PostgreSQL 13のご紹介

2020-08-20

SRA OSS, Inc. 日本支社 高塚 遥

講演の概要:

- 2020年秋にリリースが見込まれる、

  PostgreSQL 13

  の新機能や性能向上を解説します。
- 非互換の点についても説明します。

講演者:

- 高塚 遥
- 普段は ヘルプデスク、コンサルティングなど、PostgreSQLの支援業務を各種手掛ける
- (特非)日本PostgreSQLユーザ会 理事

PostgreSQL 12 まで

- PostgreSQLとは
  - 多機能 RDBMS
  - 20年以上の歴史
    - POSTGRES から 30年以上
  - 1社主導でない OSS

- これまでの主要機能追加
  - 8.0　PITR / Windows
  - 9.0　レプリケーション
  - 9.1　Serializable SI
  - 9.2　多CPUコア適応
  - 9.4　バイナリ JSON型
  - 9.6　パラレルクエリ
  - 10　論理レプリケーション
  - 11　JITコンパイル
  - 12　テーブルAM

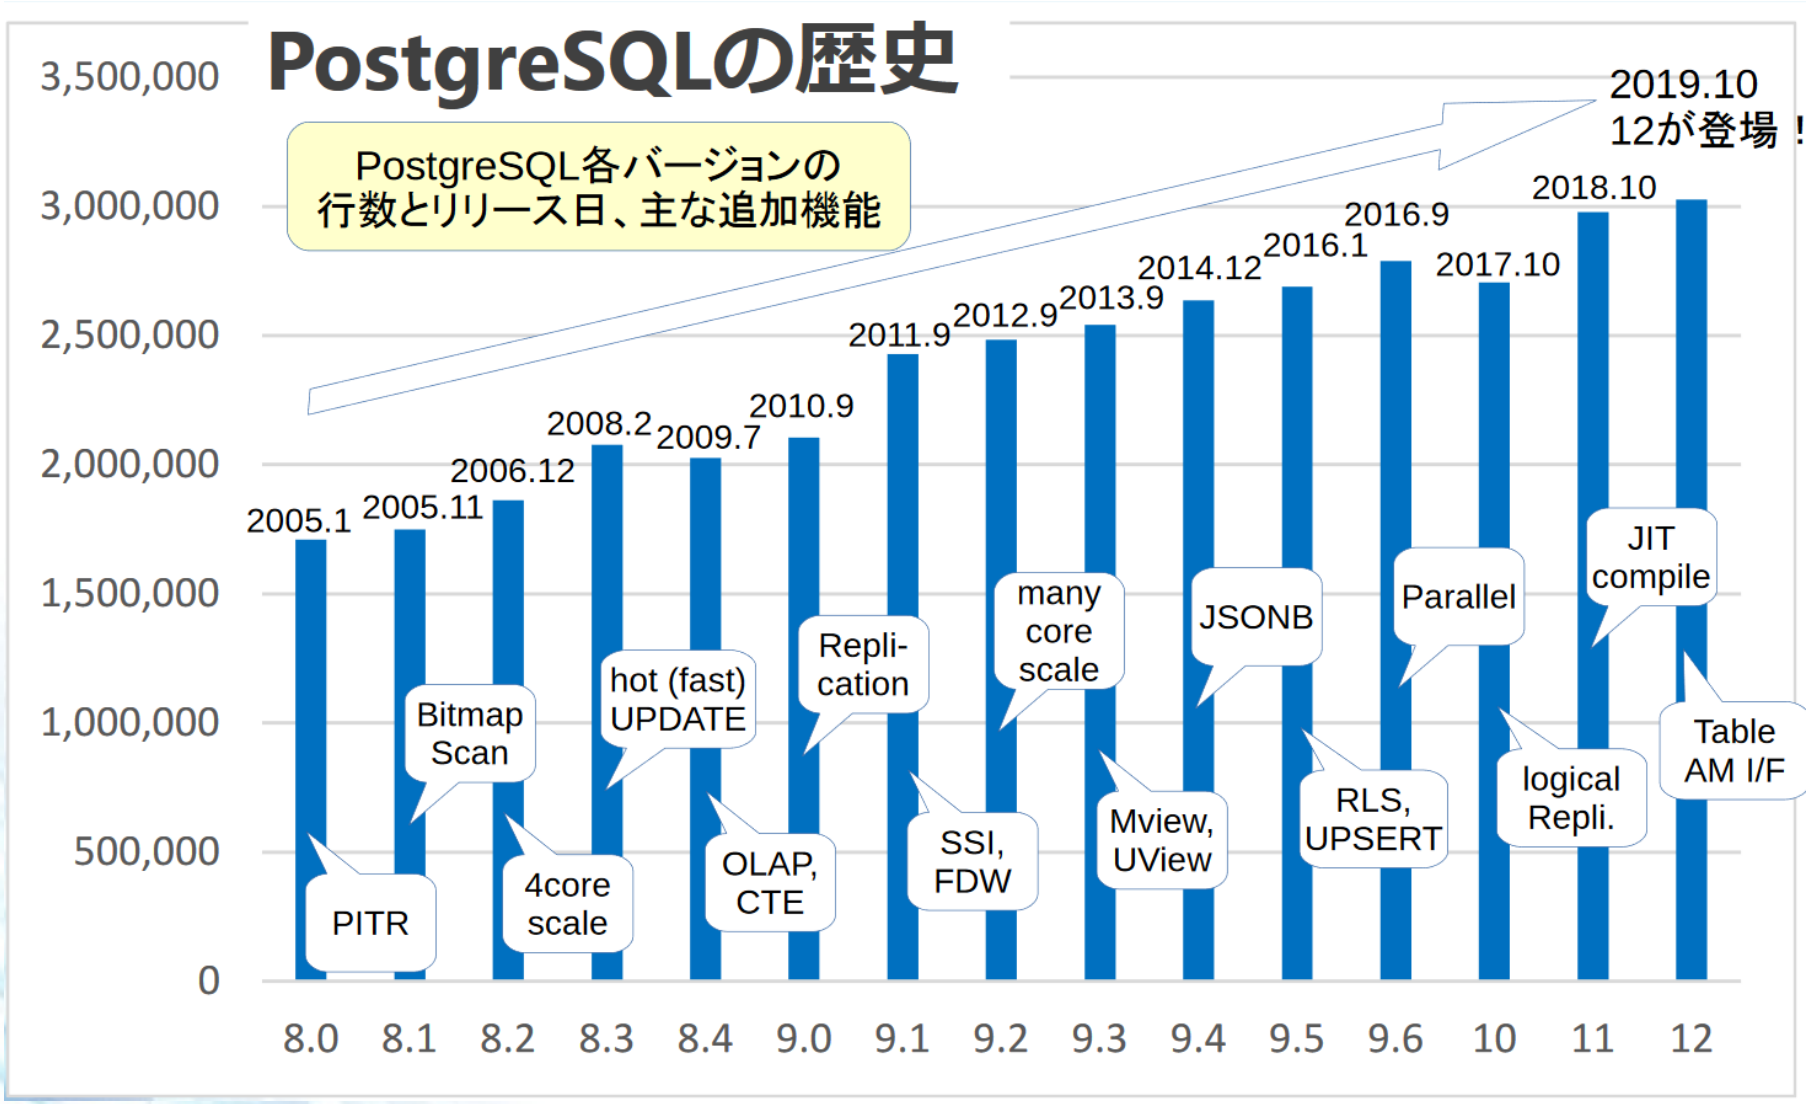

PostgreSQL 13の概要

性能向上	Btreeインデックス性能向上、 インクリメンタルソート、 ストレージハッシュ集約
SQL機能	FETCH FIRST WITH TIE、 JSON Path の datetime、 パーティションテーブル関連の各種拡張
運用管理機能	進捗レポート対応拡張、並列VACUUM、 pg_rewind改良、pgbench拡張、pg_verifybackup
含まれなかった機能	セッション変数、グローバル一時テーブル、 オンラインチェックサム検証、マテビュー差分更新、 テンポラルテーブル、 組込コネクションプーラ、 新たなテーブルアクセスメソッド

SQL機能の追加(1)

- FETCH FIRST ... WITH TIES

```
db1=# SELECT * FROM t_rank ORDER BY score DESC
        OFFSET 0 ROWS FETCH FIRST 3 ROWS WITH TIES;
 id | score
----+-------
  1 |   100
  2 |    90
  3 |    90
  4 |    90
(4 rows)
```

3件指定だが
同順位(タイ)なら、
全てを出力する。

SQL機能の追加(2)

- JSON Path の datetime() メソッド追加
  - json_path_query_tz() 等の追加

日付や時刻、日付時刻の比較ができる。

```
db1=# SELECT jsonb_path_query(
        '["12:30:54", "9:10:00", "13:20:10"]',
        '$[*].datetime() ? (@ > "12:00:00".datetime())');
 jsonb_path_query
------------------
 "12:30:54"
 "13:20:10"
```

to_timestamp() と同様の書式指定。

```
db1=# SELECT jsonb_path_query(
        '{"timestamp": "2020-06-06 05:05:05 PM +09:00"}'::jsonb,
        '$.timestamp.datetime("YYYY-MM-DD HH:MI:SS AM TZH:TZM")');
       jsonb_path_query
-----------------------------
 "2020-06-06T17:05:05+09:00"
```

Btreeインデックスの性能向上(1)

- 重複排除 (deduplication)
  - 格納データ構造の変更

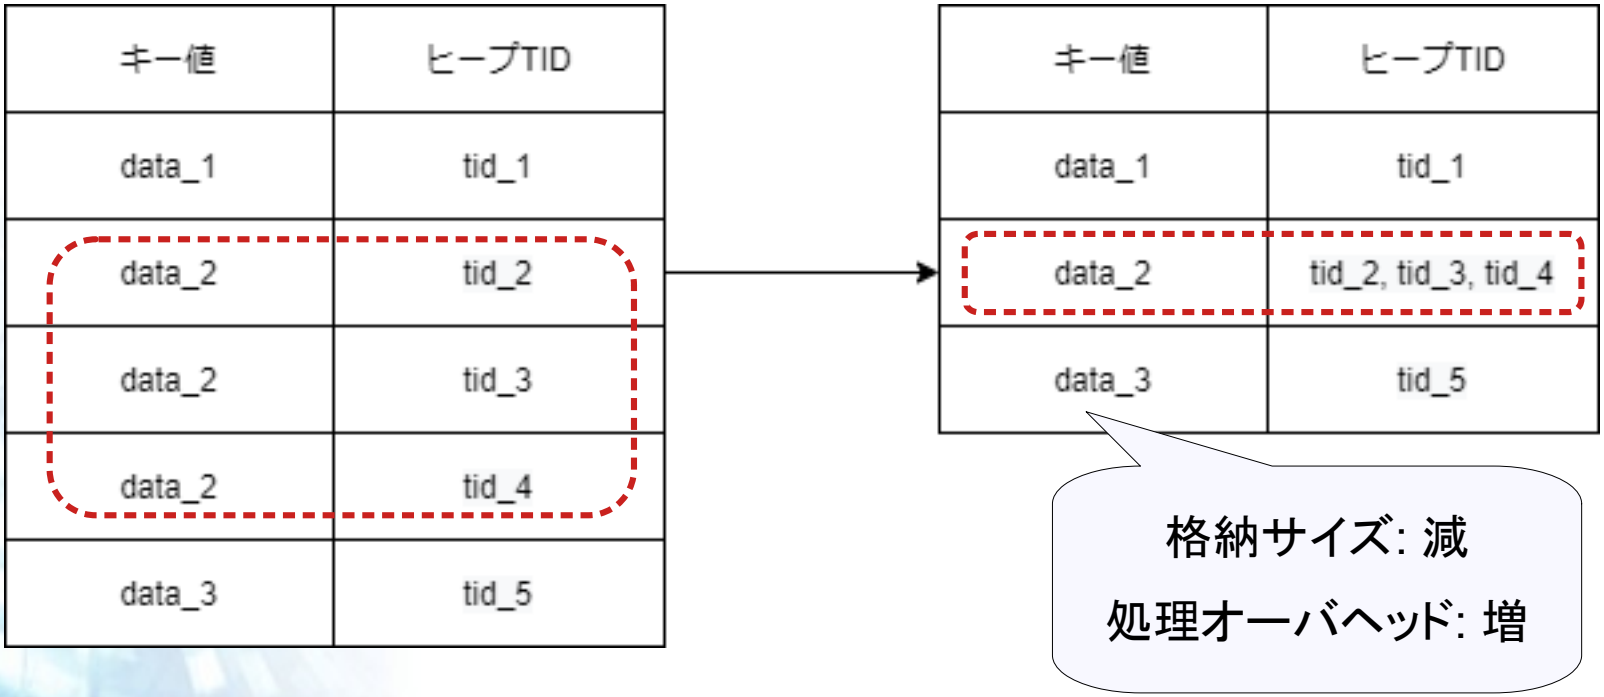

Btreeインデックスの性能向上(2)

```
db1=# CREATE TABLE btree_test (f1 text COLLATE "C");
db1=# CREATE INDEX ON btree_test (f1) WITH (deduplicate_items=on);
db1=# INSERT INTO btree_text
        SELECT 'foo' FROM generate_series(1,100000);
```

on が
デフォルト

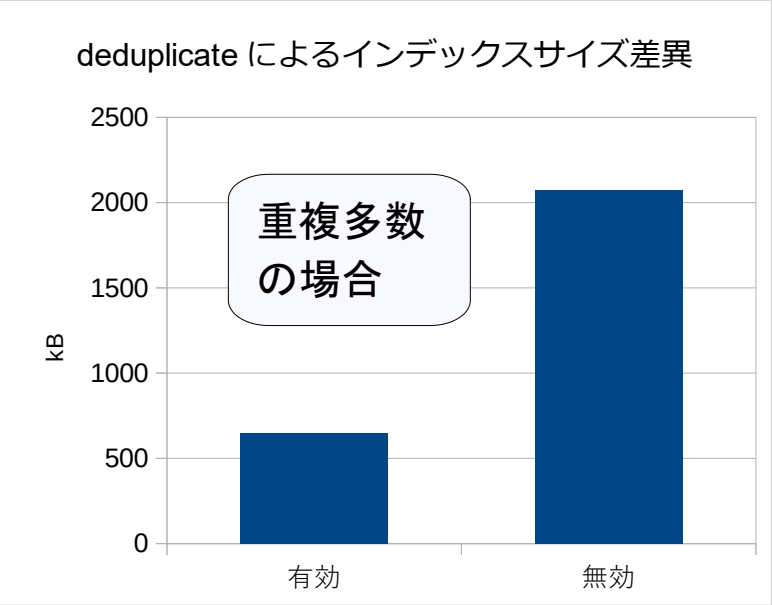

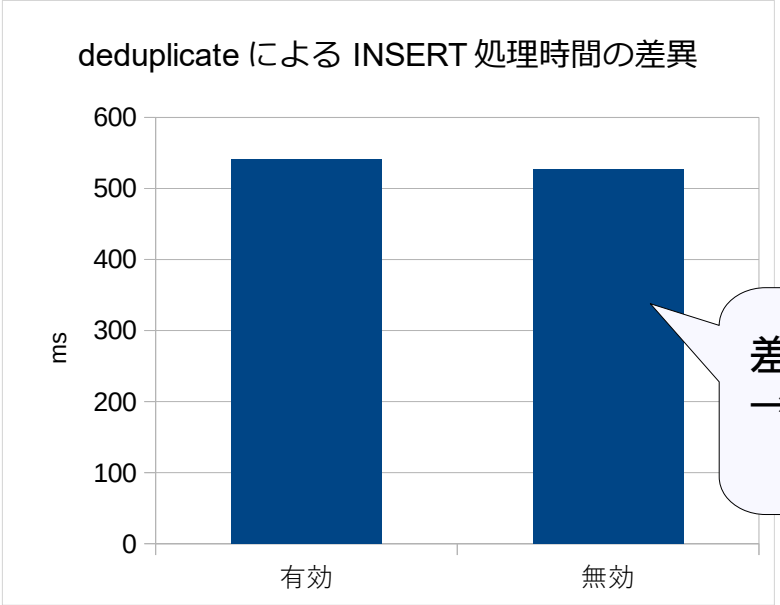

Btreeインデックスの性能向上(3)

- 遅延処理方式
  - ページ分割のときに重複排除を行う
- 重複排除が効かない場合
  - データ型:
    - 非決定的な COLLATE を使った文字列型
    - real、double precision
    - numeric
    - コンテナ型(配列、複合型、範囲型、JSONB)
  - INCLUDE を伴うインデックス

新たな実行プラン要素(1)

- インクリメンタルソート

```
db1=# SELECT * FROM t_log;
         dt          | severity |              message
---------------------+----------+-----------------------------------
 2020-05-25 14:09:51 | ERROR    | syntax error at or near "XX"
 2020-05-25 14:09:52 | FATAL    | role "pgsql" does not exist
 2020-05-25 14:09:52 | LOG      | received SIGHUP,
 2020-05-25 14:09:53 | ERROR    | cannot convert va
  : （後略）

db1=# CREATE INDEX ON t_log (dt);

db1=# SELECT * FROM t_log WHERE dt > ' 2020-05-25 14:10'
        ORDER BY dt, severity, message LIMIT 1000;
```

ソート項目のうち、
dt列はインデックスで
既にソート済み

新たな実行プラン要素(2)

```
Limit  (cost=0.38..74.06 rows=1000 width=46)
        (actual time=0.031..0.599 rows=1000 loops=1)
   ->  Incremental Sort  (cost=0.38..735.25 rows=9974 width=46)
                         (actual time=0.030..0.534 rows=1000 loops=1)
         Sort Key: dt, severity, message
         Presorted Key: dt
         Full-sort Groups: 32  Sort Method: quicksort  Average
           Memory: 27kB  Peak Memory: 27kB
         ->  Index Scan using t_log_dt_idx on t_log
               (cost=0.29..379.83 rows=9974 width=46)
               (actual time=0.011..0.333 rows=1001 loops=1)
               Index Cond:
                 (dt > '2020-05-25 14:10:00'::timestamp without time zone)
 Planning Time: 0.107 ms
 Execution Time: 0.649 ms
```

全列ソートのとき 127 kB

全列ソートのとき 3.3 ms

- 高速化、使用メモリの節約
- enable_incremental_sort（デフォルト on）

新たな実行プラン要素(3)

- ストレージ上のハッシュ集約
  - 集約問い合わせのプラン要素:

新たに、ハッシュをストレージ書き出しできるようになった

GroupAggregate	HashAggregate
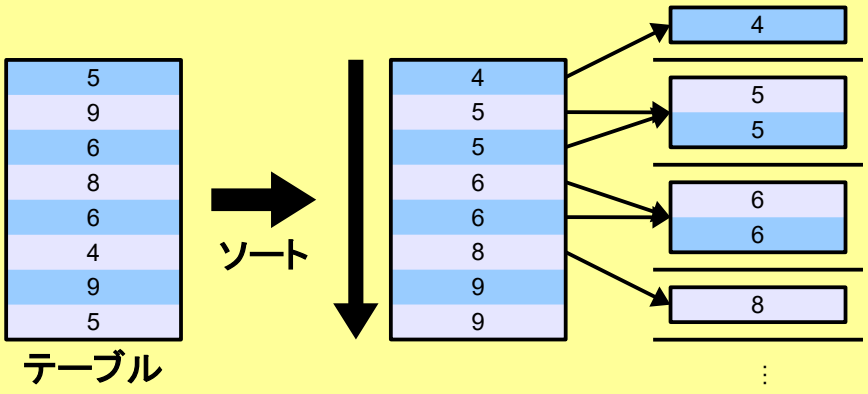	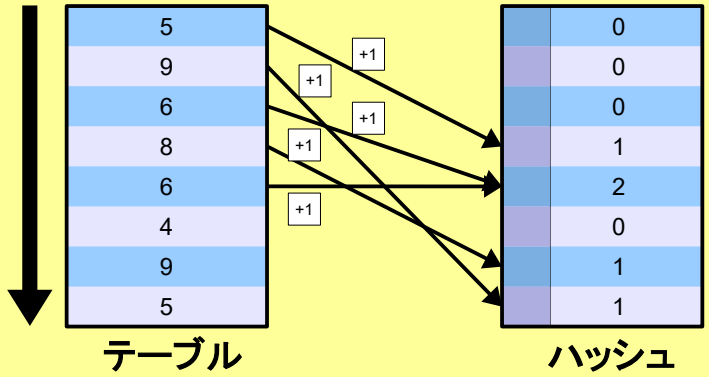
・入力にソート済みデータが必要	・ハッシュが work_memに収まる範囲で適用可能

新たな実行プラン要素(4)

```
db1=# EXPLAIN (ANALYZE)  SELECT uid, count(1) FROM t_login GROUP BY uid;
                                QUERY PLAN
-------------------------------------------------------------------------------------------
 HashAggregate  (cost=36995.00..41912.19 rows=101094 width=12)
                (actual time=198.841..295.113 rows=100000 loops=1)
   Group Key: uid
   Planned Partitions: 4
   Peak Memory Usage: 4145 kB
   Disk Usage: 30376 kB
   HashAgg Batches: 4
   ->  Seq Scan on t_login (cost=0.00..16370.00 rows=1000000 width=4)
                           (actual time=0.013..47.859 rows=1000000 loops=1)
 Planning Time: 0.092 ms
 Execution Time: 301.152 ms
```

work_mem
'4MB' の場合

- GroupAggregate より速く、メモリ HashAggregate より遅い
- ~~hashagg_avoid_disk_plan（デフォルト off）~~
  - ディスク上のハッシュ集約はデフォルトで有効

beta3 で
設定無しに

パーティションテーブルの改良 (1)

- ロジカルレプリケーション対応
  - 親パーティションテーブルで一括指定

親を指定すれば、
子パーティション群が
登録される。

```
db1=# CREATE PUBLICATION pub1 FOR TABLE pt_member;

db1=# SELECT * FROM pg_publication_tables;
 pubname | schemaname |       tablename
---------+------------+------------------------
 pub1    | public     | p_member_1
 pub1    | public     | p_member_10001
 pub1    | public     | p_member_20001
(3 rows)
```

オプション指定で、
単一テーブル同様の
パブリケーションも可能

```
db1=# CREATE PUBLICATION pub2 FOR TABLE pt_member
       WITH (publish_via_partition_root = true);
```

《→ pg_publication_tables には 1エントリだけ追加》

パーティションテーブルの改良 (2)

- パーティション毎の結合の改良

```
SELECT lo.mes, ld.detail FROM t_log_parted lo
  INNER JOIN t_log_detail_parted ld ON (lo.id = ld.id);
```

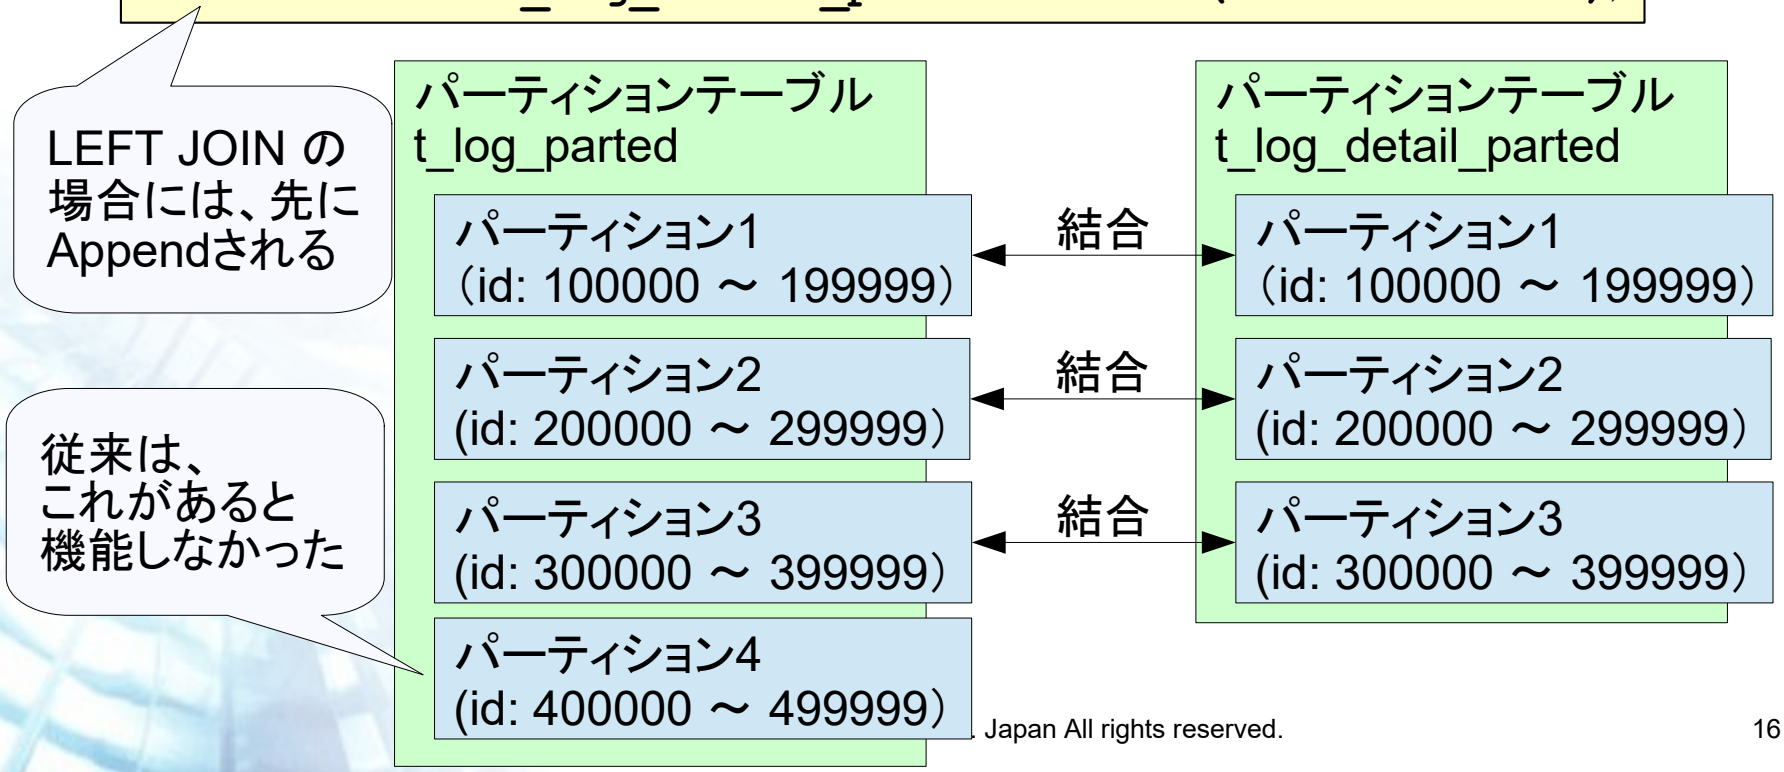

パーティションテーブルの改良 (3)

- 行単位BEFOREトリガ対応

```
db1=# CREATE FUNCTION tf_1() RETURNS TRIGGER LANGUAGE plpgsql AS
 $$ BEGIN NEW.mes := substring(NEW.mes from 1 for 1000);
    RETURN NEW; END; $$;

db1=# CREATE TRIGGER trg1 BEFORE INSERT OR UPDATE
       ON pt_log_parted FOR ROW EXECUTE FUNCTION tf_1();
```

  - パーティションテーブル(親テーブル)にトリガ定義が可能に
  - パーティション間の行移動が生じる場合は、トリガ実行時にエラーになる

本例なら id を変更する場合

並列VACUUM

- テーブルの各インデックスを並列で処理
  - デフォルトで有効
    - インデックスの数だけ並列処理を試みる
  - 関連設定
    - max_parallel_maintenance_workers = 2
      （max_worker_processes、max_parallel_workers)
    - min_parallel_index_scan_size = 512kB

無効化するために
オプション指定する

```
VACUUM (PARALLEL《並列ワーカ数》[,...]) [《テーブル指定》];

vacuumdb --parallel=《並列度》 ...

vacuumdb --jobs=《ジョブ数》...
```

ジョブ数指定は本機能とは別、
複数テーブル間の並列処理

進捗報告ビューの拡張(1)

対象コマンド	進捗確認用ビュー
（FULLでない）VACUUM	pg_stat_progress_vacuum
CLUSTER、VACUUM FULL	pg_stat_progress_cluster
CREATE INDEX、REINDEX	pg_stat_progress_create_index
pg_basebackup	pg_stat_progress_basebackup
ANALYZE	pg_stat_progress_analyze

今回追加の2項目

- 処理の phase ごとに各種指標値を報告
  - phase の理解が必要
- 実行完了すると進捗報告のエントリが無くなる
- ANALYZE等で複数テーブルが対象のコマンドだと、対象全体の何割まで完了したかの判断が難しい。

進捗報告ビューの拡張(2)

- pg_basebackup 進捗の phase:
  - ↓ initializing
  - ↓ waiting for checkpoint to finish
  - ↓ estimating backup size
  - ↓ streaming database files
  - ↓ waiting for wal archiving to finish
  - ↓ transferring wal files

pg_basebackup コマンドの -Pv オプションでも各phase を確認できる。

進捗を参照するSQL例

```
SELECT phase, backup_streamed / backup_total::float * 100
       AS "progress_ratio(%)" FROM pg_stat_progress_basebackup;

[ RECORD 1 ]------+-------------------------
phase             | streaming database files
progress_ratio(%) | 32.19553708609419
```

接続認証の拡張

- クライアントでチャネルバインディング必須指定
  - channel_binding=require　（prefer, disable）
  - バージョン11.x 以降サーバの scram-sha-256 認証で
- TLSバージョン指定
  - ssl_min_protocol_version
  - ssl_max_protocol_version
- クライアント証明書のパスワードの指定
  - sslpassword

チャネルバインディング：
認証用のダイジェストやり取りに
セッション固有の情報を含めて、
Man-In-the-middle攻撃を防ぐ

pgbenchの拡張

- パーティションテーブルの生成

```
$ pgbench -i -s 50 --partitions 5 db1
```

pgbench_account が100万行ずつ、5パーティションのパーティションテーブルに

- サーバ側データ生成
  - これまでは pgbench側でデータ生成
  - -I オプションで g の代わりに G を指定

```
$ pgbench -i -I dtGvp -s 50 -h remote_host db1
```

DBサーバが別ホストの場合に、初期化を高速化

- データ生成時の画面出力が改善
  - フェーズごとに所要時間報告

pg_rewindの改良

- 自動クラッシュリカバリ
  - 「対象データディレクトリはPostgreSQLを正常に停止したものでなければならない」 の考慮が不要に
  - 「最初にクラッシュリカバリ起動して、停止」を自動化
- リカバリ設定を自動作成 (--write-recovery-conf)
  - ソースサーバに追随するスタンバイの設定を生成
- WALアーカイブ適用 (--restore-target-wal)
  - restore_command 設定を使う
    - ターゲットのWALアーカイブを書き戻すコマンドを指定

pg_verifybackup

- 取得済ベースバックアップの健全性を検査するコマンド
- pg_basebackup で backup_manifest が生成される

```
{ "PostgreSQL-Backup-Manifest-Version": 1,
"Files": [
{ "Path": "backup_label", "Size": 224, "Last-Modified": "2020-08-06 04:47:55 GMT",
 "Checksum-Algorithm": "CRC32C", "Checksum": "fd0ec8cb" },
{ "Path": "global/1262", "Size": 8192, "Last-Modified": "2020-08-01 23:36:31 GMT",
 "Checksum-Algorithm": "CRC32C", "Checksum": "8b5cc6da" },
{ "Path": "global/2964", "Size": 0, "Last-Modified": "2020-08-01 23:23:16 GMT",
 "Checksum-Algorithm": "CRC32C", "Checksum": "00000000" },
  : 後略
```

- マニュフェストに基づき、各ファイルのチェックサムを検証
- プレーン形式のみ対応
  - 展開後に検査するなら tar形式でも可

その他の運用コマンド拡張

- reindexdb が --jobs 対応
- pg_dump が 外部テーブル内容をダンプ可能に
  - --include-foreign-data
- trusted な EXTENSION
  - データベースに CREATE権限があれば
    一般ユーザでも導入できる、という属性が追加

非互換の仕様変更(1)

- SIMILAR TO ... ESCAPE NULL
  - SQL標準通り、式が必ず NULL を返すように
    - 従来は ESCAPE指定を省略したのと同じ扱い

デフォルトの
エスケープ文字は
バックスラッシュ

- effective_io_concurrency
  - 設定値の意味が変更
    - ストレージI/O並列数ではなく、
      プリフェッチするページ数を直接指定

$$NEW = round\left(\sum_{i=1}^{OLD} \frac{OLD}{i}\right)$$

```
db1=# SELECT round(sum(OLD / i::float))
        FROM generate_series(1, OLD) s(i);
```

非互換の仕様変更(2)

- pg_stat_ssl、pg_stat_gssapi ビュー
  - 補助プロセスは出力されなくなる
- 待機イベントの名前変更
  - RecoveryWalAll → RecoveryWalStream
  - RecoveryWalStream → RecoveryRetrieveRetryInterval
- opaque疑似型の廃止
- 外部キー制約の 7.2以前の古い構文の廃止
- 演算子クラスの 7.4以前の古い構文を廃止

PostgreSQL 13 リリース予定

- 2020年 5月 21日 beta1 リリース
- 2020年 6月 25日 beta2 リリース
- 2020年 9月末くらい？　13.0 リリースの見込み
  - 2020年 3Q と計画されていたが、既に 8月
  - 8/13 beta3 リリース
  - 通常 rc 版のリリースがある

近年の実績:

version	release date
9.6.0	2016/9/29
10.0	2017/10/5
11.0	2018/10/18
12.0	2019/10/3

まとめ

- PostgreSQL は安定リリースを継続
- バージョン13 は変更が少なめのメジャーリリース
  - 非互換が少なく、アップグレードしやすい
  - 次バージョンに持ち越されていて様々な開発が継続