NTT Software Innovation Center

NTT

DB統計情報取得/可視化ツール pg_statsinfo と pg_stats_reporter のご紹介

NTT OSSセンタ
近藤 光正

自己紹介

- **正式な所属名称**
  - 日本電信電話株式会社　サービスイノベーション総合研究所
    ソフトウェアイノベーションセンタ
    研究員
- **担当業務**
  - PostgreSQL関連ツールの研究開発
    - pg_statsinfo (DB統計情報監視ツール)
    - pg_stats_reporter (DB統計情報可視化ツール)
    - PG-REX (PostgreSQLの高可用クラスタ　PG + Pacemaker + pgsqlRA)
  - PostgreSQL のコミュニティ開発
    - 特に Disk IO 周りの改善
- **過去の業務**
  - データマイニング、自然言語処理、機械学習、情報推薦、情報検索
    - こっちの方が得意
- **趣味**
  - カメラ
  - オーディオ

本日紹介するツールの概要

- **pg_statsinfo**
  - PostgreSQL の統計情報を取得/蓄積するツール
- **pg_stats_reporter**
  - pg_statsinfo で取得/蓄積した統計情報の可視化ツール

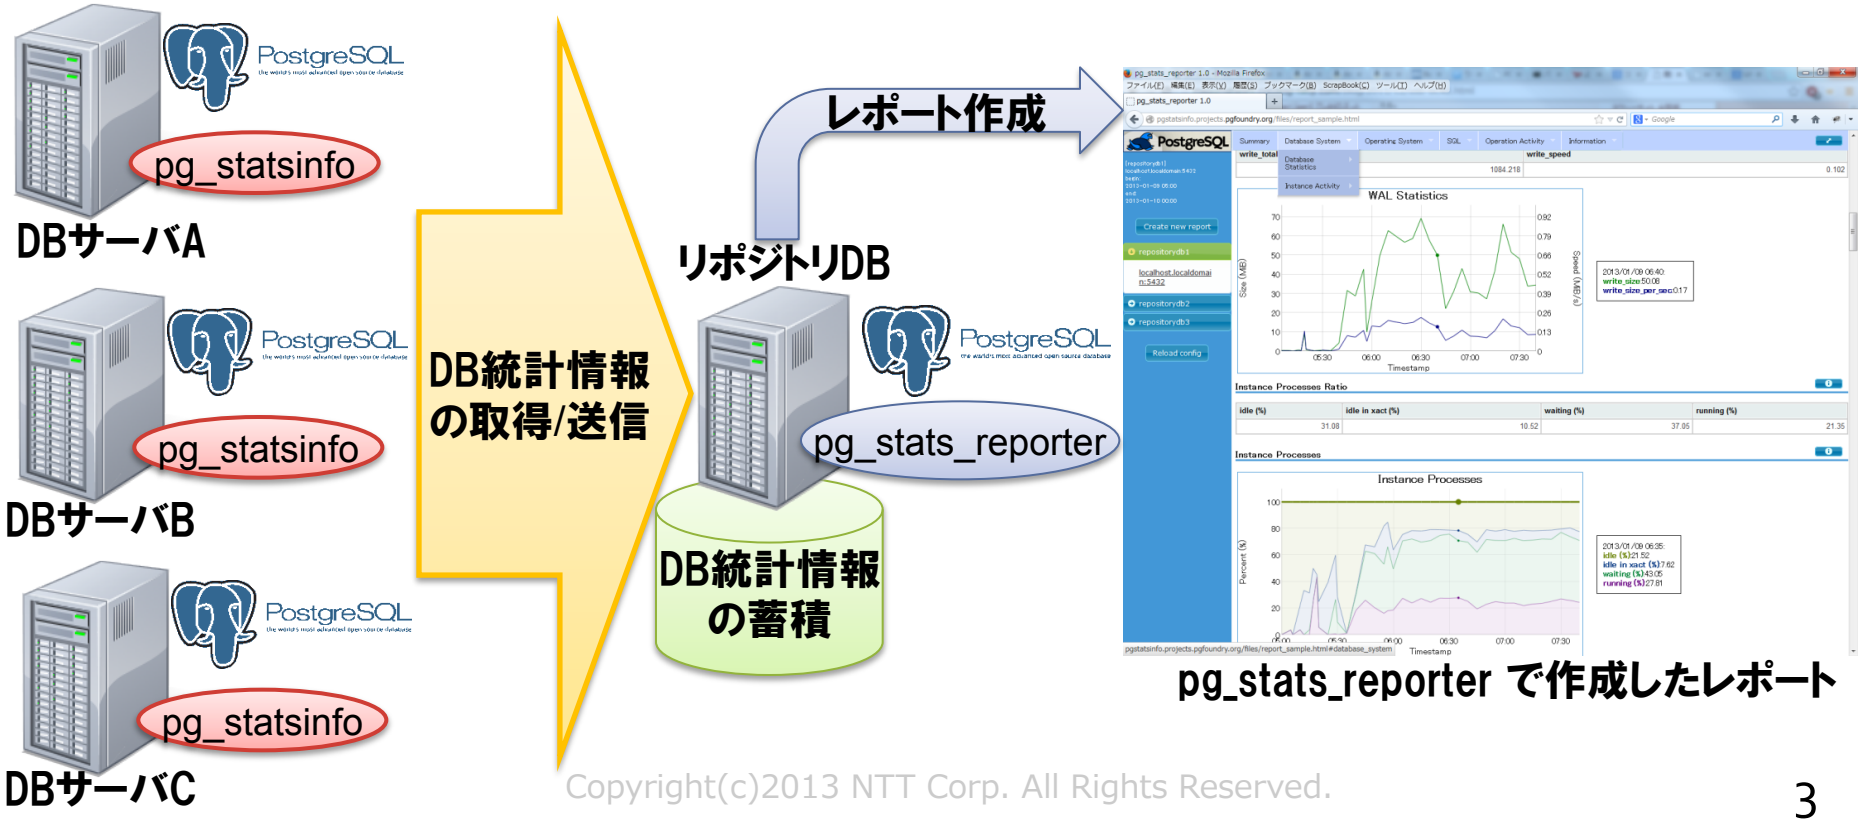

pg_stats_reporter で作成したレポート

本日のアジェンダ

- **DB 統計情報取得ツール pg_statsinfo**
  - 概要
  - 機能紹介
  - デモ
- **DB 統計情報可視化ツール pg_stats_reporter**
  - 概要
  - 機能紹介
  - デモ
- **DBT-2 ベンチマークの可視化**
  - DBT-2 ベンチマークの概要
  - 作成されたレポートの紹介
  - チューニング TIPS

pg_statsinfo の概要

- PostgreSQL に格納された統計情報を取得/蓄積するツール
- 取得する統計情報
  - 統計情報テーブル(pg_catalog)の定期的な取得/蓄積
  - ログ情報からの情報取得/蓄積
  - OSリソースの情報取得/蓄積
- その他機能
  - 簡易レポート作成機能
  - アラート機能
  - ログ管理機能
  - 自動メンテナンス機能
- **その他各種情報**
- BSDライセンス
- 最新バージョン 2.5.0
  - http://pgfoundry.org/frs/?group_id=1000422
  - PostgreSQL 9.3 にも対応
- 詳細マニュアルあり
  - http://pgstatsinfo.projects.pgfoundry.org/pg_statsinfo-ja.html

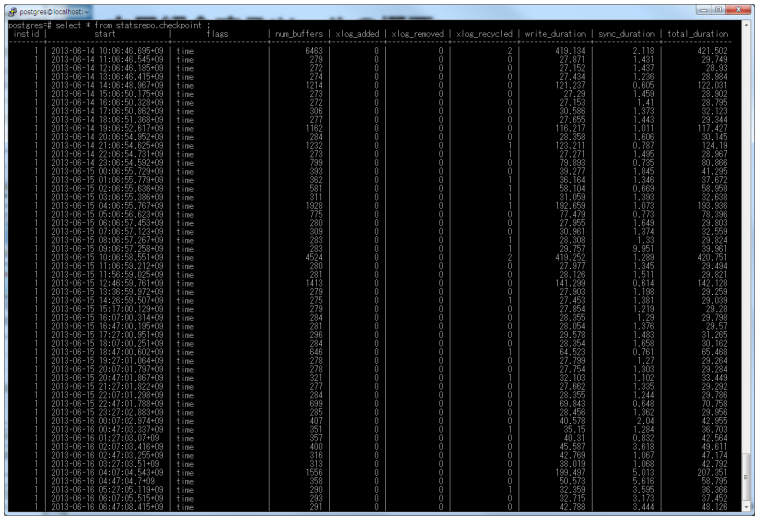

取得/蓄積したDB統計情報

pg_statsinfo のアーキテクチャ

- **プログラミング言語**
  - C言語
- **動作方法**
  - PostgreSQL の shared_preload_library 経由で起動します
  - postgresql.conf に設定を記述し、通常起動すれば動作します
- **システム構成**
  - 統計情報を取得する監視対象DBにpg_statsinfoをインストール
    - 統計情報を蓄積するリポジトリDBにはインストール不要
    - 監視対象DBとリポジトリDBは同一でもOKです

pg_statsinfo 機能紹介 1/5

- **取得する統計情報**
  - PostgreSQLの統計情報コレクタが収集する全ての情報
    - 統計情報コレクタの詳細については以下を参照してください☺
      - http://www.postgresql.jp/document/9.2/html/monitoring-stats.html
    - スナップショットとして一定間隔で取得します
      - デフォルトで10分おきに取得
  - PostgreSQL ログのテキスト解析
    - ログにしか出力されない情報を抽出
      - チェックポイント情報のログ
      - VACUUM の実行情報ログ
  - /proc に格納されるOSリソース情報の取得
    - 5秒間隔で情報を取得し、スナップショット時には平均値を格納
      - CPU使用状況情報（idel, iowait, system, user, Load Average）
      - メモリ使用状況（memfree, buffers, cached, swap, dirty）
      - ディスク使用状況（IO size, IO time, ディスク使用状況）

pg_statsinfo 機能紹介 2/5

- **簡易レポート機能**
  - コマンドライン上から、テキスト形式でレポート結果を出力する
    - 利用例）コマンドライン上からレポートを見たい運用者/開発者向け
  - pg_stats_reporterから見れるレポートは、ほぼ網羅

コマンド例：10月1日から現在までの、すべてのインスタンスの、すべてのレポート項目を作成する

```
$ pg_statsinfo -U postgres -B 2013-10-01 -r ALL | less
```

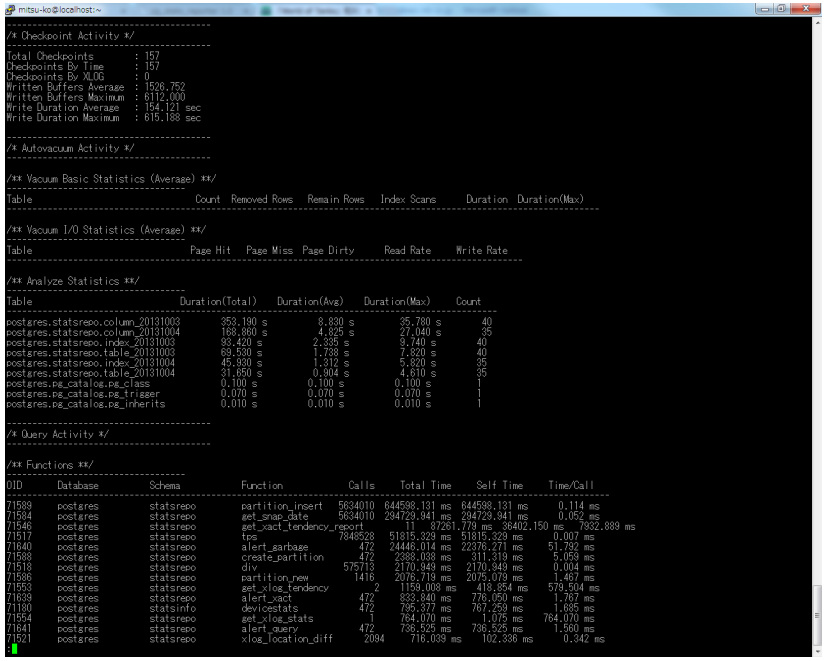

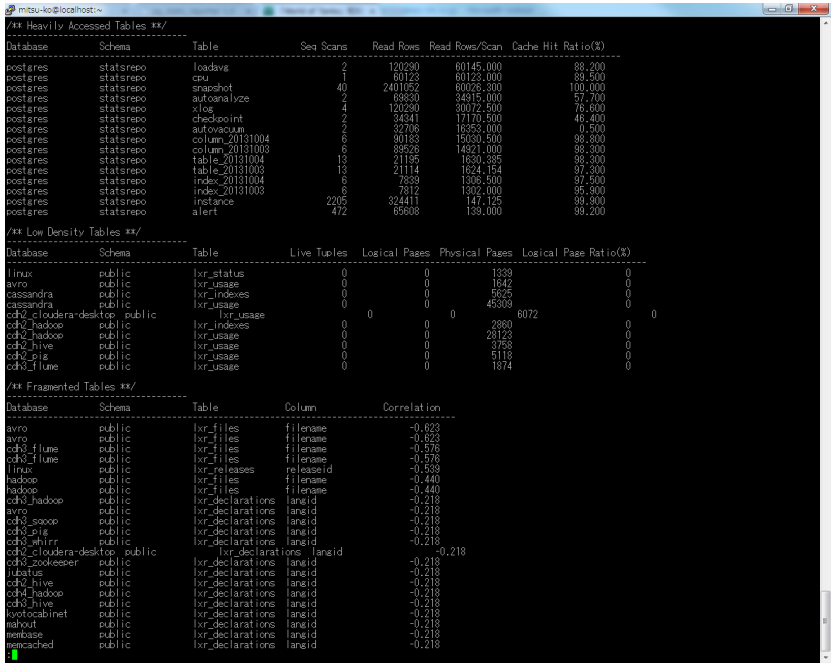

pg_statsinfo 機能紹介 3/5

- **自動メンテナンス機能**
  - リポジトリDBに蓄積した統計情報を自動削除する機能
    - pg_statsinfo は、１日間隔で自動パーティショニングを行ってデータを格納しているため、削除対象のデータはパーティションを丸ごと TRUNCATE される
    - 高速で低負荷なデータ削除を実現

- **TIPS**
  - 削除対象の期間は、監視インスタンスの設定で最も期間の近いものが優先されて実行されるので注意

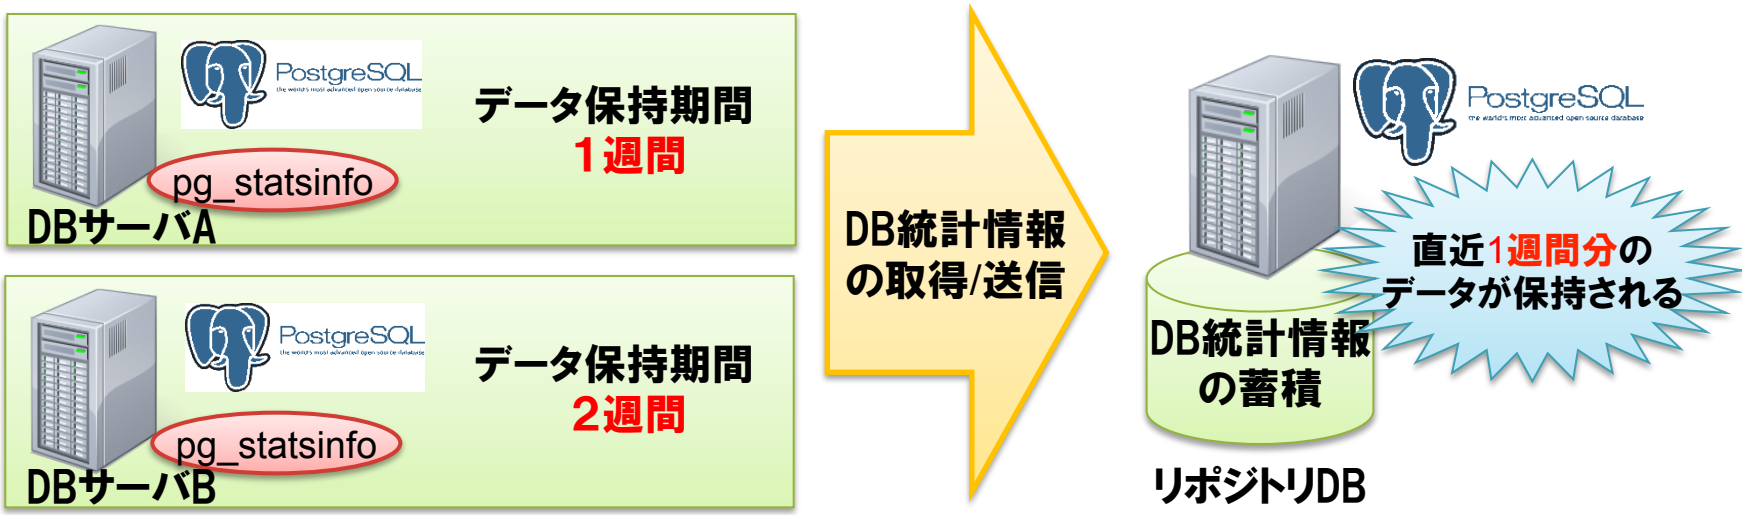

pg_statsinfo 機能紹介 4/5

- **ログ管理機能**
  - PostgreSQLのログを扱いやすく管理する
  - ２段階ログ出力機能
    - PostgreSQLログの出力レベルから、さらにpg_statsinfoのログレベルを設定可能
      - 利用例）PostgreSQLのログは詳細レベルに設定し、普段見るログは見やすいログレベルに設定する
      - ログファイル名を固定できるので、監視ミドルウェアのログ監視にも使えます
  - 複数ログ出力機能
    - syslog と pg_log に同時に書き込む
  - ログレベル変更機能
    - 特定のログに対して、ログレベルを変更して出力する機能
      - 例）ログレベルINFOの特定のログ出力をLOGに変更
  - ログ圧縮機能
    - 1日経過してログローテートされたログに対して、圧縮を実行

pg_statsinfoのログ加工の流れ

pg_statsinfo 機能紹介 5/5

- **アラート関数**
  - DB統計情報の値が想定値を超えた場合に、ログに出力する機能
    - 利用例）出力されたログを監視ミドルウェアで監視する
    - アラート関数は、スナップショット契機で実行されます
  - デフォルトで以下の値が設定されているので適宜変更すること
    - 変更方法は、statsrepo.alert テーブルの各値をUPDATE文で変更する

アラート設定テーブル

カラム名	デフォルト値	説明
instid	–	監視対象インスタンスID
rollback_tps	100	秒間のロールバック数
commit_tps	1000	秒間のコミット数
garbage_size	20000	監視インスタンス中の不要領域のサイズ(MB)
garbage_percent	30	監視インスタンスに占める不要領域の割合(%)
garbage_percent_table	30	各テーブルに占める不要領域の割合(%)
response_avg	10	クエリの平均レスポンス時間(秒)
response_worst	60	クエリの最長レスポンス時間(秒)
enable_alert	true	アラート対象判定フラグ

pg_statsinfo のインストール方法

1. RPMのインストール

```
$ su
# rpm -ivh pg_statsinfo-2.4.0-1.pg92.rhel6.x86_64.rpm
```

2. postgresql.conf に以下の内容を追加

```
#最小設定
shared_preload_libraries = 'pg_statsinfo'                # 事前ロードを行う
log_filename = 'postgresql-%Y-%m-%d_%H%M%S.log' # ログファイル名を指定する
```

3. PostgreSQLを起動

```
$ pg_ctl -D data start
```

4. 以下のログが出力されればインストール成功！

```
server starting
LOG:  loaded library "pg_statsinfo"
LOG:  pg_statsinfo launcher started
LOG:  start
LOG:  installing schema: statsinfo
LOG:  installing schema: statsrepo_partition
```

インストール手順はWebマニュアルにも記載されています☺
http://pgstatsinfo.projects.pgfoundry.org/pg_statsinfo-ja.html#install

pg_statsinfo の TIPS

- **１回のスナップショットのサイズは、約300KB ～ 800KB**
  - スナップショット取得間隔を調整して、ディスクフルにならないように注意する
- **統計情報取得の際の性能劣化は、ほぼありません**
  - DBT-２ベンチマークで２%程度の劣化を確認
    - ただし、レポジトリDBを分けた構成での話です
- **遠隔のレポジトリDBを使用したい場合は、postgresql.conf に pg_statsinfo.repository_server を設定する**
  - 設定しない場合は、'host=localhost port=5432'が設定されます
- **レポジトリDBにパスワードを使用している場合は、/var/lib/pgsql/.pgpass にパスワードを設定する**

pg_stats_reporter の概要

- **pg_statsinfo で取得/蓄積した統計情報の可視化ツール**
  - 作成できるレポート例
  - トランザクション状況
  - DBサイズの推移
  - OSリソース状況
  - WALの出力量
  - レプリケーション状況
  - デッドロック情報

  - pg_reporterの後継ツール
  - pg_reporterで作成できるレポート

  ＋ α

- **その他各種情報**
  - BSDライセンス
  - 最新バージョン 2.0.0
  - http://pgfoundry.org/frs/?group_id=1000422
  - 詳細マニュアルあり
  - http://pgstatsinfo.projects.pgfoundry.org/pg_stats_reporter-ja.html

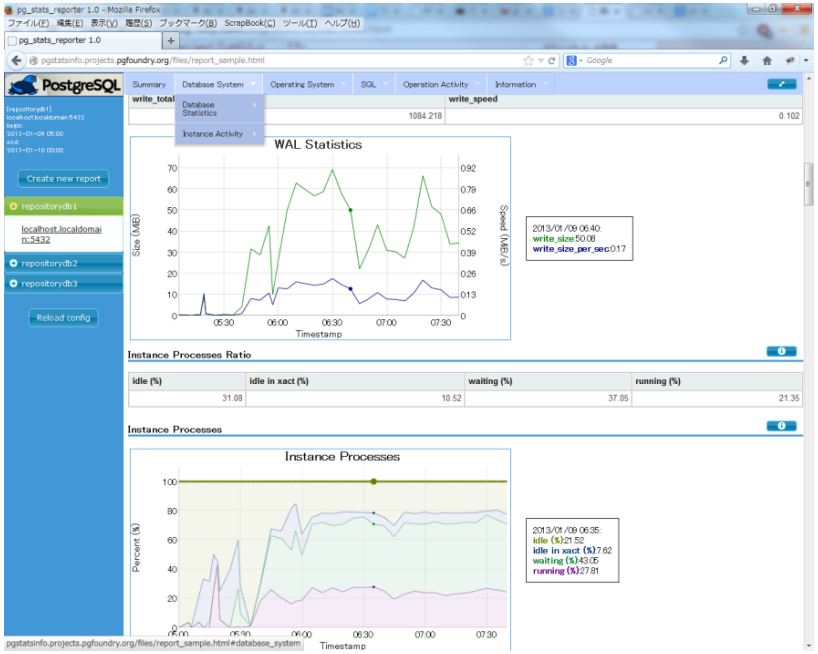

pg_stats_reporterの画面

pg_stats_reporter のアーキテクチャ

- **ソフトウェア構成**
  - Apache + PHP + PostgreSQL
    - PHP + PostgreSQL のみでも動作可能
    - PostgreSQL 8.3 以降で動作
- **プログラミング言語**
  - PHP + javascript + SQL
- **利用ライブラリ**
  - PHP フレームワーク
    - Smarty
  - ユーザインタフェース
    - jQuery, jQuery UI, tablesorter, Superfish
  - グラフ作成
    - dygraphs, jqPlot

PostgreSQL

dygraphs

レポートの作成方法 1/2

- Web ブラウザからレポート作成する方法
  - 数クリックで簡単にレポート作成

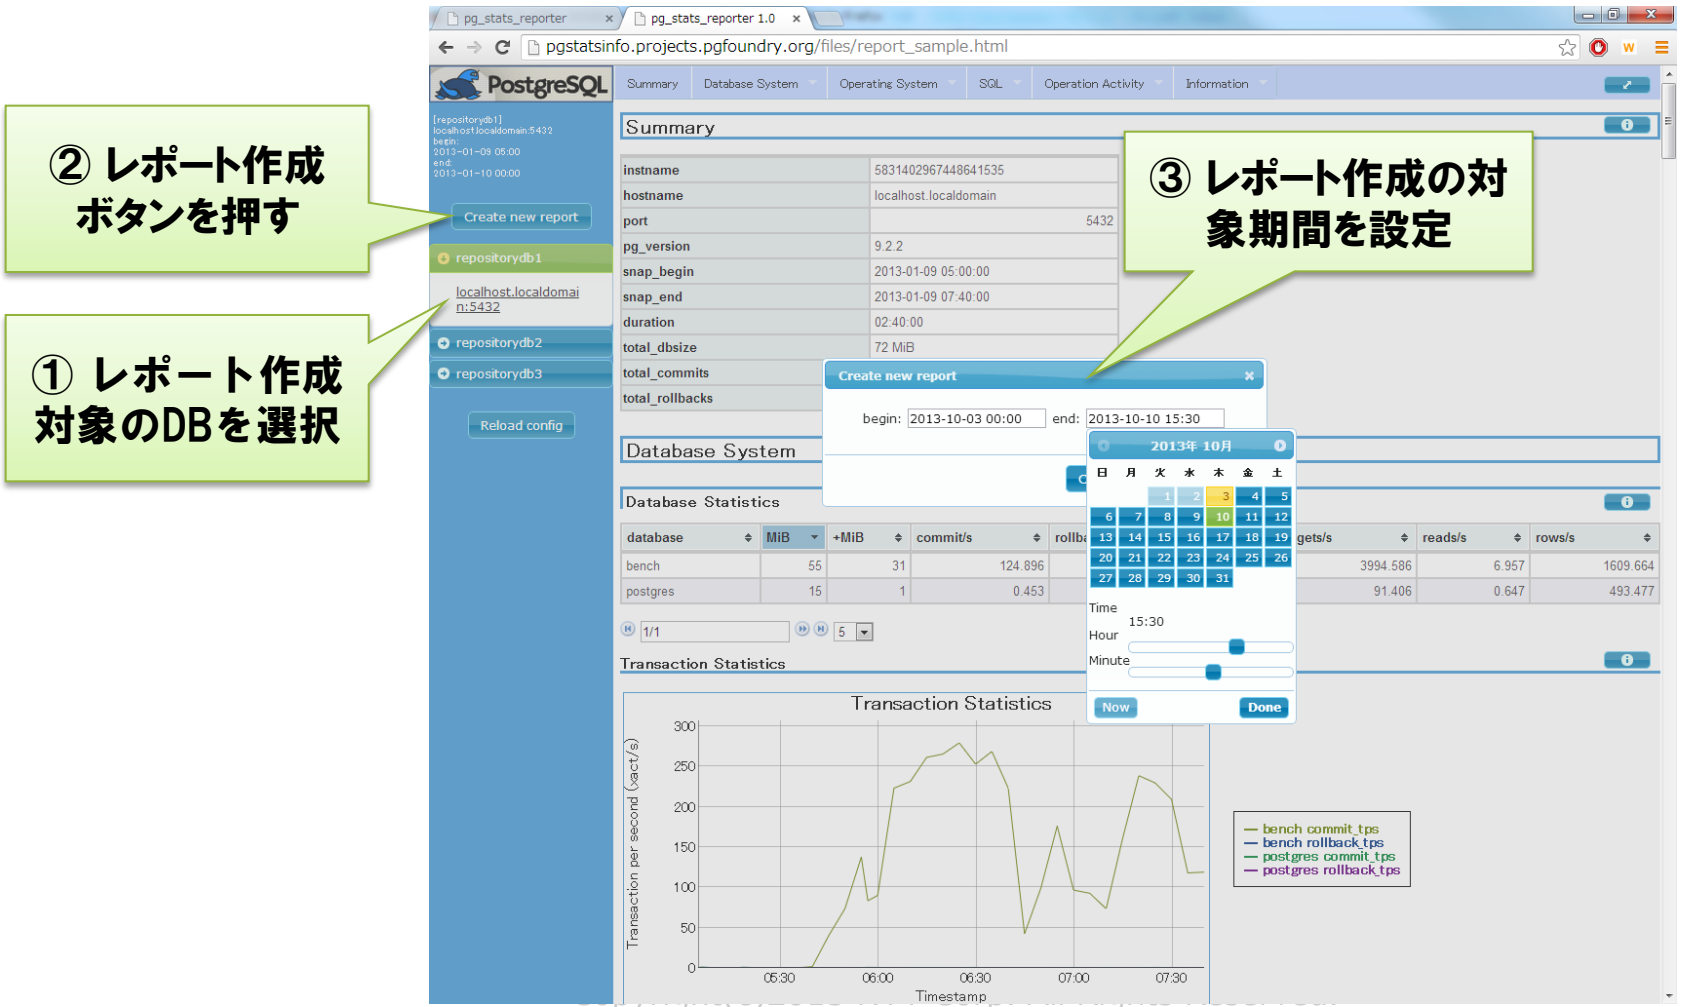

レポートの作成方法 2/2

- **コマンドラインからレポートを作成する方法**
  - PHP のスタンドアローンモードで動作します
  - 利用シーン
    - コマンドラインから、レポートを作成したい場合
    - cron 等で定期的にレポートを作成/蓄積したい場合
  - コマンドラインのみの利用の場合 Apache のインストール不要
    - システム要件等で、Apache をインストールできない場合に
  - レポジトリＤＢのデータは定期的に消したいが、レポート結果は長期間保持しておきたい場合

コマンド例：10月1日から10月12日までのレポートを repot_dir **に作成する**

```
$ pg_stats_reporter -B 2013-10-01 -E 2013-10-08 -O report_dir
[LOG] Report file created: sample_localhost_5432_1_20131008-1419_20131008-1945.html
```

レポートの作成方法 2/2

- **レポートインデックス機能**
  - コマンドラインモードで、レポート作成の際に指定したディレクトリ配下に、レポートのインデックスが自動作成されます
  - 過去のレポート一覧を見る際に便利です

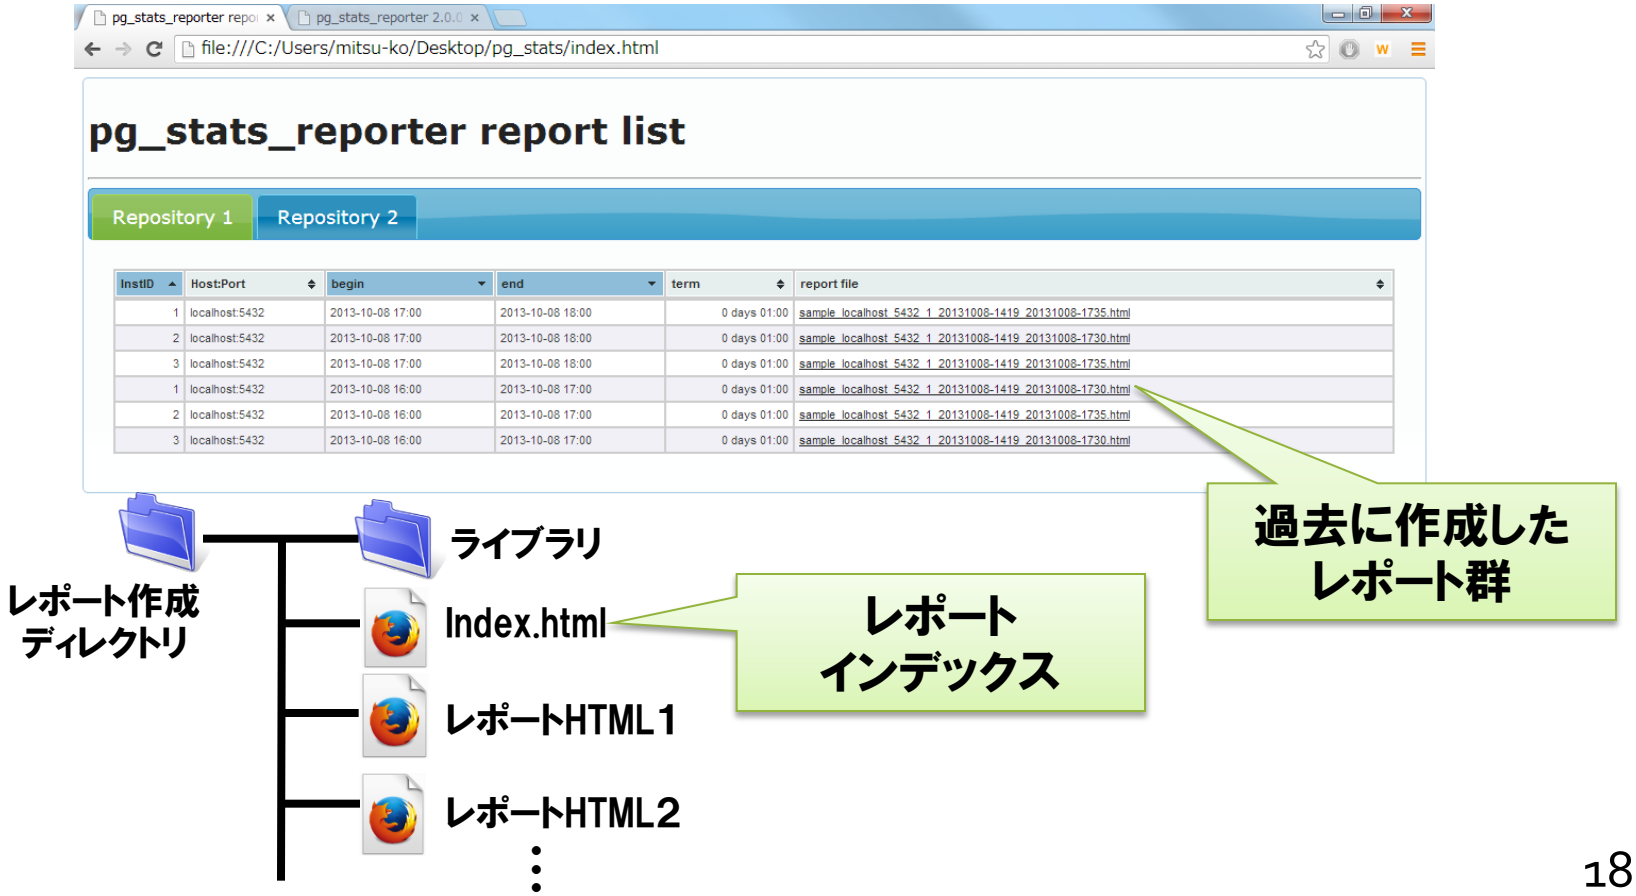

pg_stats_reporter のインストール方法

1. RPM のインストール

```
$ su
# rpm -ivh  httpd-2.2.15-15.el6_2.1.x86_64.rpm ¥¥
            php-5.3.3-3.el6_2.8.x86_64.rpm ¥¥
            php-common-5.3.3-3.el6_2.8.x86_64.rpm ¥¥
            php-pgsql-5.3.3-3.el6_2.8.x86_64.rpm ¥¥
            php-intl-5.3.3-3.el6_2.8.x86_64.rpm ¥¥
            pg_stats_reporter-1.0.0-1.el6.noarch.rpm
```

2. pg_stats_reporter.ini を書き換え（デフォルトで以下の内容になっています）

```
# vim /etc/pg_stats_reporter.ini
----- リポジトリDBの接続設定を記述 -----
host = localhost
port = 5432
dbname = postgres
username = postgres
password =
```

3. Apache を起動

```
# service httpd start
```

4. Web ブラウザから、以下の URL にアクセス

```
http://localhost/pg_stats_reporter/pg_stats_reporter.php
```

インストール手順は **Web** マニュアルにも記載されています☺
http://pgstatsinfo.projects.pgfoundry.org/pg_stats_reporter-ja.html#install

pg_stats_reporter の TIPS

- **Andoroid と iPad でも、レポートの閲覧ができます**
- **jQuery UI ベースで IF をデザインしているため、IF の配色変更が容易にできます**
  - 画面左上のロゴ画像も、ファイル置換で変更可能です
- **セキュリティ対策**
  - Apache ベースなので、.httpaccess が使えます
  - その他 Apache のセキュリティ対策がそのまま応用できます
- **表示するレポート項目の絞り込みができます**
  - /etc/pg_stats_reporter.ini に設定を行うことで、運用に必要なレポート項目のみを表示できます

DBT-2 とは？

- **Open Source Development Labs(OSDL)が開発したTPC-Cの実装**
  - 部品の卸売り業者のデータベース操作のシミュレート
  - 製品やサービスの管理、販売、配送を行う業務モデル
    - http://www.tpc.org/tpcc/
  - 一定時間内に応答が返ったものをスコアとしてカウントする
  - ＩＯネックのベンチマーク

- **主なパラメータ**
  - warehouse
    - 倉庫サイズ
      - １パラメータ毎に10万レコードが追加される
      - 主にデータベースサイズの調整に用いる
  - TPW
    - Transaction per warehouse
      - 倉庫サイズに応じたクライアント数が準備される。デフォルト値10
      - TPWをデフォルト値より大きくし、かつ warehouse がメモリサイズ以下の場合はCPU ネックのベンチマークになる

DBT-2 のトランザクション傾向

- **主なボトルネック**
  - ランダムリード/ライト
    - 大半のSQLがインデックス スキャン
  - ランダムIO性能とキャッシュ性能が結果を大きく左右
  - 同時実行性能も重要
    - 同時に多くのクライアントを捌けると有利

- **その他特徴**
  - SQLのプランは比較的単純
  - ベンチマークの理論値が存在
    - 制限時間内にすべての応答を捌けたら理論値になる
  - 性能限界のDBサイズはサーバ搭載メモリの約2倍程度
  - WALの出力量はpgbenchより少なめ

検証に用いたマシンと設定

サーバ	HP DL360 G7
CPU	Xeon E5640 2.66GHz（1P/4C）
Memory	DDR3-10600R-9 18GB
RAID card	P410i / 256MB cache
Disk	4 x 146GB（1.5krpm） RAID 1 + 0

主な postgresql.conf 設定

max_connections = 300
shared_buffers = 2458MB
work_mem = 1MB
maintenance_work_mem = 64MB
fsync = on
wal_sync_method = fdatasync
full_page_writes = on
wal_buffers = -1
archive_mode = on

checkpoint_segments = 300
checkpoint_timeout = 15min
checkpoint_completion_target = 0.7
random_page_cost = 2.0
effective_cache_size = 9GB
default_statistics_target = 10
log_destination = 'syslog’
autovacuum = on

pg_stats_reporter で可視化した結果　1/5

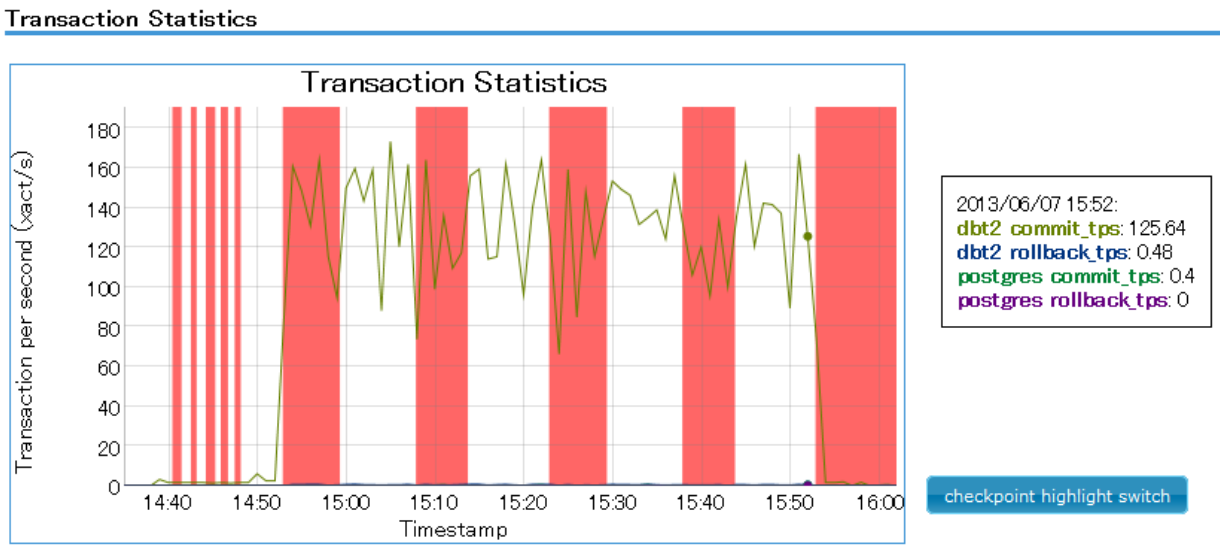

- **トランザクション量の変化**
  - 一定の間隔で接続数のムラが発生する or PostgreSQL が捌けるトランザクション数にばらつきがある
  - CHECKPOINT 実行時は性能が低下
  - CHECKPOINT は、時間契機で発生
    - checkpoint_timeout = 15min, checkpoint_segments = 300に設定

pg_stats_reporter で可視化した結果　2/5

Instance Activity

WAL Statistics

write_total	write_speed
46423.542	8.792

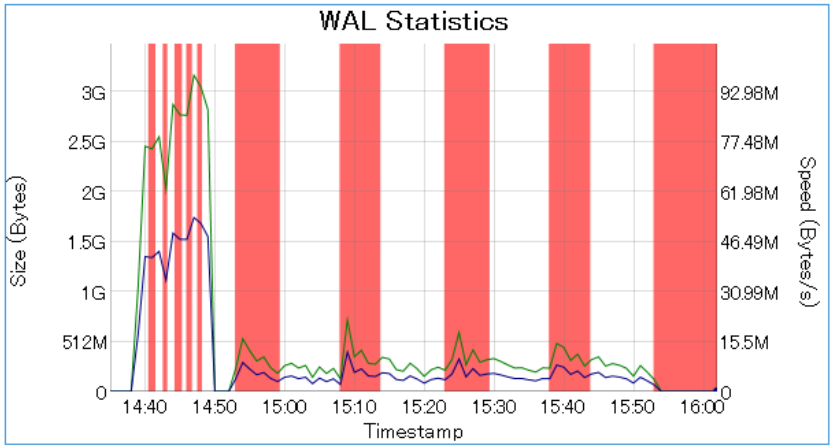

2013/06/07 16:02:
write_size (Bytes): 0
write_size_per_sec (Bytes/s): 0

checkpoint highlight switch

- **WALの出力量**
  - データロードから、ベンチマーク終了まで4.6GBのWALを出力
  - ロード時に最大のWAL出力量（54MB/s）が発生
  - ベンチマーク時の最大WAL出力量は 12MB/s
  - CHECKPOINT開始時は、full page writeの影響でWAL量が増える

pg_stats_reporter で可視化した結果　3/5

- **CPU使用率**
  - iowaitが支配的、idleも多い
  - CHECKPOINT最後の処理での Load Average が高い
    - リレーションファイルの fsync() 連打が原因

pg_stats_reporter で可視化した結果　4/5

SQL

Notable Tables

Heavily Updated Tables

database	schema	table	INSERT	UPDATE	DELETE	total	HOT (%)
dbt2	public	order_line	2224269	1804324	0	4028593	88.400
dbt2	public	stock	0	2224269	0	2224269	99.900
dbt2	public	orders	212147	189860	0	402007	99.900
dbt2	public	new_order	212147	0	189674	401821	0.000
dbt2	public	customer	0	391546	0	391546	99.900
dbt2	public	district	0	218071	0	218071	98.400
dbt2	public	history	201685	0	0	201685	0.000
dbt2	public	warehouse	0	201685	0	201685	99.400
dbt2	public	item	0	0	0	0	0.000

1/1　10

Heavily Accessed Tables

database	schema	table	seq_scan	seq_tup_read	tup_per_seq	hit (%)
dbt2	public	order_line	1	99315562	99315562.000	85.600
dbt2	public	orders	1	10417143	10417143.000	86.000
dbt2	public	history	1	10401739	10401739.000	65.400
dbt2	public	customer	1	10375737	10375737.000	63.400
dbt2	public	new_order	1	3191401	3191401.000	97.700
dbt2	public	item	1	100000	100000.000	99.900
dbt2	public	district	1	3400	3400.000	100.000

1/1　10

- **テーブルの更新状況**
  - 全体的にHOTが上手く動作している
  - order_line テーブルと stock テーブルにアクセスが多い
  - キャッシュはヒット率が高いが・・・（怪しい）

pg_stats_reporter で可視化した結果　5/5

Long Transactions

pid	client address	when to start	duration (sec)	query
15200	172.20.144.58	2013-06-07 14:38:38	621.675	VACUUM FREEZE VERBOSE ANALYZE;
4562	172.20.144.58	2013-06-07 15:57:43	106.851	SELECT now(),* FROM pgstattuple('customer');
32342		2013-06-07 15:38:26	93.753	autovacuum: ANALYZE public.new_order
4643	172.20.144.58	2013-06-07 16:00:34	85.920	SELECT now(),* FROM pgstattuple('stock');
4619	172.20.144.58	2013-06-07 15:59:36	54.508	SELECT now(),* FROM pgstattuple('order_line');
19966	172.20.144.58	2013-06-07 15:03:34	10.968	SELECT count(distinct s_i_id) FROM order_line, stock, district WHERE d_id = 4 AND d_w_id = 28 AND d_id = ol_d_id AND d_w_id = ol_w_id AND ol_i_id = s_i_id AND ol_w_id = s_w_id AND s_quantity < 10 AND ol_o_id BETWEEN 2987 AND 3006
19879	172.20.144.58	2013-06-07 15:01:50	10.091	COMMIT
20256	172.20.144.58	2013-06-07 15:09:30	10.024	SELECT count(distinct s_i_id) FROM order_line, stock, district WHERE d_id = 1 AND d_w_id = 225 AND d_id = ol_d_id AND d_w_id = ol_w_id AND ol_i_id = s_i_id AND ol_w_id = s_w_id AND s_quantity < 16 AND ol_o_id BETWEEN 2992 AND 3011
19877	172.20.144.58	2013-06-07 15:05:41	9.457	COMMIT
20251	172.20.144.58	2013-06-07 15:10:01	9.176	SELECT count(distinct s_i_id) FROM order_line, stock, district WHERE d_id = 9 AND d_w_id = 299 AND d_id = ol_d_id AND d_w_id = ol_w_id AND ol_i_id = s_i_id AND ol_w_id = s_w_id AND s_quantity < 11 AND ol_o_id BETWEEN 2995 AND 3014
19832	172.20.144.58	2013-06-07 15:16:01	9.017	COMMIT
20208	172.20.144.58	2013-06-07 15:07:07	8.266	SELECT count(distinct s_i_id) FROM order_line, stock, district WHERE d_id = 9 AND d_w_id = 205 AND d_id = ol_d_id AND d_w_id = ol_w_id AND ol_i_id = s_i_id AND ol_w_id = s_w_id AND s_quantity < 13 AND ol_o_id BETWEEN 2990 AND 3009
20209	172.20.144.58	2013-06-07 15:45:47	8.234	SELECT o_c_id FROM orders WHERE o_id = 2149 AND o_w_id = 6 AND o_d_id = 10
19830	172.20.144.58	2013-06-07 14:58:57	8.166	COMMIT
20170	172.20.144.58	2013-06-07 14:57:22	8.106	COMMIT
20078	172.20.144.58	2013-06-07 15:19:42	7.839	COMMIT
19921	172.20.144.58	2013-06-07 15:40:32	7.615	COMMIT
19919	172.20.144.58	2013-06-07 14:55:17	7.588	COMMIT

- **クエリ状況**
  - 複雑な条件句を持つSELECTが遅い
  - COMMITに時間がかかるケースも
    - COMMIT時のWAL書き込みに時間がかかっている？
    - CHECKPOINT最後のfsync()でDisk IOが詰まっているのが原因？

性能向上のための TIPS (おまけ)

- **アーカイブの copy コマンドに direct_cp を使う**
  - アーカイブのコピーの際に、不要なファイルキャッシュが大量に生成されるため、性能に大きく影響します
  - direct_cp を用いることで、ファイルキャッシュを汚さずにアーカイブのコピーが行えるため、性能が向上します
  - BSD ライセンスの OSS です
    - http://directcp.projects.pgfoundry.org/index.html
- **SSDを使う**
  - DB のボトルネックは主にランダムIO のため、SSD を使うことで性能が飛躍的に向上します。ランダムIO の多いテーブルのみをSSD 上のテーブルスペースに配置するのもいいでしょう
- **大きなRAIDキャッシュを持つRAIDカードを使う**
  - CHECKPOINT 時の リレーションファイルの fsync() が大きなボトルネックとなりがちです。それらを回避するためにRAID キャッシュは最大の物を用意することをお勧めします

まとめ

- **pg_statsinfo**
  - PostgreSQL の統計情報を取得/蓄積するツール
    - BSD ライセンス
    - http://pgstatsinfo.projects.pgfoundry.org/pg_statsinfo-ja.html
  - DB 運用に必要な統計情報は、ほぼ取得しています
    - 新たなレポートは SQL で作成できます

- **pg_stats_reporter**
  - pg_statsinfo で取得/蓄積した統計情報の可視化ツール
    - BSD ライセンス
    - http://pgstatsinfo.projects.pgfoundry.org/pg_stats_reporter-ja.html
  - jQuery ベースの先進的 IF
    - レポートインデックス機能も便利です
  - PHP + javascript で作成しているので改造も容易
    - patch 投稿も容易です！