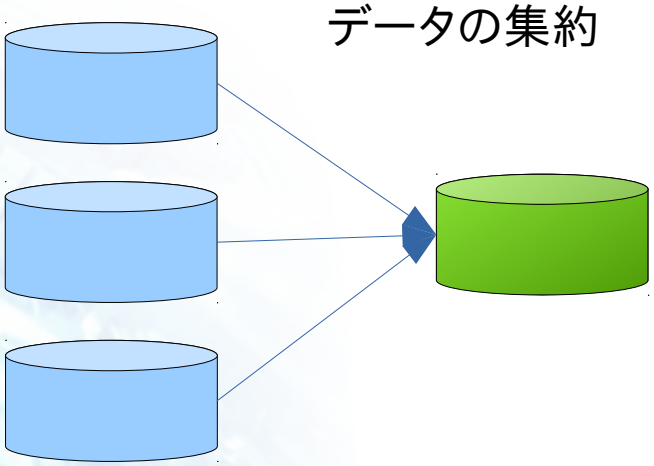

同一サーバ内での 別DBへのレプリケーション

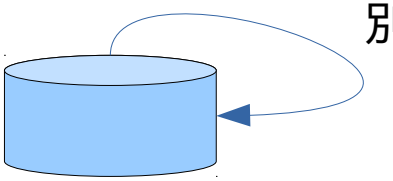

SRA OSS, INC.

PostgreSQLの将来（期待をこめて）

- 双方向レプリケーション
- 更新処理へのパラレルクエリの拡張
- 複数ノードをまたがったパラレルクエリ
- エグゼキュータへのJITコンパイル導入
- スキーマ変数
- JOINを含むビューも更新可能
- 図を含むドキュメント

参考URL

- PostgreSQL
  - http://www.postgresql.org
- Pgpool-II
  - http://pgpool.net
- Pgproto
  - https://github.com/tatsuo-ishii/pgproto

謝辞

- スライドで使用した写真の一部は、Bruce Momjian 氏からお借りしたものです。貴重な写真をご提供いただき、感謝します。

Thank you!