PGECons
PostgreSQL Enterprise Consortium

2022年度WG1活動成果報告
新機能検証編
PostgreSQLロジカルレプリケーション検証

PostgreSQL エンタープライズコンソーシアム
WG1 新機能検証チーム

Contents

1. ロジカルレプリケーション新機能検証
2. マルチマスタ検証

責任範囲

- 本資料は、PGEConsが独自に検証した結果であり、結果はPGEConsの責任の元、公開しています。

ロジカルレプリケーション新機能検証

検証概要

- 目的
  - PostgreSQL15で強化されたロジカルレプリケーション新機能の調査
  - 新機能のうち、仕様が大きく変更されロジカルレプリケーションの使用方法や利用シーンに影響する機能を確認
- 検証内容
  - PostgreSQL15で新規に追加されたロジカルレプリケーション機能のうち、ユーザへの影響が大きい変更である以下の機能の動作を確認
    - 列指定機能
    - 行フィルタ機能
  - PostgreSQL15で新規に追加されたロジカルレプリケーション時に使用する以下システムビューの動作を確認
    - pg_stat_subscription_stats

PostgreSQL15
ロジカルレプリケーション追加機能一覧

- PostgreSQL15でロジカルレプリケーションの追加機能は以下となる。

機能名	機能概要
列指定	ロジカルレプリケーションする列をパブリッシャーの特定列に制限できる
行フィルタ	WHERE句を使用してパブリッシャーのコンテンツをフィルタリングできるようにする
スキーマ内の全テーブル指定	スキーマ内のすべてのテーブルの公開を許可
LSNスキップ	ALTER SUBSCRIPTION ... SKIPでサブスクライバーでのトランザクションのスキップを許可する
二相コミット対応	準備済み (2 フェーズ) トランザクションのサポートを論理レプリケーションに追加
空のトランザクションのレプリケーションを防止	空のトランザクションの論理レプリケーションを防止
論理レプリケーションスロットのディレクトリの内容を監視するSQL関数	論理レプリケーションスロットのディレクトリの内容を監視するSQL関数を追加
	・pg_ls_logicalsnapdir()
	・pg_ls_logicalmapdir()
	・pg_ls_replslotdir()
エラー時のSUBSCRIPTION無効化	サブスクライバー側オプションでサブスクライバーエラー時にロジカルレプリケーションの変更適用を停止できる
サブスクライバー サーバー変数をパブリッシャーと一致するように調整 (datetime と float8 の値)	datetime と float8 の値が一貫して解釈されるように、サブスクライバー サーバー変数をパブリッシャーと一致するように調整
pg_stat_subscription_statsの追加	サブスクライバーのアクティビティをレポートするシステム ビューを追加
	・pg_stat_subscription_stats
pg_stat_reset_subscription_stats()	上述の統計カウンターをリセット
pg_publication_tables	システム ビューでの重複エントリの抑制

- 当該資料では、上記表中の青字で記載した「列指定」「行フィルタ」および「pg_stat_subscription_statsの追加」について説明する。

PostgreSQL15
ロジカルレプリケーションメイン機能

- PostgreSQL15ではロジカルレプリケーション機能が大幅に強化されている。
- その中でも、レプリケーションの最小単位がテーブル単位という既存の仕様から大きく変更が加わり、ユーザーニーズに合ったより細かな単位のレプリケーションを可能とした以下機能にフォーカスをあて検証を実施
  - 列指定
  - 行フィルタ
- 以下システム関数が追加されたことにより、ロジカルレプリケーション運用時の監視効率化を見込めるため、動作を検証
  - pg_stat_subscription_stats

検証環境

- 今回の検証では、Virtual Box上でLinuxマシン環境を構築し検証を実施した。
- 下記の条件で2台のVMを作成しロジカルレプリケーションを構築している。

  - VMスペック

CPU数	メモリ(GiB)	ストレージサイズ(GiB)
1	2	16GB

  - 各種バージョン情報

名称	バージョン
Rocky Linux	8.7 (Green Obsidian)
PostgreSQL	15.1

列指定 機能概要

- 列指定とは、レプリケーションをするテーブルのうち、特定の列だけをレプリケーションする機能。
- 以前はテーブル定義の全部の列のレプリケーションしかできなかったが、 当該機能の追加によりテーブル内の特定列のみを指定したレプリケーションが可能となった。

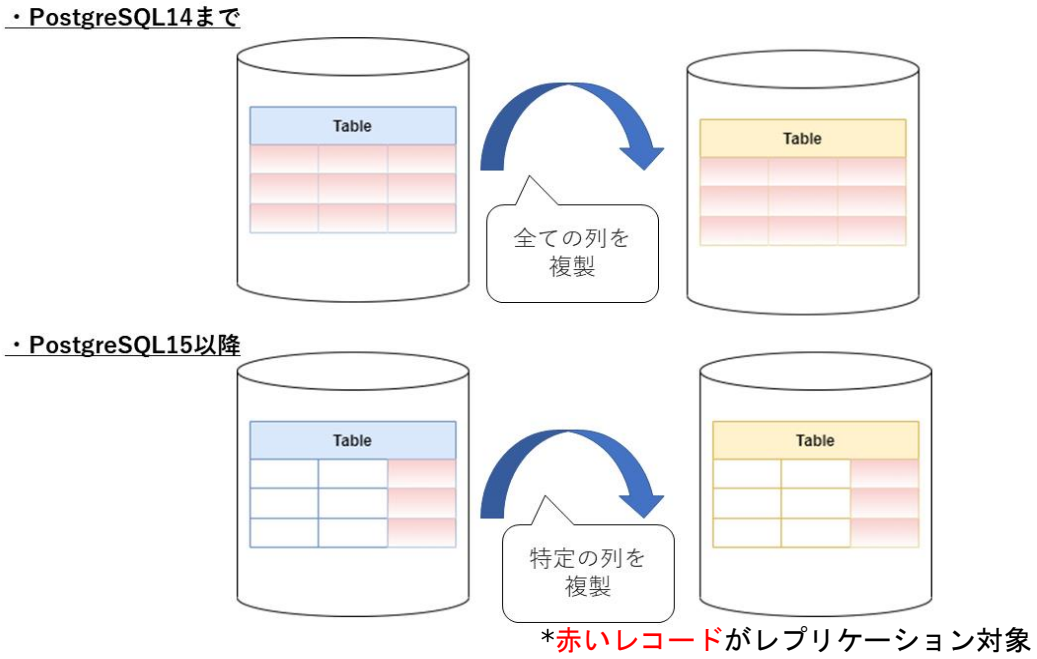

*赤いレコードがレプリケーション対象

列指定 機能概要

- 列指定のロジカルレプリケーションは、パブリケーションを定義するときに、レプリケーション対象列を指定することで機能する。

```
# CREATE PUBLICATION name
FOR TABLE table_name(column_name_1 , column_name_2 );
```

テーブル名以下に列名を記載することで、記載した列のみをレプリケーションする

指定する列には、「主キー」を含まないといけない。

列指定 検証結果

- 列指定はパブリッシャー側で対象列を定義する
- パブリッシャー側で指定する列には、主キー列を含める必要がある
- サブスクライバー側で主キーが設定されていない場合、UPDATEが動作しない
- パブリッシャー側とサブスクライバー側の列名は一致する必要がある。（型変換されるため、型は異なっていても動作する）

パブリッシャー側とサブスクライバー側それぞれで、指定列を主キーとした場合/していない場合の関係性は以下となる。

		サブスクライバー側	
		主キーを列指定する	主キーを列指定しない
パブリッシャー側	主キーを列指定する	INSERT　:できる UPDATE:できる	INSERT　:できる UPDATE:できない
	主キーを列指定しない	INSERT　:できない UPDATE:できない	INSERT　:できない UPDATE:できない

列指定 実行例

- 下記のようなテーブルを作成し、主キーとなる”id”列と”a”列を指定し、レプリケーションする。

- パブリッシャー側テーブル

id	a	b
1	test-a-1	test-b-1
2	test-a-2	test-b-2
3	test-a-3	test-b-3
4	test-a-4	test-b-4

- サブスクライバー側テーブル

id	a	b
1	test-a-1	
2	test-a-2	
3	test-a-3	
4	test-a-4	

id列・a列を指定してレプリケーション
（b列はレプリケーションしない）

列指定 実行例

- p_test_1にt1テーブルを作成し、パブリケーション設定を実行。

```
p_test_1=# CREATE TABLE t1(id int PRIMARY KEY, a text, b text);
 CREATE TABLE
p_test_1=# CREATE PUBLICATION p1 FOR TABLE t1(id ,a);
 CREATE PUBLICATION

p_test_1=# SELECT * FROM t1;
 id | a | b
 ----+----------+----------
1 | test-a-1 | test-b-1
2 | test-a-2 | test-b-2
3 | test-a-3 | test-b-3
4 | test-a-4 | test-b-4
(4 行)
```

列指定 実行例

- s_test_1にt1テーブルを作成し、サブスクリプション設定を実行。

```
s_test_1=# CREATE TABLE t1(id int PRIMARY KEY, a text, b text);
CREATE TABLE

s_test_1=# CREATE SUBSCRIPTION s1
           CONNECTION 'host=192.168.162.17 port=5432 user=logi_user dbname=p_test_1'
           PUBLICATION p1;
NOTICE: 発行サーバーでレプリケーションスロット"s1"を作成しました
CREATE SUBSCRIPTION
s_test_1=# SELECT * FROM t1 ORDER BY id;
id | a | b
----+----------+---
1 | test-a-1 |
2 | test-a-2 |
3 | test-a-3 |
4 | test-a-4 |
(4 行)
```

パブリッシャー側テーブルから、id列・a 列のみサブスクライバー側テーブルへレプリケーション

列指定
複数パブリッシャー：単一サブスクライバーについて

- 列指定ロジカルレプリケーションが可能になったことで、
  複数のパブリッシャー側の特定列を1つのサブスクライバー側にマージする
  といった使い方が想定される。
- 複数パブリッシャー：単一サブスクライバー のイメージ

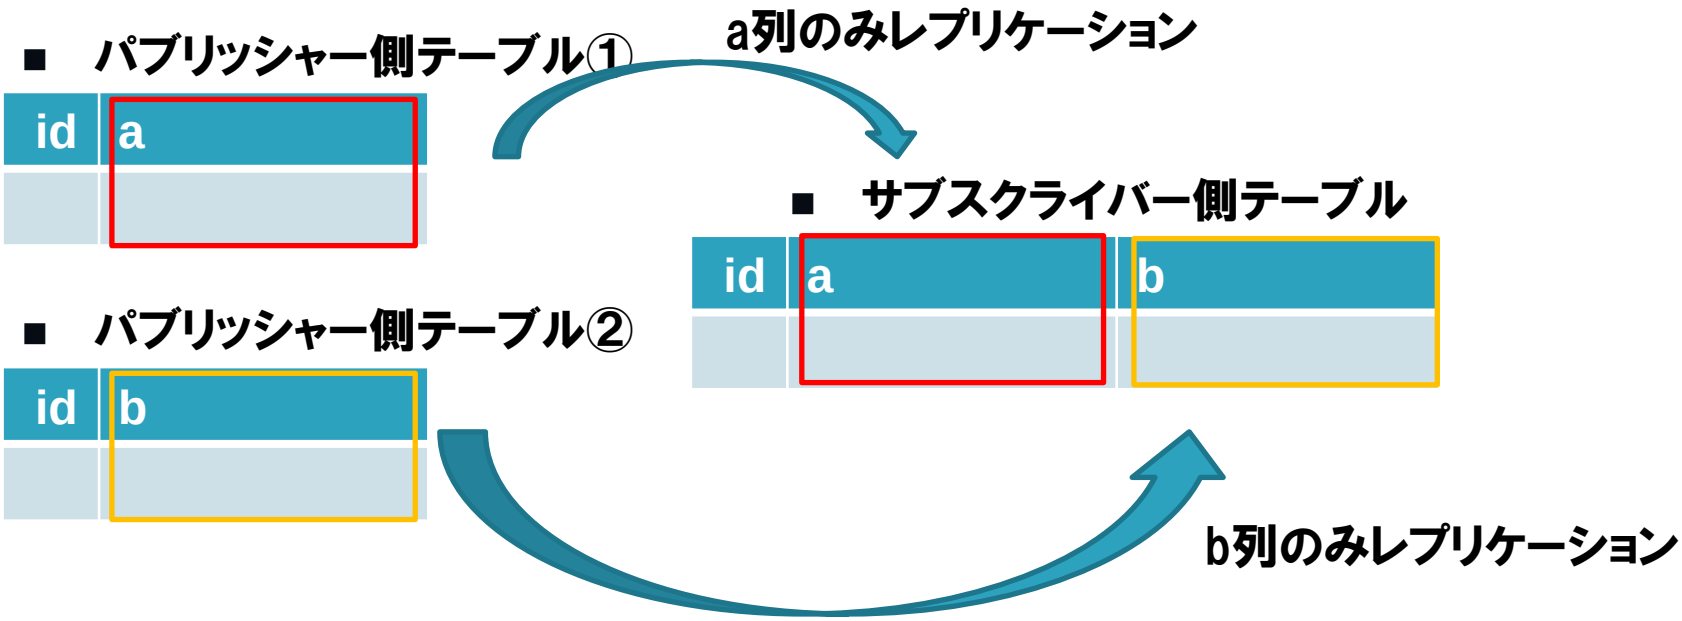

列指定
複数パブリッシャー：単一サブスクライバーについて

- 現状では以下制約がある。
  - 列指定時にレプリケーション対象とする主キー列の値が被らない範囲でのみ正常に動作可能。
    - 列指定レプリケーションを正常に動作させるためには、レプリケーションする列に主キーを含める必要がある。
    - そのため、パブリッシャー側/サブスクライバー側で主キー列を指定する必要があるが、2つ目以降のパブリッシャー側では主キーの一意性によりサブスクライバーへの初回同期のINSERTでエラーとなる。

列指定
複数パブリッシャー：単一サブスクライバーについて

- 成功例
  - id列が主キー
  - 主キー範囲が被っていないため、レプリケーションが動作する

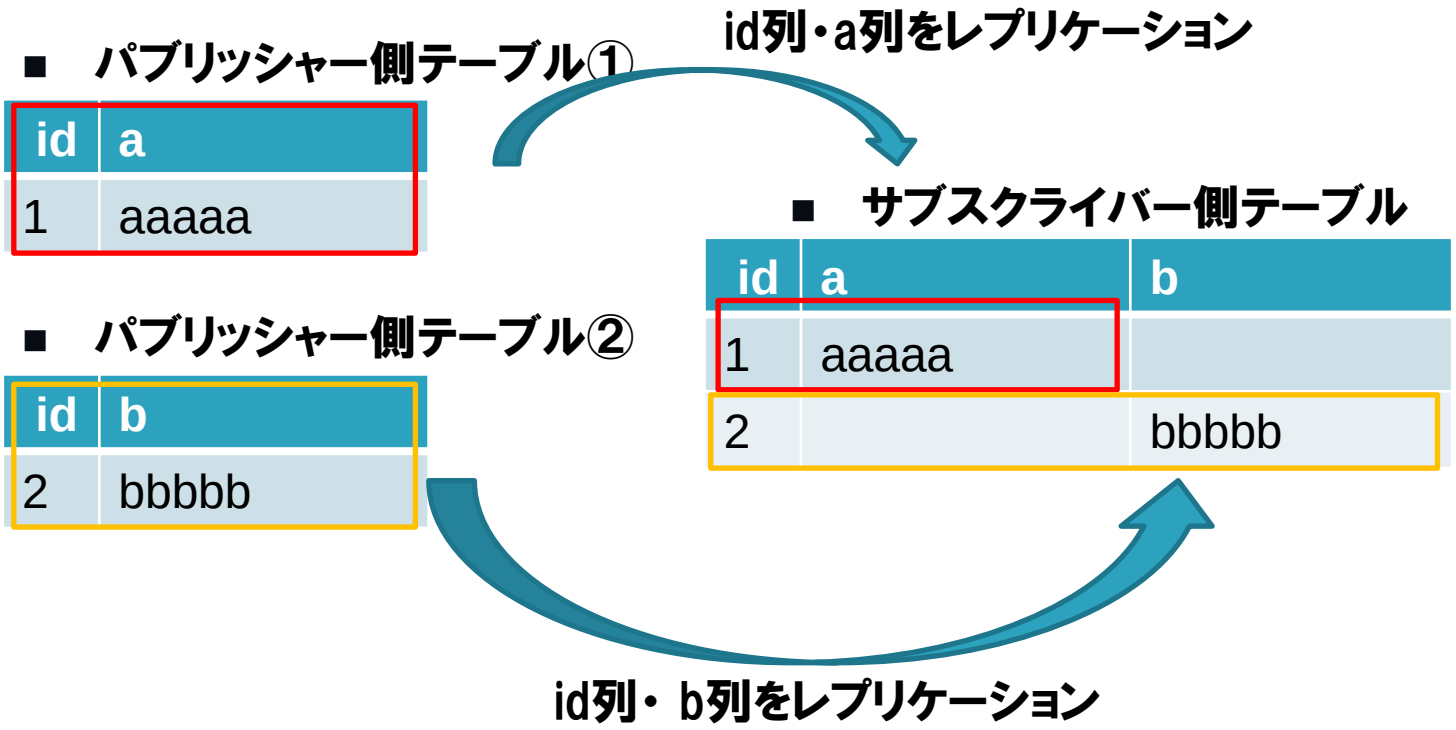

列指定
複数パブリッシャー：単一サブスクライバーについて

- 失敗例
  - id列が主キー
  - 主キー範囲が被ってるため、パブリッシャー②のレプリケーションは失敗

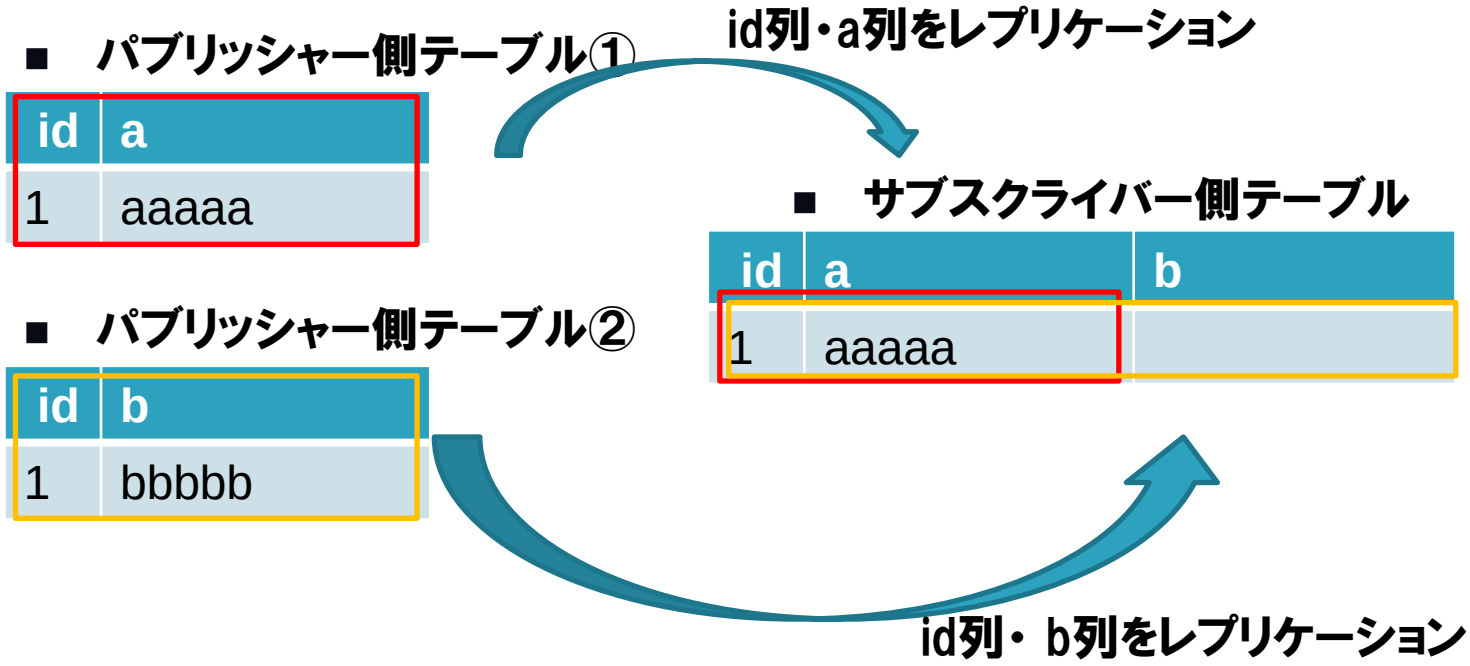

★id列に”1”をINSERTしようと動作するが、
一意性制約エラーにより更新ができない

行フィルタ 機能概要

- 行フィルタ機能とは、WHERE句を用いて、レプリケーションするテーブルのうち、条件を満たしている行だけを複製する機能

・PostgreSQL14まで

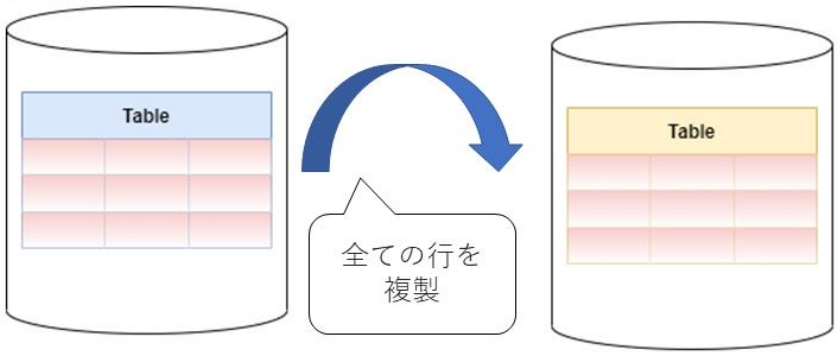

・PostgreSQL15以降

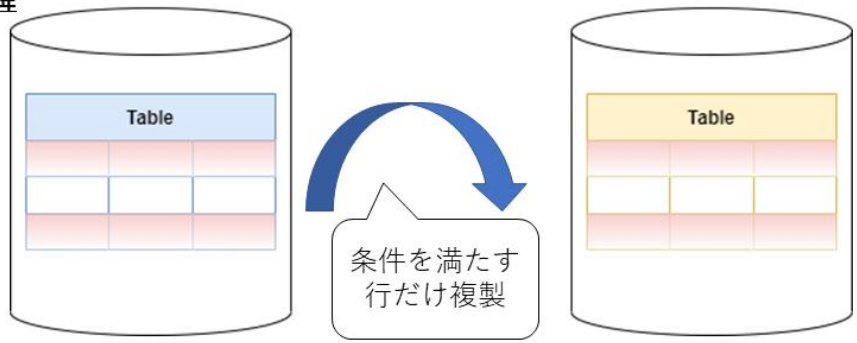

*赤いレコードがレプリケーション対象

行フィルタ 機能概要

- 行フィルタのロジカルレプリケーションは、パブリケーションを定義するときに、レプリケーションの条件をWHERE句で指定することで機能する。

```
# CREATE PUBLICATION name
FOR TABLE table_name WHERE (条件);
```

テーブル名以下にWHERE句で条件を記載することで、条件に合致した行のみをレプリケーションする

条件とする列は主キーとする必要がある

行フィルタ 実行例

- 下記のようなテーブルを作成し、WHERE句でa列が5以下の行のみ、レプリケーションする。

パブリッシャー側/サブスクライバー側の両方とも、
id列とa列を主キーにして、ロジカルレプリケーション
※ (P) の列が主キー

- パブリッシャー側テーブル

id (P)	a (P)	b
1	1	test-b-1
2	2	test-b-2
3	3	test-b-3
4	10	test-b-4
5	111	test-b-5
6	4	test-b-6

a<5の行をレプリケーション

- サブスクライバー側テーブル

id (P)	a (P)	b
1	1	test-b-1
2	2	test-b-2
3	3	test-b-3
6	4	test-b-6

行フィルタ 実行例

- WHERE句のフィルタリング条件とするa列はサブスクライバー側で主キーでなくともINSERT/UPDATE可能。

パブリッシャー側はid列とa列を主キー
サブスクライバー側はid列のみ主キーにして、ロジカルレプリケーション
※ (P) の列が主キー

- パブリッシャー側テーブル

id (P)	a (P)	b
1	1	test-b-1
2	2	test-b-2
3	3	test-b-3
4	10	test-b-4
5	111	test-b-5
6	4	test-b-6

a<5の行をレプリケーション

- サブスクライバー側テーブル

id (P)	a *	b
1	1	test-b-1
2	2	test-b-2
3	3	test-b-3
6	4	test-b-6

*サブスクライバーa列は主キーではない

行フィルタ 検証結果

- 行フィルタは、パブリッシャー側でWHERE句を用いて条件を設定する
- WHEREでフィルタリングの条件とする識別列は、パブリッシャー側の主キーである必要がある
- サブスクライバー側のテーブルでは、識別列は主キーである必要はない

行フィルタ指定 実行例

- p_test_1にt1テーブルを作成し、パブリケーション設定を実行。

```
p_test_1=# CREATE TABLE t1(id int, a int, b text ,PRIMARY KEY (id,a));
CREATE TABLE
p_test_1=# CREATE PUBLICATION p1 FOR TABLE t1 WHERE (a < 5);
 CREATE PUBLICATION

p_test_1=# table t1;
id | a | b ----+-----+----------
1 | 1 | test-b-1
2 | 2 | test-b-2
3 | 3 | test-b-3
4 | 10 | test-b-4
5 | 111 | test-b-5
6 | 4 | test-b-6
(6 行)
```

行フィルタ指定 実行例

- s_test_1にt1テーブルを作成し、サブスクリプション設定を実行。

```
s_test_1=# CREATE TABLE t1(id int ,a int,b text,PRIMARY KEY(id,a));
CREATE TABLE
s_test_1=# CREATE SUBSCRIPTION s1
            CONNECTION 'host=192.168.162.17 port=5432 user=logi_user dbname=p_test_1'
            PUBLICATION p1;
NOTICE: 発行サーバーでレプリケーションスロット"s1"を作成しました
CREATE SUBSCRIPTION
s_test_1=# table t1;
 id | a |    b
----+---+---------
  1 | 1 | test-b-1
  2 | 2 | test-b-2
  3 | 3 | test-b-3
  6 | 4 | test-b-6
 (4 行)
```

パブリッシャー側テーブルから、a列の値が4未満の行のみサブスクライバー側テーブルへレプリケーション

システムビューpg_stat_subscription_stats 機能概要

- pg_stat_subscription_statsでは、ロジカルレプリケーションを組んでいる構成で、サブスクライバーを定義したDB側の情報が格納される。
- 本システムビューをサブスクライバー側で確認することで、下記の情報を取得できる。

Column	Type	Description
subid	oid	サブスクリプションのOIDです。
subname	name	サブスクリプションの名前です。
apply_error_count	bigint	変更の適用中にエラーが発生した回数です。
sync_error_count	bigint	初期テーブル同期中にエラーが発生した回数です。
stats_reset	timestamp with time zone	統計情報がリセットされた最終時刻です。

https://pgsql-jp.github.io/current/html/monitoring-stats.html#MONITORING-PG-STAT-SUBSCRIPTION-STATS から引用

システムビューpg_stat_subscription_stats 実行例

- ロジカルレプリケーションが正常に動作している際に、サブスクライバー側でシステムビューを確認

```
s_test_1=#  SELECT * FROM pg_stat_subscription_stats;
 subid | subname | apply_error_count | sync_error_count | stats_reset
-------+---------+-------------------+------------------+-------------
 49402 | s1      |                 0 |                0 |
(1 行)
```

- サブスクライバー側でエラーを発生させると、実行結果が変化する。

```
s_test_1=#  SELECT * FROM pg_stat_subscription_stats;
 subid | subname | apply_error_count | sync_error_count | stats_reset
-------+---------+-------------------+------------------+-------------
 49402 | s1      |                 5 |                0 |
(1 行)
```

apply_error_countが加算されていることから、
パブリッシャー側で更新が発生したが、
サブスクライバー側では変更適用中にエラーが発生していることが確認できる。

システムビューpg_stat_subscription_stats検証結果

- pg_stat_subscription_statsを使用することで、ロジカルレプリケーション時のエラー発生を、サーバログを見ることなく検知が可能になる。（※）
  - （※）サーバログを確認することで判別できるが、サーバーログから自動検知は難しい。
    - PostgreSQL単体機能としてはもっていない。
    - 他の監視ツールでのサーバログのメッセージトラップが必要。
    - ログのトラップは重いため避けたほうが無難。
- PostgreSQL15では、ロジカルレプリケーション時にサブスクライバー側でエラーが発生した際に、エラーを回避する手段が追加されている。
- ユーザーはpg_stat_subscription_statsのapply_error_countの数値変化を定期的に監視することで、エラーを検知し適切な回避を実施することができる。
- pg_stat_reset_subscription_statsで、pg_stat_subscription_statsの統計情報をリセットすることができる。
  - 定期的に apply_error_count をリセットすることで、一定期間内の論理レプリケーションエラーの統計情報を取得できる。

システムビューpg_stat_subscription_stats PostgreSQL15で追加されたエラー回避手段

- LSNスキップ
  - サブスクライバーでのトランザクションのスキップを許可する
  - エラーが発生しているトランザクションをスキップしロジカルレプリケーションを継続する
  - ALTER SUBSCRIPTION ... SKIP (LSN = '*lsn_value*');
- エラー時のSUBSCRIPTION無効化
  - サブスクライバー側エラー時にロジカルレプリケーションの変更の適用を停止する
  - サブスクライバーオプションに"disable_on_error"が追加され、サブスクライバー側エラー発生時には自動でロジカルレプリケーションを無効化し停止することが可能となった
    - PostgreSQL14以前は、サブスクライバー側エラー発生時には、ユーザー側で"ALTER SUBSCRIPTION ... DISABLE"等を手動で実行し、ロジカルレプリケーションを無効化し停止させる必要があった
  - CREATE SUBSCRIPTION … WITH (disable_on_error = true);
  - ALTER SUBSCRIPTION … SET (disable_on_error = true);

まとめ

- PostgreSQL 15で追加されたロジカルレプリケーションの列指定・行フィルタを適切に用いることで、データベースサーバ間で必要な列・行だけを同期することができる。
- ネットワーク帯域幅の削減やパフォーマンス向上、より効率的で柔軟なデータ同期を実現することができる。

- システムビューpg_stat_subscription_statsを用いることで、ロジカルレプリケーション時のエラー発生を、サーバログを見ることなく検知可能
  - PostgreSQL15のロジカルレプリケーション追加機能である以下を用いることでエラー回避を実現
    - LSNスキップ
    - エラー時のSUBSCRIPTION無効化

マルチマスタ検証

検証概要

- 目的
  - PostgreSQLの論理レプリケーション機能を用いてマルチマスタ・レプリケーションが可能かを検証
  - PostgreSQL 16に追加予定のロジカルレプリケーション関連の新機能を用いて検証
- 検証内容
  - 基本更新パターン
  - 衝突時の挙動

PostgreSQL 15までの問題点

- PostgreSQL 15までの機能を使うことで、同一のテーブルに対するパブリッシャーを定義し、相互に対向側のノードからサブスクライバーで接続するマルチマスタ構成は構築できた。
- しかし、以下の問題があるため、実際にはマルチマスタ構成として機能はしない。
  - WALの循環
    - INSERT WALが永遠に2ノード間でループする。
  - 更新の衝突
    - 2ノード間で同一PKに対する操作等を抑止する機能がない。

PostgreSQL 16の機能追加

- CREATE SUBSCRIPTIONコマンドに、origin オプションが指定可能になった
  - any　　：起点以外からのパブリッシャーからも購読する（デフォルト、PostgreSQL 15までの挙動）
  - none　　：起点のパブリッシャーのみ購読する
- origin = none でない場合(およびPostgreSQL 15まで)は同一テーブルに相互にパブリッシャー/サブスクライバーを設定すると、レプリケーションが循環するという致命的な問題があった。
- origin = none の指定により、レプリケーションの循環が抑止される。

PostgreSQL 16の機能追加

- replication originの機能自体は、ロジカルデコーディング基盤を使ってレプリケーションを構築するための手段としてPostgreSQL 15以前でも実装されていた。
  - SQL関数　pg_replication_origin_create () で生成する。
  - pg_replication_origin システムビューで状態を確認可能
  - 他のreplication origin関数を使うことで、レプリケーションの循環を防止する実装はできた。
- PostgreSQL 16ではロジカルレプリケーションの作成コマンドとして、replication originが指定可能になった。

検証環境

■ インススタンススペック

名称	インスタンスタイプ	vCPU	メモリ (GiB)	ルートストレージサイズ (GiB) / IOPS	追加ストレージスサイズ (GiB) / IOPS
DB server	t2.medium	2	4	32GB / 100	32GB / 100

- AWS EC2インスタンスを1台仕様
- 性能検証ではないため低スペックのインスタンスを使用

名称	OS	バージョン	備考
DB server	Amazon Linux 2	PostgreSQL-devel	PostgreSQL 16相当

- PostgreSQLはmasterブランチから検証前のバージョンをcloneし ビルドして実行
- configureオプションは--prefix=<dir name> のみ

検証環境

- 同一EC2インスタンス上でportを分けて2つのデータベースクラスタを配置
  - 2つのインスタンス間でロジカルレプリケーション

- postgresql.conf（ノード1）

```
port = 16010
wal_level = logical
```

- postgresql.conf（ノード2）

```
port = 16020
wal_level = logical
```

検証環境

- データベース名/テーブル名は同一
- fooテーブルにパブリッシャーを定義
- そのパブリッシャーに接続するサブスクライバーを定義
  - サブスクライバーオプションに origin=none を指定

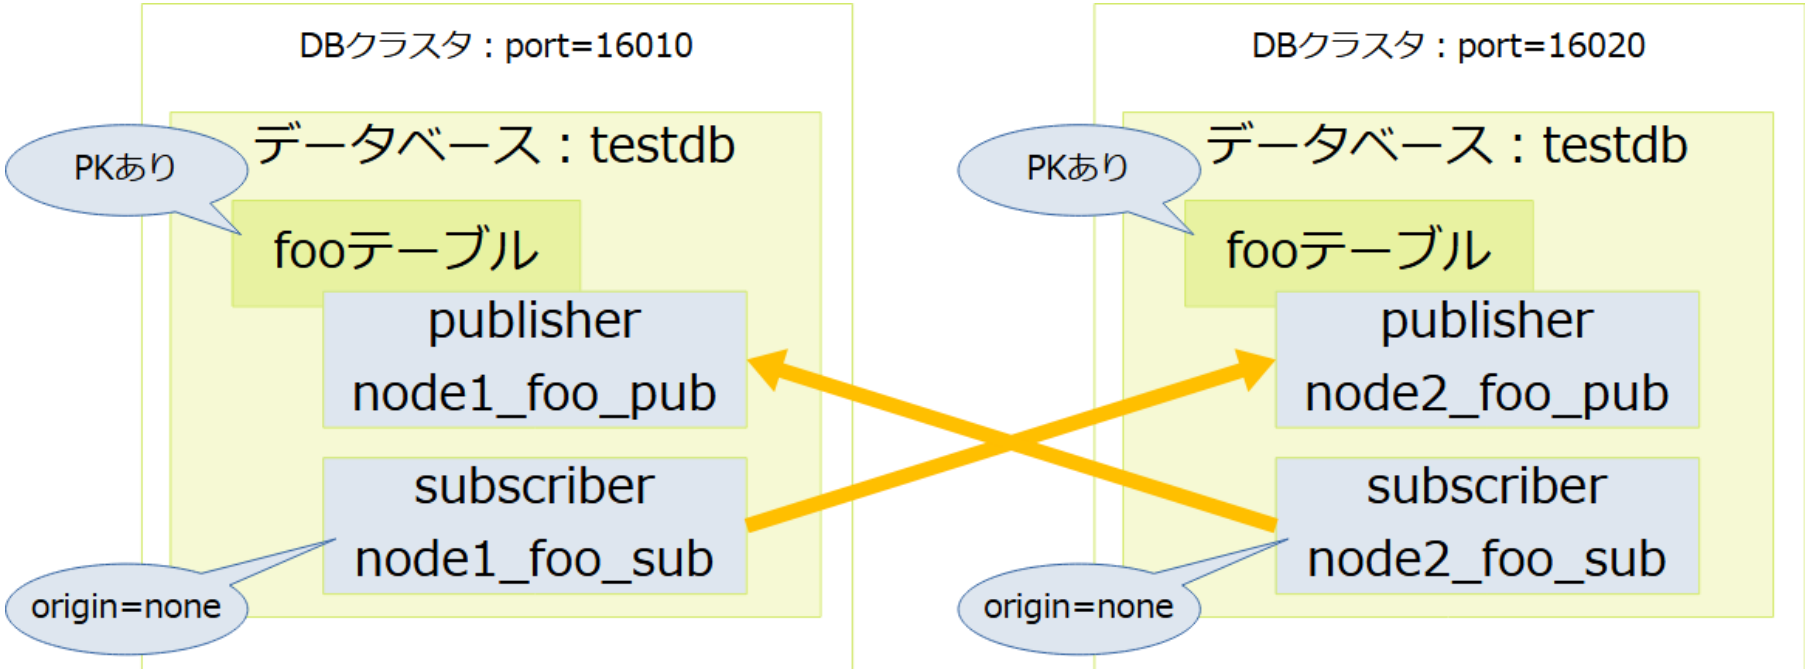

検証環境(DDL例)

- NODE1,NODE2共通

```
CREATE TABLE foo (id int primary key, data text);
```

- NODE1

```
CREATE PUBLICATION node1_foo_pub FOR TABLE foo;

CREATE SUBSCRIPTION node1_foo_sub CONNECTION 'port=16020
dbname=testdb user=postgres' PUBLICATION node2_foo_pub WITH
(origin=none);
```

- NODE2

```
CREATE PUBLICATION node2_foo_pub FOR TABLE foo;

CREATE SUBSCRIPTION node2_foo_sub CONNECTION 'port=16010
dbname=testdb user=postgres' PUBLICATION node1_foo_pub WITH
(origin=none);
```

検証内容

- 衝突が発生しないケースの確認
- 衝突が発生するケースの確認

衝突が発生しないケースの確認

- 同一IDのレコードの競合が発生しない状態で、相互に更新が伝播することを確認した。
  - INSERT
  - UPDATE
  - DELETE
  - TRUNCATE
- WALの循環防止の効果があった。

衝突が発生するケースの確認

- 同一IDのレコードに対する更新が衝突するケースを確認した。
- 結論：衝突が発生した場合には重大な問題が発生するケースがある。
  - 特に同一PKのINSERTはレプリケーション停止を引き起こす、かつ運用介入が必要になる。

パターン	系全体	node1	node2
同一PKのINSERT	値は不一致 レプリケーション停止 （運用介在が必要になる）	node1への挿入結果	node2への挿入結果
同一PKのUPDATE	値は不一致 （対向側の値が更新される）	node2への更新結果	node1への更新結果
同一PKのUPDATE/DELETE	値は一致	node2へのdelete結果	node2へのdelete結果
全行DELETEとINSERT	値は一致	全DELETE→node2へのinsert結果	全DELETE→node2へのinsert結果
TRUNCATEとINSERT	値は不一致	node2への挿入結果	TRUNCATE結果

衝突の例：同一PKのINSERT

- NODE1, NODE2に対して同一PK/別の列値で挿入する。
- 挿入は成功するが、NODE1とNODE2で異なる値が挿入される。
- また、この状態になると以降の更新処理がレプリケーションされなくなる。

衝突の例：同一PKのINSERT

- 前スライドの状態になると、レプリケーションされなくなるため、運用介在してWALをスキップする必要がある。
  - ALTER SUBSCRIPTION ...
    SKIP (LSN = スキップするLSN)
  - これをNODE1, NODE2に対して実施する必要がある。
- なお、WALスキップの運用介入をしても、NODE1とNODE2でINSERTされた値が異なる問題は解決しない。
- 本来はどうあるべきか？
  - NODE1と同じPKを持つ行をNODE2から挿入しようとした場合には、NODE2からの挿入をロールバックすべきか？
  - 現状のPostgreSQL機能だけでは、このような防止はできない。

衝突の例：同一PKに対するUPDATE

- NODE1, NODE2から同一PKを持つレコードに対してUPDATEを行った場合、どちらのUPDATEも成功する。
- NODE1
  - NODE1に対するUPDATEの結果に対し、NODE2に対するUPDATEの結果が上書きされる。
- NODE2
  - NODE2に対するUPDATEの結果に対し、NODE1に対するUPDATEの結果が上書きされる。
- NODE1とNODE2の値は同一にならない。
- 本来はどうあるべきか？
  - 同一PKに対するUPDATEは抑止すべきか？

衝突の例：TRUNCATEとINSERT

- NODE1に対してTRUNCATE, NODE2に対してINSERT を行った場合、どちらの操作も成功する。
- NODE1
  - TUNCATEされたあと、NODE2に対して行ったINSERTの結果が反映される
- NODE2
  - NODE2に対して行ったINSERT後の結果に対して TRUNCATEが反映される
- NODE1とNODE2の値は同一にならない。
- 本来はどうあるべきか？
  - どちらかの操作を抑止すべきか？
  - TRUNCATE/INSERTのどちらを優先すべきか？

まとめ

- PostgreSQL 16機能によるマルチマスタ構成の問題
  - WALの循環
    - originオプションにより、WALの循環は解決する。
  - 更新の総突
    - 更新の衝突は解決できていない。
    - 同一IDのINSERTケースはレプリケーションが停止し、運用者介入が必要になる。
    - 同一レコードのUPDATE/DELETE/TRUNCATE競合はレプリケーション停止にはならないが、想定外の結果となる。

まとめ

- 結論
  - PostgreSQL 16のSQL本体機能のみでは、実用的なマルチマスター構成は困難
  - 衝突発生時のルールを定義して制御する機能が必要
    - 例：同一PK挿入時に片側の挿入をエラーにする等

PGECons

PostgreSQL Enterprise Consortium